

Univerza v Ljubljani
Filozofska fakulteta
Oddelek za geografijo

Doktorska disertacija
**Uporaba geografskih informacijskih sistemov za določanje naravnih
pokrajinskih tipov Slovenije**

Mentor: dr. Dušan Plut
Somentor: dr. Drago Perko

Rok Ciglič

Ljubljana, 2013

Podpisani *Rok Ciglič* izjavljam, da sem avtor pričujoče doktorske disertacije z naslovom »Uporaba geografskih informacijskih sistemov za določanje naravnih pokrajinskih tipov Slovenije«.

Ljubljana, marec 2013

Rok Ciglič

*»Vse mora biti narejeno tako preprosto kot se le da, vendar ne bolj preprosto.«
»Everything should be made as simple as possible, but no simpler.«*

Albert Einstein

*»V teoriji ni nobene razlike med teorijo in prakso. V praksi pa vendarle je.«
»In theory, there is no difference between theory and practice. But, in practice, there is.«*

Jan L. A. van de Snepscheut

ZAHVALA

Rad bi se zahvalil mentorju dr. Dušanu Plutu za neprecenljive napotke pri snovanju in pisanju naloge ter skrbno vodenje mojega celotnega izobraževanja na Oddelku za geografijo. Hvala somentorju in raziskovalnemu mentorju dr. Dragu Perku za vse koristne nasvete, uvajanje v znanstveno delo ter izkušnje pri geografskem delu.

Rad bi se zahvalil tudi vsem sodelavcem Geografskega inštituta Antona Melika za delovno in hkrati sproščeno okolje, še posebej bi se rad zahvalil Mauru Hrvatinu za pomoč pri analizi kamnin.

Hvala prijateljem, ob katerih sem lahko pozabil na vse tegobe študijskih in službenih obveznosti!

Hvala staršem, da so mi omogočili brezskrbno otroštvo in mladost, ki sta bila polna pomembnih izkušenj, ter da so mi zagotovili kakovostno šolanje, kateremu sem se lahko posvetil brez odvečnih skrbi.

*Hvala Ireni in Matjažu za vse dogodivščine, zaradi katerih se je lepo vračati v zeleni raj!
Hvala Petri in Vesni za vso energijo in vse razloge za pisanje te naloge.*

Kazalo

Izvleček	iii
1 Uvod	1
1.1 Namen, hipotezi in cilji	2
1.1.1 Namen	2
1.1.2 Hipotezi	3
1.1.3 Cilji.....	3
1.2 Omejitve obravnavanega območja	4
1.3 Oris raziskave.....	4
2 Teorija klasifikacije pokrajine	6
2.1 Terminologija.....	6
2.1.2 Primerjava nekaterih terminov in uporaba terminov v nalogi.....	10
2.2 Dosedanja spoznanja	11
2.2.1 Osnovni pristop	12
2.2.2 Raznolikost izdelave klasifikacij	13
2.2.3 Pomen izbora dejavnikov.....	14
2.2.4 Lastnosti podatkov.....	15
2.2.5 Raven klasifikacije	15
2.2.6 Poimenovanje prostorskih enot.....	20
2.3 Uporabnost klasifikacij.....	20
2.3.1 Klasifikacije v uradnih dokumentih.....	22
2.4 Obstoječi problemi	23
3. Primeri klasifikacij	26
3.1 Klasifikacije Slovenije na podlagi naravnih dejavnikov.....	26
3.2 Slovenija v naravnogeografskih klasifikacijah Evrope.....	27
3.2.1 Pregled klasifikacij evropskega ozemlja.....	27
3.2.2 Primerjava klasifikacij.....	28
3.4 Primeri klasifikacij z geografskimi informacijskimi sistemi	29
4. Uporabljene metode	30
4.1 Metode za vrednotenje podatkovnih slojev in metode za vrednotenje klasifikacij.....	30
4.2 Metode za izdelavo klasifikacij	31
4.3 Metoda določanja učnih območij in izdelave spektralnih podpisov	32
4.4 Metode za računanje usklajenosti načinov vrednotenja, metode za računanje usklajenosti klasifikacij med seboj ter druge metode ugotavljanja povezanosti	33
4.5 Metoda določanja statistične značilnosti lestvic in povprečnih vrednosti koeficientov	34
4.6 Uporabljena računalniška programska oprema.....	34
5. Podatkovni sloji naravnih dejavnikov	35
5.1 Podatkovni sloji, ki so uporabljeni v nalogi	35
5.2 Priprava podatkov.....	36
6. Vrednotenje podatkovnih slojev	37
6.1 Odstopajoče vrednosti	37
6.2 Medsebojna povezanost podatkovnih slojev	40
6.3 Vrednotenje dejavnikov s pomočjo obstoječih klasifikacij.....	44
6.4 Vrednotenje dejavnikov glede na raven (prostorsko merilo) klasifikacije.....	50
6.5 Povzetek vrednotenja spremenljivk.....	55
7. Vrednotenje različnih naravnopokrajinskih tipizacij Slovenije, izdelanih z metodami nenadzorovane klasifikacije	56
7.1 Zasnova izdelave naravnopokrajinskih tipizacij z metodami nenadzorovane klasifikacije	56
7.1.1 Izbor geoinformacijskih orodij	56
7.1.2 Izbor podatkovnih slojev	58
7.2 Modelirane naravnopokrajinske tipizacije po posameznih metodah nenadzorovane klasifikacije.....	59
7.3 Vrednotenje naravnopokrajinskih tipizacij s pomočjo vhodnih podatkovnih slojev.....	64
7.3.1 Različni načini vrednotenja modeliranih naravnopokrajinskih tipizacij s pomočjo uporabljenih podatkovnih slojev	65
7.3.1.1 Različni načini vrednotenja glede na posamezni podatkovni sloj.....	65
7.3.1.2 Različni načini vrednotenja glede na vse podatkovne sloje hkrati.....	74
7.3.2 Usklajenost različnih načinov vrednotenja naravnopokrajinskih tipizacij	77
7.3.2.1 Usklajenost različnih načinov vrednotenja s pomočjo posameznega podatkovnega sloja.....	77
7.3.2.2 Usklajenost različnih načinov vrednotenja s pomočjo vseh podatkovnih slojev hkrati	82
7.3.2.3 Sklepna ugotovitev glede vrednotenja naravnopokrajinskih tipizacij po metodah nenadzorovane klasifikacije s pomočjo vhodnih podatkovnih slojev	86
7.4 Usklajenost različnih modeliranih naravnopokrajinskih tipizacij med seboj	87
7.5 Ugotavljanje števila kombinacij tipov različnih naravnopokrajinskih tipizacij	88
7.6 Ugotavljanje oddaljenosti celic od najbližjih centroidov.....	90
8. Vrednotenje različnih naravnopokrajinskih tipizacij Slovenije, izdelanih z metodami nadzorovane klasifikacije	98
8.1 Zasnova izdelave naravnopokrajinskih tipizacij z metodami nadzorovane klasifikacije	98
8.1.1 Izbor izvirnih naravnopokrajinskih tipizacij	99
8.1.2 Izbor geoinformacijskih orodij	101
8.1.3 Izbor podatkovnih slojev	102

8.1.4 Izbor učnih celic	107
8.1.4.1 Izbor učnih celic z naključnim vzorčenjem	107
8.1.4.2 Izbor učnih celic z ekspertnim vzorčenjem	111
8.1.5 Povzetek zasnove.....	117
8.2 Modelirane naravnopokrajinske tipizacije po posameznih metodah nadzorovane klasifikacije	118
8.2.1 Modelirane naravnopokrajinske tipizacije za TIPI9.....	119
8.2.2 Modelirane naravnopokrajinske tipizacije za TIPI13.....	121
8.3 Vrednotenje modeliranih naravnopokrajinskih tipizacij.....	123
8.3.1 Različni načini vrednotenja modeliranih naravnopokrajinskih tipizacij s pomočjo uporabljenih podatkovnih slojev ...	125
8.3.1.1 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnih slojev	125
8.3.1.2 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI13 s pomočjo podatkovnih slojev	131
8.3.2 Usklajenost različnih načinov vrednotenja naravnopokrajinskih tipizacij	136
8.3.2.1 Usklajenost različnih načinov vrednotenja modeliranih naravnopokrajinskih tipizacij TIPI9.....	136
8.3.2.2 Usklajenost različnih načinov vrednotenja modeliranih naravnopokrajinskih tipizacij TIPI13.....	142
8.3.3 Vrednotenje modeliranih naravnopokrajinskih tipizacij s pomočjo izvirne naravnopokrajinske tipizacije.....	147
8.3.3.1 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI9.....	148
8.3.3.2 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI13.....	150
8.4 Usklajenost različnih modeliranih naravnopokrajinskih tipizacij med seboj	152
8.4.1 Usklajenost modeliranih naravnopokrajinskih tipizacij TIPI9.....	153
8.4.2 Usklajenost modeliranih naravnopokrajinskih tipizacij TIPI13	153
8.5 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvirno naravnopokrajinsko tipizacijo	154
8.5.1 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvirno naravnopokrajinsko tipizacijo TIPI9	154
8.5.1.1 Ujemanje vseh modeliranih z izvirno naravnopokrajinsko tipizacijo.....	154
8.5.1.2 Neujemanje vseh modeliranih z izvirno naravnopokrajinsko tipizacijo	159
8.5.1.3 Ujemanje območij modeliranih tipizacij, ki niso enaka izvorni naravnopokrajinski tipizaciji	162
8.5.2 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvirno naravnopokrajinsko tipizacijo TIPI13	165
8.5.2.1 Ujemanje vseh modeliranih z izvirno naravnopokrajinsko tipizacijo	165
8.5.2.2 Neujemanje vseh modeliranih z izvirno naravnopokrajinsko tipizacijo	169
8.5.2.3 Ujemanje območij modeliranih tipizacij, ki niso enaka izvorni naravnopokrajinski tipizaciji	172
8.6 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij.....	175
8.6.1 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij TIPI9.....	176
8.6.2 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij TIPI13.....	182
8.7 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij za preverjanje pripadnosti posameznim tipom	190
8.7.1 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij TIPI9	190
8.7.2 Povezanost mehkih modeliranih naravnopokrajinskih tipizacij TIPI9 s seštevkom trdnih modeliranih naravnopokrajinskih tipizacij TIPI9	190
8.7.3 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij TIPI13.....	191
8.7.4 Povezanost mehkih modeliranih naravnopokrajinskih tipizacij TIPI13 s seštevkom trdnih modeliranih naravnopokrajinskih tipizacij TIPI13.....	191
8.8 Število kombinacij tipov pri prekrivanju modeliranih naravnopokrajinskih tipizacij.....	192
8.9 Ujemanje med ugotovitvami analiz vrednotenja za naravnopokrajinsko tipizacijo TIPI9 in ugotovitvami analiz vrednotenja za naravnopokrajinsko tipizacijo TIPI13	193
8.9.1 Vrednotenje s pomočjo podatkovnih slojev	193
8.9.2 Vrednotenje s pomočjo obstoječe izvirne naravnopokrajinske tipizacije.....	195
9. Najpomembnejše ugotovitve glede uporabnosti geografskih informacijskih sistemov pri določanju naravnih pokrajinskih tipov Slovenije	196
9.1 Preverjanje hipotez.....	196
9.1.1 Objektivnost vrednotenja tipizacij	196
9.1.2 Potrjevanje obstoječih naravnih pokrajinskih tipov	200
9.2 Spoznanja o uporabnosti geoinformacijskih orodij	203
9.2.1 Pregled uporabnosti uporabljenih geoinformacijskih orodij	203
9.2.1.1 Geoinformacijska orodja za nenadzorovano klasifikacijo	203
9.2.1.2 Geoinformacijska orodja za nadzorovano klasifikacijo.....	206
9.2.1.3 Geoinformacijska orodja za vrednotenje tipizacij z več podatkovnimi sloji hkrati	208
9.2.1.4 Geoinformacijska orodja za vrednotenje s posameznimi podatkovnimi sloji	209
9.2.1.5 Geoinformacijska orodja za vrednotenje ujemanja klasifikacij	210
9.2.2 Druge pomembne ugotovitve.....	210
10. Sklep	214
11. Viri.....	220
12. Seznam preglednic, slik in prilog	233
12.1 Seznam preglednic	233
12.2 Seznam slik	237
12.3 Seznam prilog.....	239
13. Summary.....	240
14. Priloge	243

Izvleček

Uporaba geografskih informacijskih sistemov za določanje naravnih pokrajinskih tipov Slovenije

V doktorski disertaciji smo analizirali nekatere možnosti uporabe geografskih informacijskih sistemov (GIS) pri določanju naravnih pokrajinskih tipov v Sloveniji. Sodobna računalniška oprema in digitalizacija podatkov namreč omogočata uporabo različnih geoinformacijskih orodij, s katerimi lahko omilimo nekatere probleme pri določanju naravnih pokrajinskih tipov, predvsem na področju objektivnosti in preglednosti, kar je pogosto omenjeno tudi v literaturi. V disertaciji smo navedli primere različnih regionalizacij in tipizacij, pregledali dostopne digitalne podatkovne sloje ter geoinformacijska orodja, s katerimi lahko izdelamo tipizacijo in vrednotimo dobljene rezultate. Podatkovne sloje smo za območje Slovenije tudi ovrednotili z vidika uporabnosti za določanje naravnih pokrajinskih tipov. Nato smo z izbranimi podatkovnimi sloji in geoinformacijskimi orodji izdelali več naravnopokrajinskih tipizacij. Analizirali smo, kako se različne tipizacije med seboj ujemajo, poskušali pa smo tudi čim bolj objektivno ovrednotiti dobljene tipizacije. Osrednji del disertacije se je namreč osredotočil na preučevanje usklajenosti različnih načinov vrednotenja naravnopokrajinskih tipizacij. Poleg tega je velik del posvečen tudi ugotavljanju, kje so v Sloveniji območja, ki so po različnih metodah klasificirana v isti tip.

Ugotovili smo, da so načini vrednotenja med seboj bolj usklajeni pri vrednotenju modeliranih naravnopokrajinskih tipizacij, ki so izdelane z metodami nadzorovane klasifikacije, kot pa pri vrednotenju modeliranih tipizacij, ki so izdelane z metodami nenadzorovane klasifikacije. V disertaciji smo s prekrivanjem več tipizacij, ki so izdelane z različnimi metodami, dobili pogled na tista območja, na katerih so tipizacije bolj usklajene, in tista, kjer so manj. Na koncu smo navedli ugotovitve o splošni uporabi GIS-ov za določanje naravnih pokrajinskih tipov Slovenije ter predlagali konkretne postopke izdelave tipizacije in njenega vrednotenja.

Ključne besede: naravni pokrajinski tipi, tipizacija, geografski informacijski sistemi, metode nenadzorovane klasifikacije, metode nadzorovane klasifikacije, geografija, Slovenija.

Abstract

Using Geographic Information Systems to Determine Natural Landscape Types in Slovenia

This doctoral dissertation analyzes selected potentials of using geographic information systems (GIS) in determining natural landscape types in Slovenia. Computer equipment and digital data make it possible to use various geographic information tools that can mitigate certain problems in determining natural landscape types, especially in terms of objectivity and transparency, which are also frequently emphasized in literature. The dissertation presents examples of various landscape regionalizations and typifications, and examines accessible digital data layers and geographic information tools that can be used to design a specific classification and evaluate the results obtained. In addition, the data layers covering the territory of Slovenia were also evaluated in terms of their applicability to determine natural landscape types. The selected data layers and geographic information tools were then used to produce several natural landscape typifications. This was followed by an analysis of how these typifications correspond to one another. Typifications were also evaluated as objectively as possible. The main part of the dissertation focuses on studying the consistency of various methods of evaluating natural landscape typifications. In addition, a significant part is also dedicated to determining which Slovenian areas are classified into the same type by different methods.

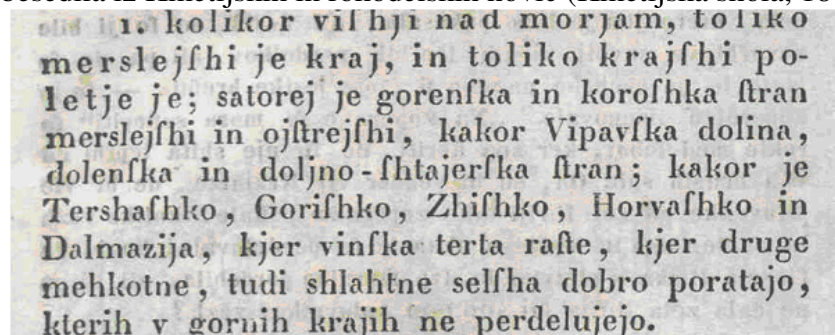
It was established that evaluation methods are more consistent when evaluating modeled natural landscape typifications that are produced with supervised classifications than with those with unsupervised classifications. By overlapping several typifications produced with various methods, areas were determined in which typifications are more consistent and areas in which they are less consistent. The dissertation concludes by presenting findings on the use of GIS for determining natural landscape types in Slovenia and proposes procedures for typification design and evaluation.

Key words: natural landscape types, typification, geographic information systems, unsupervised classification, supervised classification, geography, Slovenia.

1 Uvod

Klasifikacija Slovenije na razne prostorske enote ima v slovenski geografiji dolgo tradicijo. To ne preseneča, saj je običajno, da človek v pokrajini vedno išče red (Haggett, 2001), s katerim si pomaga v vsakdanjem življenju. Klasifikacija je ena izmed najbolj osnovnih mentalnih človekovih dejavnosti, s katero urejamo informacije, ki jih dobimo, saj bi bilo pomnjenje lastnosti vsakega posameznika nemogoče. Zato ljudje združujemo objekte, osebe, dogodke v skupine po neki skupni lastnosti (Theodoridis in Koutroumbas, 2006, 484). Za Slovenijo najdemo številne klasifikacije pokrajine glede na naravnogeografske in družbenogeografske dejavnike (na primer Melik, 1935; Melik, 1946; Ilešič, 1957/58; Ilešič, 1972; Gams, 1986a; Natek, 1993; Gams, Kladnik, Orožen Adamič, 1995; Ogrin, 1996; Perko, 1998a; Plut, 1999a; Špes s sod., 2002), zapise o razlikah med pokrajinami pa lahko najdemo v zelo starih publikacijah. Tak je na primer zapis iz Kmetijskih in rokodelskih novic leta 1843 (slika 1). Med klasifikacijami prevladujejo regionalizacije, tipizacij pa je manj. Zaradi nekaterih metodoloških podobnosti med regionalizacijami in tipizacijami v nalogi navajamo primere obeh načinov, a se bomo v praktičnem delu naloge posvetili izključno tipizaciji.

Slika 1: Izsek besedila iz Kmetijskih in rokodelskih novic (Kmetijska shola, 1843).



Tehnološki razvoj je omogočil napredek v geografiji, računalništvu ter tudi pri pridobivanju in urejanju digitalnih podatkov. Na uporabnost teh podatkov za območje Slovenije je že opozoril Repe (2010). Kladnik (1996) ter Hargrove in Hoffman (2005) so poudarili, da se je treba na področju klasifikacij opreti na računalniške analize, statistične metode in podobno.

Modeliranje je v geografiji in tudi drugih vedah dejansko postalo zelo razširjen in vpliven način raziskovanja (Demeritt, Wainwright, 2005). Kar nekaj primerov uporabe geoinformacijskih orodij pri klasificiranju pokrajin je znanih za območja v Sloveniji (na primer Plut, 1977; Perko, 1989; Krevs, 1992; Perko, 1998a; Perko, 2001; Repe, 2006; Ferreira, 2006; Breskvar Žaucer, Marušič, 2006) in drugod po svetu (na primer Soto, Pintó, 2010; Jongman s sod., 2006). Pri tem velja izpostaviti, da so nekatere klasifikacije Evrope že tako podrobne (na primer Múcher s sod., 2009), da delijo na prostorske enote tudi območje Slovenije (Ciglič, 2009).

Za naravnogeografske dejavnike je v Sloveniji vedno več digitalnih prostorskih podatkov (na primer digitalni model višin, digitalni zemljevidi temperatur, letalski in satelitski posnetki), hkrati je na voljo tudi vedno več različnih geoinformacijskih orodij, med katerimi nekatera izvirajo iz strojnega učenja in statistike. Zato lahko za klasifikacijo Slovenije na naravne pokrajinske tipe preizkusimo različne pristope.

Pri naravnogeografskih klasifikacijah so bili izpostavljeni številni problemi (na primer Ilešič, 1957/58; Kladnik, 1996; Gams, 1984; Gams, 1986b; Gams, 2000; Plut, 1981; Plut, 1999a; Klemenčič, 2004), ki jih podrobneje predstavljamo v teoretičnem pregledu (poglavje 2). Nobena metoda ni popolna in vsaka prispeva svoj delež k poznavanju krajevnih razlik (Gams, 1984), zato tudi nobena klasifikacija pokrajine ni popolna. Vse klasifikacije so subjektivne

(Owen, 2006, 311), saj gre pri klasifikaciji za abstrakcijo (Van Melsen, 1955 cv: Zonneveld 1994, 25; Bernert s sod. 1997, 417), pri čemer za raziskavo izberemo le nekatere izmed mnogih značilnosti dejanskega objekta ter jih uporabimo za opis abstraktnih enot, za katere sklepamo, da predstavljajo resničnost (Zonneveld, 1994, 25).

Zato ne stremimo k popolni rešitvi problematike tipizacije Slovenije na naravne pokrajine oziroma je ne pričakujemo, ampak nameravamo preizkusiti uporabnost geografskih informacijskih sistemov (GIS-ov) v te namene ter ugotoviti, na katerih področjih so najbolj uporabni. Geoinformacijska orodja namreč na osnovi podatkovnih slojev in uporabnikovih nastavitvev sama izdelajo tipizacije, vendar lahko te zaradi obilice različnih parametrov, izbora orodij in podatkov dajejo različne in težko opisljive rezultate, kar lahko zmanjšuje uporabno vrednost tipizacij. S kombiniranjem ustreznih geoinformacijskih orodij ter strokovno presojo lahko dobimo bolj reprezentativne naravne pokrajinske tipe Slovenije. K tem dejstvom dodajamo, da je bilo v literaturi opozorjeno na pomanjkanje vrednotenja dobljenih rezultatov (Hargrove, Hoffman, 2005) ter poziv k uporabi bolj transparentnih in ponovljivih postopkov (McMahon, Wiken, Gauthier, 2004; Bernert s sod., 1997). To je tudi glavni predmet preučevanja naše raziskave. K temu je treba dodati, da preverjanje ustreznosti metod omogoča tudi znanstveno vrednost teh klasifikacij (McMahon, Wiken, Gauthier, 2004).

V disertaciji se posvečamo povečanju objektivnosti pri postopku klasifikacije s pomočjo geografskih informacijskih sistemov. Pri tem je težišče prispevka predvsem na reševanju problemov, kot so vrednotenje rezultatov (tipizacij) in pregledna uporaba geoinformacijskih orodij in podatkov (za določanje meja, klasifikacijo ...), s katerimi je možna ponovljivost in preverljivost rezultatov.

Smiselnost disertacije podpira tudi dejstvo, da je evropska politika leta 1996 oblikovala Panevropsko strategija biotske in pokrajinske raznovrstnosti (*Pan-European Biological and Landscape Diversity Strategy*; Pan-European ..., 2011), leta 2000 pa je sprejela Konvencijo o krajini¹ (*The European Landscape Convention*, 2011). Obe se posvečata tudi omenjeni problematiki, kar pomeni, da je razvijanje tega znanstvenega področja pomembno.

Klasifikacije pokrajin so namreč lahko uporabljene za različne namene (Klijn, 1994), na primer zagotavljajo nam lahko osnovo za analize, monitoring, pripravo scenarijev in predstavitev naravnih in družbenih informacij (Mücher s sod., 2003).

Poleg tega se pojavljajo težnje po vzpostavitvi naravnogeografskih območij, kot je na primer ideja o evropski makroregiji Alpe (Bätzing, 2011), ter tudi ustanavljanje strokovnih in znanstvenih združenj, kot so *Landscape Europe* (*Landscape Europe*, 2011), *European Landscape Network* (*European Landscape ...*, 2011) in *OpenLandscapes* (*OpenLandscapes*, 2011).

1.1 Namen, hipotezi in cilji

1.1.1 Namen

Namen disertacije je preučiti kakovost in ustreznost določanja naravnih pokrajinskih tipov v Sloveniji z različnimi geoinformacijskimi orodji in digitalnimi prostorskimi podatki ter predlagati optimalen postopek tipizacije. Pri tem smo skušali uporabiti geoinformacijska orodja, ki omogočajo čim bolj objektivne in preverljive rezultate, ter njihovo rabo ustrezno prilagoditi tipizaciji Slovenije na naravne pokrajinske tipe.

V nalogi smo se pri preučevanju kakovosti in ustreznosti določanja tipov osredotočili na različne faze določanja tipov. V ospredje smo postavili možnost objektivnega vrednotenja vhodnih podatkovnih slojev in možnost objektivnega vrednotenja končnih rezultatov, naravnopokrajinskih tipizacij (izhodnih slojev), saj verjamemo, da lahko GIS-i pomembno

¹ Izraz *Konvencija o krajini* je bil sprejet z Zakonom o ratifikaciji Evropske konvencije o krajini (Zakon o ratifikaciji ..., 2003). V disertaciji angleški izraz *landscape* navadno prevajamo kot *pokrajina*, *pokrajinski*.

prispevajo k razvoju izdelave tipizacij ravno na področju objektivnega vrednotenja. Predvidevamo, da nam GIS-i omogočajo ustrezno vrednotenje dobljenih rezultatov ter s tem tudi vrednotenje geoinformacijskih orodij in podatkovnih slojev. S poznavanjem kakovosti vseh teh elementov določanja naravnih pokrajinskih tipov se lahko ustrezneje lotimo tipizacij za različne namene.

1.1.2 Hipotezi

Doktorska disertacija ima dve hipotezi.

Prva hipoteza: **»Z ustrezno kombinacijo geoinformacijskih orodij tipizacij in vrednotenjem rezultatov tipizacij je mogoče objektivno oceniti kakovost tipizacij.«**

Za preverjanje hipoteze smo uporabili različna geoinformacijska orodja oziroma klasifikacijske metode, s katerimi smo izdelali več različnih naravnopokrajinskih tipizacij. Te smo nato na različne načine ovrednotili in preverili, ali so ti različni načini vrednotenja med seboj usklajeni in jih lahko označimo kot objektivne.

Druga hipoteza: **»Z geografskimi informacijskimi sistemi je možno ugotoviti, katera so tista območja, ki se ne glede na uporabo različnih geoinformacijskih orodij uvrščajo v enake oziroma podobne tipe, ter katera so tista območja, ki jih geoinformacijska orodja uvrščajo različno.«**

S prekrivanjem kart naravnopokrajinskih tipizacij, ki smo jih izdelali z različnimi geoinformacijskimi orodji, lahko najdemo območja, ki so vedno oziroma pogosteje klasificirana enako, ter območja, ki večinoma ali pa celo nikoli niso enako klasificirana. Takšna območja lahko določamo na več načinov, kar zopet omogoča primerjavo in iskanje najbolj objektivne ocene. Obstoječe tipe naravnopokrajinskih tipizacij lahko na tak način preverimo in potrdimo oziroma opozorimo na morebitne slabosti.

1.1.3 Cilji

Za doseglo namena in preverjanje hipotez smo pripravili načrt, sestavljen iz več ciljev:

- pregledati naravnogeografske klasifikacije Slovenije v slovenski geografski literaturi ter pregledati klasifikacije Slovenije v okviru klasifikacij Evrope v mednarodni geografski literaturi,
- pregledati primere uporabe geoinformacijskih orodij in digitalnih podatkov kot primerov uporabe pri klasifikacijah pokrajine,
- pregledati nabor digitalnih prostorskih podatkov naravnih dejavnikov za območje Slovenije ter jih ovrednotiti z vidika primernosti za izdelavo tipizacije naravnih pokrajinskih tipov Slovenije,
- preizkusiti različna geoinformacijska orodja in digitalne prostorske podatke na primeru določanja naravnih pokrajinskih tipov v Sloveniji ter ovrednotiti njihove prednosti in slabosti,
- primerjati naravnopokrajinske tipizacije, ki so izdelane z različnimi geoinformacijskimi orodji, ter jih primerjati tudi z nekaterimi obstoječimi naravnopokrajinskimi tipizacijami Slovenije,
- poiskati morebitne naravne pokrajinske tipe, ki so najpogosteje prepoznani oziroma so prepoznani z več različnimi geoinformacijskimi orodji,
- ugotoviti, ali so posamezna geoinformacijska orodja posebej ustrezna za določeno opravilo pri naravnopokrajinski tipizaciji (na primer za vrednotenje dejavnikov, za vrednotenje rezultatov ali za določanje meja med tipi),
- po analizi in vrednotenju različnih geoinformacijskih orodij in njihovih rezultatov predlagati najbolj ustrezno kombinacijo posameznih orodij za naravnopokrajinsko tipizacijo Slovenije.

1.2 Omejitev obravnavanega območja

V nalogi smo se omejili na območje Republike Slovenije, uporabili pa smo dostopne digitalne podatke različnih naravnogeografskih dejavnikov, ki so pomembni za tipizacijo Slovenije na naravne pokrajinske tipe.

1.3 Oris raziskave

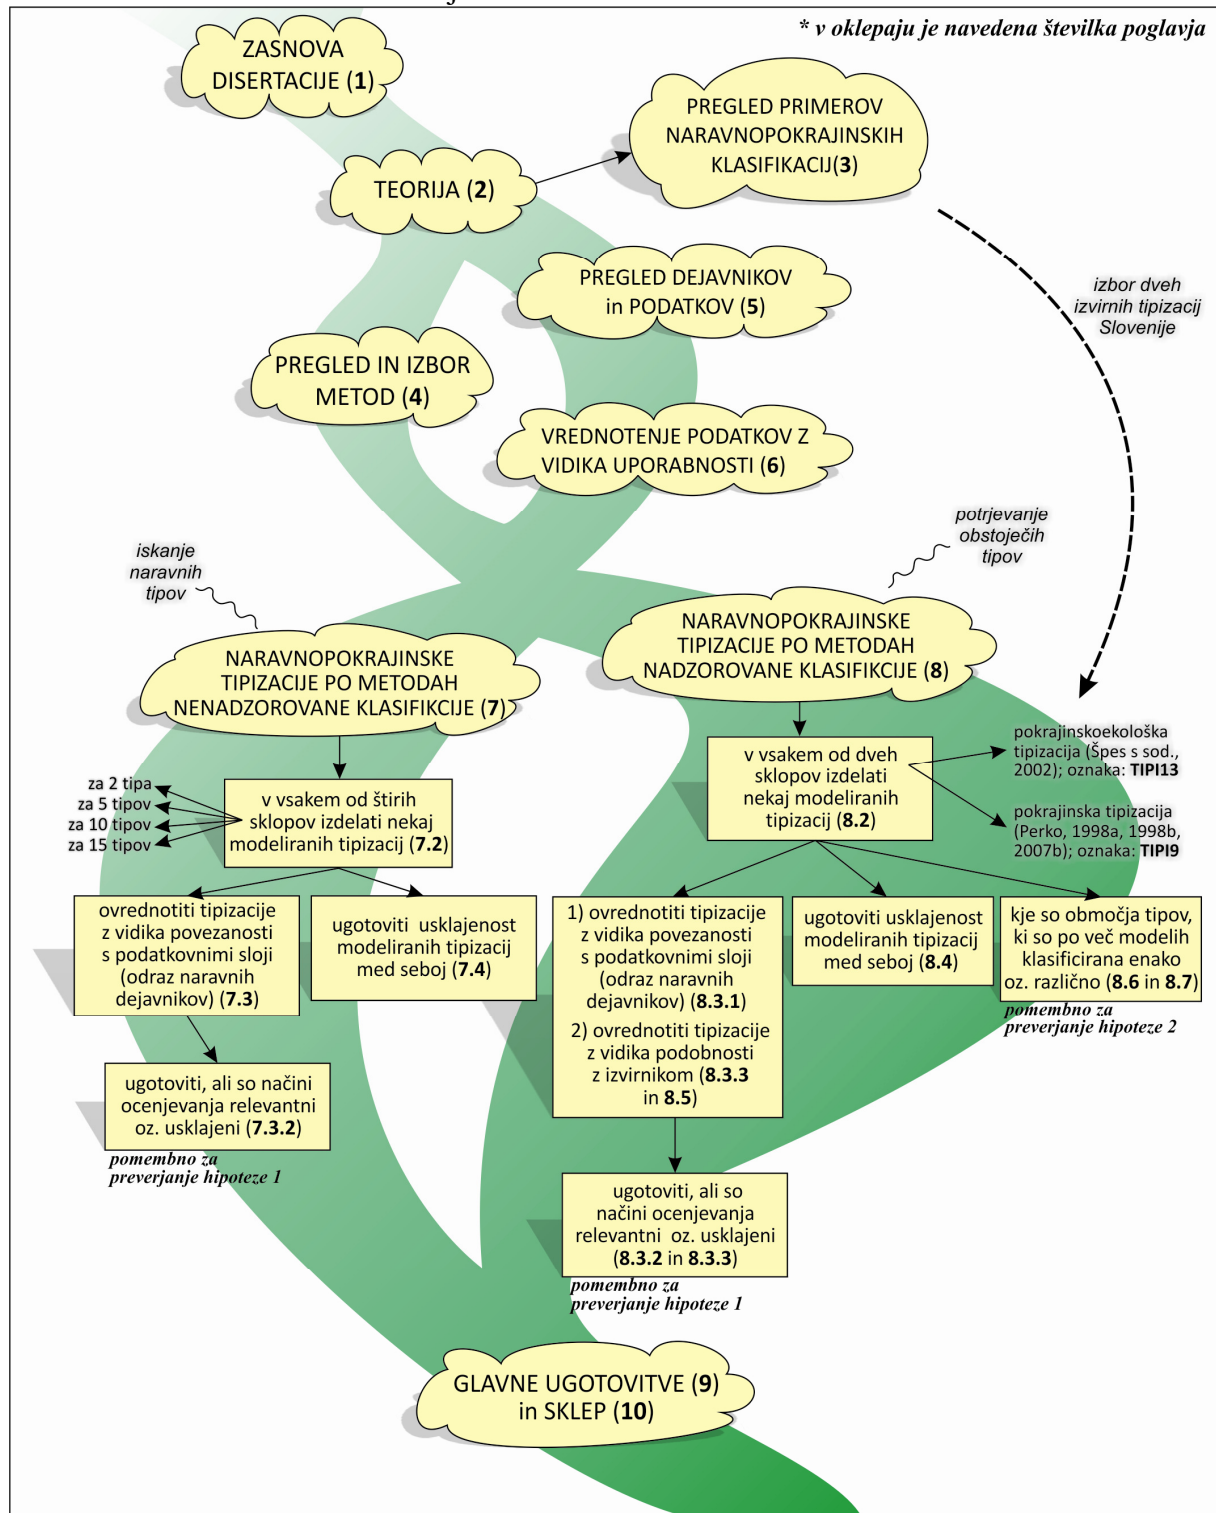
Raziskava je zasnovana v dveh delih. V bolj teoretičnem delu smo poiskali primere klasifikacij (tako tipizacij kot regionalizacij), primere uporabljenih geoinformacijskih orodij in podatkov ter izbrali nekatera geoinformacijska orodja za izvedbo tipizacij. V bolj praktičnem delu smo se popolnoma posvetili tipizacijam. Preverili smo uporabnost izbranih geoinformacijskih orodij za vrednotenje podatkovnih slojev ter za izdelavo in vrednotenje modeliranih tipizacij. Na koncu smo podali primernost geoinformacijskih orodij za izdelavo tipizacijo ter navedli predloge za optimalni postopek tipizacije.

V prvem delu smo se lotili pregleda znanstvene literature. Pregledali smo primere klasifikacij pokrajin in uporabo geoinformacijskih orodij za namen različnih združevanj ali delitev prostora. Pri tem pregledu smo se ozrli tudi na uporabo sorodnih orodij izven geografske stroke za druge namene klasificiranja. Navedene primere klasifikacij pokrajin smo analizirali ter ugotovili, katera geoinformacijska orodja in podatki so bili uporabljeni. Hkrati smo pregledali dostopnost digitalnih prostorskih podatkov za območje Slovenije, naredili bazo podatkov ter ugotovili, ali so primerni za obdelavo z geoinformacijskimi orodji. Zbrane podatkovne sloje smo z različnimi metodami skušali kar najbolj objektivno ovrednotiti z vidika njihove uporabnosti za tipizacijo Slovenije. Glede na nabor pregledanih orodij in podatkovno bazo smo izbrali nekaj različnih geoinformacijskih orodij in najbolj relevantne podatkovne sloje, s katerimi smo izdelali različne modelirane tipizacije Slovenije. Preizkusili smo različne načine določanja tipov, ki jih v splošnem lahko razdelimo na metode nadzorovane klasifikacije in metode nenadzorovane klasifikacije. Iz obeh skupin smo želeli preizkusiti čim bolj različne metode, na primer metodo odločitvenih dreves (Kononenko, 2005; Lin, Noe, He, 2006), metodo največje verjetnosti (Eastman, 2009), metodo voditeljev (Ferligoj, 1989) in segmentacijo (Acharya, Ray, 2005; Pratt, 2007). Vsako geoinformacijsko orodje ima namreč svoje prednosti in slabosti, ki so odvisne tudi od lastnosti podatkov. Preizkušena geoinformacijska orodja so bila dovolj raznolika in so omogočila različne metode tipizacij, vključitev številskih in neštevilskih podatkov ter upoštevanje v geografski literaturi že določenih tipov. Ker smo skušali zaobjeti čim večjo raznolikost v celem postopku, smo pri metodah nadzorovane klasifikacije uporabili tudi dva načina izbora učnih celic.

Osrednji del naloge je osredotočen na vrednotenje različnih modeliranih naravnopokrajinskih tipizacij, ki smo jih izdelali v prejšnjem koraku. Vse te tipizacije smo vrednotili z vidika vključenih podatkovnih slojev, modelirane tipizacije, narejene po metodah nadzorovane klasifikacijske, pa tudi z vidika izvirnih naravnopokrajinskih tipizacij. Ob tem smo preučili tudi podobnost samih modeliranih naravnopokrajinskih tipizacij med seboj. Modelirane tipizacije po metodah nenadzorovane klasifikacije smo pripravili predvsem zaradi tega, da smo preučili, kako na vrednotenje klasifikacij vpliva različno število tipov, modelirane tipizacije po metodah nadzorovane klasifikacije pa smo pripravili zato, ker smo skušali objektivno ovrednotiti različne modele izbranih obstoječih tipizacij. Zanimalo nas je namreč, kako dobro lahko obstoječo izvirno klasifikacijo določimo (ponovimo) tudi po »računalniški poti« oziroma z uporabo GIS-ov. V celotnem osrednjem delu naloge smo dali velik poudarek analizi usklajenosti različnih načinov vrednotenja, na primer primerjavi lestvic uspešnosti modeliranih tipizacij po različnih metodah vrednotenja ali pa primerjavi različnih lestvic relevantnosti podatkovnih slojev.

V zadnji fazi smo analizirali prednosti in slabosti geoinformacijskih orodij, nato pa smo za najbolj primerna orodja predlagali optimalen način vključitve v postopek določanja naravnih pokrajinskih tipov v Sloveniji (slika 2).

Slika 2: Shema doktorske disertacije.



2 Teorija klasifikacije pokrajine

Na začetku je treba izpostaviti, da splošno sprejete teoretične osnove za deljenje in združevanje enot v pokrajini oziroma klasifikacijo pokrajine ni (McMahon, Wiken, Gauthier, 2004, 111). Poleg tega je Thompson s sodelavci (2005) že opozoril na razlike med klasifikacijami, ki so po mnenju Hazeuja s sodelavci (2010) predvsem odraz različnih metod in namenov, s katerim so bile te uporabljene, in ne toliko prednosti in slabosti klasifikacij samih. Obstajajo torej različna načela, metode in nameni, od njihovega izbora pa sta odvisna potek raziskave in končni rezultat. Predvsem namen ima velik vpliv na izbiro klasifikacijskih dejavnikov (Zonneveld, 1994). V tem poglavju zaradi nedorečenosti v teoriji navajamo nekatera spoznanja, s katerimi želimo orisati celotno problematiko klasificiranja pokrajine.

2.1 Terminologija

Pri pregledu terminov navajamo tiste, ki so pogosto v zvezi s klasifikacijo pokrajine:

- regija, pokrajina,
- tip,
- ekološka regija/ekološko območje,
- klasifikacija,
- metoda nenadzorovane klasifikacije in metoda nadzorovane klasifikacije,
- regionalizacija,
- tipologija,
- tipizacija,
- segmentacija.

Termine na kratko opisujemo zato, ker v teoretičnem pregledu možnosti klasifikacij navajamo spoznanja s področja določanja različnih prostorskih enot (tipi, regije ...). Pri tem se ne opredeljujemo do posameznih izrazov, ob opisu nekaterih terminov pa so navedeni tudi terminu podobni izrazi. Ob koncu poglavja je opisan tudi **termin naravni pokrajinski tip**.

Regija, pokrajina

Pojma regija in pokrajina sta ponekod v literaturi enakovredna, velikokrat pa najdemo opise le enega izmed pojmov. Perko (1999, 14) je za regijo oziroma pokrajino navedel, da »je sestavljena iz pokrajinskih sestavin, te pa iz cele vrste pojavov in procesov ...«. V Slovarju slovenskega knjižnega jezika (elektronska izdaja v1.1) je *regija* opredeljena kot »področje, območje«. V Geografskem terminološkem slovarju (2005) pa kot »bolj ali manj enoten del Zemljinega površja ali večje območje, ki zaradi svojih pokrajinskih sestavin in procesov, njihovega medsebojnega prepletanja, součinkovanja predstavlja značilno pokrajinsko enoto z enakimi naravnimi in/ali družbenimi značilnostmi«. Podobna opredelitev je tudi v leksikonu Geografija (Učila, 2001). V nekaterih temeljnih geografskih delih domače in tuje literature je regija predstavljena kot »del zemeljske površinske sfere (pokrajinske prostorske stvarnosti ali geografskega okolja), pri katerem se pojavi in faktorji ter delujoče sile medsebojno povezujejo v kompleksno individualizirano celoto« (Vrišer, 1998) in kot »območje zemeljskega površja, ki ima opredeljive meje ali značilnosti« (Haggett, 2001, 794). Sicer pa obstajajo še mnoge druge interpretacije pojma regija, na katere je opozoril Klemenčič (2005). Morda bi na tem mestu omenili le najbolj pereče vprašanje o regiji, in sicer: »Ali regija obstaja in jo moramo prepoznati ter zamejiti njene lastnosti, ki sicer obstajajo, a so brez raziskovanja manj očitne, ali pa je regija le vsiljena struktura, ki je plod raziskovalčevega dela?« (Haggett, 2001, 367).

Treba je opozoriti na prevod besede »region«. V Velikem angleško-slovenskem slovarju (elektronska izdaja v1.2) so za ta izraz navedene »regija, pokrajina, ... , območje ...«. Kar pomeni, da samo iz besede ne moremo sklepati, ali gre za regijo ali gre za območje, kjer se

avtor ne opredeljuje za regijo, tip, pokrajino ali drugo. To pomeni, da moramo pri prevodu smiselno upoštevati celotno besedilo.

Loveland in Merchant (2004, 4) sta navedla definiciji regije (izvirno *region*) po Hartshornu iz leta 1939 in Hartu iz leta 1982. Po Hartshornu je »regija določena individualna enota, ki ima obliko in sestavo, in kot konkreten objekt skupaj z ostalimi tovrstnimi objekti na površju Zemlje tvori mozaik posameznih pokrajin ali regij«, bolj preprosta po Hartu pa je »regija bolj ali manj homogena površina oziroma območje, ki se razlikuje od ostalih območij«.

Dodajamo še definicijo, da so regije (izvirno *landscape character areas*) edinstvena individualna geografska območja (Swanwick, 2002). S tem želimo podčrtati, da je regija samostojen prostorsko povezan del Zemljinega površja.

Termin pokrajina je »v pomeni ozemlja, predela, regije, geografsko homogenega ozemlja ... v geografiji že dolgo časa sprejet in uveljavljen.« (Lovrenčak, 1996, 265). Lovrenčak (1996, 266) je navedel številna pojmovanja tega izraza in povzel, da pojem označuje »del zemeljskega površja, kjer sestavlja prepletajoče se delovanje naravno in družbenogeografskih dejavnikov, prostorsko enoto z značilno zunanjo podobo.« Gams (1984, 77 in 78) je naravnogeografski pomen še nekoliko bolj izpostavil, saj je za izraz pokrajina navedel, da ima v slovenski geografski stroki različne pomene, večinoma pa je prisoten naravnogeografski izgled zemeljskega površja. V Slovarju slovenskega knjižnega jezika je *pokrajina* označena kot: a) »manjše ali večje ozemlje glede na oblikovanost, obraslost, urejenost oziroma določeno manjše ali večje ozemlje sploh«; b) »višja upravna enota«; c) »slika, na kateri je upodobljena pokrajina; krajina«; d) »področje, območje«.

Predstavitev pokrajine, ki vključuje tudi četrto razsežnost in s se s tem dotakne tudi problema »naravnih pokrajin«, lahko dopolnimo s trditvijo (ki sicer opisuje pokrajinsko enoto), da je pokrajinska enota »geografski kompleks homogene naravnogeografske enote in družbenogeografske stvarnosti ... Naravnogeografske enote, vsaj za eno ali več generacij, predstavljajo skoraj stalnico, medtem ko se družbene razmere hitro spreminjajo« (Černe, Klemenčič, Plut, 1981, 130).

V Velikem angleško-slovenskem slovarju (elektronska izdaja v1.2) so za izraz *landscape* navedeni »pokrajina, pokrajinska slika, pejzaž«. Whitthow (2000, 295) izraz pokrajina (izvirno *landscape*) razlaga kot del površja z vključenimi naravnimi in antropogenimi lastnostmi.

Pokrajina (izvirno *landscape*) je vzorec oziroma mozaik ekotopov (Haber, 1994, 59) oziroma del površja Zemlje (Meeus, 1995). Pokrajine so deli Zemljinega površja, ki jih lahko prepoznamo in ki kažejo značilno razporeditev elementov, čeprav so pogosto heterogeni. Pokrajine so zapleteni prostorsko heterogeni sistemi s številnimi lastnostmi (Mücher s sod., 2009).

Pokrajinska značilnost (izvirno *landscape character*) je po mnenju The Countryside Agency and Scottish Natural Heritage opisana kot razločen, prepoznaven in pravilen (konsistenten) vzorec elementov v pokrajini, ki naredi eno pokrajino drugačno od druge (Wascher, 2005). Ob vseh opredelitvah naj navedemo še, da je pokrajina v teoriji lahko dejansko tudi »prosto izbran kvadrat zemeljskega površja« (Perko, 1998d, 15).

Tip

Slovar slovenskega knjižnega jezika (elektronska izdaja v1.1) opredeljuje izraz *tip* kot nekaj, »kar ima v veliki meri lastnosti, značilnosti, zaradi katerih se uvršča v posebno skupino stvari iste vrste«, izraz *tipologija* pa kot »ureditev, uvrstitev v tipe« oziroma kot »postopek, po katerem se kaj uvršča v določen tip«. V geografski literaturi se oba pojma uporabljata, a njune opredelitve ni v osnovnih geografskih leksikonih in priročnikih.

Tipi pokrajinskih značilnosti (izvirno *landscape character types*) imajo po Swanwicku (2002) podobne vzorce geologije, reliefa, prsti, vegetacije, rabe tal, poselitve in poljske razdelitve povsod, kjer se pojavijo.

Ekološka regija/ekološko območje

V literaturi se pogosto pojavlja izraz *ecoregions*, kar lahko prevedemo kot *ekološka regija* oziroma *ekološko območje*. V nadaljevanju uporabljamo izraz ekološko območje, saj pogosto ni jasno definirano, ali gre za območja, ki so sestavljena iz več prostorsko ločenih delov ali pa le iz enega prostorsko zaključenega. Ekološka območja so relativno velike enote površja, ki vsebujejo sestavo določenih naravnih združb in vrst in ki imajo meje, ki približno ustrezajo naravnim, torej tistim pred spremembami rabe tal zaradi človekovega posega (Olson s sod., 2001). Posamezna ekološka območja imajo relativno homogene biotske in abiotske značilnosti ter se razlikujejo od značilnosti sosednjih območij (McMahon, Wiken, Gauthier 2004, 112). Z ekosistemskega vidika so ekološka območja definirana kot večji ekosistemi, ki vsebujejo manjše ekosisteme s podobno zmožnostjo odzivanja in podobnimi naravnimi viri (Zhou s sod., 2003, 445) oziroma kot območje relativne homogenosti ekosistemov (Loveland, Merchant, 2004, 1).

Čeprav je splošno sprejeto, da ekološka območja predstavljajo mozaik ekosistemov, ki so relativno homogeni v primerjavi s sosednjimi območji, ni nobenega jasnega dogovora glede prepoznavanja (določanja) in dojetanja ekoloških območij (Omernik, 1995 cv: McMahon, Wiken in Gauthier, 2004, 113). Loveland in Merchant (2004) trdita, da moramo ekološka območja jemati kot model. To pa lahko razumemo kot človekovo definicijo, ki se glede na metodo lahko razlikuje. Hkrati dodajta še, da »je ekološko območje zgolj konstrukt, s katerim posplošimo kompleksnost pokrajine (landscape)« (Loveland, Merchant, 2004, 2).

Drugi izrazi

V tuji literaturi najdemo še druge izraze (Bailey, 1996): *landschaft, natural land types, site, site regions, land systems* in druge. Ponekod srečujemo tudi izraze, kot so *okoljske domene* (izvirno *environmental domains*), ki jih označujejo kot geografske enote s podobnim okoljem (Leathwick, Overton, McLeod, 2003).

Klasifikacija

Za izraz klasifikacija sta v Slovarju slovenskega knjižnega jezika (v1.1) navedeni dve razlagi. Prva pravi, da je to »razvrstitev, razporeditev česa glede na enake ali podobne lastnosti«, druga pa, da gre za »ocenitev, ovrednotenje«. Pojem klasifikacija (ang. *classification*) ima v literaturi precej razlag (McGarigal, 2000, 10). Klasifikacija je lahko vsaka formalna ureditev podatkov v hierarhijo kategorij ali razvrstitev v razrede (Whittow, 2000, 88) oziroma sistematična ureditev v razrede ali skupine na podlagi skupnih lastnosti (Clark, 1998, 74). Pojavlja se tudi podoben izraz klaster analiza (*cluster analysis*), ki se nanaša na metode organiziranja enot v diskretne razrede. Te metode označujejo tudi z *botryology, classification, clumping, grouping, morphometrics, nosography, nosology, numerical taxonomy, partitioning, q-analysis, segmentation analysis, systematics, taximetrics, taxonrics, typology, unsupervised pattern recognition*. V spletnem priručniku programa Statistica (StatSoft, 2012) se tudi metoda faktorске analize omenja kot način klasifikacije spremenljivk, kar pojem klasifikacija še nekoliko razširi.

Ker obstaja več metod, tudi ni splošne definicije izrazov klaster, grozd ali gruča (ang. *cluster*). Eden izmed splošnih opisov pojma pravi, da *cluster* vsebuje enote, ki kot točke zavzemajo natančno določeno mesto v večrazsežnostnem prostoru, kjer vsako od p spremenljivk predstavlja ena od osi. Te točke oblikujejo oblake v tem prostoru in *clustri* so območja, v

katerih je relativno visoka gostota točk in so hkrati med seboj ločeni z območji, v katerih je gostota točk manjša (McGarigal, 2000, 85, 86).

Pomembno razlikovanje klasifikacij je izpostavila Ferligojeva (1989, 18), ki pravi, da »nalogo razvrščanja v skupine razlikujemo od naloge uvrščanja, kjer so skupine oziroma karakteristike skupine že določene in je potrebno vsako dano enoto prirediti skupini, ki ji je najbolj podobna (najbližja).«

Metoda nenadzorovane klasifikacije in metoda nadzorovane klasifikacije

Razlago metode nenadzorovane klasifikacije in metode nadzorovane klasifikacije opisujemo s pomočjo terminologije daljinskega zaznavanja.

»Pri nenadzorovani klasifikaciji piksele razporedimo v razrede glede na njihovo 'naravno' združevanje v spektralnem prostoru. Za razliko od nadzorovane pri nenadzorovani klasifikaciji v prvem koraku ne potrebujemo nikakršnega vedenja o površju« (Oštir, 2006, 178). Metode nenadzorovane klasifikacije so po Ferligojevi (1989) označene kot razvrščanje v skupine. To pomeni, da pri nenadzorovani klasifikaciji združujemo prostorske enote (na primer piksele oziroma rastrske celice) glede na njihove vrednosti (na primer odbojna vrednost, višina) v večrazsežnostnem prostoru, ki ga določajo izbrani podatkovni sloji (na primer višina odboja v določenem spektralnem razredu, nadmorska višina).

»Pri nadzorovani klasifikaciji za ustvarjanje spektralnih vzorcev uporabimo svoje poznavanje zemeljskega površja. Na nek način računalniški program 'naučimo', kaj je na primer voda in kaj je trava, nato pa ta svoje znanje prenese na celoten posnetek. Postopek nadzorovane klasifikacije razdelimo na: ustvarjanje in urejanje vzorcev ter razvrščanje² v razrede (klasifikacija)« (Oštir, 2006, 179). To pomeni, da pri tem načinu klasifikacije izberemo določene primere pokrajinskih tipov ter jim določimo njihove tipične vrednosti (na primer nadmorsko višino, naklon in podobno). Nato na podlagi teh primerov z metodo nadzorovane klasifikacije izdelamo pravila, s katerimi klasificiramo vse enote (celice) v vnaprej določene tipe.

Regionalizacija

Regionalizacija je pojem, ki je v Slovarju slovenskega knjižnega jezika (elektronska izdaja v1.1) označen kot »postopek členitve ozemlja na regije«. Kot sopomenko navaja pojem »tipizacija«, kar se nam ne zdi pravilno. Perko (1998d, 14 in 15) je pojem označil kot »postopek prostorskega ločevanja regij oziroma členitev Zemljinega površja na pokrajine«. Izraz pojmuje tudi kot »hierarhično razvrščanje, delitev in združevanje regij oziroma pokrajin«. V leksikonu Geografija (Učila, 2001) so to razlago povzeli, hkrati pa dodali, da sta podobna pojma tudi »členitev« in »rajonizacija«. V literaturi se izraz pojmuje tudi kot »delitev zemeljskega površja na regije« (Vrišer, 1998) in kot razmejevanje zemeljskega površja »na pokrajine, območja, predele ali ozemlja, ki jih družijo podobne ali celo enake naravne in/ali družbene značilnosti« (Vrišer, 1999, 38). Torej je regionalizacija zgolj ena od možnih oblik klasifikacije, razvrščanja pojavov (Natek, Žiberna, 2004, 25) oziroma posebna oblika klasifikacije (Loveland, Merchant 2004, 3). To je v statistiki imenovano kot razvrščanje v skupine z omejitvami (Ferligoj, 1989, 115), kjer lahko kot dodaten pogoj za združevanje določimo pravilo, da se morata enoti stikati. Iz literature so znani tudi opisi regionalizacije kot prostorske klasifikacije, pri kateri klasificiramo območja (Loveland, Merchant, 2004, 3). Regionalizacija (izvirno *regionalization*) je proces poenostavitve geografskih pojavov v različne prostorske enote (Bernert s sod., 1997, 405). Ta definicija je dokaz, da angleški izraz *regionalization* ni nujno enak slovenskemu izrazu *regionalizacija*, saj ne govori o tem, ali so enote enkratne ali ne.

² Metode nadzorovane klasifikacije so po Ferligojevi (1989) označene kot uvrščanje v skupine.

Tipizacija

Izraz tipizacija je v Slovarju slovenskega knjižnega jezika (v1.1) označen kot »glagolnik od tipizirati«. Slednje pa pomeni »urediti, razvrstiti kaj glede na določene lastnosti, značilnosti v skupine«. Podoben izraz, tipologija, je označen kot »ureditev, uvrstitev v tipe« oziroma »postopek, po katerem se kaj uvršča v določen tip«. Po tem pojmovanju sta si pojma tipizacija in tipologija zelo blizu, v geografiji pa se očitno bolj uporablja pojem tipizacija, saj je njegovo obrazložitev možno zaslediti v Geografskem terminološkem slovarju, kjer pomeni »delitev ozemlja na tipe glede na en sam pojav, geografsko prvino ali skupek izbranih pojavov, procesov v pokrajini«, in v leksikonu Geografija, kjer je opredeljen kot »pokrajinska členitev po eni sami pokrajnotvorni prvini«. V nadaljevanju slednje razlage je dodano: »Ker gre za povezanost pokrajinskih sestavin, tudi tipizacija na podlagi ene same sestavine pomeni regionalizacijo na osnovi z njo močno povezanih in prepletenih sestavin. Zato regionalizacija pogosto temelji na tipizaciji pokrajin, tj. na njihovem razvrščanju v skupine glede na njihove značilnosti. Vsaka regija spada v določen tip regij in v vsak tip regij se lahko uvrsti več regij.« Da je tipizacija členitev po eni prvini, je zapisano tudi v drugi literaturi (Gams, 1983), hkrati pa zasledimo tudi razlago, da je tipizacija (pokrajin) razvrščanje (pokrajin) po značilnostih v skupine oziroma tipe (pokrajin) ter tudi primer konkretnega določanja tipizacije po več pokrajinskih značilnostih (Perko, 1998b). Natek (1993) pravi, da je treba tipizacijo »razlikovati tudi od kvantitativno zasnovane klasifikacije na osnovi razlik med vrednostmi izbrane numerične spremenljivke, na primer klasifikacija Slovenije na osnovi spremenljivke 'umerjeni reliefni koeficient' (Perko 1992), pri čemer so vse ostale značilnosti zavestno izpuščene«.

Pomembno pri zapisovanju imen tipov je, da »se pri tipizaciji vsak tip lahko pojavi večkrat«, zato »imena pokrajinskih tipov zapisujemo z malo začetnico« (Geografija, 2001).

Členitev

Izraz členitev se zdi nadpomenka vseh omenjenih metod (regionalizacija, tipizacija, tipologija). V Slovarju slovenskega knjižnega jezika (v1.1) je ta pojem obrazložen kot »glagolnik od členiti«, slednji pa ima razlago »deliti celoto na zaključene dele, enote«. Tudi Kladnik (1996) je pri opisu različnih regionalizacij in tipizacij uporabil besedo členitev.

Segmentacija

Izraz segmentacija po Slovarju slovenskega knjižnega jezika (v1.1) označuje »razčlenitev« oziroma »razčlenjenost«. V geografiji se pogosto uporablja podoben izraz »členjenje« ali »členitev« (na primer Kladnik, 1996). Segmentacija je tudi postopek, ki deli površja na homogene enote. Zaradi računskega načina določanja enot ga lahko v geografiji prevedemo kot računalniška členitev (ali razmejitev) območja na homogene enote po izbranih kriterijih. Uporaba tujke »segmentacija« je smiselna, predvsem ko označujemo geoinformacijski postopek, saj lahko po njej dobljene prostorske enote nadalje razvrstimo v skupine ter šele nato dokončno razdelimo površje na regije ali tipe. Segmentacija v metodološkem smislu namreč izbrano območje le deli glede na vrednosti podatkovnih slojev na homogene prostorske enote, pri tem pa ne prepozna individualnosti teh enot ali razmerij do ostalih (Pratt, 2007, 579).

2.1.2 Primerjava nekaterih terminov in uporaba terminov v nalogi

Našteti opisi terminov dokazujejo, da številni nimajo povsem jasnih in dokončno urejenih definicij. Sklepamo, da sta klasifikacija in členitev sopomenki in da sta to nadpomenki za tipizacijo (tipologijo) in regionalizacijo oziroma za razdelitev zemeljskega površja na tipe ali regije. Pri tem poudarjamo, »da je za tipizacijo značilno načelo podobnosti, za regionalizacijo pa veljata načeli posamičnosti in posebnosti« (Geografija, 2001) oziroma da je delitev

ozemlja glede na podobnost tipizacija, delitev površja glede na individualnost pa je regionalizacija (Gams, 1984 cv: Natek, 1993, 26). Pri razlikovanju pojmov tipizacija in regionalizacija je pomembno to, da se tip lahko pojavi na več prostorsko ločenih območjih in se piše z malo začetnico, regija pa je ena sama prostorsko zaključena enota in se piše z veliko začetnico.

V nalogi bomo uporabljali izraz klasifikacija tudi kot nadpomenko za vse vrste klasifikacij (nenadzorovanih in nadzorovanih). Za nenadzorovane klasifikacije bomo uporabljali tudi izraz razvrščanje v skupine, za nadzorovane klasifikacije pa izraz uvrščanje v skupine. Kjer je pomembno, je zapisano »klasifikacija na tipe« oziroma »tipizacija« in »klasifikacija na regije« oziroma »regionalizacija«. Izraz segmentacija uporabljamo kot metodo oziroma geoinformacijsko orodje. Med besedilom uporabljamo tudi izraz enota ali prostorska enota, predvsem ko imamo v mislih le del površja brez kakršne koli specifične oznake.

V osrednjem, analitičnem, delu smo uporabili **nekaj specifičnih izrazov**, s katerimi smo poimenovali klasifikacije. Tu jih posebej izpostavljam zaradi lažjega razločevanja:

- izvirna naravnopokrajinska tipizacija, s katero označujemo tipizaciji, ki smo ju modelirali; to sta tipizacija Slovenije na devet tipov (Perko, 1998a; Perko, 1998b; Perko, 2007b) in pokrajinskoekološka tipizacija (Špes s sod., 2002),
- modelirana naravnopokrajinska tipizacija, s katero označujemo vsako tipizacijo, ki je bila narejena v tej nalogi s pomočjo metode nenadzorovane ali nadzorovane klasifikacije,
- popačena izvirna naravnopokrajinska tipizacija, s katero označujemo popačeni oziroma nesmiselni izvorni tipizaciji; to sta popačeni tipizaciji, ki sta služili za prikaz, kakšni so modeli potencialnih nesmiselnih tipizacij Slovenije (priloga 14),
- modelirana popačena naravnopokrajinska tipizacija, s katero označujemo vsako tipizacijo, ki je bila narejena v nalogi s pomočjo metod nadzorovane klasifikacije na podlagi popačene izvirne tipizacije (priloga 14).

Glede na navedene opise pojmov regija, pokrajina, tip in drugih moramo za dosleden opis pojma **naravni pokrajinski tip** vključiti naslednje lastnosti:

- podobnost,
- stalnost v primerjavi s človeškim življenjem in
- prostorska stičnost ni obvezna.

V skladu s tem lahko naravne pokrajinske tipe obrazložimo kot dele Zemljinega površja, ki so si glede na značilnosti bolj stalnih naravnih dejavnikov (torej tistih, ki so manj spremenljivi oziroma nespremenljivi z vidika človekovega življenja) podobni, ob tem pa so lahko ti med seboj prostorsko bolj ali manj oddaljeni.

2.2 Dosedanja spoznanja

Pregledali smo nekatere značilnosti klasifikacij pokrajine, tako tipizacij kot tudi regionalizacij (čeprav se v praktičnem delu naloge posvečamo izključno tipizaciji). Pri obeh načinih gre namreč za klasifikacijo površja na podlagi določenih kriterijev. Kljub temu da metodi tipizacije in regionalizacije dajeta različne rezultate, to ne pomeni, da nimata podobnih metodoloških postopkov. Na to je opozoril Ilešič (1957/1958, 86), ki pravi, da lahko *»naravnogeografsko regionalizacijo označimo kot regionalizacijo na podlagi meril tipologije naravnih pokrajin«*. Pa tudi Perko (1998b, 12) pravi, da *»regionalizacija pogosto temelji na tipizaciji pokrajin, razvrščanju pokrajin po njihovih značilnostih v skupine, tipe pokrajin«*. Tudi Natek in Žiberna (2004, 25) sta izpostavila, da na primer upoštevanje pokrajinskih značilnosti kot kriterijev za razlikovanje ni prisotno samo pri geografski regionalizaciji, temveč pri vsakem razvrščanju katerih koli pojavov.

Poleg tega smo pri teoretičnem pregledu klasifikacij pokrajine upoštevali spoznanja iz geografije, biogeografije, ekosistemske geografije, pokrajinske ekologije in drugih sorodnih

ved. Načela členitve v fizični geografiji in pokrajinski ekologiji, po katerih je bilo veliko členitev, so namreč sorodna, čeprav prva vidi regije kot celoto, pokrajinska ekologija pa kot splet ekotopov (Gams, 1986a). Poleg tega je ekosistemska geografija podobna pokrajinski ekologiji (Bailey, 1996), razlikovanje med ekosistemske in vegetacijske klasifikacije pa ni vedno jasno (Runhaar s sod., 1994). Z navedenimi trditvami želimo zgolj upravičiti navajanje spoznanj različnih avtorjev, ki so uporabili različne definicije, metode, podatke, dejansko pa so povezani s skupnim ciljem, to je razdeliti površje na določene enote. V besedilu zato uporabljamo različne izraze, ki so jih uporabili avtorji (na primer regija, tip, pokrajina, ekološko območje in podobno), ponekod pa zaradi lažjega branja in poenotenja besedila uporabljamo bolj splošen izraz *prostorsko enota*.

Pri pripravi teoretičnega pogleda na klasifikacijo pokrajin smo se oprli na vprašanja, ki so izpostavljena v literaturi s tega področja. Po Hargrovu in Hoffmanu (2005, 39) so denimo temeljna vprašanja, ki so povezana z naravnimi enotami, naslednja:

- Ali so namenjena specifičnemu ali splošnemu namenu?
- Ali so prostorsko zvezne ali nezvezne?
- Ali so hierarhične ali ne?
- Ali so lahko to enote upravljanja, podlage v zakonodaji in podobno?
- Ali jih lahko določimo s kvantitativnimi metodami ali jih lahko zarišemo le ekspertno?

McMahon, Wiken in Gauthier (2004) so za boljše razumevanje prepoznavanja ekoloških regij oziroma območij (izvirno *ecological region identity*) svoje predloge strnili v štiri točke: meje in stabilnost, vpliv človeka, vzorec in merilo za definiranje enot ter hierarhičnost enot.

Bailey (1996, 27) ter McMahon, Wiken in Gauthier (2004) izpostavljajo pri obravnavi (ekosistemskih) klasifikacij predvsem dve vprašanji:

- Kateri dejavniki so pomembni pri prepoznavanju ekosistemov?
- Kako določiti meje med njimi?

2.2.1 Osnovni pristop

Pri raziskovalnem delu se opiramo na analizo in sintezo ter indukcijo in dedukcijo (Vrišer, 1998, 102). Pri deduktivnem pristopu izhajamo iz teorije o zgradbi in delovanju narave. Razlike med območji iščemo na podlagi teorije, ki izhaja iz predhodnih izkušenj. Že na začetku se osredotočimo na dejavnike, za katere predvidevamo, da so pomembni za razlikovanje. Tak način se odraža v strogih načelih. Glavna znanstvena naloga je torej preizkusiti hipotezo (Udo de Haes, Klijn, 1994, 14 in 15). Pri induktivnem pristopu je v ospredju vzorčenje podatkov, ki jih klasificiramo, navadno s pomočjo kvantitativnih metod. Prične se brez domnev o razmerjih in predvideva, da se bodo podobnosti in razlike pokazali z obdelavo podatkov. Pri tem je treba paziti na izbor vzorca in značilnosti (Udo de Haes, Klijn, 1994, 14 in 15; Bunce, 1994). Pri delu moramo uporabiti tako analizo kot tudi sintezo. Vrišer (1998) meni, da se moramo v čim večji meri opreti na sintezo, kajti le tako je mogoče pravilno predstaviti pokrajino, analitične metode pa uporabljamo, ko obravnavamo posamezne osnovne komponente pokrajine in njihovo vlogo pri njenem oblikovanju.

Na načelo, po katerem se bomo lotili raziskave, pomembno vpliva dojetje predmeta raziskave. Udo de Haes in Klijn (1994, 3) sta izpostavila, da je lahko ekosistem definiran kot abstrakten pojem ali pa kot dejansko prepoznaven objekt. To deli raziskave po dveh načelih:

- enote obstajajo, lahko jih prepoznamo in so zato resnične,
- enote določa človek in so zato abstraktne.

Da so enote dejansko lahko prepoznane, trdi Bailey (1996, 4), ki pravi, da ekosistemi kot geografske enote pokrajine vključujejo vse naravne pojave in so lahko prepoznani in zamejeni z mejami. Tak način nasprotuje Gamsovi (1984, 76) trditvi, da v naravi takšne enote ne obstajajo in da gre pri razmejevanju enot v naravi za zavestno silo naravi z metodo, ki je le

miselni konstrukt. Gams (1978a, 15) pravi še, da »je vsaka regija z omejeno črto na karti nenaravna, umetna tvorba in rabi samo kot sredstvo ugotavljanja razlik«.

Neenoten pogled na enote naravne pokrajine lahko ponazorimo z mnenji govorcev okrogle mize v Bratislavi leta 1972 (Demek, Quitt, Raušer 1972, 196–197):

- Schmithüsen je trdil, da je naravnogeografska potencialna pokrajina le abstrakcija, kulturna pokrajina pa je (nasprotno) realnost.
- Muchina je trdil, da fizično-geografski rajoni v naravi obstajajo in niso abstrakcija.
- Roglič je trdil, da je naravno okolje realnost, zato je tudi fizično-geografska klasifikacija nujna.
- Sočava je trdil, da je potencialna naravna pokrajina realnost ter da je pokrajina naravni kompleks in pri temu klasifikacija pomaga odkrivati naravo in pomaga tudi v praksi.

Torej se že na začetku soočimo z dilemo, ali določamo tipe naravnih pokrajin, uberemo bolj induktiven pristop in z analizo pridemo do spoznanj o tem, kje so posamezni tipi, ali pa moramo tipe prepoznati in zato ubrati bolj deduktiven pristop ter upoštevati dosedanja spoznanja (geografske) znanosti in jih prenesti v prostor, kjer raziskujemo.

2.2.2 Raznolikost izdelave klasifikacij

Že pregled terminov je nakazal dve glavni delitvi klasifikacij Zemljinega površja v geografiji: glede na podobnost (tipizacija) in glede na individualnost (regionalizacija). Regije so lahko po Haggettu grupirane na dva načina. Prvi postavlja v ospredje homogenost, drugi pa nodalnost. Zaradi tega je znanih tudi več vrst regij: homogene regije, nodalne regije in planske regije (Haggett, 2001, 367). Ta vidik je bolj uporaben pri družbenogeografskih klasifikacijah.

Demek, Quitt in Raušer (1972, 15) so navedli, da obstajata dva načina izdelave naravnogeografske klasifikacije. Pri enem se območja določa neposredno, pri drugem pa se v prvem koraku naredi delne klasifikacije (glede na geomorfološke, hidrološke in druge značilnosti) in šele nato končna.

Klasifikacija lahko poteka z deljenjem ali pa z združevanjem osnovnih enot. Noben pristop ni vnaprej določen kot boljši (Loveland, Merchant, 2004, 4). Zonneveld (1994, 43) priporoča, da je za območja z dovolj podatki v obliki zemljevidov najprimerneje določiti pokrajinske enote šele po analizi, razmejitvi in klasifikaciji posameznih pokrajinskih dejavnikov. Klasifikacija je možna tudi s postopnim abstrahiranjem pokrajinskih razlik med posameznimi pokrajinskoekološkimi enotami na različnih ravneh klasifikacije, tako da na koncu izločimo glavne pokrajinskoekološke tipe (Špes s sod., 2002, 33).

Delitev površja na enote je lahko zvezna ali nezvezna. Nezvezna delitev je bolj kvalitativna, narejena na podlagi strokovnega znanja in ima bolj aplikativno vrednost, vendar je bolj podvržena subjektivnosti, zvezna delitev pa je bolj kvantitativna in objektivna ter ima večjo analitično vrednost. Zvezna delitev površja je pogosto le prva stopnja nezvezne delitve površja. Za nezvezno delitev površja je značilno, da posamezne dele površja združujemo v ploskve z enakimi ali podobnimi vrednostmi izbranih spremenljivk in jasnimi mejami. Za zvezno delitev površja je značilno, da posamezne dele površja uvrščamo zgolj glede na vrednosti izbranih spremenljivk ne glede na njihovo prostorsko lego. Take neprostorske enote najpogosteje imenujemo razredi (Hrvatina, Perko, 2010, 22).

Poleg naštetih dejstev je treba omeniti še neskončno vrsto kombinacij posameznih delovnih postopkov v praksi. Kljajn (1994) na primer podpira to, da se najprej določijo enote, nato pa se glede na velikost enot oziroma merilo izbere nabor značilnosti in z njimi enote dokončno klasificira v skupine.

Zaključujemo z dejstvom, da sta glavna načina klasifikacije pokrajin regionalizacija in tipizacija. To sta različna pristopa, ki pa pogosto uporabljata enake metode (na primer za določanje meja, računanje številskih lastnosti enot). Raznolikost klasifikacij povečajo še

možnosti deljenja enot ali združevanja enot, uporaba zveznih in nezveznih delitev ter kombiniranje različnih delovnih postopkov.

2.2.3 Pomen izbora dejavnikov

Klasifikacijo lahko torej opravimo zgolj na podlagi enega dejavnika (monotetični pristop) ali pa na podlagi več dejavnikov (politetični pristop) (Loveland, Merchant 2004, 4). V geografiji bi po Gamsu morali ločiti vsaj dve kategoriji tipizacije (Gams, 1984, 75 in 76): podobnost glede na en pojav (na primer območje pogoste toče, območje malarije), podobnost v pogledu kompleksnosti ene pokrajnotvorne prvine (relief, podnebje, vodovje, prst ...). Tema dvema lahko dodamo še tipizacijo po več pokrajinskih značilnostih (Perko, 1998b). Vsekakor bi morala geografija po mnenju Ilešiča (1957/1958) vztrajati pri kompleksnih rajonizacijah. Tudi Zonneveld (1994, 42) meni, da naj bi se pokrajinska enota ne določala le po eni spremenljivki. To naj bi bilo možno le v čistih naravnih pokrajinah. Prav tako Bailey (1996) in Ilešič (1957/1958, 86) menita, da mora sistem temeljiti na več dejavnikih oziroma da se moramo izogniti kriteriju enega samega dejavnika in kriteriju ene same prevladujoče značilnosti, četudi jo povzroča več dejavnikov.

V literaturi obstaja delitev na razlikovalne dejavnike in diagnostične dejavnike. Vink (1975 cv: Klijn, 1994, 95) prve navaja kot uporabne za določanje prostorskih enot (na primer tipov), druge pa za bolj temeljit opis, pri čemer so slednji zaradi povezanosti lahko uporabljeni tudi pri določanju enot. Zonneveld pa uporablja oziroma prepozna le diagnostične dejavnike, s katerimi razmejuje in opisuje enote (Zonneveld 1979 cv: Klijn, 1994, 95). V osnovi morajo biti dejavniki merljivi in konstantni v času. Za izbrane diagnostične značilnosti ni nujno, da imajo pomembno funkcijo; lahko so namreč izbrane zaradi njihove prepoznavnosti, zmožnosti meritve pojava in podobno (Zonneveld, 1994, 25 in 26).

Dejavniki v naravi medsebojno učinkujejo in so zato povezani. To pomeni, da je lahko celota znana že samo po nekaterih lastnostih. Če izberemo najbolj relevantne značilnosti, po katerih klasificiramo, lahko veliko število preostalih značilnosti ocenimo z zadostno natančnostjo (Klijn, 1994, 91). Bailey (1996) je zato izpostavil metodo usmerjevalnih dejavnikov (izvirno *controlling factors*). Po tej metodi bi morali izmed vseh dejavnikov najti tiste, ki so relevantni. Ti so nato uporabni za členitev pokrajine, ostali dejavniki pa se lahko uporabijo za opis. Statistične metode nam omogočajo tudi izračun stopnje povezanosti, zato lahko odvečne dejavnike, ki jih dovolj dobro odražajo drugi, odstranimo iz postopka klasifikacije. Pri tem velja izpostaviti, da ni nujno, da so vsi dejavniki enako pomembni na vseh ravneh (o tem je napisanega več v poglavju 6), čeprav naj bi bilo po mnenju Ilešiča temeljno merilo ves čas isto (Ilešič, 1958 cv: Kladnik, 1996). Vsekakor je dobro pri klasifikaciji analizirati dejavnike na različnih ravneh. Za določanje meja moramo definirati pomembne spremembe dejavnikov v prostoru (Bailey, 1996, 38).

Dejstvo je torej, da lahko dejavnike oziroma značilnosti pokrajine uporabimo za razmejevanje in/ali za opis enot (tipov, regij). Nekateri (Mücher s sod., 2003; Mücher s sod., 2006; Klijn, 1994, 95) ponujajo ločevanje dejavnikov v dve glavni skupini; v prvi so dejavniki, ki jih uporabimo za postavljanje meja med (homogenimi) enotami, v drugi pa dejavniki, ki jih uporabimo za klasifikacijo enot v skupine. Pri tem Mücher (2003, 81) trdi, da naj bi se za oznako in opis pokrajinskih tipov uporabilo ekspertno znanje, za razmejevanje pa bi se morali uporabiti računalniški podatkovni sloji.

Klasifikacija je navsezadnje lahko določena tudi na podlagi jasno izraženih lastnosti (na primer značilnosti reliefa) ali pa bolj abstraktnih lastnosti (na primer glavna komponenta) (McMahon, Wiken, Gauthier, 2004, 118).

2.2.4 Lastnosti podatkov

Podatki imajo številne lastnosti, ki jih moramo poznati, preden jih uporabimo. Med njimi lahko izpostavimo na primer način zapisa, prostorski obseg, ločljivost (prostorska natančnost), dostopnost (avtorstvo) in kakovost (natančnost izmere). Podatki nam zaradi teh lastnosti določajo izbor metod in dosego rezultatov v določenem okviru.

Način zapisa podatkov nas omejuje na določeno rabo orodij. Če podatka ni v digitalni obliki, torej obstaja le v fizični, potem ne moremo uporabiti računalniških metod. Vektorski podatki so predstavljeni kot zbirka preprostih geometrijskih objektov, kot so točke, linije in poligoni (Gandhi, 2008, 1217), rastrski podatki pa so podatkovni sloji z mrežo pikslov (celic) z določeno vrednostjo (Galati, 2006, 6).

Obseg in ločljivost neposredno vplivata na kakovost rezultata. Prvi pomeni površino območja, ki ga lahko analiziramo, drugi dejavnik pa pove, kakšna je lahko prostorska natančnost rezultata (McMahon, Wiken, Gauthier, 2004, 115). Pri rastrskih podatkih je prostorska ločljivost nedvoumna, saj jo ponazarja velikost celic, pri vektorskih pa je ločljivost težje definirati, zato se v znanosti priporoča raba rastrskih podatkov (Goodchild, 2011, 6).

Kot pomembno dejstvo pri klasifikaciji so Múcher s sodelavci (2003, 19) ter Bunce s sodelavci (1996, 45) izpostavili tudi dostopnost podatkov, saj je ta navadno omejena. Z različnimi (pred)obdelavami podatkov lahko spremenimo njihove lastnosti. Tako lahko na primer pred analizo odstranimo nepotrebne podrobnosti in ohranimo bistvo (Goodchild, 2011, 5), vendar različni načini združevanja podatkov povzročajo različne rezultate, kar je v angleščini znano kot *modifiable areal unit problem*. Da »lahko z odločitvijo o tem, za katere prostorske enote zberemo podatke, pomembno ali celo odločilno vplivamo na rezultate analize«, je opozoril že Krevs (1998, 186), ki še dodaja, da »so nekateri pojavi po izbranih prostorskih enotah predstavljeni ustrežneje kot drugi« (Krevs, 1998, 188). Sklepanje o značilnostih posameznikov na podlagi agregatnih podatkov imenujemo ekološka napaka (Krevs, 1998, 188).

2.2.5 Raven klasifikacije

Pokrajinskoekološko delitev je mogoče izpeljati na različnih ravneh – od globalnega do topološkega (Leser, 1976, 231). Pri klasifikaciji je zaradi različnega prostorskega obsega preučevanih enot pomembna odločitev, na kakšni prostorski ravni se bomo lotili raziskave. Seveda so cilji in namen tisti, ki v glavnem določajo, katera prostorska raven je primerna (Bailey, 1996, 158). Pri klasificiranju so lahko namreč določene stopnje homogenosti na različnih prostorskih ravneh. Hierarhija je lahko taka, da se meje (ekosistemov) različnih ravni ujemajo (*nested*), vsaka nižja raven pa je bolj podrobna (Klijn, 1994, 92) oziroma vsaka višja raven (prikazana v manjšem merilu) je bolj splošna in abstraktna (Kramer, 1973 cv: Leser, 1976, 301), s čimer se strinja tudi Bailey (1996, 9), ki trdi, da se meje različnih nivojev med seboj ujemajo.

Pri klasifikaciji pokrajine na enote moramo zato ugotoviti, kateri dejavniki so na določeni ravni najbolj ustrezni oziroma kateri so tisti, s katerimi lahko najbolj razlikujemo enote. Kar nekaj avtorjev je že poskusilo smiselno urediti različne dejavnike v nekakšen sistem ali model, vendar razdelitev po ravneh ostaja arbitrarna (Udo de Haes, Klijn, 1994). Težavo predstavlja tudi to, da snovni, energijski in drugi pretoki med posameznimi območji spreminjajo meje (McMahon, Wiken, Gauthier, 2004, 113). McMahon, Wiken, Gauthier (2004) zato predlagajo, da se pri določanju ekoloških območij upošteva stabilnost v ekosistemu, ki ga gradi. To lahko razumemo tudi kot dejstvo, da se moramo opreti na bolj stabilne dejavnike v okolju. Kot dejavniki (geokomponente ali delni kompleksi) se raziskujejo predvsem: podnebje, prst, vodovje, relief, geološka osnova ter živi svet (Plut, 1980, 135). Upoštevanje ravni je razvidno tudi pri trditvi, da pokrajinskoekološke klasifikacije ne moremo izvesti vedno po istem dominantnem elementu (Špes s sod., 2002). Pri različnih raziskavah sta

se največkrat kot glavna pokrajnotvorna dejavnika izkazala relief in litološka sestava, poleg tega pa je pri pokrajinskoekološki delitvi bolj v ospredju tudi rastje kot viden pokrajinski element in pokazatelj ekoloških razmer (Gams, 1986a).

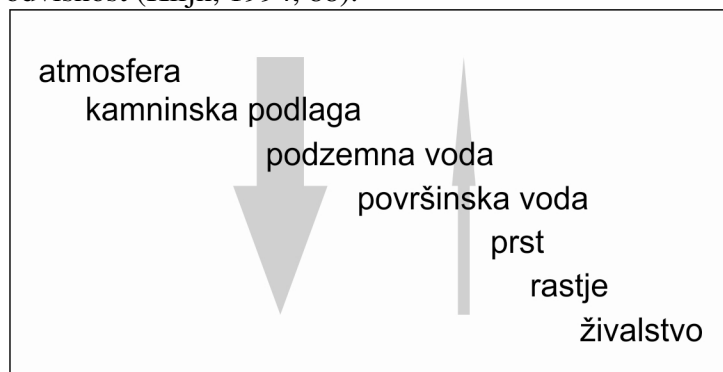
Tudi različne prostorske enote (regije, tipi) imajo lahko zato več ravni oziroma so klasifikacije urejene po ravneh. Tako naj bi za regije hierarhija enot pri klasifikaciji na regije potekala od primarne makroregije prek mezoregije do mikroregije, vmes pa bi lahko bile sekundarne submakroregije, submezoregije in submikroregije. Na primer pri pokrajinsko ekoloških klasifikacijah bi kot najnižjo stopnjo določili ekotop (Ilešič, 1958; Natek, 1994 cv: Kladnik, 1996).

Kot omenjeno, avtorji dejavnike povezujejo z ravnimi preučevanja in njim ustreznim enotam. Godron (1994) je kot prvo ekološko delitev na Zemlji označil delitev na kopno in morje, glavni dejavniki, ki se uporabljajo za razdeljevanje na območju kopnega, pa so podnebje, relief in kamninska podlaga. Na nivoju celin se ekološki vzorec najbolj povezuje s podnebjem (Godron 1994, 71). Odgovarjajoče enote so ekološke cone. Znotraj vsake podnebje določa rastje, oba skupaj pa določata prst. Na regionalnem nivoju (ekološke regije oziroma območja) sta relief (višina) in oddaljenost od oceana dodatna vzroka za razlikovanje pokrajine, saj vplivata na podnebje. Razlike so opazne na daljše razdalje. Na nižjih nivojih (ekološki sektorji, distrikti in pokrajine; ang. *sectors, districts, landscapes*) imajo pomembno vlogo geomorfološke značilnosti in prsti. Ekološka postaja (*station*) oziroma ožje območje (*site*) je območje, kjer preplet kamninske podlage, prsti in podzemne vode določa količino vode za rast rastlin (Godron, 1994, 72–80). Podnebni dejavniki so torej odločilni za raznolikost na kontinentalni ravni, znotraj posameznega podnebnega pasu oziroma območja pa geofizični dejavniki prevladujejo nad podnebnimi pri razlagi vzorcev (Anderson, Ferree, 2010). Godron (1994) v hierarhijo ekoloških klasifikacij torej uvršča (od največje proti najmanjši): ekološke cone, ekološke regije oziroma območja, ekološke distrikte, ekološke sektorje, ekološke pokrajine in manjša ekološka območja (*sites, stations*) ter ustrezajoče dejavnike, ki so na posamezni ravni najbolj pomembni.

Klijn (1994, 88, 89) je predstavil hierarhični model relativne odvisnosti med glavnimi dejavniki, med katerimi je najbolj vplivna atmosfera³, sledijo pa kamninska podlaga, podtalnica, površinska voda, prst, rastje in živalstvo. Tako razporeditev je določil tudi zaradi tega, ker abiotski dejavniki skoraj v celoti določajo razporeditev ekosistemov na globalni ravni. Dejavniki nižje v hierarhiji so bolj odvisni od višjih kot pa obratno (slika 3).

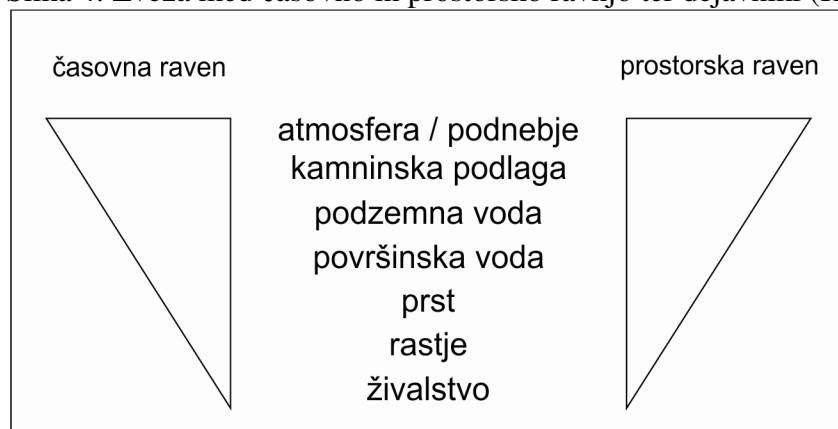
Poleg tega da dejavniki tvorijo vzorce na različnih prostorskih ravneh, lahko tudi glede na časovno skalo ločimo različne ravni spreminjanja (slika 4, Klijn, 1994, 90).

Slika 3: Teoretična razporeditev pomena dejavnikov po posameznih ravneh ter medsebojna odvisnost (Klijn, 1994, 88).



³ Iz besedila avtorja ni jasno, ali je pod atmosfero vključena tudi nadmorska višina.

Slika 4: Zveza med časovno in prostorsko ravno ter dejavniki (Klijn, 1994, 91).



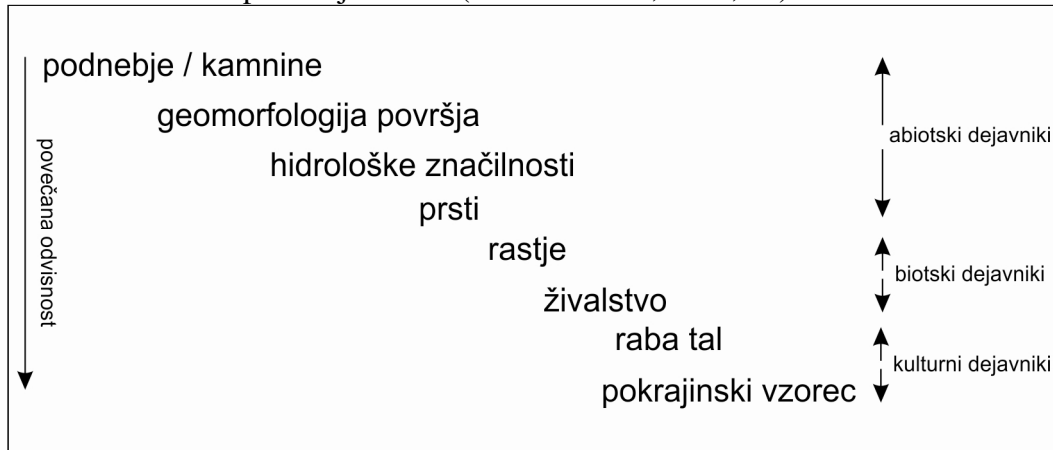
Klijn (1994) je predstavil naslednjo hierarhijo enot v ekološkem razčlenjevanju: ekocona, ekopokrajina (ekoprovinca), ekoregija oziroma območje, ekodistrikt, ekosekcija, ekoserija, ekotop in ekoelement. Enotam je določil tudi orientacijsko velikost in merilo. Poleg je ponudil tudi natančen nabor dejavnikov, ki najbolj vplivajo na posamezni nivo (preglednica 1).

Preglednica 1: Hierarhija prostorskih enot in ustrezni dejavniki po Klijnu (1994).

merilo	velikost prostorskih enot	imena prostorskih enot	bolj pomembni dejavniki
1 : >50.000.000	>62.500 km ²	ekocona	klima, kamnine
1 : 10.000.000–50.000.000	2.500–62.500 km ²	ekopokrajina (provinca)	klima, kamnine, relief
1 : 2.000.000–10.000.000	100–2.500 km ²	ekoregija (ekološko območje)	kamnine, relief, podzemna voda, površina voda
1 : 500.000–2.000.000	6,25–100 km ²	ekodistrikt	kamnine, relief, podzemna voda, površinska voda
1 : 100.000–500.000	25–625 ha	ekosekcija (odsek)	relief, podzemna voda, površinska voda, prst
1 : 25.000–100.000	1,5–25 ha	ekoserija	podzemna voda, površinska voda, prst
1 : 5.000–25.000	0,25–1,5 ha	ekotop	podzemna voda, površinska voda, prst, rastje
1 : <5.000	<0,25 ha	ekoelement	površinska voda, prst, vegetacija, favna

Mücher in sodelavci (2003) predlagajo hierarhijo, ki je praktično enaka Klijnovi (1994), dodali so še družbenogeografske dejavnike (slika 5). Hkrati opozarjajo, da imajo pri klasifikaciji abiotiki dejavniki pravi pomen le, če se uporabijo ekološko pomembna razlikovanja, torej če se na primer pragovi za podnebne značilnosti določajo na podlagi ekologije (Mücher s sod., 2003, 16 in 17).

Slika 5: Ravni in vplivi dejavnikov (Mücher s sod., 2003, 17).



Bohn je s sodelavci (2004) kot najbolj stabilne dejavnike navedel orografijo (nadmorska višina) in kamninsko podlago, kot manj stabilno pa rastje, zato se slednje pri razdelitvi lahko uporablja le kot potencialni dejavnik.

Bailey je opisal pomen dejavnikov na treh ravneh. Na najvišji ravni (makroraven) na podnebje vplivajo geografska širina, razporeditev kopnih in vodnih površin ter izoblikovanost površja (Bailey, 1996, 51). Vendar moramo paziti, saj rastje v gorovju na nižji geografski širini ni enako rastju ob morju na višji geografski širini. Razlike so zaradi dolžine dneva, deklinacije sonca, dolžine sezone, padavinskega vzorca (Bailey, 1996). Na mezoravni reliefne oblike razkosajo širše vzorce, vplivajo na količino vode in izpostavljenost sončni energiji (Bailey, 1996, 105), spreminjajo klimatske pogoje in vplivajo na rabo tal. Geološki procesi (vulkanizem, tektonika in drugo) pa igrajo posebno vlogo pri oblikovanju reliefa. Podnebje vpliva na reliefne oblike tako kot na prsti in vegetacijo s temperaturo in vlago (Bailey, 1996 119). Na najnižji ravni (mikroraven) sta najpomembnejša dejavnika topoklima (posebno ekspozicija) in prst, še posebej količina vlage (Bailey, 1986). Vpliv kamnine je tudi prisoten, saj prek različne dovzetnosti za erozijo in preperevanje povzroča razlike v višini prsti in količini vlage (Bailey, 1986, 125).

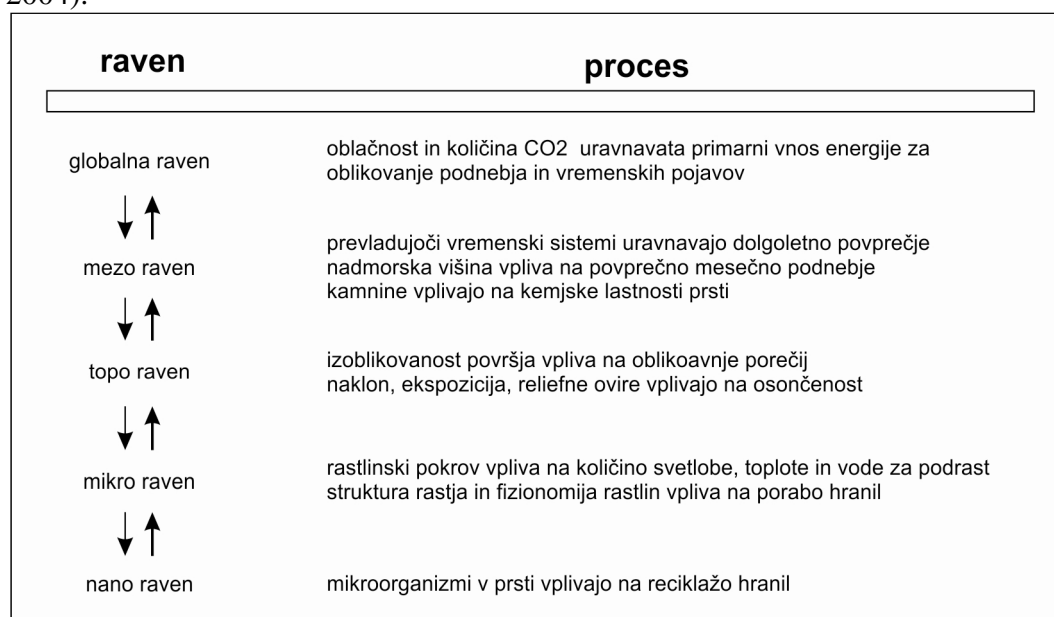
Bailey (1996) loči tri glavne ravni: makrosistem, mezosistem in mikrosistem. Za vsako je določil približna merilo in velikost ter kriterije, ki so najbolj primerni za njihovo razmejevanje (preglednica 2). Pri tem je omenil, da so vodni in obrežni sistemi tesno povezani s površinskimi, zato ne potrebujejo ločene klasifikacije (Bailey, 1996, 157 in 158).

Preglednica 2: Hierarhija prostorskih enot in ustrezni dejavniki po Baileyu (1996).

prostorska enota	velikost	merilo	bolj pomembni dejavniki
ekoregija oziroma območje (<i>ecoregion</i>)	10^5 km^2	1 : 3.000.000	ekoklimatske cone; klima z variacijami zaradi geografske širine, celinskosti, nadmorske višine
pokrajinski mozaik (<i>landscape mosaic, landscape</i>)	10^3 km^2	1 : 250.000–1 : 1.000.000	reliefne oblike
območje (<i>site</i>)	10 km^2	1 : 10.000–1 : 80.000	topoklima in vlažnost prsti

Mackey (1996 cv: Burrough, 2001, 524) je elemente hierarhične teorije povezal z ekološkimi pojavi. Prikazal je pet ravni za modeliranje okolja (slika 6); za vsako so navedeni primeri prevladujočih procesov in dejavnikov na primeru gozdnega okolja v vlažni erozijski pokrajini. Osnovni okoljski procesi določajo razporeditev svetlobe, toplote, vode in mineralnih hranil za fotosintezo rastlin, procesi na višjih ravneh pa določajo omejitve za tiste na nižjih ravneh. Nekaj vpliva je tudi po hierarhiji navzgor.

Slika 6: Hierarhija prevladujočih biofizikalnih procesov po Mackeyu (cv: Burrough s sod., 2004).



Pri pokrajinskoekološki členitvi Slovenije na pokrajinske sklope oziroma območja, pokrajinske enote in pokrajinske podenote je Špesova s sodelavci (2002) na najvišji ravni razvrstila naslednje dejavnike: relief (z nadmorsko višino), litološka zgradba (delež karbonatnih kamnin), podnebje (povprečne letne temperature in padavine). Na nižjih ravneh so velik pomen dali reliefu, hkrati pa so upoštevali tudi dejavnike, ki so bili na posameznem območju najbolj ustrezni (na primer litološka sestava v jugozahodni Sloveniji). Perko (1998a) je kot najpomembnejše dejavnike za regionalizacijo za območje celotne Slovenije navedel nadmorsko višino, naklone, vrsto kamnin, podnebje, rastje in rabo tal. Za nižje ravni ni podrobnega opisa. Plut (1981) je kot pomembne za pokrajinskoekološko členitev Bele krajine višjega reda (večje enote) navedel stabilne geofaktorje (relief in geologijo), za manjše enote pa kraški značaj pokrajine in višinsko slojevitost.

Groom (2005) je navedel dejavnike, ki so jih uporabili evropski raziskovalci pri izdelavi klasifikacij za posamezne države. Najpogosteje uporabljena sta bila relief in kamninska podlaga, podnebje pa nekoliko manj od pričakovanj (preglednica 3). Razlog je morda ta, da gre večinoma za državne klasifikacije, pri katerih razlike v podnebnih pasovih ne pridejo do izraza, ali pa v tem, da so podnebni podatki dostopni le točkovno (merilne postaje).

Preglednica 3: Uporaba naravnih dejavnikov pri klasifikacijah (Groom, 2005, 39 in 40).

dejavnik	število primerov nedvoumne uporabe	število primerov nejasne uporabe
relief	43	4
kamninska podlaga	33	3
prst	33	2
rastje	25	5
vodovje	18	3
podnebje	17	2
pokrovnost tal	10	3

McMahon, Wiken in Gauthier (2004, 116) menijo, da absolutna velikost pokrajine ne obstaja. Ob tem dodajamo še pomislek, da so lahko klasifikacije prostorsko in/ali kategorično hierarhične, lahko pa tudi ne (Loveland, Merchant 2004, 4). Torej za ekološke klasifikacije (*ecological regionalization*) ni enovitega in pravilnega merila (McMahon, Wiken, Gauthier 2004).

2.2.6 Poimenovanje prostorskih enot

Možnosti poimenovanja raznih prostorskih enot je veliko. V knjigi *Landscape Character Assessment* (Swanwick, 2002) sta predstavljena način določanja pokrajinskih tipov (*landscape character types*) in regij (*landscape character areas*), hkrati pa tudi priporočila za njihovo poimenovanje. Za tipe je značilno, da ime sestavljajo dve ali tri besede, ki opisujejo njihove lastnosti, na primer apneniško višavje. Za manjše območje se lahko vključi tudi lastnost rabe tal, na primer gozdnato pobočje. Za regije je pomembno, da so imena geografsko specifična, vseeno pa se lahko v njih odraža pokrajinski tip. Pomembno je tudi, da se uporabijo krajevna lastna imena, ki so v uporabi (Swanwick, 2002). Zhou (2003, 456) se je za poimenovanja prostorskih enot oprl na pokrovnost in rabo tal ter naravnogeografske značilnosti. Nekatera poimenovanja enot so zelo formalna. Múcher je s sodelavci (2003) tipe pokrajin na nižjih ravneh na primer poimenoval s kombinacijo številskih in črkovnih oznak, pri katerih je vsaka oznaka pomenila določeno pokrajinsko lastnost.

Poleg imen posameznih tipov in regij (na primer *prodna ravnina* in *Brkini*) je različno poimenovanje tudi za vrste prostorske enote (na primer naravni pokrajinski tip, regija, cona, provinca). Klijn (1994, 93) pravi, da avtorji uporabljajo različna poimenovanja in klasifikacijske značilnosti za različne prostorske ravni. Pri tem gre lahko za niz klasifikacij z različnimi prostorskimi ravnmi in ne za primere, kjer bi bila klasifikacija enotna na vseh ravneh. Predstavitev različnih enot ekosistema so opisali tudi McMahan, Wiken, Gauthier (2004, 115), primerjavo poimenovanj pa Bailey (1996; preglednica 4). Pregled več kot deset različnih naravnih in pokrajinskoekoloških klasifikacij je leta 1967 pripravil Richter (cv: Leser, 1976, 78).

Preglednica 4: Poimenovanja prostorskih enot na različnih ravneh (Bailey, 1996, 24).

Avstralija	Velika Britanija	Kanada	bivša Sovjetska zveza	ZDA
			<i>zone</i>	
	<i>land zone</i>			<i>domain</i>
	<i>land region</i>	<i>ecoregion</i>	<i>province</i>	<i>division</i>
	<i>land district</i>	<i>ecodistrict</i>		<i>province</i>
			<i>landscape</i>	<i>section</i>
<i>land system</i>	<i>land system</i>	<i>ecosection</i>		<i>district</i>
	<i>land type</i>	<i>ecosite</i>	<i>urochisccha</i>	<i>landtype</i>
<i>land unit</i>				<i>association</i>
<i>land type</i>	<i>land phase</i>			<i>landtype</i>
<i>site</i>		<i>ecoelement</i>		<i>landtype phase</i>
			<i>facia</i>	<i>site</i>

2.3 Uporabnost klasifikacij

Izpostaviti je treba smiselnost klasifikacije površja na manjše enote. Po mnenju Gamsa (1984, 76) s tem povzročamo zavestno silo naravi z metodo, ki je plod miselne konstrukcije. Res je, da je vsaka klasifikacija večja ali manjša abstrakcija razlik med pojavi (Natek, Žiberna, 2004, 25), a kljub temu se zdi za človeka normalno, saj gre za iskanje reda (Haggett, 2001). Glede na geografske stalnice in spremenljivke Slovenije (Plut, 1995, 155 in 156; Plut, 1999a, 12) je Haggettovo razmišljanje razumljivo, saj je težko upravljati s prostorom oziroma delovati v njem, če ga ne poznaš in se geografske značilnosti spreminjajo na kratke razdalje. Poleg tega pa pokrajinska raznolikost Slovenije otežuje kakršno koli klasifikacijo, določanje pokrajinskih mej pa je zaradi prehodnosti večine pokrajinskih sestavin zapleteno (Perko, 1998b, 12). Navsezadnje so vsa območja prehodna, saj predstavljajo dele enega samega prostorsko-časovnega kontinuuma (Natek, Žiberna 2004, 31). Kljub temu da pokrajine nikoli niso in ne

bodo statične, je pregled nad pokrajinskimi tipi nujen (Mücher s sod., 2003, 11), saj naj bi bil prostor organiziran na način, ki omogoča varčno rabo naravnih virov in s tem njihovo obnavljanje. Nujna sta torej temeljno poznavanje tako fizičnih procesov kot delovanja družbe (Plut, 1999a). Klasifikacija prostora z upoštevanjem naravnogeografskih značilnosti je temelj za optimalno prostorsko organizacijo. Poleg tega pa so okoljski problemi ustrezneje opredeljeni z naravnimi lastnostmi kot z administrativnimi mejami (Bailey, 1996; Olson s sod., 2001), navsezadnje pa tudi »pokrajinsko-ekološko raziskovanje omogoča pretehtan poseg v pokrajino« (Plut, 1981, 141). Zaradi vseh teh dejstev je nujno, da se to področje geografije stalno razvija in izpopolnjuje, še posebej ob obilici podatkov in računalniških metod, ki jih je na voljo vedno več. Že Gams (1978a, 1) je izpostavil, da je »vedno večja količina razpoložljivih statističnih podatkov, predvsem pa rast geografske znanosti v svetu in doma zahtevajo vedno podrobnejšo delitev na enote in vedno bolj specializirano delitev ozemlja«. Ob vsem navedenem lahko izpostavimo tudi Gamsovo trditev (1978, 1), da je »delitev ozemlja ... ena osnovnih nalog geografije«.

Uporabnost klasifikacije površja na regije ali tipe je v literaturi večkrat navedena (McMahon, Wiken, Gauthier 2004, 112). S klasifikacijo lahko začrtamo meje za splošne namene; določene meje oziroma prostorske enote nato služijo kot začetna točka za bolj specifične namene (Bailey, 1996, 20). Razumevanje razmerij med pokrajino, biodiverzitetu in rabo tal je bistveno za upravljanje z okoljem (pokrajino) in njenimi viri (Jongman, 2006, 410). Pokrajinska klasifikacija, regionalizacija in tipologija so pomembni za ohranjanje pokrajine in načrtovanje (Romportl, 2007; Bernert, 1997, 405). Določitev ekoloških območij (*ecoregions*) ima več namenov: inventarizacijo, vrednotenje, spremljanje stanja (monitoring), upravljanje, načrtovanje, izvajanje meritev, predstavitev dejstev, napovedovanje oziroma študijo scenarijev, določanje vzorčnih območij, vzorčenje, prenos modelov v prostoru, prikaz raznolikosti pokrajine, povezavo med kopenskimi in vodnimi sistemi, analizo pritiskov na okolje in drugo (Loveland, Merchant 2004, 2; Mücher s sod., 2003, 7; Bastian, 2000, 146; Loveland, Merchant, 2004; Bailey, 1996, 146–152; Runhaar s sod., 1994, 160; Bunce s sod., 1996, 41).

Z vidika uporabnosti v znanosti je treba izpostaviti, da različne vede uporabljajo svoje klasifikacije (na primer klasifikacija rastlinstva, prsti, kemijskih elementov) in delo bi olajšale enotne pokrajinske klasifikacije (Brabyn, 2009). Različni kriteriji so vzrok različnim zemljevidom istega območja. Odsotnost skupne prostorske enote naredi multidisciplinarno raziskavo težavno (Bailey, 1996, 38), zato različne vede potrebujejo skupno prostorsko enoto. Z rabo skupne ekosistemske enote bi se zbiranje in analiza podatkov nanašala na območje enakega prostorskega obsega (Bailey, 1996, 143 in 144). To je tudi eden izmed izzivov v interdisciplinarnih raziskavah pri upravljanju naravnih virov (Axelsson, Angelstam, Törnblom, 2010, 135).

Na drugi strani se tudi upravitelji srečujejo s težavo, ker morajo uporabiti informacije z različnih področij (in območij). Da bi ravnali sonaravno, moramo določiti meje v ekosistemu. Potrebujemo sintezo dostopnih informacij in sposobnost uporabiti ta spoznanja pri upravljanju (Bailey, 1996, 19; Khoroshev, Brusilovskaya 2010). Razne prostorske klasifikacije, narejene na podlagi naravnih dejavnikov, so vse pogostejše v uporabi, saj upravitelji iščejo klasifikacijo, ki je boljša od politične in ki bolje odraža naravne razmere (Bernert s sod., 1997, 417). Na primer, NUTS3 regije v Sredozemlju pogosto vključujejo podeželska območja in mestna območja ob obali (Hazeu s sod., 2005), ki so si različna po naravno- in družbenogeografskih lastnostih. Pristop povezovanja naravnogeografskih in družbenogeografskih (upravnih) podatkov je uporabil Plut (1999a), ko je zasnoval predlog upravne razdelitve Slovenije. Pomembno je povezati ekosistemsko in upravljalsko hierarhijo (Bailey, 1996). Pri tem pa moramo biti pozorni na dejstvo, da različni okoljski problemi nastopajo na različnih ravneh, zato ne moremo na eni ravni prikazati vseh (Klijn, 1994, 86). Udejanjanje načela trajnostnosti

na gospodarskem, družbenem in okoljskem področju pomeni trajno prilagajanje organizacije in delovanja družbe okolju (Plut, 2005, 59) in pokrajinskoekološki tipi so zaradi preučevanja ranljivosti pomembni zaradi bolj ali manj homogenega odzivanja na antropogene vplive (Špes, 2002, 33). V geografiji sonaravni razvoj oziroma napredek pomeni usmeritev prostorskega, gospodarskega in regionalnega razvoja v okviru zmogljivosti (omejitev) geografskega okolja, pokrajine (Plut, 2005, 99), lahko bi dejali tudi pokrajinskega tipa. Zaradi omenjenega je členjenje površja zelo pomembno v geografiji in prinaša pomembna uporabna spoznanja. »Členitev prostora ... z upoštevanjem naravnogeografskih značilnosti (naravne regije, bioregije oziroma ekoregije, ekodistrikti, porečja, okoljski prostor) je ena izmed osnov za okolju primerno organizacijo življenja in dela na regionalni ravni« (Plut, 1999b, 65). Kot primer uporabe klasifikacije lahko navedemo klasifikacijo Nizozemske, ki je bila uporabljena pri ocenjevanju dviga podtalnice za ugotavljanje erozije na obali ter za ugotavljanje vplivov ravnjanja s površinsko vodo in podtalnico na naravno vegetacijo. Pri tem je bilo merilo različno (od 1 : 5.000 do 1 : 500.000) (Runhaar s sod., 1994, 158). Renentzeder je s sodelavci (2010) za pokrajinske enote na različnih ravneh ugotavljal ekološko trajnostnost. Kljin (1994) je predstavil model uporabe klasifikacije pri varstvu okolja. McMahon, Wiken, Gauthier (2004, 112) so navedli primere uporabe členitev v ZDA in Kanadi. Olson in sodelavci (2001, 935) so kot uporabnost biogeografskih klasifikacij navedli razvrščanje po stopnji ogroženosti biodiverzitete, stanju naravnih habitatov in vrst ter stopnji zaščitenosti.

Pri klasificiranju pokrajine je pomembno, kako splošno naj bo zasnovana klasifikacija. Sakal (1974 cv: Bailey, 1996, 21) trdi, da je klasifikacija, ki temelji na več značilnostih, splošna in zato ne more biti uporabljena v specifične namene, je pa lahko vseeno uporabna na različnih področjih. To Bailey pojmuje kot naravna klasifikacija (Bailey, 1996, 21). Schmithüsen (1972) razlikuje med osnovnimi zemljevidi in ovrednotenimi zemljevidi. Prvi naj bi bili narejeni tako, da se lahko iz njih za določen namen izpeljejo tudi drugi. Za večnamensko rabo je pomembna tudi prilagodljivost, ki je podprta s podatkovno bazo, različnimi klasifikacijskimi in ocenjevalnimi postopki (Mücher s sod., 2003, 18). Ilešič sicer meni, da je »iluzorno stremeti za kakršno koli vsestransko, 'splošno' geografsko rajonizacijo« (Ilešič, 1957/1958). Prav tako Loveland in Merchant (2004) menita, da bi morala imeti klasifikacija namen, kar podpira tudi Neef (1972). Ocena tega, katera klasifikacija je dobra, pa je odvisna od namena (Thompson s sod., 2005, 146).

2.3.1 Klasifikacije v uradnih dokumentih

Strategije, ki temeljijo na naravnih območjih, dobivajo vse večjo pozornost, saj lahko klasifikacije dejansko pripomorejo k varstvu okolja (Olson s sod., 2001, 937). Evropska politika je leta 1996 oblikovala Panevropsko strategijo biotske in pokrajinske raznovrstnosti (*Pan-European Biological and Landscape Diversity Strategy*) (Pan-European ..., 2011), leta 2000 pa sprejela Konvencijo o krajini (*The European Landscape Convention* 2011). Evropska konvencija o krajini spodbuja države članice, da prepoznajo in opišejo pokrajine na svojem območju (Van Eetvelde, 2009, 160). To je tudi eden izmed razlogov za razmah raznih metod klasifikacije pokrajin.

Poleg tega se pojavljajo ideje po vzpostavitvi regij, ki temeljijo na naravnogeografskih značilnostih; ena takih je na primer ideja o evropski makroregiji Alpe (Bärzing, 2011). Na strokovnem in znanstvenem področju se oblikujejo združenja, kot so Landscape Europe (Landscape Europe, 2011), European Landscape Network (European Landscape ..., 2011) in OpenLandscapes (OpenLandscapes, 2011).

Nazoren primer uporabe klasifikacije Slovenije je uporaba makroregij Slovenije (Perko, 1998a) pri določanju meril za bonitiranje zemljišč, kjer so bile makroregije uporabljene za določanje lastnosti podnebja (Pravilnik o določanju ..., 2008). Berk s sodelavci (2012) je

preučeval nov način ocenjevanja proizvodnih sposobnosti zemljišč, v katerem so uporabili tudi delitev Slovenije na devet tipov (Perko, 1998a; Perko, 1998b; Perko, 2007b). Omeniti velja tudi primer z Norveške, kjer podjetje Asplan Viak AS na pobudo sveta Okrožja Nordland izdeluje zemljevid pokrajinskih tipov za okrožje Nordland ter pripravlja metodologijo določanja pokrajinskih tipov, ki se bo uporabila za celotno Norveško (Uttakleiv, 2012).

2.4 Obstoječi problemi

Nobena klasifikacija ni popolna, njen rezultat pa je vedno subjektiven, saj se ne moremo izogniti subjektivnim odločitvam pri izboru dejavnikov, njihovemu ponderiranju, določanju mejnih vrednosti, meril, digitalizaciji, interpolaciji (Natek, Žiberna, 2004, 25; McMahan, Wiken, Gauthier, 2004; Ellison, 2010). Kljub temu da so ponekod v naravi vidne nenadne spremembe (na primer stik gorovij in ravnin; Bailey, 1996, 34 in 35), je večina klasifikacij arbitrarnih (Leathwick, Overton, McLeod, 2003). Objektivnost je manjša tudi zaradi pomanjkanja opisa postopka za določanje meja in klasifikacijo enot (Loveland, Merchant, 2004, 8). Poleg tega prepoznavanje območij včasih ne temelji le na podlagi biofizikalnih dejavnikov, temveč tudi na podlagi raznih spominov, pričakovanj in stereotipov o pokrajini (McMahon, Wiken, Gauthier, 2004, 114). Zato je proces klasifikacije pokrajine težaven, hkrati pa ostaja še veliko nerešenih vprašanj.

Pri naravnogeografskih klasifikacijah Slovenije so bili največkrat izpostavljeni naslednji problemi (Ilešič, 1957/58; Kladnik, 1996; Gams, 1984; Gams, 1986a; Gams, 2000; Plut, 1981; Plut, 1999a; Klemenčič, 2004):

- spremenjenost pokrajine oziroma odsotnost naravnih regij,
- subjektivnost,
- izbor dejavnikov oziroma kriterijev,
- premajhna preglednost,
- premalo sistematično razvrščanje oziroma nesistematičnost, ki izhaja iz nejasnih meril delitve in hierarhije,
- različen potek meja,
- preveliko število izdvojenih enot,
- uporaba prehodnih regij,
- imena regij (to velja predvsem pri regionalizacijah),
- nedoslednost uporabe nekaterih terminov (na primer sredogorje, visokogorje),
- vprašljiva uporabnost na podlagi reliefa zasnovanih naravnogeografskih členitev za trajnostno sonaravni razvoj,
- (ne)dostopnost podatkov.

Eden izmed večjih problemov je spremenjenost pokrajine zaradi človekovega delovanja. Tu se zastavlja vprašanje, ali je možna klasifikacija z vidika naravnih dejavnikov kljub pozidanim površinam in vse manjšemu prilagajanju človeških dejavnosti naravnim razmeram. Pojem čiste naravne regije je močno nerealen (Ilešič, 1957/58). Naravne regije si lahko le predstavljamo, kakšne so bile pred preoblikovanjem (Kladnik, 1996). Sicer pa si lahko predstavljamo naravno pokrajino kot manj spreminjajoči del pokrajinske enote.

»Naravnogeografske enote, vsaj za eno ali več generacij, predstavljajo skoraj stalnico, medtem ko se družbene razmere hitro spreminjajo« (Černe, Klemenčič, Plut, 1981, 130). V literaturi je že bilo izpostavljeno (Perko, 1998b), da je naravnogeografska regionalizacija narejena iz naravnih sestavin pokrajine in pa tistih družbenih sestavin, ki so z naravnimi močno povezane. Pri kmetijski ali urbano-industrijski pokrajinski rabi je izvedba (na primer pokrajinsko ekološke) klasifikacije težja, saj je treba upoštevati tudi antropogene sestavine pokrajine in ugotavljati skladnost z naravnimi razmerami (Špes s sod., 2002). Pri tem je treba paziti, da so nekatere rabe tal tudi na manj primernih zemljiščih, kot bi pričakovali. Na primer

njive na kraških poljih so slabše kot na prodnih ravninah – tam so pač zato, ker prebivalci nimajo druge možnosti (Gams, 1986a, 151). Tudi številna naselja so na raznih naravnih mejah, a se to z zmanjšanjem pomena kmetijstva čedalje bolj izgublja (Kladnik, 1996), saj se ob pozidavi novih objektov naravne dejavnike upošteva manj kot nekoč. Pri nekaterih klasifikacijah naravne pokrajine (na primer Mücher s sod., 2009) so zato mestna območja preprosto izločili kot poseben tip.

Zaradi čedalje večjega človekovega vpliva naj bi antropogene dejavnike vključili znotraj posamezne pokrajinske ravni. Kako interpretirati in razvrstiti (antropogene) podatke, pa še ni dobro opredeljeno (Mücher s sod., 2009). Loveland in Merchant (2004, 9) zato priporočata izdelavo dveh klasifikacij – dejanskih in potencialnih ekoloških območij.

Posebna pozornost je večkrat posvečena rastju, ki je pokazatelj naravnih razmer, a ne tam, kjer je prvotno rastje odstranjeno. Ekologija tako izgubi pomembno osnovo za delitev. V taki situaciji ostane sintetična metoda ugotavljanja ekotopov in regij. Pri slednji (Gams, 1986a, 150) analiziramo ozemlje, ločeno po dejavniki, ki so pomembni za živi svet. Kombinacija teh elementov nakazuje sorodne ekotipe, ki se odražajo v potencialnih gozdnih združbah. Zaradi sekundarnega rastja se lahko uporabi tudi karto prsti, ki je bolj stabilna. Pri tem pa je treba paziti na prisotnost fosilnih prsti (Bailey, 1996, 8).

Klijnovo (1994) trditev, da je za klasifikacijo treba uporabiti značilnosti, ki so vzrok za vzorec, in ne značilnosti, ki vzorec kažejo (Klijn, 1994, 95), daje upanje, da lahko pri klasifikaciji pokrajine kljub njeni spremenjenosti uporabimo tiste glavne (usmerjevalne) dejavnike, ki vplivajo na večino ostalih. Relief, kamninska podlaga in podnebje so bolj stalni dejavniki in vplivajo na tiste bolj spremenljive (na primer na rastje in rabo tal), ki sicer kažejo dejansko podobo pokrajine. Torej mora sistem temeljiti na vzrokih, saj lahko ekosistem v pokrajini razumemo le tako, da poznamo njegov izvor (Bailey, 1996, 21; Runhaar s sod., 1994, 165). Poleg navednih težav se omenja tudi spremenljivost samega naravnega okolja, na primer zaradi spreminjanja podnebja (Loveland, Merchant, 2004, 10).

Kot temeljno načelo v znanosti velja, da so rezultati ponovljivi, preden se jih sprejme kot resnične. Ker so pojavi v naravi odvisni od okolja in se to spreminja v prostoru in času, je v nekaterih primerih nemogoče doseči dejansko ponovljivost. Kljub temu pa so lahko nekateri sintezni deli raziskav ponovljivi; ko imamo podatke že pripravljene in opravljamo delne analize. Če so sinteze transparentne in se jih lahko ponovno preveri ter so podatki in modeli prosto dostopni, potem bi morali dobiti konsistentne ponovljive rezultate. Sicer se lahko pojavijo razhajanja v interpretaciji rezultatov, a vsaj glede ponovljivosti rezultatov samih ne bo dvoma. Ponovljivost zahteva dokumentiranje uporabljenih podatkov in metod ter navedbo odločitev med raziskovanjem (Ellison, 2010). Večina se strinja, da je klasifikacija subjektivna (Loveland, Merchant 2004, 3; Leathwick, Overton, McLeod 2003; Natek, Žiberna, 2004), hkrati pa so klasifikacije tudi redko ocenjene (Kireyeu, Shkaruba, 2010).

Geografski informacijski sistemi kot rešitev nekaterih problemov klasifikacija prostora

Nekateri vidijo zmanjšanje subjektivnosti v rabi GIS-ov in kvantitativnih metod. Na uporabnost GIS-ov je bilo že večkrat opozorjeno (Thompson s sod., 2005, 146; Loveland, Merchant, 2004; Repe 2010; Hazeu s sod., 2010).

Podatkovni sloji in kvantitativne metode v klasifikaciji pokrajine omogočajo razne novosti, hkrati pa odmaknejo področje klasifikacij stran od subjektivnosti. Klasifikacije so lahko narejene na podlagi izbranih podatkovnih slojev ter prilagojene za specifične namene. Poleg tega je mogoče tudi ugotoviti razlike med dobljenimi prostorskimi enotami (Hargrove, Hoffman, 2005, 39; Leathwick, Overton, McLeod 2003, 1613). S kvantitativnim pristopom se vzorci pojavijo, ko analiziramo razne dejavnike, ne glede na posamezne predsodke o velikosti, pomenu dejavnikov in drugem (McMahon, Wiken, Gauthier, 2004, 119).

Kvantitativne metode lahko definirajo enote, ki so objektivne in ponovljive, a je treba paziti

na uporabljene podatkovne sloje (*input*), izbor klasifikacijskih metod ter na način določanja meja (McMahon, Wiken, Gauthier, 2004, 119). Eastman (2009, 158) je na primer opozoril, da ni jasno, katera metoda je najboljša, ko je opisoval geoinformacijska orodja za podporo odločanju. Zato je kljub prednostim treba rezultat GIS-ov in kvantitativnih metod vseeno preveriti (McMahon, Wiken, Gauthier 2004, 119; Zhou s sod., 2003, 460). Kvantitativne in kvalitativne metode naj bi bile za klasifikacijo v prostoru konceptualno bolj podobne, kot je splošno priznано. Sicer je prednost kvantitativnih metod, da lahko postopek ponovimo, vendar so tudi kvalitativni pristopi ponovljivi, če so odločitve dobro dokumentirane (McMahon, Wiken, Gauthier, 2004, 119, 122). Nenazadnje je subjektivnost prisotna tako v kvantitativnem kot tudi v kvalitativnem pristopu (Loveland, Merchant 2004, 4).

Izzivi za prihodnje raziskave

Izbor nekaterih še nerešenih vprašanj (McMahon, Wiken, Gauthier, 2004, 117 in 118):

- Katere so ključne ekosistemske značilnosti (in podatki) na posamezni ravni? Kateri dejavniki vplivajo na oblikovanje vzorcev na posameznih ravni?
- Ali obstajajo idealna ekološka območja (ki so za vse enaka) ali so to le rezultati posameznih individualnih raziskav?
- Do kolikšne mere je možno zaobjeti prehodnost?
- Se vzorci in procesi ekosistemskih značilnosti območja lahko pojavijo na več ravneh?
- Ali se lahko pravila klasifikacij med ravnmi spreminjajo?
- Ali lahko s kvantitativnimi metodami razmejimo območje na manjše prostorske enote, določimo meje ter vključimo negotovost in predstavimo prehodnost?
- Koliko podatkov potrebujemo za določanje oziroma prepoznavanje vzorcev?

Tovrstna vprašanja so dokaz, da je področje klasifikacij pokrajine še marsikje nedorečeno.

Mücher je s sodelavci (2003, 16) zbral izzive, katerim naj bi morali nameniti več pozornosti:

- namembnost klasifikacij končnemu uporabniku na mednarodni ravni,
- fleksibilnost klasifikacij glede na namen na različnih ravneh,
- zmožnost posodabljanja in izboljšave klasifikacij,
- poenotenje različnih konceptov klasifikacij,
- zmožnost fleksibilnosti interpretacije in generalizacije rezultatov klasifikacij,
- metodološka preglednost oziroma transparentnost procesa klasifikacije,
- odpraviti razlike, ki se pojavljajo med državami na področju klasifikacij,
- podpora znanstvenikov (zagotovitev čim večje uporabnosti klasifikacije),
- zmanjšati subjektivnost procesa klasifikacije in povečati bolj formalen, objektivni in kvantitativni sistem.

Kot pomembna točka na področju klasifikacij na homogene prostorske enote je bilo izpostavljeno tudi izobraževanje (Loveland, Merchant, 2004, 10 in 11). Razni avtorji (na primer Loveland, Merchant, 2004; Bailey, 2005) so v svojih prispevkih predstavili obsežna navodila in priporočila za klasifikacijo pokrajine.

3. Primeri klasifikacij

3.1 Klasifikacije Slovenije na podlagi naravnih dejavnikov

Doslej je bilo izdelanih več regionalizacij Slovenije kot pa tipizacij na osnovi enega ali več naravnih dejavnikov. Glede na veliko število izpeljanih klasifikacij celotne Slovenije (preglednica 5, preglednica 6, opis v prilogi 1) ali le manjših območij (preglednica 7) je razumljivo, da so avtorji uporabili različne pristope, podatke (dejavnike), različno število enot, hierarhičnih ravni in tudi osnovnih načel. Najpogosteje so klasifikacije izdelane na podlagi reliefa (nadmorske višine), kamninske podlage in podnebja.

Preglednica 5: Primeri klasifikacij glede na več naravnih dejavnikov.

avtor, avtorji (leto izdelave)	naslov
Melik (1935)	zgradbene enote na Slovenskem
Melik (1946)	prirodnogeografska sestava Slovenije
Melik (1954, 1957, 1959 in 1960)	regionalnogeografske monografije
Ilešič (1956)	slovenske pokrajine (le opis)
Ilešič (1957/1958)	pokrajinsko-fiziognomične regije Slovenije
Ilešič (1972)	pokrajinsko-ekološka razčlenjenost
Gams (1978a)	kvantitativna prirodnogeografska regionalizacija
Gams (1983)	slovenske regije
Gams (1986a)	pokrajinskoekološke regije v Sloveniji
Gams (1998a)	pokrajinsko ekološka sestava Slovenije
Natek (1994, cv: Kladnik, 1996)	izpopolnjena členitev po Gamsu
Gams, Kladnik, Orožen Adamič (1995)	naravnogeografske regije Slovenije
Gabrovec, Orožen Adamič, Pavšek, Perko, Topole, Kladnik, 1996 (Perko, 1998a; Perko 1998b; Perko 2007b)	naravnogeografska regionalizacija in tipizacija
Marušič, Ogrin, Jančič (1998)	krajinska regionalizacija s tipološko členitvijo krajinskih vzorcev
Plut (1999a)	regionalizacija Slovenije po sonaravnih kriterijih
Špes s sodelavci (2002)	členitev na pokrajinskoekološke enote
Špes s sodelavci (2002)	členitev na pokrajinskoekološke tipe
Žiberna, Natek, Ogrin (2004)	naravnogeografska regionalizacija Slovenije za pouk geografije
Hladnik (2005)	pokrajinski tipi v Sloveniji (<i>landscape types in Slovenia</i>)

Preglednica 6: Primeri klasifikacij glede na en naravni dejavnik.

avtor, avtorji (leto izdelave)	vrsta klasifikacije
Melik (1935)	geomorfološka karta
Natek (1993)	tipi površja
Ogrin (1996)	podnebni tipi
Gabrovec in Hrvatina (1998)	površje
Perko (2001)	enote razgibanosti površja
Gams (2003)	regionalizacija krasa v Sloveniji
Zupančič in Puncer, 1989 (cv: Zupančič, 1989, 120)	fitogeografske razdelitve različnih avtorjev
Matvejev (1991)	biomi
Sket (2003)	biogeografska členitev Slovenije po ozemeljsko vezanih vrstah; biogeografska členitev Slovenije po ozemeljsko nevezanih vrstah; povodja
Ogrin (2009)	življenjska okolja

Preglednica 7: Primeri klasifikacij manjših območij znotraj Slovenije.

avtor, avtorji (leto izdelave)	ime klasifikacije
Plut (1977)	Korsko Primorje – regionalizacija katastrskih občin s faktorsko analizo glede na prirodno-geografske dejavnike
Gams (1978b)	pokrajinsko-ekološke enote soseske Soča
Gams, Lovrenčak in Plut (1978)	pokrajinsko-ekološke enote k. o. Kamno
Gams, Lovrenčak in Plut (1978)	pokrajinsko-ekološke enote k. o. Breginja

Gams (1979)	pokrajinsko-ekološke enote mariborske regije
Plut (1981)	pokrajinska ekologija Bele krajine (pokrajinsko - ekološki mozaiki, mikro-, mezo- in makrohore v Beli krajini)
Gams (1981)	pokrajinsko-ekološka sestava Gorenjske
Černe, Klemenčič, Plut (1981)	pokrajinsko-ekološke enote (občina Tržič)
Perko (1989)	vzhodna Krška kotlina
Perko (1990)	tipi pokrajin v porečju Kokre
Gabrovec (1990)	pomen reliefa za geografsko podobo Polhograjskega hribovja
Topole (1992)	tipi pokrajin v porečju Mirne
Hrvatini, Perko (2000)	regionalizacija in tipizacija Mestne občine Ljubljana
Ferreira (2006)	pokrajinskoekološka členitev Zgornje Gorenjske
Breskvar Žaucer, Marušič (2006)	kraške krajine notranje Slovenije

3.2 Slovenija v naravnogeografskih klasifikacijah Evrope

V geografski literaturi se pogosto poudarjata pokrajinska raznolikost Slovenije in njena lega na stiku Alp, Sredozemlja, Panonske kotline in Dinarskega gorovja, zato v tem poglavju opisujemo, kako se raznolikost Slovenije kaže tudi pri naravnogeografskih klasifikacijah na ravni Evrope. Na raznolikost so opozorili številni slovenski avtorji. Melik (1935) je izpostavil, da se na ozemlju Slovenije stikajo Alpe z dinarskim gorskim sistemom, slovensko ozemlje pa sega še do Jadranskega morja, Furlanske nižine in Panonske kotline. Slovenijo je poimenoval »zemlja stikov« (Melik, 1935, 1–3). Stik štirih evropskih naravnogeografskih regij (Alpe, Dinarsko gorstvo, Sredozemlje, Panonska kotlina) sta opisala tudi Ilešič (1956) ter Gams (1998b). Pokrajinska raznolikost Slovenije je dobro zaobjeta z dejstvom, da se »v krogu s polmerom 150 km, kjer leži Slovenija, stikajo in prepletajo visokogorske Alpe s predalpskimi hribovji in kotlinami, ravninska Panonska nižina z gričevnatim obrobjem, zakraseli svet Dinarskega gorstva s kraškimi planotami in vmesnimi podolji ter sredozemski svet z blažilnimi vplivi Jadranskega morja ...« (Kladnik, Perko 1998, 20). Če k temu dodamo še stik štirih kulturnih prostorov – slovanskega, germanskega, romanskega in madžarskega – vidimo, da so se na majhnem območju izoblikovali tudi številni tipi kulturnih pokrajin (Kladnik, Perko, 1998). Plut (1999a, 12) je navedel stik štirih evropskih naravnogeografskih makroregij (Alpe, Panonska nižina, Dinarsko gorovje, Sredozemlje) in oblikovanje petih pokrajinskih tipov kot geografsko stalnico, ki jo je treba upoštevati pri načrtovanju sonaravnega razvoja. Da lahko pri pregledu evropskih klasifikacij pričakujemo zanimiv rezultat za območje Slovenije, je mogoče sklepati iz Ilešičeve (1956, 25) trditve: »Celo v Evropi, ki je sama dokaj raznolična, ni zlepa dežele, kjer bi mogli na tako kratko razdaljo doživeti podobne razlike v geografskem licu pokrajine.«

3.2.1 Pregled klasifikacij evropskega ozemlja

Pregled klasifikacij evropskega ozemlja smo povzeli po Cigliču (2009) ter Cigliču in Perku (2012), hkrati pa smo njuna spoznanja še nekoliko nadgradili. Pregledali smo različne klasifikacije Evrope (preglednica 8; priloga 2) in bili pozorni na to, kam se uvršča Slovenija. Predvidevali smo, da se mora raznolikost slovenskega ozemlja pokazati tudi na ravni celotne Evrope. Osredotočili smo se predvsem na naravnogeografske klasifikacije za območje celotne Evrope, pregledali pa smo tudi nekatere, ki upoštevajo družbenogeografske dejavnike, ki so bolj povezane z naravnogeografskimi prvinami (kot je na primer raba tal). V Evropi je po Meeusu (1995, 57 in 58) namreč kot prave naravne pokrajine mogoče označiti le 10–30 % ozemlja. Preverili smo, v koliko makroenot (tipov ali regij) in v katere se uvršča ozemlje Slovenije. S tem smo hoteli ugotoviti, ali je tudi pri klasifikacijah manjšega merila opazna raznolikost Slovenije. Poleg tega lahko na ta način dodatno argumentiramo, koliko tipov se v Sloveniji pojavlja na najvišji ravni.

Pri vsaki klasifikaciji smo ugotovili njen prostorski obseg, število ravni in kategorij (različnih regij ali tipov) na celotnem območju klasifikacije in na ozemlju Slovenije, prostorsko

ločljivost podatkov, namen, glavne metodološke postopke, vsaki klasifikaciji pa smo pripisali še slovenski prevod (priloga 2). Ohranili smo izvirna poimenovanja kategorij na posameznih ravneh (na primer *region* 'regija', kar je sicer lahko mišljeno tudi kot 'območje'), pri tem pa poskušali ovrednotiti, za kakšno vrsto geografske klasifikacije gre (tipizacijo ali regionalizacijo). Imena posameznih enot (na primer alpska pokrajina, dinarska regija) smo prevedli, saj gre za nam domača imena, za imena, ki izvirajo iz imen večjih zemljepisnih enot (celine, držav, morij), ali za večbesedna imena, sestavljena v celoti ali deloma iz občnoimenskih sestavin (na primer čnomorska regija ali sredozemske pokrajine travnikov in gozdov). Pri tem smo se oprli na Toponimska navodila za Slovenijo (Radovan 1995). Nekatere, predvsem starejše, klasifikacije so dostopne kot računalniške datoteke v slabi slikovni ločljivosti, novejša pa so na voljo kot natančen podatkovni sloj. Starejše klasifikacije Evrope so narejene tradicionalno, po subjektivni presoji in znanju avtorjev (Mücher s sod., 2003), novejša klasifikacije pa so pripravljene z uporabo GIS-ov in so zanimive z metodološkega vidika in tudi z vidika uporabe podatkovnih slojev. Ker je rastje močno povezano z ostalimi naravnogeografskimi dejavniki (Digital map ..., 2009), smo pregledali tudi nekatere klasifikacije, ki temeljijo na naravnem rastju.

Preglednica 8: Seznam klasifikacij območja Evrope.

ime klasifikacije in vir	izvirno ime klasifikacije
okoljska členitev Evrope (Mücher s sod., 2003; Metzger s sod., 2005; Jongman s sod., 2006)	<i>Environmental stratification of Europe</i>
evropska pokrajinska klasifikacija (Mücher s sod., 2003; Mücher s sod., 2006; Mücher s sod., 2009)	<i>European landscape classification</i>
digitalni zemljevid evropskih ekoloških regij/območij, 2000 (Digital map ..., 2009) in kopenske ekološke regije (območja) sveta (Olson s sod., 2001)	<i>Digital map of European ecological regions; Terrestrial ecoregions of the world</i>
biogeografske regije/območja (Biogeographical regions ..., 2009)	<i>Biogeographical regions</i>
naravnogeografska razdelitev Evrope (Bohn s sod., 2002/2003)	<i>Physisch-geographische Gliederung Europas</i>
vseevropski pokrajinski tipi (Meeus, 1995)	<i>Pan-European landscape types</i>
ekološke regije/območja kontinentov (Bailey, 1996)	<i>Ecoregions of the continents</i>
biogeografske pokrajine Evrope (Europe's ..., 1995) in biogeografske pokrajine sveta (Udvardy, 1975)	<i>Biogeographical provinces of Europe and Biogeographical provinces of the World</i>
biogeografski zemljevid Evrope in bioklimatski zemljevid Evrope (Rivas-Martínez, Penas, Díaz, 2009)	<i>Biogeographic map of Europe and Bioclimatic map of Europe</i>

3.3.2 Primerjava klasifikacij

Pri ugotavljanju števila različnih kategorij (enot) na ozemlju Slovenije v posameznih klasifikacijah Evrope (preglednica 9) smo zaradi različnega načina določanja mej med enotami in ločljivosti upoštevali tudi bližnjo okolico oziroma enote, ki se dotikajo Slovenije. Rezultati naše analize prikazujejo klasifikacije s številom kategorij (raznih tipov, regij, ekoloških območij ...) po posameznih ravneh. V oklepaju je pripisano število kategorij, ki se pojavljajo na ozemlju Slovenije. V zadnjem stolpcu je pripisano, ali so enote pri klasifikaciji bolj regije ali bolj tipi, ali pa gre za prepletanje obeh vrst klasifikacije.

Preglednica 9: Pregled nekaterih značilnosti klasifikacij Evrope.

klasifikacija	število kategorij na ozemlju Evrope (število kategorij na ozemlju Slovenije)				vrsta klasifikacije
	1. raven	2. raven	3. raven	4. raven	
okoljska členitev Evrope	2 (2)	6 (3)	13 (5)	84 (12)	višja raven: bolj regionalizacija, nižja raven: bolj tipizacija
evropska pokrajinska členitev	8 (3)	31 (8)	76 (12)	350 (19)	višja raven: bolj regionalizacija, nižja raven: bolj tipizacija

digitalni zemljevid evropskih ekoloških regij/območij	68 (5)	-	-	-	bolj tipizacija
kopenske ekološke regije/območja sveta	8 (1)	14 (3)	867 (5)		najvišja raven: bolj regionalizacija, nižje ravni: bolj tipizacije
biogeografske regije/območja, 2008	9 (3)	-	-		bolj tipizacija
biogeografske regije/območja, 2005	11 (4)	-	-		bolj tipizacija
naravnogeografska regionalizacija	4 (2)	9 (3)	47 (4)		bolj regionalizacija
vseevropski pokrajinski tipi	9 skupin tipov (4)	30 (4)	-		bolj tipizacija
ekološke regije/območja kontinentov	4 (1)	5 (30)	-		bolj tipizacija
biogeografske pokrajine Evrope in biogeografske pokrajine sveta	4 (-)	19 (4)	-		bolj regionalizacija
biogeografski zemljevid Evrope	5 (1)	<i>ponekod podenote</i>	30 (2)	71 (3)	višja raven: bolj tipizacija, nižja raven: bolj regionalizacija
bioklimatski zemljevid Evrope	4 (1)	16 (2)	<i>ponekod različice</i>		bolj tipizacija

Pri večini klasifikacij Evrope se celo na najvišji ravni ozemlje Slovenije uvršča v več kategorij oziroma enot, kar potrjuje spoznanja slovenskih geografov, da je Slovenija raznolika v naravnogeografskem smislu (in tudi družbenogeografskem, če upoštevamo še rabo tal). Kljub majhni površini Slovenije, ki pri večini evropskih klasifikacij zavzema manj kot 1 % ozemlja celotne klasifikacije, se na njenem ozemlju pojavlja znatno večji delež kategorij oziroma enot (regij ali tipov), ki so v Evropi. Uvrščanje Slovenije v več enot tudi na najvišjih ravneh evropskih členitev pomeni, da Slovenije na najvišji, državni, ravni nikakor ne moremo obravnavati kot ene same enote (regije ali tipa). Imena enot, v katere se uvršča Slovenija, slonijo na zemljepisnih imenih in imenih vrst rastja, podnebja in drugih naravnih dejavnikov. Po pregledu imen⁴ se najpogosteje pojavljajo (vse navajamo v pridevniški obliki): alpski, sredozemski, celinski, panonski, balkanski, ilirski, padski, dinarski, karpatski, srednjeevropski, apeninski. Poimenovanje enot na ozemlju Slovenije kaže, da tudi tuja literatura Slovenijo uvršča na stik večjih (naravno)geografskih enot Evrope, predvsem na stik Alp, Sredozemlja in Panonske kotline.

3.4 Primeri klasifikacij z geografskimi informacijskimi sistemi

Pri pregledu literature smo naleteli na številne primere uporabe GIS-ov za namen klasifikacije pokrajine na regije ali tipe (priloga 3). Pregled literature je potrdil, da je raba geografskih informacijskih sistemov že precej razširjena, uporaba posameznih geoinformacijskih orodij pa zelo raznolika. Primere klasifikacij lahko najdemo tudi v raznih publikacijah (na primer European Landscape Character Areas ..., 2005).

⁴ Pri analizi imen nismo upoštevali Zemljevida potencialne vegetacije in Bioklimatskega zemljevida, ki sta tipizacija po enem naravnogeografskem elementu (rastju oziroma podnebjju), prav tako nismo upoštevali ravni, ki v imenih vključujejo strani neba (na primer Južna Evropa) ali ravni, pri katerih je Slovenija uvrščena le v eno enoto (preglednica 9).

4. Uporabljene metode

Z razvojem računalniških programov se čedalje več poudarka daje kvantitativnim metodam in uporabi GIS-ov. Porazdelitev v prostoru se lahko namreč analizira tudi s pomočjo raznih statističnih metod (Haggett, 2001, 17). Poleg tehnologije (programska in strojna oprema) se izboljšuje tudi ponudba raznih prostorskih podatkov – podatkovnih slojev. Zato je Kladnik (1996, 156) poudaril, da se je treba na področju regionalizacij opreti na računalniške analize. Pri tem bi dodali, da je ta način treba razvijati tudi v tipizacijah in preučiti, katere metode sploh obstajajo, ter najbolj primerne uporabiti. Kar nekaj primerov uporabe geografskih informacijskih sistemov je znanih pri klasifikaciji pokrajin (na primer Plut, 1977; Perko, 1989; Gabrovec, 1990; Krevs, 1992; Perko, 1998a; Perko, 2001; Múcher s sod., 2009; več primerov je v poglavju 3).

Ne smemo pozabiti, da gre pri klasifikaciji tudi za določeno abstrakcijo. Model je namreč lahko definiran kot poenostavljen prikaz oziroma abstrakcija resničnega sveta. V najširšem smislu so modeli vse ponazoritve od fizičnih analognih modelov, narisanih diagramov in različnih računalniških modelov (Demeritt, Wainwright, 2005, 207). Postopek klasifikacije sestavljajo različni koraki. V vsakem koraku lahko uporabimo različne metode oziroma geoinformacijska orodja in jih med seboj tudi kombiniramo. Primer uporabe raznih metod v geografiji ter drugih vedah (ne samo za namen klasifikacije pokrajine) je obsežen, saj lahko najdemo primere metod strojnega učenja, statističnih metod, segmentacije in drugih (na primer Hauser-Davis s sod., 2010; Armitage, Ober, 2010; Kampichler s sod., 2010; Kutnar, Kobler, Bergant, 2009; Clark s sod., 2010; Stumpf, Kerle, 2011; Dominguez-Granda, Lock, Goethals, 2011; Mora, Wulder, White, 2010; Carteron s sod., 2012; Eskelson, Temesgen, Hagar, 2012; Džeroski, 2002). Izbira primerne klasifikacijskega algoritma je ključna, saj vpliva na rezultate in končno interpretacijo, poleg tega pa ima vpliv tudi način vzorčenja (Carteron s sod., 2012).

V doktorski disertaciji smo preučevali, kako lahko vrednotimo naravnopokrajinske tipizacije, ter ugotavljali, kje lahko z več različnimi geoinformacijskimi orodji potrdimo posamezne tipe. Zato smo morali izdelati (modelirati) tipizacije, jih med seboj primerjati, ovrednotiti z vidika podatkovnih slojev in ustrezne izvirne tipizacije ter na koncu primerjati usklajenost različnih načinov vrednotenja. V okviru raziskave smo zato uporabili različne metode oziroma geoinformacijska orodja znotraj nekaterih računalniških programov. Metode, ki smo jih uporabili, lahko združimo v naslednje glavne sklope:

- metode za vrednotenje podatkovnih slojev in metode za vrednotenje klasifikacij (naravnopokrajinskih tipizacij),
- metode za pripravo učnih celic,
- metode za izdelavo klasifikacij (naravnopokrajinskih tipizacij),
- metode za računanje usklajenosti načinov vrednotenja,
- metode za računanje usklajenosti klasifikacij med seboj.

Podroben pristop raziskave je naveden na začetku poglavij 7 in 8. Tu so navedene zgolj uporabljene metode oziroma geoinformacijska orodja, ki smo jih vključili v raziskave.

4.1 Metode za vrednotenje podatkovnih slojev in metode za vrednotenje klasifikacij

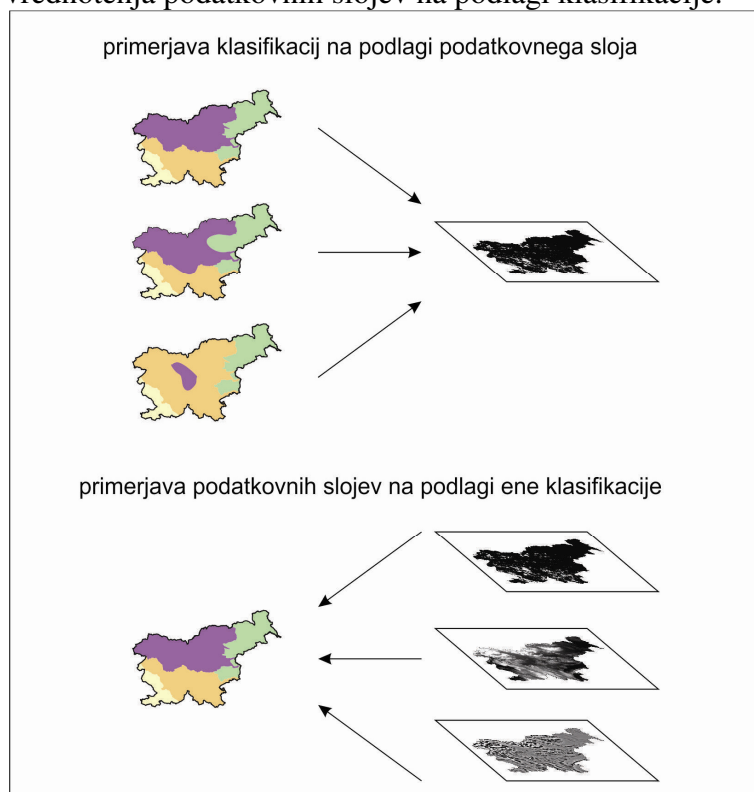
Za ugotovitev o tem, kakšna je pojasnjevalna moč podatkovnih slojev za določeno klasifikacijo (v našem primeru tipizacijo) oziroma kako se določeni tipi posameznih klasifikacij razlikujejo med seboj glede na izbrane podatkovne sloje, lahko uporabimo različne metode. Te metode lahko prav tako uporabimo za vrednotenje klasifikacij z vidika enega ali več podatkovnih slojev (primerjamo različne klasifikacije). Poleg tega lahko ocenimo še druge lastnosti podatkovnih slojev, denimo na kateri prostorski ravni so pomembni.

Pri metodah, ki smo jih uporabili za vrednotenje podatkovnih slojev ter klasifikacij, gre večinoma za računanje stopnje povezanosti med različnimi tipi podatkovnih slojev (predvsem med številskimi in nominalnimi):

- koeficient F (v praktičnem delu naloge smo ga ponekod označili z oznako F),
- povprečni umerjeni koeficient variacije (oznaka PUKV),
- koeficient η^2 (oznaka E2),
- informacijski prispevek (oznaka IG),
- razmerje informacijskega prispevka (oznaka GR),
- delež enako klasificiranih celic po modelu odločitvenega drevesa, različica CT (algoritem *Classification and Regression Trees* z Ginijevim koeficientom; oznaka ODL),
- delež enako klasificiranih celic po diskriminančni analizi (oznaka DA),
- povprečna oddaljenost posamezne celice od najbližjega centroida (oznaka (ODDP).

Predpostavljamo, da je stopnja povezanosti med klasifikacijo in podatkovnim slojem večja, če klasifikacija dobro razlikuje tipe glede na podatkovni sloj. Zaradi tega je tudi vrednotenje podatkovnih slojev in klasifikacij dejansko možno v obeh smereh: primerjava podatkovnih slojev z vidika izbrane klasifikacije in primerjava klasifikacij z vidika izbranega podatkovnega sloja (slika 7). Za vsako metodo smo navedli podroben opis (priloga 4). Pri računanju medsebojne povezanosti podatkovnih slojev smo uporabili Pearsonov in Spearmanov koeficient (Sagadin, 2003).

Slika 7: Shematski prikaz možnosti vrednotenja klasifikacij na podlagi podatkovnega sloja in vrednotenja podatkovnih slojev na podlagi klasifikacije.



4.2 Metode za izdelavo klasifikacij

Klasifikacija je združevanje podobnih enot. Če je vsaka enota opredeljena s p podatkovnimi sloji, je lahko razvrstitev narejena po nekem racionalnem kriteriju (Dodge, 2008, 82). Obstaja več različnih vrst metod, ki se ukvarjajo s klasifikacijo (Rogerson, 2006; Dodge, 2008; Abonyi s sod., 2007; McGarigal, 2000; Warner, Campagna, 2009, 181). Vsaka metoda pri

rezultatu lahko vsili svojo strukturo oziroma vodi do svoje rešitve, zato je najbolje primerjati rezultate različnih metod (McGarigal, 2000; Ferligoj, 1989; Theodoridis, Koutroumbas, 2006). Z možnostjo izbire metode ima raziskovalec velik vpliv na končne rezultate (McGarigal, 2000, 91). Metode klasifikacij se lahko po mnenju Warnerja in Campagne (2009, 180) delijo na nadzorovane (*supervised*) in nenadzorovane (*unsupervised*), mehke (*soft*) in trdne (*hard*), relativne in absolutne.

V osnovi se klasifikacije lahko delijo na nadzorovane in nenadzorovane. Pri prvih imamo na voljo znane vrednosti klasifikacije za učne podatke, pri drugih pa tega podatka nimamo (Theodoridis, Koutroumbas, 2006, 6). V praksi sta nenadzorovana in nadzorovana klasifikacija podvrženi subjektivnim presojam in znanju (Warner, Campagna, 2009, 181).

Metode, ki smo jih uporabili za izdelavo modeliranih klasifikacij v doktorski disertaciji, so:

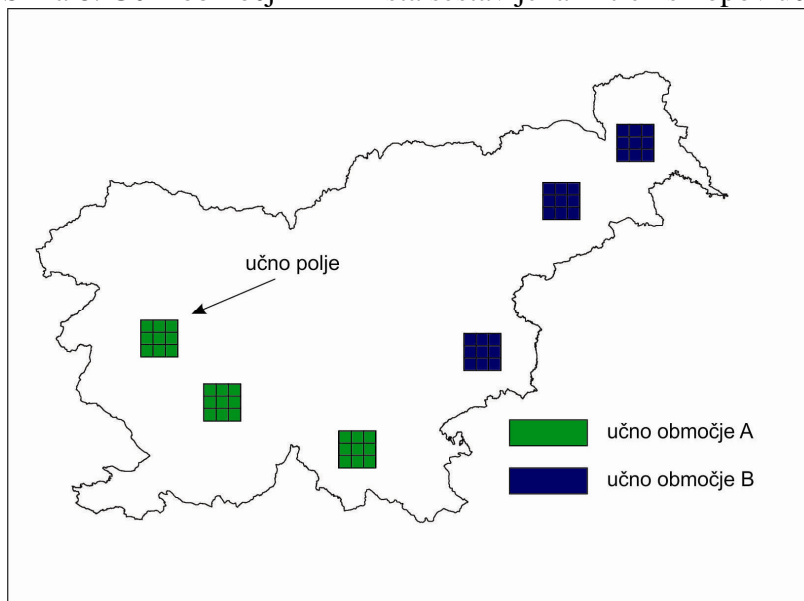
- metode nenadzorovane klasifikacije⁵:
 - metoda voditeljev (več različic)
 - segmentacija
 - analiza vrhov v histogramu
 - metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja
- metode nadzorovane klasifikacije⁶:
 - odločitveno drevo (več različic)
 - metoda največje verjetnosti
 - metoda najmanjše razdalje
 - metoda k najbližjih sosedov

Za vsako metodo smo navedli podroben opis (priloga 4).

4.3 Metoda določanja učnih območij in izdelave spektralnih podpisov

Učna območja so območja z znano identiteto (kategorijo, tipom). Cilj določanja učnih območij je izbrati celice, ki čim bolj natančno ponazarjajo spektralno spremenljivost za vsak informacijski razred (Campbell, 1996, 329) oziroma v našem primeru lastnosti podatkovnih slojev (naravnih dejavnikov) za vsak tip. Učno območje obsega vse učne celice, učno območje pa je lahko sestavljeno iz več sklopov celic, ki jih imenujemo učna polja (slika 8).

Slika 8: Učni območji A in B sta sestavljena iz treh sklopov učnih celic – učnih polj.



⁵ Označe za posamezno metodo so zapisane v preglednici 16.

⁶ Označe za posamezno metodo so zapisane v preglednici 43.

V programu Idrisi smo za določanje izdelav učnih območij pri večini metod nadzorovane klasifikacije uporabili modul MAKESIG. MAKESIG ustvari podpise (*signatures*) za učne celice (*training site*). Ti podpisi se nato uporabijo pri metodah nadzorovane klasifikacije podatkovnih slojev. Znotraj učnih celic program izbere določeno minimalno število celic, na podlagi katerih naredi podpise (Idrisi Taiga, 2010). Ob izdelavi podpisa se za vsako kategorijo ustvarita dve datoteki: .spf hrani celice, .sig pa hrani statistiko (Idrisi Taiga, 2010). Uporaba modula je predpogoj za nadzorovane klasifikacije modulov kot so MINDIST (metoda najmanjše razdalje), KNN (metoda k najbližjih sosedov), MAXLIKE (metoda največje verjetnosti) in BAYCLASS (mehka različica metode največje verjetnosti). Za odločitvena drevesa različic CTR, CTG in CTE posebno določanje učnih območij ni potrebno, saj ima Idrisi določanje učnih območij in izdelavo modela že vključeno znotraj lastnega modula za odločitvena drevesa. Pri metodi odločitvenih dreves po različici CT v programu SPSS smo izdelali odločitveno drevo samo z učnimi celicami, nato pa smo z nastalim pravilom klasificirali vse celice. Pri določanju učnih polj smo se trudili čim bolj upoštevati priporočila iz literature (priloga 5).

4.4 Metode za računanje usklajenosti načinov vrednotenja, metode za računanje usklajenosti klasifikacij med seboj ter druge metode ugotavljanja povezanosti

V analitičnem delu doktorske disertacije večkrat ugotavljamo, kako dobro so povezani/usklajeni različni podatki, načini vrednotenja in rezultati. Tipizacije smo na primer vrednotili na več načinov, nato pa smo ugotavljali, ali so si izbrani načini vrednotenja med seboj podobni. Stopnjo povezanosti smo računali s Pearsonovim in Spearmanovim koeficientom (Sagadin, 2003). Izračun Pearsonovega in Spearmanovega koeficienta smo uporabili pri:

- ugotavljanju medsebojne povezanosti podatkovnih slojev,
- ugotavljanju usklajenosti načinov vrednotenja podatkovnih slojev (z vidika obstoječih naravnopokrajinskih tipizacij),
- ugotavljanju usklajenosti načinov vrednotenja modeliranih tipizacij, ki so narejene z metodami nenadzorovane klasifikacije,
- ugotavljanju povezanosti (usklajenosti) med oddaljenostjo celic od centroidov raznih modeliranih tipizacij, ki so narejene z metodo nenadzorovane klasifikacije,
- ugotavljanju usklajenosti načinov vrednotenja modeliranih tipizacij, ki so narejene z metodami nadzorovane klasifikacije,
- ugotavljanju povezanosti med seštevkom klasifikacij v posamezen tip po metodah nadzorovane klasifikacije z naključnim vzorčenjem in seštevkom klasifikacij v posamezen tip po metodah nadzorovane klasifikacije z ekspertnim vzorčenjem,
- ugotavljanju povezanosti med seštevkom klasifikacij v posamezen tip (po več metodah nadzorovane klasifikacije) in posamezno mehko modelirano tipizacijo po metodah mehke nadzorovane klasifikacije,
- ugotavljanje povezanosti obeh sklopov analiz (TIPI9 in TIPI13) za posamezen način vrednotenja tipizacij po metodah nadzorovane klasifikacije.

Razloga, da smo ob Pearsonovem koeficientu izračunavali še Spearmanov koeficient, sta nenormalna večmodalna porazdelitev nekaterih podatkovnih slojev ter majhen numerus pri nekaterih analizah, saj je Spearmanov koeficient v takih primerih bolj primeren (Krevs, 2001b). Večji pomen smo zaradi tega pri končnih sklepih dali rezultatom na podlagi Spearmanovega koeficienta.

Za računanje usklajenosti različnih tipizacij med seboj smo uporabili Cramerjev koeficient V in koeficient $kappa$ (priloga 4).

4.5 Metoda določanja statistične značilnosti lestvic in povprečnih vrednosti koeficientov

Pri statističnih analizah (kot je na primer računanje stopnje povezanosti med dvema številskima spremenljivkama s Pearsonovim koeficientov) se predpostavlja, da analizo opravljamo na podlagi določenega vzorca. Vsaka analiza nam zato pove, kolikšna je statistična značilnost testa oziroma kolikšna je možnost, da je naš rezultat naključen in v resnici za celotno populacijo ne drži. Če sklepamo iz več ločenih analiz, se statistična značilnost spremeni.

Kot primer lahko navedemo naslednjo situacijo. Izračunali smo Pearsonov koeficient z vrednostjo 0,850, s katerim smo ugotovili stopnjo povezanosti med spremenljivkama A in B. Ugotovili smo še, da je statistično značilen pri $p=0,05$, kar pomeni, da obstaja 5-odstotna možnost napačnega rezultata oziroma da smo lahko s 95-odstotno gotovostjo prepričani, da smo dobili pravi rezultat, ki velja za celotno populacijo. Izračunamo še en Pearsonov koeficient, ki kaže stopnjo povezanosti, na primer med spremenljivkama B in C. Njegova vrednost je 0,900 in je statistično značilen pri $p=0,05$. Če želimo sedaj skleniti, da je drugi Pearsonov koeficient večji od prvega, tega ne moremo trditi s 95-odstotno gotovostjo, saj sklepamo iz dveh ločenih analiz, pri kateri ima vsaka 5-odstotno tveganje. Zato moramo sklepanje izračunati. Po McKillupu in Dyarju (2010) to storimo preprosto tako, da pomnožimo verjetnosti pravilnega sklepanja med seboj. V našem primeru: $0,95 * 0,95 = 0,9025$. To pomeni, da je verjetnost našega sklepanja približno 90-odstotna.

Če bi po velikosti rangirali tri Pearsonove koeficiente s statistično značilnostjo $p=0,05$ oziroma s po 5-odstotnim tveganjem, bi to dejansko pomenilo 14-odstotno možnost napake ($0,86 = 0,95^3$).

V nalogi smo nekajkrat rangirali izračunane koeficiente ali pa smo izračunali povprečne vrednosti več koeficientov. Pri vsaki preglednici smo zato navedli tudi, kolikšna je povečana stopnja tveganja oziroma statistična značilnost.

4.6 Uporabljena računalniška programska oprema

Za izvedbo vseh računalniških postopkov smo uporabljali naslednjo programsko opremo:

- Idrisi 16.05 (Taiga)
- ArcGIS 9.3 in 10.0
- SPSS 17.0
- Statistica 10
- Weka 3.5.8
- MS Office Excel 2007, MS Office Word 2007
- Windows XP (SP 3)

Analize smo izvedli z osebnim računalnikom s procesorjem Intel[®] Core[™] 2 Duo (2,66 GHz) in delovnim spominom 3,00 GB.

5. Podatkovni sloji naravnih dejavnikov

»Vsak informacijski sistem in digitalni zemljevidi, ki za podlago jemljejo modeliranje digitalnih slojev podatkov, so le tako dobri in zanesljivi, kolikor so dobri, zanesljivi in kvalitetni izvorni digitalni podatki. Slovenija premore sorazmerno zadostno število digitalnih podatkov, s katerimi je mogoče zadovoljivo opredeliti pedogenetske in morfološke dejavnike za pokrajinske enote prsti« (Repe, 2010, 108). Glede na izkušnje iz pedogeografije predpostavljamo, da je tudi za tipizacijo Slovenije na tipe naravne pokrajine sorazmerno dovolj kakovostnih digitalnih podatkov, ki ponazarjajo naravne dejavnike. Izpostaviti je treba, da so nekateri naravni dejavniki relativno stabilni in neodvisni, drugi pa bolj odvisni (Mücher s sod., 2009), zato je kar nekaj avtorjev navedlo arbitrarno določene sezname dejavnikov po pomembnosti (poglavje 2). S kakovostnimi podatki lahko določamo ali pa analiziramo pokrajine. Mücher je s sodelavci (2009) takole zapisal teoretično enačbo za pokrajino:

$$\text{pokrajina} = f(C_{(t)}, G_{(t)}, H_{(t)}, S_{(t)}, V_{(t)}, F_{(t)}, LU_{(t)}, STR_{(t)}).$$

To pomeni, da je pokrajina funkcija podnebja (C), kamninske podlage in geomorfoloških značilnosti (G), vodovja (H), prsti (S), rastja (V), živalstva (F), rabe tal (LU), pokrajinske strukture (STR) in časa (t).

5.1 Podatkovni sloji, ki so uporabljeni v nalogi

Pri izbiri podatkov so pomembni tudi njihova dostopnost, natančnost, kakovost in podobno. Tako sta na primer Badgley in Fox (2000) izločila nekatere podatkovne sloje, ker niso vsebovali podatkov za celo območje. Pri pripravi podatkovnih slojev je sicer najbolje interpretirati neobdelane informacije, zato da se poudari tiste značilnosti, ki so pomembne za določanje pokrajin (Swanwick, 2002, 21).

V nalogi smo po pregledu naravnih dejavnikov in ustreznih obstoječih podatkovnih slojev (priloga 6), ki ponazarjajo naravne dejavnike, izbrali nekaj izvirnih podatkovnih slojev (preglednica 10), ki smo jim nato dodali še nekaj izpeljanih podatkovnih slojev ter vse skupaj uporabili v nalogi (preglednica 11).

Preglednica 10: Pregled izvirnih podatkovnih slojev.

podatkovni sloj	zapis (ločljivost)	vir
digitalni model višin	raster (25 m)	Digitalni model ..., 2010
kamninska podlaga	vektor	Litostratigrafska karta ..., 2007; Zemljevid tipov kamnin, 2012
zemljevidi povprečnih mesečnih temperatur	raster (1 km)	Zemljevidi povprečnih ..., 2010
zemljevidi povprečnih mesečnih padavin	raster (1 km)	Zemljevidi povprečnih ..., 2010
sončno obsevanje	raster (100 m)	Gabrovec, 1996
linije vodotokov	vektor	Vodotoki, 2006
pokrajinskoekološka tipizacija Slovenije	vektor	Špes s sod., 2002
pokrajinski tipi Slovenije	vektor	Perko, 1998a; Perko, 1998b; Perko, 2007b

Preglednica 11: Seznam vseh izvirnih in izpeljanih podatkovnih slojev.

podatkovni sloj	oznaka	enota
pokrajinskoekološki tipi (razdelitev na 13 tipov)	TIPI13	ime tipa
pokrajinski tipi (razdelitev na 9 tipov)	TIPI9	ime tipa
pokrajinski tipi (razdelitev na 4 tipe)	TIPI4	ime tipa
kamninska sestava	KAM25	tip kamnine
prepustnost (ocena na podlagi koeficienta prepustnosti)	PREP	ocenjena številna vrednost 1–10
nadmorska višina	VISINA	nadmorska višina v m
naklon	NAKLON	naklon v °
ekspozicija	EKSPO	ekspozicija v °
višinska razgibanost	RAZGIB_V	koeficient razgibanosti v %

naklonska razgibanost	RAZGIB_N	koeficient razgibanosti v %
ekspozicijska razgibanost	RAZGIB_E	koeficient razgibanosti v %
skupna razgibanost	RAZGIB_S	koeficient razgibanosti v %
tekstura	TEKS	delež celic v %
letna temperaturna razlika	TEMRAZ	razlika v °C
povprečna letna temperatura	TEMLET	temperatura v °C
povprečne mesečne temperature	T_JAN– T_DEC	temperatura v °C
razlika v aprilski in oktobrski temperaturi	APRMOKT	razlika v °C
povprečna letna višina padavin	PADLET	višina padavin v mm
povprečna mesečna višina padavin	P_JAN– P_DEC	višina padavin v mm
padavinski režim (poletje, jesen)	PADRAZPJ	razmerje med poletnimi in jesenskimi padavinami
padavinski režim (poletje, zima)	PADRAZPZ	razmerje med poletnimi in zimskimi padavinami
indeks mediteranskosti padavin	PADRAZM	razlika med količino padavin v oktobru in novembru ter količino padavin v maju in juniju, pomnožena s 100 in deljena z letno količino padavin (po Ogrin, 1996)
sončno obsevanje	OSONC	osončenost v MJ/m ²
gostota rečne mreže (0,5 km)	GRM500	km / km ²

5.2 Priprava podatkov

Podatkovne sloje smo obrezali na meje Slovenije ter izračunali osnovne statistične vrednosti (najnižja in najvišja vrednost). Glede na najvišjo in najnižjo vrednost posameznega številskega podatkovnega sloja smo vsak sloj prenesli na mersko lestvico z najnižjo vrednostjo 0 in najvišjo vrednostjo 100. S tem smo izničili vpliv različnih merskih lestvic. Na primer za nadmorsko višino smo določili:

- nadmorski višini 0 m nad morjem smo pripisali vrednost 0,
- nadmorski višini 2864 m nad morjem smo pripisali vrednost 100,
- ostalim vrednostim smo po linearnem načelu pripisali ustrezno vrednost med 0 in 100.

Opozoriti je treba sicer na vpliv odstopajočih vrednosti, ki smo jih vseeno ohranili. Na to smo bili pri vrednotenju podatkov posebej pozorni (poglavje 6).

Vsi podatkovni sloji so bili pripravljeni tako, da so imeli prostorsko ločljivost 200 m in so se meje celic različnih slojev med seboj ujemale. Slovenija je bila tako razdeljena na 506.450 celic. Vrednosti na merski lestvici smo zaokrožili na eno decimalko, kjer je bilo to z metodološkega vidika nujno (na primer pri izračunu informacijskega prispevka in razmerja informacijskega prispevka).

Podatkovnim slojem smo pripisali tudi oznake (preglednica 11), ki jih uporabljamo v celotni disertaciji zaradi bolj strnjene prikaza v preglednicah in slikah.

6. Vrednotenje podatkovnih slojev

Izbor podatkovnih slojev lahko definiramo kot izbiranje primernega oziroma optimalnega nabora spremenljivk (*feature selection*), ki jih potrebujemo za zadosten opis izbranega modeliranega pojava. Z ustreznim izborom lahko odstranimo odvečne podatke, šum (nejasne, moteče podatke) in preveč povezane spremenljivke ter se izognemo kompleksnim in dolgotrajnim izračunom ter uporabi velike količine računalniškega spomina. Če opustimo analizo nerelevantnih spremenljivk, se lahko izognemo višjim stroškom, izboljšamo izvedbo ter razumevanje analiziranih procesov (Tirelli, Passani, 2011; Jiang s sod., 2008).

Raziskovane na področju vrednotenja podatkovnih slojev je nujno, saj novejša raziskave še vedno uporabljajo pristop poskušanja in ugotavljanja napak (*»trial and error«*) pri izboru podatkovnih slojev oziroma se opirajo na izkušnje (Duro, Franklin, Dubé, 2012, 262). V literaturi je veliko primerov vrednotenja podatkovnih slojev glede informativnosti, medsebojne povezanost in podobno (na primer Kraft, Einax, Kowalik, 2004; Melo s sod., 2012; Tirelli, Passani 2011; Ciglič, 2010a; Armitage, Ober 2010; Williams s sod., 2012). V nalogi smo zbrali podatkovne sloje, s katerimi ponazarjamo naravne dejavnike (poglavje 5). Iz izkušenj vemo, da so naravni dejavniki v Sloveniji med seboj povezani (na primer temperatura in nadmorska višina), se z oddaljenostjo različno hitro spreminjajo (na primer padavinski režim se v primerjavi z ekspozicijo spreminja na daljše razdalje), imajo različen pomen za naravnogeografske klasifikacije in so merjeni na različnih merskih lestvicah. Podatkovne sloje, ki smo jih zbrali v disertaciji, smo zato ovrednotili na več načinov:

- analiza odstopajočih vrednosti,
- medsebojna povezanost podatkovnih slojev,
- vrednotenje podatkovnih slojev s pomočjo obstoječih geografskih klasifikacij,
- vrednotenje podatkovnih slojev z vidika prostorske ravni klasifikacije (prostorskega merila).

Z navedenimi načini vrednotenja ter priporočili iz literature smo za nadaljnje delo izbrali najbolj relevantne podatkovne sloje, s katerimi smo nato modelirali klasifikacije z metodami nenadzorovane in nadzorovane klasifikacije. Rezultati vrednotenja veljajo za območje celotne Slovenije in jih ne moremo posplošiti za druga (manjša ali večja) območja.

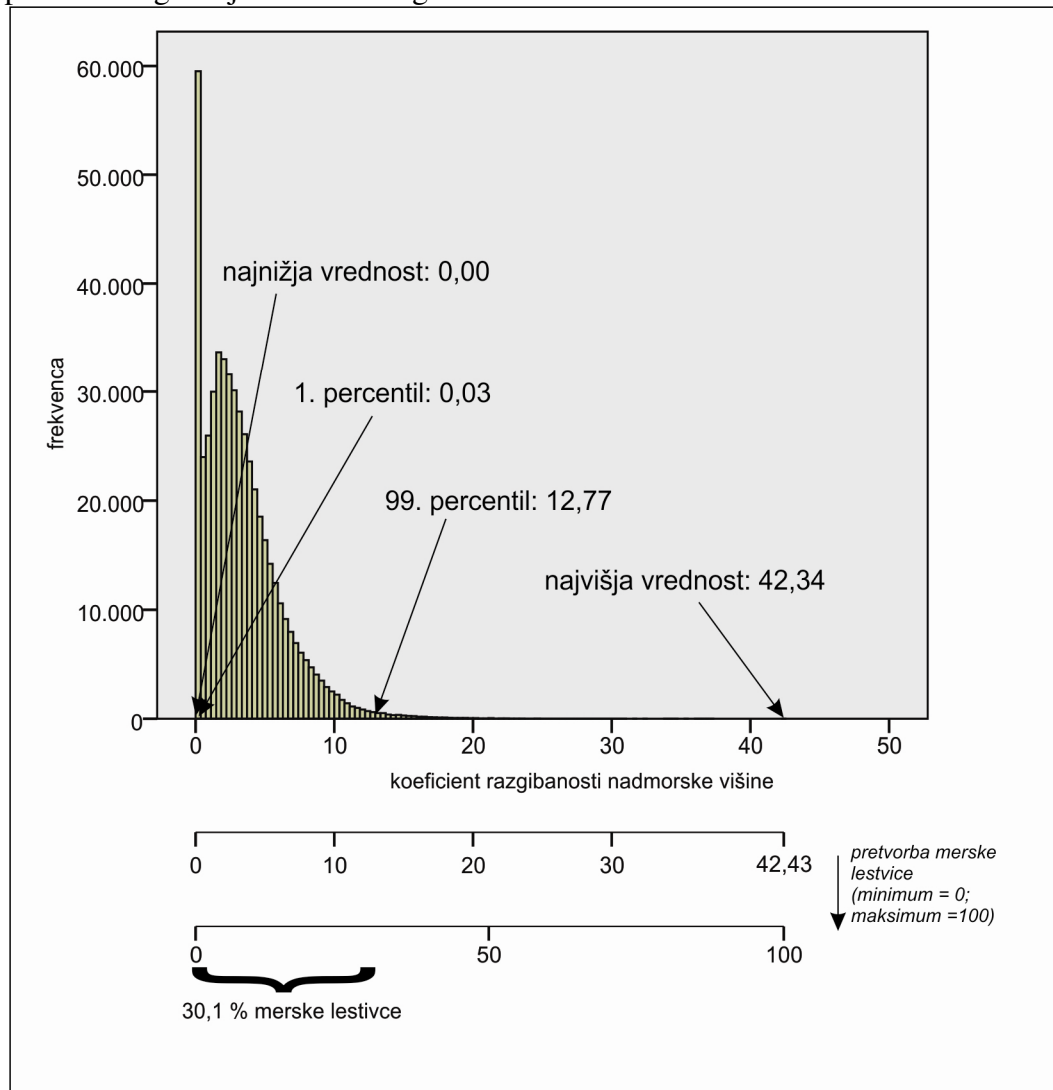
6.1 Odstopajoče vrednosti

V okviru priprave podatkovnih slojev smo vse sloje med drugim poenotili tako, da smo jih prenesli na mersko lestvico 0–100. Ob prenosu vrednosti podatkovnih slojev z izvorne na normalizirano mersko lestvico (z vrednostmi 0–100) imajo pomembno vlogo tudi odstopajoče (skrajne) vrednosti, ki vplivajo na izgled histograma (ta je ob večjih ekstremih ožji) in zato tudi na pojasnjevalno moč pri nekaterih metodah⁷. Zaradi tega smo pri vrednotenju podatkovnih slojev pogledali, če ima katera izmed spremenljivk zelo velika odstopanja skrajnih vrednosti. To smo storili tako, da smo izračunali vrednost 1. percentila in 99. percentila na normalizirani lestvici (0–100) ter izračunali, kolikšna je razlika med njima. Tako smo hkrati dobili tudi podatek o tem, kolikšen delež merske lestvice 0–100 zavzemajo vrednosti enot med obema percentiloma (98 % vseh enot) (slika 9). Pri močno izstopajočih

⁷ Če sta minimalna, maksimalna ali pa celo obe ekstremni vrednosti določene spremenljivke močno izstopajoči, lahko pri normalizaciji, pri kateri vzamemo za skrajne vrednosti minimum in maksimum, na novo mersko lestvico enote močno nagnetemo na ožji del nove lestvice. To neposredno pomeni, da bo v primerjavi s spremenljivkami, ki nimajo izstopajočih ekstremov, ta spremenljivka slabše razlikovala med skupinami (*clustri*), če recimo uporabimo metodo, ki temelji na oddaljenosti enot (na primer metoda voditeljev z Evklidovo razdaljo). Pri spremenljivki, ki nima izstopajočih vrednosti, bodo le-te namreč enakomerneje razporejene po celotni lestvici 0–100.

skrajnih vrednostih je rezultat vrednotenja nizek, pri malo izstopajočih vrednostih pa je rezultat visok.

Slika 9: Metoda vrednotenja z vidika merske lestvice in izstopajočih vrednosti. Primer podatkovnega sloja višinska razgibanost.



Spremenljivke smo razvrstili glede na razliko med normaliziranimi vrednostma 1. in 99. percentila (preglednica 12), kar lahko razumemo tudi kot odstotek dolžine merske lestvice med 1. in 99. percentilom v primerjavi z dolžino celotne lestvice. Opazimo, da imata gostota rečne mreže (s polmerom kroga 500 m) in višinska razgibanost zelo nizko vrednost, kar pomeni, da lahko skrajne minimalne in maksimalne vrednosti močno vplivajo na pojasnjevalno moč spremenljivk pri nekaterih metodah. Vrednosti čez 80 ima sicer le spremenljivka ekspozicija. Vidimo, da je pri večini ostalih spremenljivk ta vrednost med 60 in 80. Standardizacija z Z vrednostmi lahko to odpravi, saj posameznim vrednostim pripiše novo vrednost na podlagi standardnega odklona.

Preglednica 12: Vrednotenje podatkovnih slojev glede na izstopajoče vrednosti oziroma glede na razliko med normaliziranimi vrednostma 1. in 99. percentila.

oznaka podatkovnega sloja ⁸	izvirne vrednosti ⁹					normalizirane vrednosti na lestvici 0–100		
	povprečje	najnižja vrednost	najvišja vrednost	1. percentil	99. percentil	vrednost 1. percentila	vrednost 99. percentila	razlika med vrednostjo 1. in 99. percentila ¹⁰
EKSPO	93,97	1,42	180,00	13,26	167,75	6,6	93,1	86,5
PREP	71,75	10,00	100,00	20,00	100,00	20,0	100,0	80,0
P_DEC	124,33	49,92	335,61	55,77	281,51	2,0	81,1	79,0
P_OKT	163,71	57,59	437,06	68,29	364,69	2,8	80,9	78,1
P_SEP	146,99	77,10	344,66	81,57	289,30	1,7	79,3	77,6
P_APR	123,74	55,94	352,46	58,53	288,03	0,9	78,3	77,4
P_NOV	161,99	70,72	501,11	74,91	404,11	1,0	77,5	76,5
PADRAZPZ	1,60	0,73	2,81	0,86	2,46	6,5	82,9	76,4
P_MAJ	129,27	66,79	353,77	76,91	288,49	3,5	77,3	73,7
PADLET	1573,26	787,44	4061,90	838,63	3252,23	1,6	75,3	73,7
PADRAZPJ	0,99	0,51	1,51	0,65	1,38	14,1	87,3	73,2
T_JAN	-0,73	-6,71	5,33	-4,69	4,11	16,8	89,9	73,1
T_DEC	0,31	-5,59	6,31	-3,58	5,05	16,8	89,4	72,5
APRMOKT	-1,13	-4,79	0,43	-3,50	0,27	24,7	97,0	72,3
P_JAN	91,17	36,17	293,22	37,82	221,90	0,6	72,3	71,6
T_NOV	3,70	-3,73	9,68	-1,14	8,35	19,3	90,1	70,8
T_FEB	0,55	-7,74	5,89	-4,77	4,86	21,8	92,4	70,6
T_OKT	9,05	0,73	14,36	3,68	13,27	21,7	92,0	70,3
P_JUL	136,73	67,55	300,10	79,29	242,46	5,1	75,2	70,2
TEMLET	8,64	-0,76	13,65	2,60	12,63	23,3	92,9	69,6
T_MAR	4,14	-6,18	8,91	-2,52	7,98	24,3	93,8	69,6
TEKS	15,57	0,00	54,84	0,00	37,86	0,0	69,0	69,0
T_AVG	17,71	7,12	22,88	10,94	21,79	24,3	93,1	68,8
T_JUL	18,14	6,94	23,11	10,97	22,06	24,9	93,5	68,6
T_APR	7,92	-3,99	12,38	0,25	11,47	25,9	94,5	68,6
T_SEP	13,84	4,17	18,99	7,62	17,73	23,3	91,5	68,2
T_MAJ	12,92	1,12	17,07	5,36	16,22	26,6	94,7	68,1
P_MAR	104,63	46,91	316,13	50,57	233,75	1,4	69,4	68,0
T_JUN	16,01	4,33	20,50	8,52	19,49	25,9	93,7	67,8
RAZGIB_E	585,96	0,00	1359,11	139,37	1050,83	10,3	77,3	67,1
TEMRAZ	18,86	13,24	20,97	15,48	20,65	28,9	96,0	67,1
P_JUN	165,91	80,55	379,46	96,56	295,34	5,4	71,9	66,5
PADRAZM	1,20	-7,12	12,83	-5,26	7,82	9,4	74,9	65,5
P_FEB	85,33	37,93	245,48	40,82	175,54	1,4	66,3	64,9
P_AVG	139,45	85,97	331,90	90,58	246,35	1,9	65,2	63,3
RAZGIB_S	31,52	0,00	92,73	4,56	61,82	4,9	66,7	61,7
NAKLON	14,20	0,00	69,82	0,15	43,18	0,2	61,8	61,6
VISINA	556,88	0,01	2794,20	95,84	1794,72	3,4	64,2	60,8
OSONC	4012,96	851,88	5279,25	2383,64	4809,70	34,6	89,4	54,8
RAZGIB_N	32,22	0,00	154,43	0,70	82,75	0,5	53,6	53,1
RAZGIB_V	3,37	0,00	42,34	0,03	12,77	0,1	30,2	30,1
GRM500	1,45	0,00	19,52	0,00	5,19	0,0	26,6	26,6

⁸ Celotno ime posameznega podatkovnega sloja je zapisano v preglednici 11.

⁹ Merske enote so zapisane v preglednici 11.

¹⁰ To je hkrati odstotek dolžine merske lestvice med 1. in 99. percentilom v primerjavi s celotno dolžino lestvice. Nižje vrednosti pomenijo močno izstopajoče vrednosti in zelo ozek histogram.

6.2 Medsebojna povezanost podatkovnih slojev

Kot smo že v uvodu omenili, so naravni dejavniki med seboj bolj ali manj povezani, zato nekaterih podatkovnih slojev za analizo naravnih pokrajinskih tipov ne potrebujemo. Zaradi povezanosti slojev je lahko model preveč prilagojen vzorčnim podatkom (*overfitting*) in lahko vpliva na rezultate nekaterih metod. Povezanost med naravnogeografskimi (nadmorska višina, naklon, ekspozicija, razgibanost, kamnine, rastje) in družbenogeografskimi (število prebivalcev, naselij) podatkovnimi sloji je za območje Slovenije računal tudi Perko (2001). Pri povezanosti je treba izpostaviti dejstvo, da preučujemo območje Slovenije in ne vsega sveta, zato izračunane povezanosti (Pearsonovi in Spearmanovi koeficienti) veljajo za območje Slovenije in jih ne moremo prenesti v druga okolja. Pri primerjavi obeh koeficientov smo ugotovili, da se koeficienti ne razlikujejo močno (preglednica 13). Tako smo na dva načina preverili povezanost med podatkovnimi sloji.

Preglednica 13: Matrika povezanosti podatkovnih slojev, izražena s Pearsonovim koeficientom in tudi s Spearmanovim koeficientom.

podatkovni sloj	K	EKSP0	GRM500	NAKLON	OSONC	P_APR	P_AVG	P_DEC	P_FEB	P_JAN	P_JUL	P_JUN	P_MAJ	P_MAR	P_NOV	P_OKT	P_SEP	PADLET	PADRAZPJ	PADRAZPZ	PADRAZM	PREP		
APRMOKT	P	0,03	0,28	-0,51	0,19	-0,77	-0,70	-0,77	-0,80	-0,78	-0,51	-0,74	-0,71	-0,80	-0,75	-0,79	-0,77	-0,79	0,68	0,64	-0,71	0,06		
	S	0,03	0,30	-0,50	0,10	-0,84	-0,67	-0,83	-0,83	-0,83	-0,44	-0,76	-0,82	-0,84	-0,81	-0,83	-0,84	-0,85	0,71	0,67	-0,74	0,13		
EKSP0	P		-0,01	-0,06	0,67	-0,02	-0,02	-0,02	-0,03	-0,02	0,00	-0,02	-0,01	-0,03	-0,01	-0,02	-0,02	-0,02	0,03	0,03	-0,03	0,04		
	S		-0,01	-0,07	0,72	-0,03	-0,02	-0,03	-0,04	-0,03	NP	-0,01	-0,01	-0,04	-0,02	-0,02	-0,02	-0,02	0,02	0,03	-0,03	0,05		
GRM500	P			-0,02	-0,02	-0,23	-0,16	-0,26	-0,28	-0,27	-0,05	-0,18	-0,19	-0,26	-0,23	-0,24	-0,23	-0,23	0,28	0,29	-0,27	-0,23		
	S			0,04	-0,03	-0,28	-0,14	-0,31	-0,32	-0,31	0,03	-0,18	-0,23	-0,31	-0,28	-0,29	-0,28	-0,27	0,33	0,34	-0,33	-0,22		
NAKLON	P				-0,40	0,50	0,56	0,42	0,43	0,41	0,56	0,56	0,51	0,49	0,47	0,46	0,49	0,51	-0,21	-0,17	0,23	-0,31		
	S				-0,23	0,45	0,55	0,39	0,40	0,37	0,53	0,54	0,48	0,45	0,41	0,41	0,45	0,46	-0,19	-0,17	0,22	-0,44		
OSONC	P					-0,27	-0,34	-0,21	-0,23	-0,19	-0,37	-0,32	-0,27	-0,27	-0,25	-0,25	-0,25	-0,27	0,06	0,03	-0,10	0,05		
	S					-0,17	-0,29	-0,13	-0,14	-0,11	-0,31	-0,24	-0,18	-0,17	-0,15	-0,16	-0,17	-0,18	0,02	NP	-0,07	0,05		
P_APR	P						0,85	0,96	0,95	0,95	0,72	0,93	0,98	0,98	0,98	0,94	0,97	0,99	-0,73	-0,68	0,73	0,05		
	S						0,77	0,97	0,96	0,95	0,53	0,90	0,98	0,98	0,98	0,96	0,98	0,99	-0,82	-0,78	0,83	-0,03		
P_AVG	P							0,74	0,77	0,72	0,91	0,94	0,87	0,85	0,82	0,82	0,87	0,88	-0,40	-0,31	0,47	-0,10		
	S							0,67	0,69	0,63	0,88	0,92	0,81	0,76	0,72	0,74	0,80	0,81	-0,37	-0,29	0,46	-0,18		
P_DEC	P								0,97	0,99	0,56	0,86	0,92	0,95	0,97	0,93	0,95	0,96	-0,83	-0,80	0,82	0,08		
	S								0,98	0,99	0,39	0,84	0,93	0,97	0,98	0,96	0,96	0,96	-0,90	-0,88	0,90	NP		
P_FEB	P									0,97	0,58	0,86	0,90	0,98	0,94	0,92	0,93	0,96	-0,80	-0,79	0,80	0,07		
	S									0,98	0,42	0,83	0,93	0,98	0,96	0,95	0,95	0,96	-0,87	-0,87	0,88	-0,01		
P_JAN	P										0,54	0,85	0,92	0,96	0,96	0,92	0,94	0,95	-0,82	-0,81	0,80	0,10		
	S										0,36	0,81	0,91	0,96	0,96	0,94	0,94	0,95	-0,91	-0,90	0,89	0,01		
P_JUL	P											0,84	0,78	0,69	0,68	0,66	0,72	0,74	-0,14	-0,04	0,24	-0,14		
	S											0,75	0,60	0,50	0,48	0,48	0,56	0,58	-0,06	0,02	0,17	-0,22		
P_JUN	P												0,95	0,91	0,91	0,90	0,94	0,95	-0,57	-0,49	0,59	-0,05		
	S													0,93	0,87	0,87	0,88	0,91	0,93	-0,58	-0,52	0,62	-0,12	
P_MAJ	P														0,95	0,96	0,92	0,97	0,98	-0,64	-0,59	0,64	0,02	
	S														0,95	0,96	0,94	0,96	0,98	-0,75	-0,70	0,76	-0,07	
P_MAR	P															0,96	0,94	0,95	0,98	-0,73	-0,71	0,74	0,05	
	S															0,96	0,96	0,96	0,98	-0,83	-0,81	0,85	-0,04	
P_NOV	P																0,94	0,97	0,98	-0,76	-0,70	0,77	0,08	
	S																0,96	0,97	0,98	-0,87	-0,82	0,88	0,00	
P_OKT	P																	0,95	0,96	-0,80	-0,70	0,84	0,02	
	S																		0,97	0,97	-0,86	-0,79	0,90	-0,03
P_SEP	P																			0,99	-0,74	-0,67	0,74	0,02
	S																			0,98	-0,81	-0,76	0,83	-0,04
PADLET	P																				-0,73	-0,67	0,74	0,03
	S																				-0,80	-0,75	0,83	-0,05
PADRAZPJ	P																					0,96	-0,96	-0,14
	S																					0,96	-0,97	-0,08
PADRAZPZ	P																						-0,89	-0,17
	S																						-0,90	-0,10
PADRAZM	P																							0,10
	S																							0,06
PREP	P																							
	S																							

*K pomeni koeficient, P pomeni Pearsonov koeficient, S pomeni Spearmanov koeficient, NP pomeni »ni povezano« pri statistični značilnosti p=0,001.

podatkovni sloj	K.	RAZGIB_E	RAZGIB_N	RAZGIB_S	RAZGIB_V	T_APR	T_AVG	T_DEC	T_FEB	T_JAN	T_JUL	T_JUN	T_MAJ	T_MAR	T_NOV	T_OKT	T_SEP	TEKS	TEMLET	TEMRAZ	VISINA
APRMOKT	P	0,21	-0,41	-0,28	-0,52	0,80	0,72	0,31	0,57	0,29	0,74	0,80	0,81	0,73	0,44	0,58	0,70	-0,26	0,66	0,98	-0,82
	S	0,21	-0,39	-0,25	-0,52	0,77	0,69	0,37	0,56	0,34	0,71	0,76	0,78	0,70	0,45	0,57	0,69	-0,27	0,64	0,97	-0,80
EKSP0	P	-0,05	-0,09	-0,10	-0,06	0,01	0,01	-0,01	NP	NP	0,01	0,01	0,01	0,01	-0,01	NP	0,01	-0,06	0,003*	0,02	-0,01
	S	-0,07	-0,09	-0,11	-0,07	0,03	0,03	-0,01	NP	NP	0,03	0,03	0,03	0,02	NP	0,01	0,02	-0,07	0,02	0,03	-0,03
GRM500	P	0,15	0,04	0,07	-0,05	0,24	0,22	0,07	0,17	0,07	0,22	0,24	0,24	0,22	0,12	0,18	0,22	0,04	0,20	0,31	-0,28
	S	0,12	0,11	0,12	0,02	0,23	0,22	0,07	0,16	0,06	0,21	0,24	0,24	0,21	0,11	0,17	0,22	0,06	0,19	0,33	-0,28
NAKLON	P	-0,32	0,71	0,46	0,97	-0,56	-0,53	-0,40	-0,49	-0,39	-0,55	-0,56	-0,56	-0,54	-0,46	-0,50	-0,52	0,44	-0,53	-0,51	0,58
	S	-0,32	0,77	0,50	0,99	-0,56	-0,54	-0,38	-0,49	-0,37	-0,56	-0,57	-0,56	-0,54	-0,45	-0,50	-0,52	0,50	-0,53	-0,51	0,61
OSONC	P	0,12	-0,30	-0,17	-0,43	0,32	0,33	0,33	0,34	0,34	0,33	0,32	0,32	0,33	0,34	0,34	0,33	-0,11	0,34	0,17	-0,28
	S	0,02	-0,23	-0,18	-0,24	0,26	0,27	0,26	0,27	0,25	0,27	0,26	0,25	0,27	0,26	0,27	0,27	-0,10	0,27	0,08	-0,21
P_APR	P	-0,20	0,40	0,24	0,53	-0,70	-0,63	-0,35	-0,53	-0,33	-0,65	-0,70	-0,71	-0,64	-0,43	-0,55	-0,63	0,23	-0,60	-0,76	0,71
	S	-0,20	0,37	0,22	0,47	-0,72	-0,64	-0,36	-0,53	-0,33	-0,66	-0,72	-0,74	-0,65	-0,41	-0,55	-0,64	0,25	-0,61	-0,79	0,72
P_AVG	P	-0,21	0,44	0,28	0,58	-0,80	-0,77	-0,61	-0,73	-0,59	-0,79	-0,81	-0,81	-0,78	-0,67	-0,73	-0,76	0,26	-0,77	-0,67	0,80
	S	-0,23	0,44	0,27	0,57	-0,82	-0,79	-0,66	-0,76	-0,63	-0,80	-0,82	-0,82	-0,80	-0,70	-0,76	-0,78	0,29	-0,79	-0,62	0,80
P_DEC	P	-0,17	0,35	0,22	0,45	-0,61	-0,53	-0,21	-0,41	-0,19	-0,55	-0,62	-0,63	-0,54	-0,30	-0,43	-0,53	0,21	-0,50	-0,76	0,63
	S	-0,18	0,32	0,20	0,41	-0,63	-0,54	-0,21	-0,41	-0,19	-0,56	-0,63	-0,65	-0,55	-0,28	-0,43	-0,55	0,22	-0,50	-0,80	0,65
P_FEB	P	-0,18	0,36	0,23	0,45	-0,68	-0,61	-0,29	-0,49	-0,27	-0,62	-0,68	-0,70	-0,62	-0,38	-0,51	-0,61	0,23	-0,57	-0,79	0,70
	S	-0,18	0,33	0,20	0,42	-0,68	-0,60	-0,26	-0,46	-0,24	-0,61	-0,67	-0,69	-0,60	-0,33	-0,48	-0,60	0,23	-0,55	-0,81	0,68
P_JAN	P	-0,17	0,33	0,21	0,43	-0,60	-0,52	-0,17	-0,38	-0,16	-0,53	-0,60	-0,62	-0,52	-0,27	-0,41	-0,51	0,20	-0,48	-0,77	0,62
	S	-0,17	0,31	0,19	0,39	-0,60	-0,51	-0,17	-0,37	-0,14	-0,52	-0,60	-0,62	-0,52	-0,24	-0,39	-0,51	0,21	-0,46	-0,81	0,62
P_JUL	P	-0,22	0,42	0,24	0,59	-0,75	-0,75	-0,71	-0,75	-0,70	-0,76	-0,76	-0,75	-0,76	-0,74	-0,76	-0,75	0,22	-0,77	-0,49	0,73
	S	-0,21	0,43	0,25	0,54	-0,70	-0,70	-0,69	-0,71	-0,66	-0,71	-0,69	-0,69	-0,71	-0,70	-0,70	-0,69	0,26	-0,72	-0,39	0,66
P_JUN	P	-0,22	0,45	0,29	0,58	-0,74	-0,69	-0,47	-0,61	-0,44	-0,71	-0,74	-0,75	-0,70	-0,54	-0,63	-0,68	0,27	-0,67	-0,72	0,74
	S	-0,23	0,44	0,27	0,56	-0,79	-0,74	-0,52	-0,66	-0,48	-0,75	-0,80	-0,80	-0,75	-0,57	-0,67	-0,73	0,28	-0,73	-0,72	0,79
P_MAJ	P	-0,21	0,40	0,23	0,54	-0,66	-0,60	-0,36	-0,51	-0,34	-0,63	-0,67	-0,68	-0,61	-0,43	-0,54	-0,60	0,22	-0,58	-0,71	0,68
	S	-0,21	0,40	0,25	0,50	-0,75	-0,67	-0,40	-0,57	-0,37	-0,69	-0,75	-0,76	-0,68	-0,46	-0,58	-0,67	0,26	-0,64	-0,78	0,74
P_MAR	P	-0,20	0,39	0,24	0,52	-0,74	-0,68	-0,38	-0,57	-0,37	-0,69	-0,74	-0,76	-0,68	-0,47	-0,59	-0,67	0,23	-0,65	-0,79	0,75
	S	-0,20	0,36	0,22	0,47	-0,74	-0,66	-0,34	-0,54	-0,32	-0,67	-0,74	-0,76	-0,67	-0,41	-0,56	-0,66	0,25	-0,62	-0,82	0,74
P_NOV	P	-0,18	0,38	0,23	0,50	-0,66	-0,59	-0,31	-0,49	-0,29	-0,61	-0,67	-0,68	-0,60	-0,40	-0,51	-0,59	0,21	-0,57	-0,73	0,67
	S	-0,18	0,34	0,21	0,43	-0,67	-0,59	-0,30	-0,47	-0,27	-0,60	-0,67	-0,69	-0,60	-0,35	-0,49	-0,59	0,23	-0,56	-0,77	0,67
P_OKT	P	-0,20	0,37	0,23	0,48	-0,68	-0,61	-0,32	-0,51	-0,30	-0,63	-0,69	-0,70	-0,62	-0,40	-0,52	-0,61	0,21	-0,58	-0,76	0,69
	S	-0,19	0,33	0,20	0,43	-0,70	-0,62	-0,32	-0,50	-0,29	-0,63	-0,70	-0,71	-0,63	-0,38	-0,52	-0,62	0,22	-0,58	-0,80	0,69
P_SEP	P	-0,20	0,40	0,25	0,51	-0,66	-0,59	-0,30	-0,48	-0,28	-0,61	-0,66	-0,68	-0,60	-0,38	-0,50	-0,58	0,24	-0,56	-0,75	0,68
	S	-0,20	0,36	0,22	0,47	-0,71	-0,63	-0,35	-0,52	-0,32	-0,64	-0,71	-0,72	-0,64	-0,40	-0,54	-0,63	0,25	-0,60	-0,80	0,71
PADLET	P	-0,21	0,41	0,25	0,53	-0,72	-0,65	-0,37	-0,55	-0,35	-0,67	-0,72	-0,73	-0,66	-0,46	-0,57	-0,65	0,24	-0,62	-0,77	0,73
	S	-0,21	0,38	0,23	0,48	-0,76	-0,68	-0,39	-0,57	-0,36	-0,69	-0,75	-0,77	-0,69	-0,45	-0,58	-0,68	0,25	-0,65	-0,80	0,75
PADRAZPJ	P	0,11	-0,20	-0,14	-0,22	0,34	0,25	-0,13	0,09	-0,15	0,26	0,34	0,36	0,25	-0,03	0,12	0,25	-0,13	0,19	0,66	-0,36
	S	0,10	-0,18	-0,12	-0,21	0,37	0,28	-0,06	0,13	-0,09	0,29	0,37	0,40	0,28	-0,01	0,16	0,28	-0,13	0,23	0,70	-0,39
PADRAZPZ	P	0,09	-0,16	-0,12	-0,18	0,30	0,20	-0,18	0,05	-0,20	0,21	0,30	0,32	0,21	-0,08	0,07	0,20	-0,13	0,15	0,64	-0,32
	S	0,08	-0,15	-0,11	-0,18	0,32	0,23	-0,13	0,08	-0,14	0,24	0,32	0,35	0,23	-0,06	0,11	0,24	-0,13	0,18	0,67	-0,36
PADRAZM	P	-0,12	0,22	0,15	0,25	-0,45	-0,37	-0,02	-0,24	-0,01	-0,38	-0,45	-0,47	-0,38	-0,11	-0,25	-0,37	0,14	-0,32	-0,67	0,46
	S	-0,12	0,19	0,12	0,24	-0,48	-0,39	-0,09	-0,26	-0,06	-0,40	-0,47	-0,50	-0,40	-0,14	-0,29	-0,40	0,13	-0,35	-0,71	0,48
PREP	P	0,03	-0,27	-0,31	-0,23	0,07	0,07	0,08	0,09	0,08	0,08	0,07	0,07	0,08	0,08	0,07	0,05	-0,37	0,08	0,04	-0,09
	S	0,05	-0,36	-0,36	-0,42	0,17	0,17	0,11	0,16	0,10	0,19	0,18	0,17	0,17	0,15	0,16	0,16	-0,45	0,17	0,14	-0,22

*K pomeni koeficient, P pomeni Pearsonov koeficient, S pomeni Spearmanov koeficient, NP pomeni »ni povezano« pri statistični značilnosti $p=0,001$.

podatkovni sloj	K.	RAZGIB_E	RAZGIB_N	RAZGIB_S	RAZGIB_V	T_APR	T_AVG	T_DEC	T_FEB	T_JAN	T_JUL	T_JUN	T_MAJ	T_MAR	T_NOV	T_OKT	T_SEP	TEKS	TEMLET	TEMRAZ	VISINA	
RAZGIB_E	P	-0,01	0,43	-0,38	0,22	0,21	0,15	0,19	0,15	0,22	0,22	0,22	0,21	0,21	0,17	0,19	0,21	0,23	0,20	0,21	-0,22	
	S		-0,01	0,44	-0,38	0,23	0,23	0,18	0,21	0,18	0,23	0,24	0,23	0,23	0,20	0,22	0,22	0,22	0,22	0,21	-0,24	
RAZGIB_N	P			0,85	0,66	-0,42	-0,40	-0,28	-0,36	-0,27	-0,41	-0,42	-0,43	-0,40	-0,33	-0,36	-0,39	0,52	-0,39	-0,40	0,43	
	S			0,84	0,76	-0,44	-0,42	-0,29	-0,37	-0,27	-0,44	-0,44	-0,44	-0,42	-0,34	-0,39	-0,40	0,56	-0,41	-0,40	0,46	
RAZGIB_S	P				0,37	-0,26	-0,24	-0,15	-0,21	-0,14	-0,25	-0,26	-0,27	-0,25	-0,18	-0,21	-0,23	0,67	-0,24	-0,28	0,28	
	S				0,46	-0,28	-0,26	-0,15	-0,22	-0,14	-0,28	-0,28	-0,28	-0,26	-0,20	-0,23	-0,25	0,68	-0,26	-0,27	0,30	
RAZGIB_V	P					-0,58	-0,55	-0,42	-0,51	-0,41	-0,57	-0,58	-0,58	-0,56	-0,47	-0,52	-0,54	0,32	-0,55	-0,52	0,60	
	S					-0,58	-0,55	-0,40	-0,51	-0,39	-0,58	-0,59	-0,58	-0,55	-0,47	-0,52	-0,54	0,43	-0,55	-0,53	0,62	
T_APR	P									0,99	0,81	0,95	0,80	0,99	1,00	0,99	0,89	0,95	0,99	-0,26	0,98	
	S									0,98	0,79	0,93	0,77	0,99	1,00	1,00	0,99	0,86	0,94	0,98	-0,31	
T_AVG	P										0,87	0,98	0,86	1,00	0,99	0,99	1,00	0,94	0,98	1,00	-0,24	
	S										0,83	0,96	0,82	1,00	0,98	0,98	0,99	0,90	0,96	1,00	-0,30	
T_DEC	P											0,95	1,00	0,86	0,81	0,79	0,87	0,99	0,94	0,88	-0,16	
	S											0,94	0,99	0,83	0,78	0,77	0,85	0,98	0,92	0,84	-0,16	
T_FEB	P												0,95	0,97	0,95	0,94	0,98	0,99	1,00	0,98	-0,22	
	S												0,93	0,95	0,93	0,92	0,97	0,98	0,99	0,96	-0,25	
T_JAN	P													0,85	0,80	0,78	0,86	0,98	0,94	0,87	-0,15	
	S													0,81	0,77	0,75	0,84	0,97	0,92	0,83	-0,15	
T_JUL	P														1,00	0,99	1,00	0,93	0,97	1,00	-0,25	
	S														0,99	0,99	1,00	0,90	0,96	0,99	-0,31	
T_JUN	P															1,00	0,99	0,89	0,95	0,99	-0,26	
	S															1,00	0,99	0,86	0,94	0,98	-0,32	
T_MAJ	P																0,99	0,88	0,94	0,98	-0,26	
	S																0,98	0,84	0,93	0,98	-0,32	
T_MAR	P																	0,93	0,98	1,00	-0,24	
	S																	0,91	0,97	0,99	-0,29	
T_NOV	P																			0,98	0,94	-0,19
	S																			0,97	0,90	-0,21
T_OKT	P																				0,98	-0,22
	S																				0,96	-0,26
T_SEP	P																					0,99
	S																					-0,23
TEKS	P																					-0,29
	S																					-0,24
TEMLET	P																					-0,29
	S																					-0,29
TEMRAZ	P																					0,65
	S																					-0,24
	P																					0,65
	S																					0,59
	P																					-0,82
	S																					-0,77

*K pomeni koeficient, P pomeni Pearsonov koeficient, S pomeni Spearmanov koeficient, NP pomeni »ni povezano« pri statistični značilnosti p=0,001.

Ob pregledu matrike povezanosti je opazna povezanost med nadmorsko višino, podatki o temperaturi (osnovni in izpeljani) in nekoliko manj močneje tudi s količino padavin po mesecih in celoletnem povprečju, kar je posledica tega, da relief z nadmorsko višino močno vpliva na podnebne značilnosti; podatek o reliefu pa je bil uporabljen tudi pri interpolaciji točkovnih podatkov (Dolinar, 2004). Padavinski režimi so z višino manj povezani, saj smo z deljenjem podatkov o mesečnih padavinah ta vpliv močno zmanjšali. Se pa padavinski režimi dokaj dobro povezujejo s temperaturnim razponom, saj je znano, da se s kontinentalnostjo letna temperaturna razlika povečuje, padavinski režim pa se nagiba v prid poletnim padavinam. Opazno je, da se padavinski režimi povezujejo s podatki o mesečnih padavinah, ne povezujejo pa se močno s temperaturami. Osončenost se opazneje povezuje le z ekspozicijo. Višinska razgibanost se povezuje z višino, naklonom, naklonsko razgibanostjo in (nekoliko manj) tudi s temperaturnimi in padavinskimi podatki; naklonska razgibanost se povezuje z višinsko razgibanostjo, naklonom, teksturo površja in skupno razgibanostjo. Slednja se povezuje tudi s teksturo. Ekspozicijska razgibanost in prepustnost se z nobenim podatkovnim slojem ne povezujeta močneje.

Izmed vseh kombinacij lahko ločimo višinsko-temperaturni dejavnik, dejavnik reliefne razgibanosti (naklon), dejavnik ekspozicije (in posledično osončenosti), dejavnik prepustnosti in padavinski dejavnik.

Do podobnih ugotovitev je prišel z izračunom Spearmanovega koeficienta tudi Ciglič (2012), ki je primerjal povezanost različnih podatkovnih slojev naravnih dejavnikov s prostorsko ločljivostjo 500 m.

6.3 Vrednotenje dejavnikov s pomočjo obstoječih klasifikacij

V geografiji je bilo narejenih veliko klasifikacij Slovenije na podlagi naravnih dejavnikov (poglavje 3), ki odražajo vrsto spoznanj. Predpostavljamo, da obstoječe, sicer ročno zarisane, klasifikacije Slovenije ustrezno prikazujejo pokrajinsko raznolikost in jih lahko uporabimo za vodilo pri izbiri podatkovnih slojev. Z računanjem povezanosti med podatkovnimi sloji in obstoječimi klasifikacijami oziroma stopnje pojasnjevalne moči podatkovnih slojev za razlago obstoječih klasifikacij dobimo dodatne informacije, kateri podatkovni sloji so bolj uporabni za klasifikacijo Slovenije in kateri manj. Spoznanja iz tega dela vrednotenja so še posebej pomembna pri izbiri podatkovnih slojev za nadzorovano klasifikacijo (poglavje 8), kjer skušamo neposredno modelirati dve obstoječi klasifikaciji oziroma z računalnikom priti do podobnih rezultatov, kot so prišli raziskovalci že pri ročnem določanju meja.

Vse zbrane podatkovne sloje smo zato primerjali z izbranimi obstoječimi klasifikacijami.

Izbrali smo tri klasifikacije Slovenije, za katere so bili dostopni digitalni zapisi:

- pokrajinski tipi (Perko, 1998a; Perko, 1998b; Perko, 2007b) – oznaka TIPI9,
- pokrajinskoekološki tipi Slovenije (Špes s sod., 2002) – oznaka TIPI13,
- pokrajinski tipi (Perko, 1998a, Perko, 1998b) – oznaka TIPI4.

Pri vrednotenju podatkovnih slojev v okviru primerjave z obstoječimi klasifikacijami smo za vsakega izračunali:

- informacijski prispevek,
- razmerje informacijskega prispevka,
- koeficient F,
- delež enako klasificiranih celic po modelu odločitvenega drevesa (različica CT),
- koeficient η^2 .

Vrednotenje podatkovnih slojev na podoben ali enak način so že uporabili na primer Ciglič (2010a) ter Tirellijeva in Pessanijeva (2011). Ciglič (2010a) je s pomočjo informacijskega prispevka in razmerja informacijskega prispevka primerjal količino informacije dveh podatkovnih slojev (višinska razlika, nadmorska višina) glede pojasnjevanja lege vinogradov v Sloveniji. Tirellijeva in Pessanijeva (2011) sta za izbor spremenljivk uporabili štiri različne

metode: h_i^2 , informacijski prispevek, razmerje informacijskega prispevka in simetrično negotovost (*Symmetrical Uncertainty*). Tudi Melo s sodelavci (2012) ter Jiang s sodelavci (2008) so vrednotili podatkovne sloje, preden so izdelali svoje modele.

Za posamezne podatkovne sloje smo izračunali vrednosti posameznih mer (načinov) vrednotenja z vidika posamezne obstoječe klasifikacije (preglednica 14). Vrednosti so izražene v indeksih povprečne vrednosti vseh podatkovnih slojev za posamezno mero vrednotenja. Ta preglednica prikazuje, kako dobro lahko podatki pojasnjujejo oziroma so povezani z obstoječimi klasifikacijami. Za posamezen podatkovni sloj smo izračunali tudi povprečno vrednost vseh indeksov za posamezno klasifikacijo (predzadnje tri kolone) in za vse klasifikacije (zadnja kolona).

Vidimo, da so v povprečju glede na vse klasifikacije najbolj informativni podatkovni sloji tisti, ki se nanašajo na podnebje (temperaturni, padavinski režimi), nadmorsko višino, prepustnost, manj informativni pa so podatkovni sloji, ki so povezani z izoblikovanostjo reliefa, osončenostjo in rečno mrežo. Izmed kazalcev izoblikovanosti reliefa sta še najbolj pomembna naklon in koeficient razgibanosti nadmorske višine.

Ob pregledu povprečnih vrednosti mer za posamezno klasifikacijo smo prišli do nekaterih spoznanj. Očitno je, da ekspozicija, koeficient razgibanosti glede na ekspozicijo, skupni koeficient razgibanosti, tekstura, osončenost, koeficient razgibanosti glede na naklon in gostota rečne mreže zasedajo pri vseh klasifikacijah zadnjih sedem mest. Ti podatkovni sloji so torej izjemno malo informativni, če želimo izdelati klasifikacijo, ki je podobna obstoječim. Pri klasifikaciji TIPI13 so nekoliko podpovprečno pomembni tudi padavinski režimi, pri klasifikacijah TIPI9 in TIPI4 pa sta manj pomembna tudi naklon in koeficient razgibanosti glede na višino. Najbolj pomembne so spremenljivke o temperaturi in padavinah. Njihova pomembnost verjetno izvira iz dejstva, da dobro ponazarjajo nadmorsko višino, hkrati pa obstajajo tudi nekatere razlike med območji glede na temperature oziroma padavine, kar viša informativno vrednost.

Preglednica 14: Pojasnjevalna moč in stopnja povezanosti podatkovnih slojev z obstoječimi klasifikacijami Slovenije. Statistična značilnost posameznih izračunanih koeficientov F in η^2 je manjša od $p=0,001$, kar pomeni, da je statistična značilnost teh lestvic $p=0,041$.

oznaka podatkovnega sloja	koeficient F			delež enako klasificiranih po odločitvenem drevesu (CT)			informacijski prispevek			razmerje informacijskega prispevka			koeficient η^2			povprečje po tipizacijah			povprečje vse tipizacije
	F			ODL			IG			GR			E2						
	TIP14	TIP19	TIP113	TIP14	TIP19	TIP113	TIP14	TIP19	TIP113	TIP14	TIP19	TIP113	TIP14	TIP19	TIP113	TIP14	TIP19	TIP113	
APRMOKT	1,54	1,57	1,66	1,07	1,11	1,11	1,30	1,24	1,24	1,25	1,17	1,17	1,42	1,30	1,32	1,32	1,28	1,30	1,30
EKSP0	0,01	0,01	0,01	0,75	0,56	0,59	0,04	0,04	0,04	0,07	0,08	0,08	0,01	0,03	0,02	0,18	0,15	0,15	0,16
GRM500	0,29	0,23	0,26	0,94	0,84	0,87	0,33	0,33	0,36	0,73	0,74	0,85	0,41	0,41	0,48	0,54	0,51	0,56	0,54
NAKLON	0,66	0,75	0,86	0,95	0,90	0,99	0,47	0,68	0,75	0,67	1,02	1,18	0,80	0,92	1,00	0,71	0,85	0,96	0,84
OSONC	0,24	0,15	0,11	0,86	0,78	0,84	0,45	0,51	0,48	0,59	0,69	0,69	0,34	0,29	0,24	0,50	0,49	0,47	0,49
P_APR	0,78	1,09	1,12	1,14	1,16	1,14	1,38	1,30	1,26	1,28	1,15	1,10	0,91	1,12	1,13	1,10	1,16	1,15	1,14
P_AVG	1,33	1,43	1,18	1,07	1,07	1,00	1,23	1,19	1,11	1,13	1,10	1,00	1,30	1,25	1,16	1,21	1,21	1,09	1,17
P_DEC	0,78	0,81	0,76	0,96	0,98	1,01	1,18	1,17	1,15	1,04	1,01	0,99	0,91	0,96	0,94	0,97	0,99	0,97	0,98
P_FEB	0,82	0,89	0,90	0,97	0,99	0,98	1,02	1,04	1,06	0,92	0,92	0,93	0,94	1,01	1,03	0,93	0,97	0,98	0,96
P_JAN	0,70	0,79	0,75	0,95	1,02	0,97	1,13	1,13	1,12	1,01	0,98	0,97	0,84	0,95	0,94	0,93	0,98	0,95	0,95
P_JUL	1,81	2,01	1,30	1,14	1,11	1,03	1,36	1,32	1,18	1,27	1,23	1,04	1,56	1,41	1,21	1,43	1,42	1,15	1,33
P_JUN	1,31	1,39	1,35	1,07	1,07	1,08	1,20	1,22	1,22	1,09	1,10	1,07	1,29	1,24	1,22	1,19	1,21	1,19	1,19
P_MAJ	0,61	0,90	0,97	1,10	1,13	1,10	1,21	1,17	1,20	1,12	1,08	1,07	0,75	1,02	1,07	0,96	1,06	1,08	1,03
P_MAR	0,78	1,02	1,12	1,00	1,05	1,06	1,14	1,14	1,15	1,10	1,02	1,02	0,91	1,08	1,13	0,99	1,06	1,10	1,05
P_NOV	0,66	0,88	0,84	1,00	1,09	1,08	1,26	1,25	1,20	1,18	1,11	1,06	0,79	1,01	1,00	0,98	1,07	1,03	1,03
P_OKT	0,95	0,99	0,97	1,06	1,07	1,09	1,34	1,28	1,24	1,18	1,09	1,06	1,04	1,07	1,06	1,11	1,10	1,09	1,10
P_SEP	0,88	1,09	0,99	1,05	1,10	1,07	1,26	1,25	1,22	1,20	1,12	1,07	0,99	1,12	1,08	1,08	1,14	1,09	1,10
PADLET	0,83	1,08	1,09	1,07	1,11	1,11	1,27	1,25	1,24	1,20	1,13	1,09	0,95	1,11	1,12	1,06	1,13	1,13	1,11
PADRAZPJ	2,09	1,30	0,80	1,01	0,96	0,91	1,30	1,15	1,05	1,17	0,96	0,87	1,68	1,21	0,97	1,45	1,12	0,92	1,16
PADRAZPZ	1,85	1,10	0,63	0,96	0,92	0,90	1,17	1,11	1,03	1,00	0,90	0,83	1,57	1,12	0,86	1,31	1,03	0,85	1,06
PADRAZM	1,65	1,07	0,71	0,97	0,94	0,94	1,17	1,09	1,00	1,02	0,91	0,84	1,48	1,10	0,91	1,26	1,02	0,88	1,05
PREP	0,25	0,37	0,34	0,99	1,08	1,11	0,99	1,01	0,93	2,17	2,31	2,14	0,35	0,59	0,57	0,95	1,07	1,02	1,01
RAZGIB_E	0,06	0,07	0,07	0,75	0,58	0,61	0,05	0,08	0,09	0,10	0,16	0,17	0,10	0,14	0,15	0,21	0,21	0,22	0,21
RAZGIB_N	0,43	0,51	0,47	0,92	0,81	0,87	0,33	0,50	0,54	0,49	0,81	0,91	0,56	0,74	0,71	0,55	0,67	0,70	0,64
RAZGIB_S	0,21	0,33	0,29	0,82	0,69	0,75	0,18	0,31	0,32	0,32	0,56	0,58	0,30	0,54	0,51	0,37	0,49	0,49	0,45
RAZGIB_V	0,62	0,70	0,82	0,94	0,93	1,00	0,49	0,71	0,78	0,71	1,08	1,21	0,76	0,89	0,98	0,70	0,86	0,96	0,84
T_APR	1,01	1,21	1,51	1,08	1,14	1,13	1,20	1,19	1,25	1,08	1,06	1,11	1,09	1,17	1,27	1,09	1,15	1,26	1,17
T_AVG	1,02	1,18	1,44	1,05	1,09	1,09	1,16	1,16	1,23	1,06	1,04	1,09	1,09	1,16	1,25	1,08	1,13	1,22	1,14
T_DEC	2,53	1,69	1,33	1,03	1,00	0,92	1,26	1,15	1,07	1,23	1,07	0,97	1,84	1,34	1,22	1,58	1,25	1,10	1,31
T_FEB	1,43	1,24	1,33	1,04	1,05	1,02	1,17	1,11	1,14	1,10	1,01	1,02	1,36	1,18	1,22	1,22	1,12	1,15	1,16
T_JAN	2,43	1,61	1,28	1,01	1,01	0,91	1,20	1,11	1,04	1,19	1,03	0,93	1,81	1,31	1,20	1,53	1,21	1,07	1,27
T_JUL	1,01	1,22	1,47	1,06	1,12	1,13	1,18	1,19	1,26	1,08	1,08	1,12	1,09	1,17	1,26	1,08	1,15	1,25	1,16


T_JUN	0,99	1,24	1,58	1,07	1,16	1,18	1,19	1,20	1,29	1,08	1,08	1,15	1,07	1,18	1,30	1,08	1,17	1,30	1,18
T_MAJ	0,98	1,22	1,57	1,07	1,16	1,17	1,18	1,19	1,26	1,06	1,06	1,12	1,06	1,18	1,29	1,07	1,16	1,28	1,17
T_MAR	1,06	1,17	1,41	1,07	1,10	1,09	1,18	1,15	1,21	1,07	1,02	1,08	1,12	1,15	1,24	1,10	1,12	1,21	1,14
T_NOV	1,77	1,43	1,33	1,03	1,02	0,99	1,21	1,16	1,12	1,17	1,07	1,02	1,54	1,25	1,22	1,35	1,19	1,14	1,22
T_OKT	1,36	1,30	1,43	1,06	1,10	1,05	1,21	1,16	1,18	1,16	1,07	1,08	1,32	1,21	1,25	1,22	1,17	1,20	1,20
T_SEP	1,00	1,16	1,43	1,06	1,10	1,10	1,17	1,16	1,22	1,07	1,05	1,10	1,08	1,15	1,25	1,07	1,12	1,22	1,14
TEKS	0,18	0,25	0,27	0,83	0,69	0,77	0,18	0,30	0,32	0,34	0,61	0,65	0,26	0,45	0,48	0,36	0,46	0,50	0,44
TEMLET	1,21	1,24	1,43	1,04	1,12	1,08	1,22	1,17	1,22	1,15	1,07	1,09	1,23	1,18	1,25	1,17	1,16	1,22	1,18
TEMRAZ	1,08	1,29	1,42	0,97	1,00	1,01	1,10	1,15	1,16	0,98	1,02	1,04	1,14	1,20	1,25	1,06	1,13	1,18	1,12
VISINA	0,82	1,00	1,38	1,02	1,09	1,14	0,91	0,98	1,08	1,17	1,24	1,42	0,94	1,07	1,23	0,97	1,08	1,25	1,10

Usklajenost mer vrednotenja

Pri vrednotenju se lahko vprašamo, ali so ocene smiselne oziroma verodostojne. Z namenom odgovoriti na to vprašanje, smo ugotavljali usklajenost lestvic različnih načinov vrednotenja za posamezno klasifikacijo in preverili, kakšna je povezanost med posameznimi načini oziroma merami vrednotenja (slike 10, 11 in 12). Predpostavljamo, da moramo za relevantno vrednotenje upoštevati različne načine vrednotenja; če so ti med seboj usklajeni, bolje zaupamo v vrednotenje.


Tako smo ugotovili, da se merske lestvice med seboj statistično značilno ($p=0,01$) povezujejo po izračunu Pearsonovega koeficienta in tudi po izračunu Spearmanovega koeficienta (priloga 7). Nekoliko manjša je bila ugotovljena povezanost med vrednostjo koeficienta F in razmerjem informacijskega prispevka ter η^2 in razmerjem informacijskega prispevka, najbolj povezani pa sta lestvici koeficienta F in η^2 , kar je logično, saj imata podoben izračun.

Slika 10: Grafikonu povezanosti med načini vrednotenja podatkov glede na TIPI4.



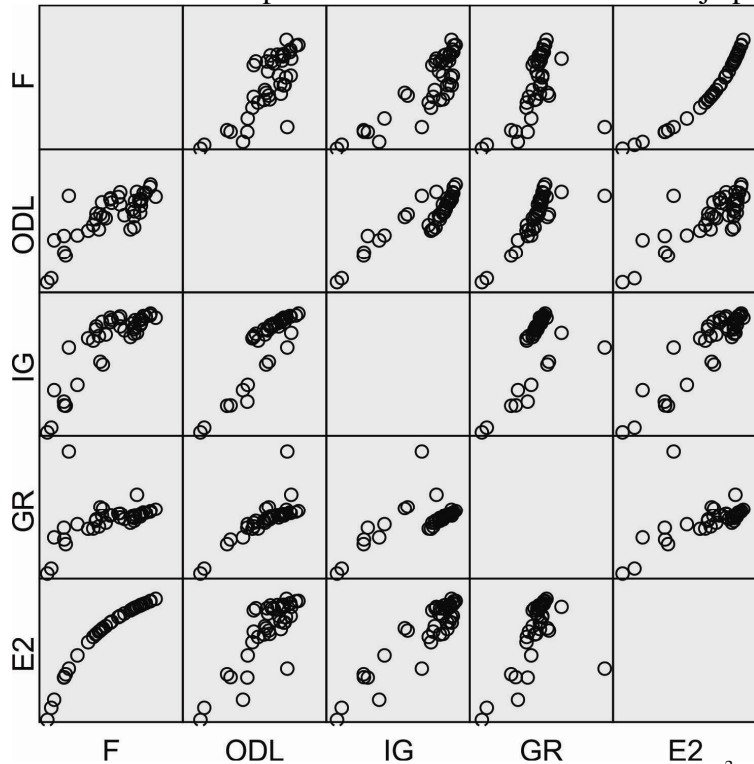
Oznake v grafikonu pomenijo: F – koeficient F, E2 – koeficient η^2 ; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; ODL – delež enako klasificiranih celic po odločitvenem drevesu, različica CT.

Slika 11: Grafikoni povezanosti med načini vrednotenja podatkov glede na TIPI9.



Oznake v grafikonu pomenijo: F – koeficient F, E2 – koeficient η^2 ; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; ODL – delež enako klasificiranih celic po odločitvenem drevesu, različica CT.

Slika 12: Grafikoni povezanosti med načini vrednotenja podatkov glede na TIPI13.




Oznake v grafikonu pomenijo: F – koeficient F, E2 – koeficient η^2 ; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; ODL – delež enako klasificiranih celic po odločitvenem drevesu, različica CT.

Usklajenost povprečnih mer vrednotenja med klasifikacijami

Pomembnost podatkovnih slojev se je izkazala za zelo podobno z vidika vseh treh obstoječih klasifikacij (slika 13). Tudi med vsemi lestvicami s povprečno vrednostjo obstaja visoka povezanost tako po izračunanem Pearsonovem koeficientu kot tudi po Spearmanovem koeficientu (priloga 7). Nekoliko manjša stopnja povezanosti je pri izračunanem Spearmanovem koeficientu med lestvicama vrednotenja glede na TIPI13 in vrednotenja glede na TIPI4. To sta klasifikaciji, ki imata najbolj različno število tipov. Visoka stopnja povezanosti pomeni, da so za vse klasifikacije v splošnem pomembni isti podatkovni sloji.

Slika 13: Povezanost povprečnih vrednosti pri vrednotenju podatkov z vidika posamezne klasifikacije.



6.4 Vrednotenje dejavnikov glede na raven (prostorsko merilo) klasifikacije

V pregledu teorije (poglavje 2) smo obravnavali raven klasifikacije oziroma pomen naravnogeografskih dejavnikov za klasifikacije različno velikih območij (celine, države, manjše enote ...). V literaturi so pogosto objavljene preglednice, v katerih so navedeni dejavniki ter pripadajoča raven oziroma prostorsko merilo, v katerem naj bi se določen dejavnik najbolj obnesel pri klasifikaciji pokrajine. V tem delu naloge temu teoretičnemu pregledu dodajamo praktičnega. Z izračunom povprečnega umerjenega koeficienta (PUKV, podroben opis je v prilogi 4), ki temelji na koeficientu variacije (KV), smo namreč poskušali na računski način ovrednotiti zbrane podatkovne sloje z vidika prostorskega merila.

Za uvod, kako lahko takšne izračune uporabimo pri vrednotenju podatkovnih slojev, na začetku predstavljamo praktično zasnovano domnevo:

»Koefficient variacije za nadmorsko višino za Slovenijo je 63 %. Če Slovenijo razdelimo na manjše enote (na primer tipe ali pa na kvadratne enote, ki jih dobimo, če Slovenijo razdelimo s preprosto mrežo), lahko pričakujemo, da se bo znotraj vsake posamezne enote spremenljivost zmanjšala. Če izračunamo povprečje vseh KV-jev posameznih enot, dobimo povprečni KV, ki ima navadno nižjo vrednost, kot pa je vrednost KV za območje celotne Slovenije; to velja še posebej, če za izračun KV-ja vsake enote vzamemo povprečje za Slovenijo (in ne povprečje enote). Čim manjše so enote, tem manjši so KV-ji. Takšne rezultate

sicer pričakujemo za večino slojev, a domnevamo, da se izračunane vrednosti za sloje z zmanjševanjem velikosti posameznih enot (tipov ali kvadratov) različno spreminjajo. Razlike v stopnji spreminjanja lahko nakažejo, kako se pomen podatkovnega sloja spreminja glede na prostorsko merilo.»

V tem delu vrednotenja smo Slovenijo razrezali na manjša območja s pomočjo mrež različnih razmikov. Dobili smo Slovenijo, ki je razdeljena na kvadrate (z izjemo mejnih območij, ki niso kvadratna; glej sliki 105 in 106 v prilogi 4). Za vsak podatkovni sloj smo nato izračunali povprečni umerjeni koeficient variacije (PUKV) za različno velike razdelitve (mreže kvadratov z velikostjo stranic 100, 50, 10 in 5 km) ter tudi za območje celotne Slovenije kot ene enote (preglednica 15).


Preglednica 15: PUKV za razdelitev Slovenije na različne enote.

oznaka podatkovnega sloja	vrednost PUKV za mreže z različnimi razmiki (%)				vrednost PUKV za Slovenijo (%)
	5 km	10 km	50 km	100 km	
APRMOKT	5,5	8	14,4	17	24,2
EKSPO	40,5	41,9	42,9	43	43,3
GRM500	66,6	75,4	90	92,6	96,2
NAKLON	42,9	48,8	60,6	63,7	73,2
OSONC	11,4	12,2	13,3	13,8	15
PADLET	7,2	11,5	27,9	36,9	63
PADRAZPJ	3,2	5,5	14,2	20,2	40,4
PADRAZPZ	4,4	7,4	18,3	24,3	46,8
PADRAZM	4,7	7,8	18	22,6	38,1
P_APR	7,7	12,3	30,1	39,9	71,1
P_AVG	8,3	13,3	28,9	36,1	53,7
P_DEC	7,6	12,4	30	39,6	68,5
P_FEB	8,7	14	30,5	37,6	61,1
P_JAN	9	14,5	33,4	43	76,9
P_JUL	5,1	8,4	21,8	27,3	44,9
P_JUN	5,5	9	21,6	28,8	45,1
P_MAJ	6,6	10,8	27,5	36,9	66,5
P_MAR	9,1	14,2	30,5	37,7	63,4
P_NOV	7,6	12	30,5	41,8	75,6
P_OKT	6,8	11,2	27,9	37,4	58,7
PREPS	20,9	23,9	29,7	30,1	33
P_SEP	6,5	10,3	25,6	35,7	59,5
RAZGIB_E	33,2	34,3	35,8	36	36,6
RAZGIB_N	38	42,2	50,3	51,9	56,6
RAZGIB_S	30,8	33,5	38,1	38,8	40,7
RAZGIB_V	46,7	53,1	66,4	70,3	84,3
T_APR	4,9	7	13,6	15,5	19,6
T_AVG	4,7	6,9	13,9	16,1	19,9
T_DEC	4,2	6,2	14,6	19,4	25,6
TEKS	50	54,5	61,8	62,9	65,4
TEMLET	4,8	6,9	13,7	16	20
TEMRAZ	5,4	7,7	13,6	16,1	21,3
T_FEB	4,9	7,1	14,4	17,2	21,2
T_JAN	4,2	6,4	15	19,6	25,6
T_JUL	4,8	7	13,7	15,6	19,4
T_JUN	4,9	7	13,4	15,2	19,3
T_MAJ	4,8	6,9	13,3	15,1	19,3
T_MAR	4,9	7,1	14	16,1	20,1
T_NOV	4,5	6,5	14	17,3	22,3
T_OKT	4,6	6,7	13,7	16,3	20,6
T_SEP	4,7	6,8	14	16,3	20,1
VISINA	20,8	27,9	46,9	51,4	64,3


Po pregledu rezultatov (preglednica 15) na izbranih ravneh opazimo, da se nekaterim podatkovnim slojem vrednost PUKV med ravnmi ne spreminja (na primer ekspozicija, osončenost), večina pa ima visoko vrednost po izračunu za večja območja, nato pa se vrednosti z zmanjševanjem enote različno hitro znižujejo. Tu opozarjamo, da so vrednosti podnebnih podatkovnih slojev nekoliko nižje tudi zaradi grobe ločljivosti izvirnih podatkov. Za vsak podatkovni sloj smo nato primerjali vrednosti po izbranih ravneh (5 km, 10 km, 50 km, 100 km) z vrednostjo, ki velja za Slovenijo kot eno enoto (slika 14). To smo naredili zaradi boljše primerljivost vedenja podatkovnih slojev na različnih ravneh, saj nas ne zanimajo njihove absolutne vrednosti za posamezne ravni. Tako smo ugotovili, kateri sloji so bolj pomembni v večjem merilu (za večje kvadrate), kateri v manjšem (za manjše kvadrate) in na katere podatkovne sloje sprememba merila v izbranem razponu ni pokazala vpliva¹¹. Z Wardovo metodo hierarhičnega razvrščanja smo na podlagi teh vrednosti dobili tri skupine (slika 15): v prvi so temperaturni podatkovni sloji in nadmorska višina, v drugi padavinski podatki, v tretji pa ostali podatki (razgibanost površja, ekspozicija, prepustnost ...). Ob pregledu grafikona je opazno, da to razdelitev lahko potrdimo, dodatno pa bi lahko določili še četrto skupino, saj vidimo, da močno izstopata ekspozicija in koeficient razgibanosti glede na ekspozicijo, ki imata vrednosti PUKV na vseh analiziranih ravneh približno enake vrednosti koeficienta variacije za celo Slovenijo in bi lahko tvorila ločeno skupino. To, izjemno blago zmanjševanje vrednosti PUKV, lahko dejansko pomeni tudi šum v podatkovni zbirki! Podatkovni sloji, katerim vrednosti z manjšanjem računskih ploskev najhitreje padejo, so dobri predvsem za določanje večjih enot. Mednje spadajo podatki o količini padavin ter padavinskih režimih. Zelo hitro padajo tudi vrednosti za podatke o temperaturi, temperaturnih režimih in nadmorski višini. Ostalim podatkovnim slojem vrednosti upadajo počasneje (gre predvsem za prepustnost, gostoto rečne mreže, osončenost ter razne podatke o reliefu), kar pomeni, da so primerna tudi za razmejevanje na manjših (lokalnih) območjih.

¹¹ Da sprememba merila (velikosti kvadratov) ne vpliva, trdimo le za ravni, ki smo jih analizirali (5, 10, 50, 100 km). Teoretično se ob zelo podrobni mreži (razdelitev na le nekoliko večje kvadrate, kot je ločljivost rastrov) vsi podatkovni sloji približajo vrednosti 0. To pomeni, da je na zelo majhnem (lokalnem) območju, velikem le nekaj celic, ponavadi spremenljivost zelo majhna ali celo nična.

Slika 14: Stopnja spreminjanja PUKV glede na vrednost za Slovenijo (PUKVSI=1).



Slika 15: Z Wardovo metodo smo hierarhično združili podatkovne sloje glede na njihove vrednosti spreminjanja PUKV glede na vrednost za Slovenijo.



Glede na vrednotenje posameznih podatkovnih slojev z vidika informativnosti za izbrane obstoječe klasifikacije in rezultate analize ravni lahko povzamemo, da gre pri obstoječih klasifikacijah za razdelitev Slovenije na prostorsko večje enote. Kot bolj pomembni so se namreč izkazali podatkovni sloji, povezani s podnebjem, poleg teh pa tudi nadmorska višina. Manjši pomen osončenosti, ekspozicije, koeficientov reliefnih razgibanosti in podobnih to

potrjujejo. Razlog tiči v dejstvu, da je variabilnost tu zelo velika in onemogoča dobro razmejitev na državni ravni.

6.5 Povzetek vrednotenja spremenljivk

Za celostno vrednotenje podatkovnih slojev je dobro analizirati:

- preglednico 12, ki prikazuje vpliv izstopajočih vrednosti,
- preglednico 13, ki prikazuje medsebojno povezanost,
- preglednico 14, ki prikazuje, kako dobro pojasnjujejo podatkovni sloji obstoječe klasifikacije Slovenije, ter
- sliko 14, ki prikazuje, kako se podatkovni sloji »obnašajo« na različnih prostorskih ravneh.

Prepričani smo, da ob spoznanjih iz literature in predstavljenem kvantitativnem vrednotenju podatkovnih slojev lažje izberemo podatkovne sloje za klasifikacijo Slovenije na tipe naravne pokrajine.

Pred izvedbo metod nenadzorovane klasifikacije (poglavje 7) in metod nadzorovane klasifikacije (poglavje 8) smo se pri izbiri podatkovnih slojev oprli na rezultate vrednotenja podatkovnih slojev, ki so prikazani v tem poglavju. Razlogi za izbor podatkovnih slojev so navedeni na začetku obeh poglavij (7 in 8).

7. Vrednotenje različnih naravnopokrajinskih tipizacij Slovenije, izdelanih z metodami nenadzorovane klasifikacije

V tem poglavju smo uporabili različne metode nenadzorovane klasifikacije ter z izbranimi podatkovnimi sloji izdelali modelirane naravnopokrajinske tipizacije. Dobljene tipizacije smo nato ovrednotili; primerjali smo jih in ugotavljali, katere klasifikacije so ovrednotene kot boljše ter kako se različni načini vrednotenja oziroma lestvice vrednotenja med seboj sploh ujemajo. Velik poudarek naloge je ravno preučevanje, kako dobro se razni načini vrednotenja med seboj ujemajo.

Glavni nameni tega dela analize so bili:

- preizkusiti različne načine vrednotenja in jih med seboj primerjati glede usklajenosti,
- ugotoviti, kako število skupin vpliva na vrednotenje klasifikacij,
- ugotoviti oddaljenost posameznih celic od povprečnih vrednosti tipa,
- ugotoviti, kakšno je medsebojno ujemanje izdelanih klasifikacij po različnih metodah glede na število skupin.

Tovrsten način preizkusa klasifikacij in različnih geoinformacijskih orodij se nam je zdel smiseln, saj smo morali preučiti nekatere značilnosti vrednotenja (vpliv števila skupin in vpliv izbranega geoinformacijskega orodja na rezultat). Nekakšne splošne kvantitativne metode za vrednotenje različnih klasifikacij pokrajin namreč ni. V statističnem smislu namreč ni »napačnih« ali »resničnih« pokrajin, tipov in drugih prostorskih enot. Pogost in uveljavljen način vrednotenja klasifikacij je le primerjava z ročno določenimi (ekspertnimi) klasifikacijami (Hargrove, Hoffman, 2005, 56). Zaradi zadnjega dejstva smo se lotili še bolj obširne raziskave z metodami nadzorovane klasifikacije (poglavje 8).

7.1 Zasnova izdelave naravnopokrajinskih tipizacij z metodami nenadzorovane klasifikacije

V tem poglavju navajamo, kako smo izbrali podatkovne sloje in geoinformacijska orodja, s katerimi smo izdelali različne tipizacije, ki smo jih nato vrednotili na različne načine.

7.1.1 Izbor geoinformacijskih orodij

Izbrali smo 10 metod nenadzorovane klasifikacije (preglednica 16) in štiri različna števila skupin (tipov):

- 2 skupini (tipa),
- 5 skupin (tipov),
- 10 skupin (tipov),
- 15 skupin (tipov).

Geoinformacijska orodja oziroma metode, ki smo jih uporabili, so vključeni v programe SPSS, Statistica in Idrisi. V programu SPSS smo uporabili metodo voditeljev z načinom računanja centroidov po prestavljanju vseh enot in tudi način računanja centroidov po prestavljanju vsake posamezne enote. V programu Statistica smo uporabili metodo voditeljev z izborom začetnih skupin (*clustrov*), ki imajo maksimalne razdalje med seboj, ter z izborom centroidov na podlagi intervala na lestivici razdalj. V programu Idrisi smo prav tako uporabili metodo voditeljev s tremi različnimi nastavitvami izbora začetnih centroidov, poleg tega pa smo v Idrisiju uporabili še metodo analize vrhov v histogramu, metodo iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (ISOCLUST) ter metodo segmentacije. Tu je treba dodati, da smo pri nekaterih postopkih metode voditeljev v Idrisiju šele s poskušanjem dobili želeno število skupin¹².

¹² Pri načinu določanja začetnih centroidov s pomočjo diagonalnih osi (*diagonal axis*) smo za dosego 5 skupin morali pri nastavitvah dati največje možno število skupin na 6, za 10 skupin na 21, za 15 skupin na 38; pri

Preglednica 16: Pregled metod nenadzorovane klasifikacije.

oznaka	metoda	modul (računalniški program)	nastavitve
01SPSS	metoda voditeljev (računanje centroidov po prestavljanju vseh enot)	K-Means Cluster Analysis (SPSS)	število prestavljanj: 999 kriterij konvergence: 0
02STAT1	metoda voditeljev (centroidi so določeni na podlagi začetnih skupin, ki so najbolj oddaljeni drug od druge)	K-means clustering (Statistica)	število prestavljanj: 99
03STAT2	metoda voditeljev (določitev začetnih centroidov na podlagi določenega intervala)	K-means clustering (Statistica)	število prestavljanj: 99
04SPSS2	metoda voditeljev (računanje centroidov po prestavljanju vsake enote)	K-Means Cluster Analysis (SPSS)	število prestavljanj: 999 kriterij konvergence ¹³ : 0
05KM1	metoda voditeljev (izbor začetnih centroidov je naključen; <i>random seed</i>)	KMEANS (Idrisi)	kriterij prekinitve: -odstotek celic, ki se prestavijo mora biti vsaj 1 % -število prestavljanj: 999; združitev skupin z deležem manj kot 1 %
06KM2	metoda voditeljev (izbor začetnih centroidov: glede na interval diagonalne osi v večrazsežnostnem prostoru spremenljivk; <i>diagonal axis</i>)	KMEANS (Idrisi)	kriterij prekinitve: -odstotek celic, ki se prestavijo mora biti vsaj 1 % -število prestavljanj: 999; združitev skupin z deležem manj kot 1 %
07KM3	metoda voditeljev (izbor začetnih centroidov: naključna razdelitev vseh enot in naknadna določitev centroidov; <i>random partition</i>)	KMEANS (Idrisi)	kriterij prekinitve: -odstotek celic, ki se prestavijo mora biti vsaj 1 % -število prestavljanj: 999; združitev skupin z deležem manj kot 1 %
08CL	analiza vrhov v histogramu	CLUSTER (Idrisi)	število svin: 6 delež saturacije: 1 posplošenost: fina pravilo združevanja: maksimalno število skupin
09ISO	metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (ISOCLUST)	ISOCLUST (Idrisi)	število prestavljanj: 3 število celic v vzorcu: 30
10SEG	segmentacija	SEGMENTATION (Idrisi)	okno: 3 x 3 celice, uteži podatkovnih slojev: enake (1/3), razmerje med varianco in povprečjem je 0,5 : 0,5, korak segmentacije (združevanja): čim manjši (0, 4, 8 itd.) ¹⁴

določanju začetnih centroidov z naključno razdelitvijo (*random partition*) pa smo za 10 skupin nastavili največjo možnost število skupin na 50, za 15 skupin pa na 112.

¹³ Pri klasifikaciji s 15 tipi se je proces končal pri 999 prestavljanjih.

¹⁴ Pri določitvi 15 segmentov smo poiskali najbližjo rešitev med tolerančnima pragovoma 120 (17 enot) in 124 (14 enot), ki je bila na tolerančnem pragu 121 (16 enot). Preverili smo, kakšna je razlika med 16 in 14 enotami, in ugotovili, da se vmes združijo 3 enote v 1 (1 enota meji na vsako stran na 1 sosedo). Za določitev 15 smo zato naredili dve različici (15a in 15b). Pri vsaki smo združili osrednjo enoto z eno izmed sosednjih enot.

7.1.2 Izbor podatkovnih slojev

Na podlagi literature in kvantitativnega vrednotenja (medsebojna povezanost, odstopajoče vrednosti in spreminjanje povprečnega umerjenega koeficienta variacije med posameznimi ravnmi) smo za izdelavo tipizacij z metodami nenadzorovane klasifikacije izbrali naslednje podatkovne sloje:

- povprečna letna temperatura (oznaka TEMLET),
- naklon (oznaka NAKLON),
- prepustnost (oznaka PREP).

Pred dokončnim izborom smo poskusili izbrati podatkovne sloje, ki bi ponazarjali čim bolj različne naravne dejavnike. Nato smo preverili tudi kvantitativno vrednotenje (poglavje 6). Prepustnost smo izbrali zato, ker gre za podatkovni sloj, ki ponazarja kamnine. Povprečno letno temperaturo pa zato, ker je to klimatski podatek, ki je najbolj povezan z nadmorsko višino, povezan (a šibkeje) pa je tudi s podatki za mesečne in letno količino padavin. Naklon je tipičen podatkovni sloj, ki ponazarja izoblikovanost površja, povezan pa je s koeficientom razgibanosti glede na naklon in glede na višino. Naklon in povprečna letna temperatura imata mersko lestvico z vidika odstopajočih vrednosti podobno, prepustnost pa je bila iz nominalnega transformirana v številski podatek na isti lestvici, a ima zaradi bolj porazdeljenih vrednosti nekoliko prednosti pred vsemi sloji pri metodah, pri katerih se upošteva Evklidova razdalja. V analizo nismo vzeli podatka, ki bi lahko povzročil »šum«, na primer ekspozicije ali koeficienta razgibanosti glede na ekspozicijo.

Preglednica 17: Stopnja povezanosti izbranih podatkovnih slojev.

	koeficient	NAKLON	PREP	TEMLET
NAKLON	Pearsonov koeficient	1,000	-0,312	-0,529
	Spearmanov koeficient	1,000	-0,442	-0,531
PREP	Pearsonov koeficient		1,000	0,077
	Spearmanov koeficient		1,000	0,172
TEMLET	Pearsonov koeficient			1,000
	Spearmanov koeficient			1,000

Povezanost med za to analizo izbranimi podatkovnimi sloji smo preverili z izračunom Pearsonovega in Spearmanovega koeficienta (preglednica 17) ter tudi z analizo glavnih komponent. Metoda glavnih komponent je pokazala, da najmanjša še vedno pojasnjuje kar 13,9 % variacije (preglednici 18 in 19).

Preglednica 18: Delež pojasnjene variance, ki jo pojasni posamezna glavna komponenta po metodi glavnih komponent s podatkovnimi sloji prepustnost, povprečna letna temperatura in naklon.

komponenta	delež pojasnjene variance (%)
1	55,0
2	31,1
3	13,9

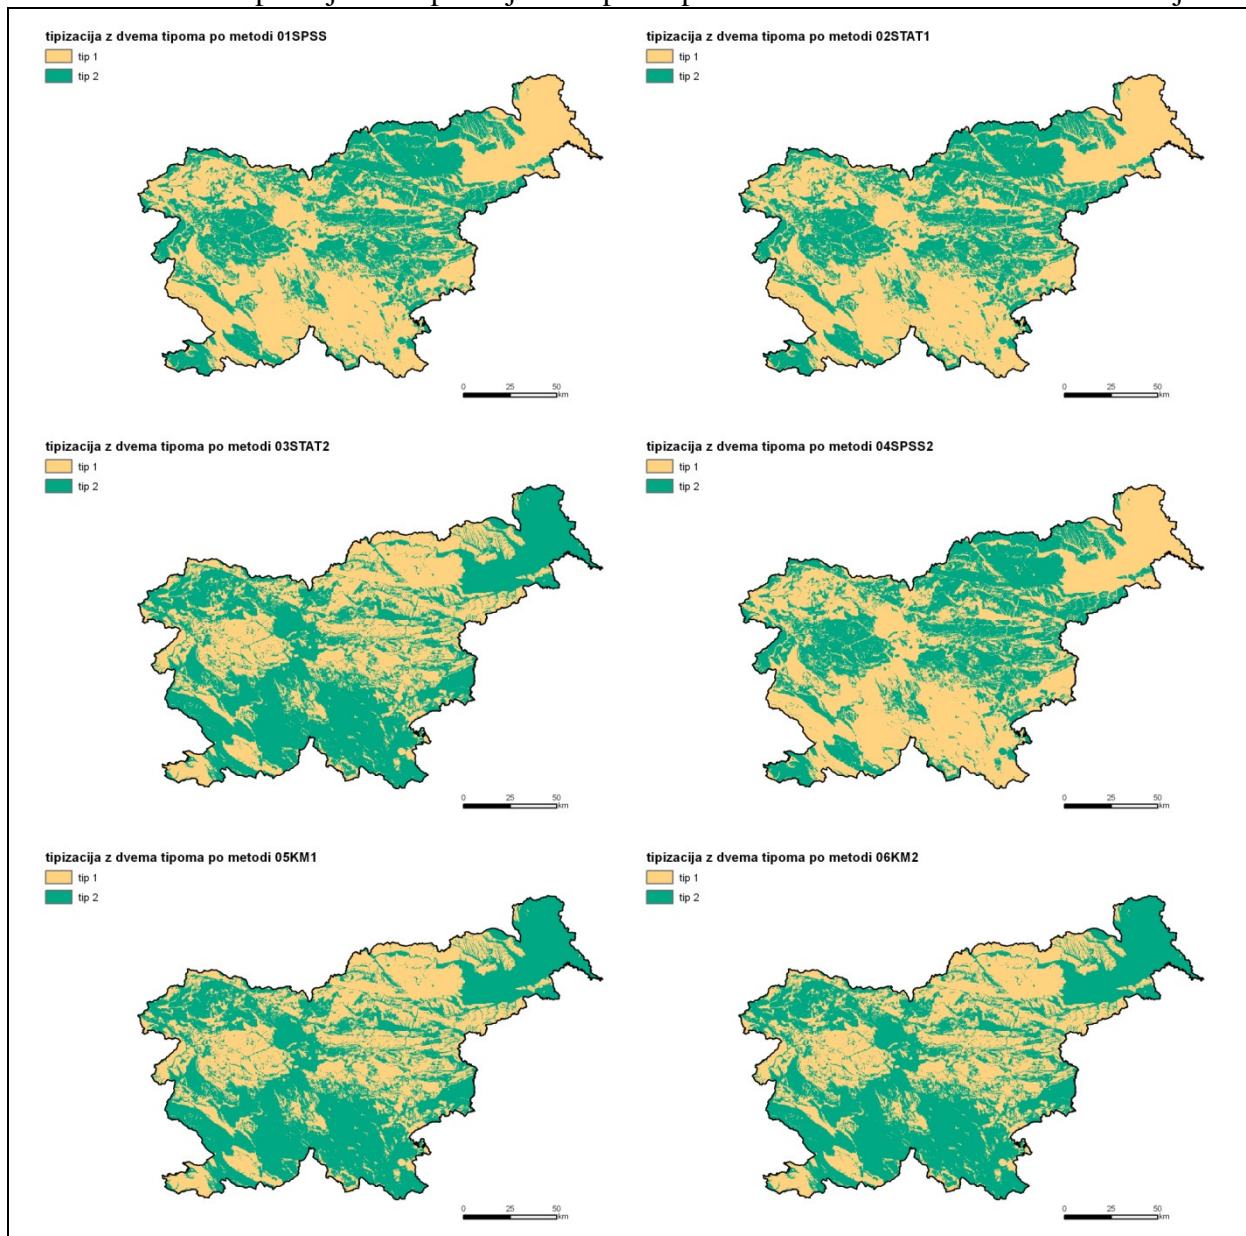
Preglednica 19: Povezanost glavnih komponent s posameznimi podatkovnimi sloji.

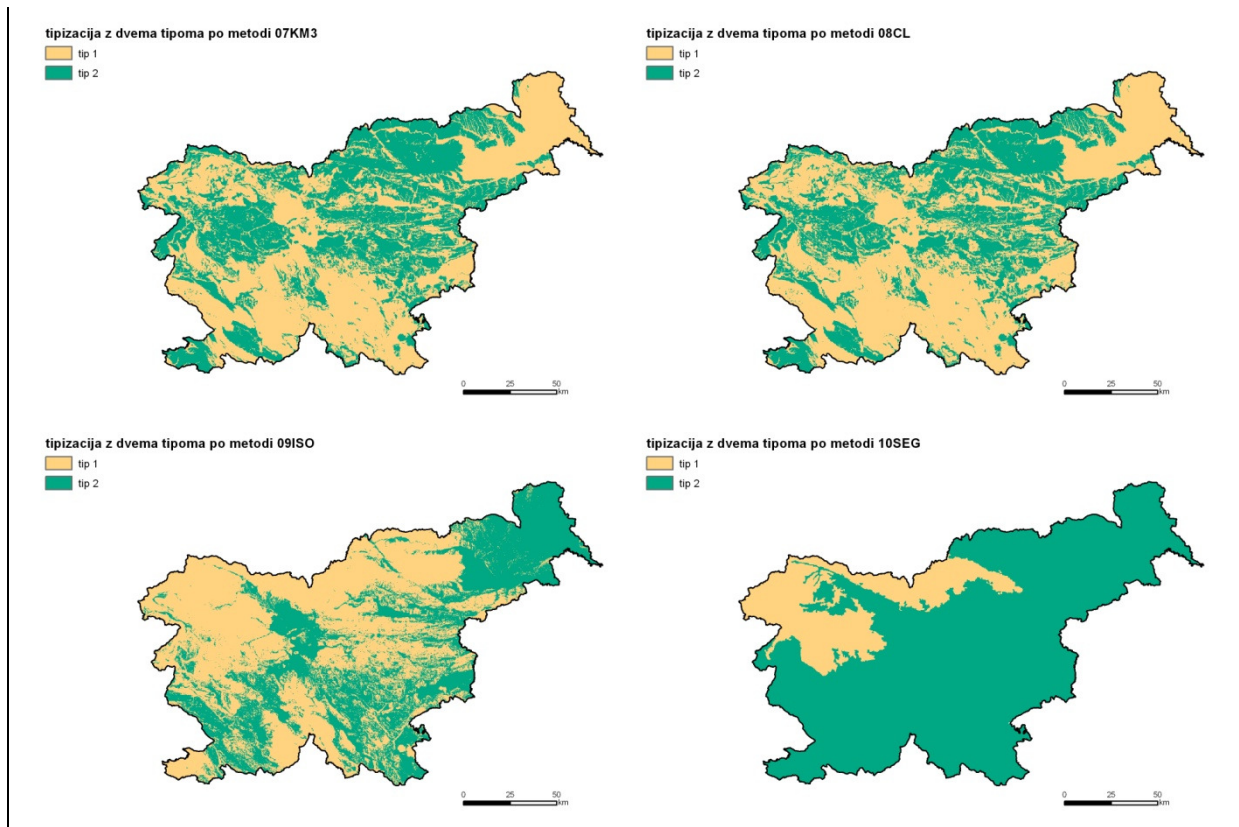
podatkovni sloj	glavne komponente		
	1	2	3
NAKLON	-0,882	0,060	0,468
PREP	0,516	0,833	0,198
TEMLET	0,778	-0,485	0,399

7.2 Modelirane naravnopokrajinske tipizacije po posameznih metodah nenadzorovane klasifikacije

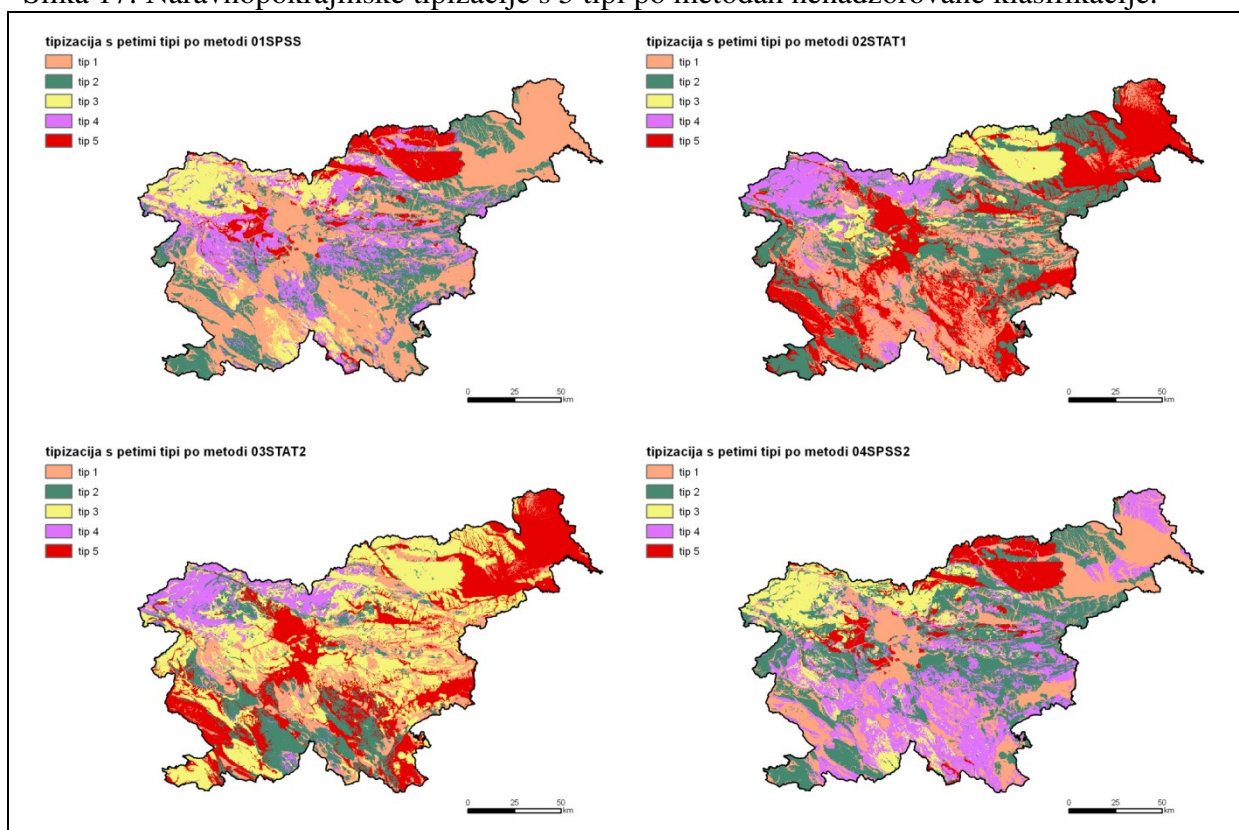
Z vsakim geoinformacijskim orodjem smo izdelali po 4 tipizacije (za 2, 5, 10 in 15 skupin), kar pomeni, da smo dobili 40 tipizacij. Ker smo pri metodi segmentacije za 15 skupin dobili dve različici, je vseh modeliranih naravnopokrajinskih tipizacij dejansko 41 (slike 16–19). Vse v nadaljnjih podpoglavjih tudi vrednotimo. Pri analizi nas je zanimalo, kako se tipizacije med seboj ujemajo in kakšne ocene imajo po vrednotenju z vidika podatkovnih slojev.

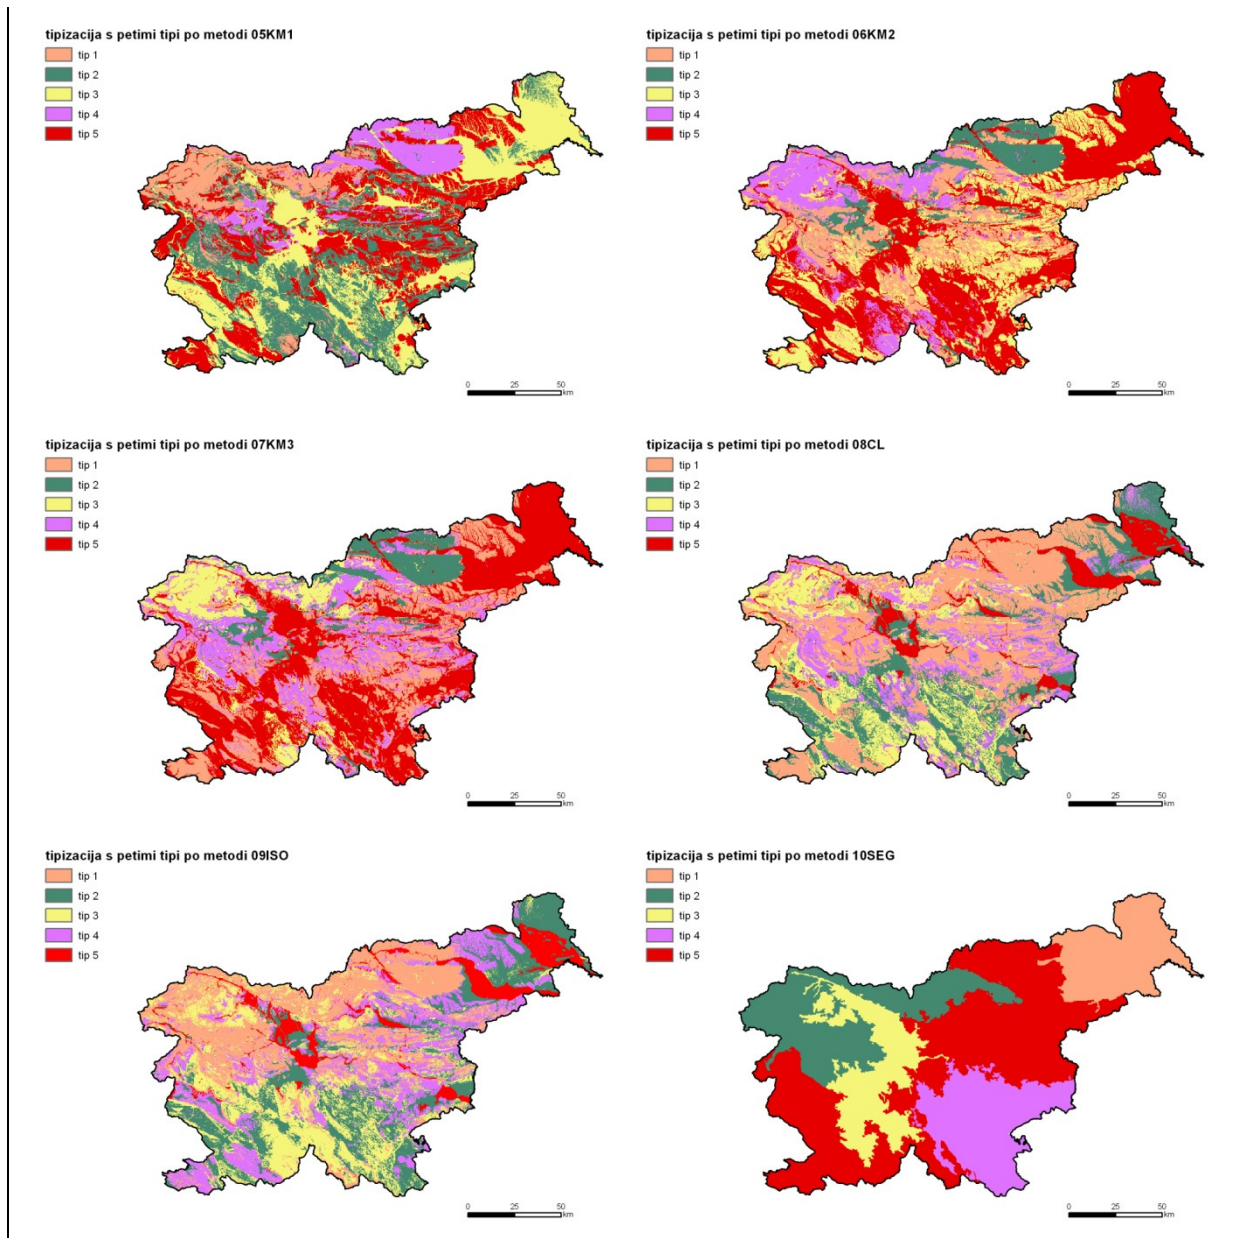
Slika 16: Naravnopokrajinske tipizacije z 2 tipoma po metodah nenadzorovane klasifikacije.



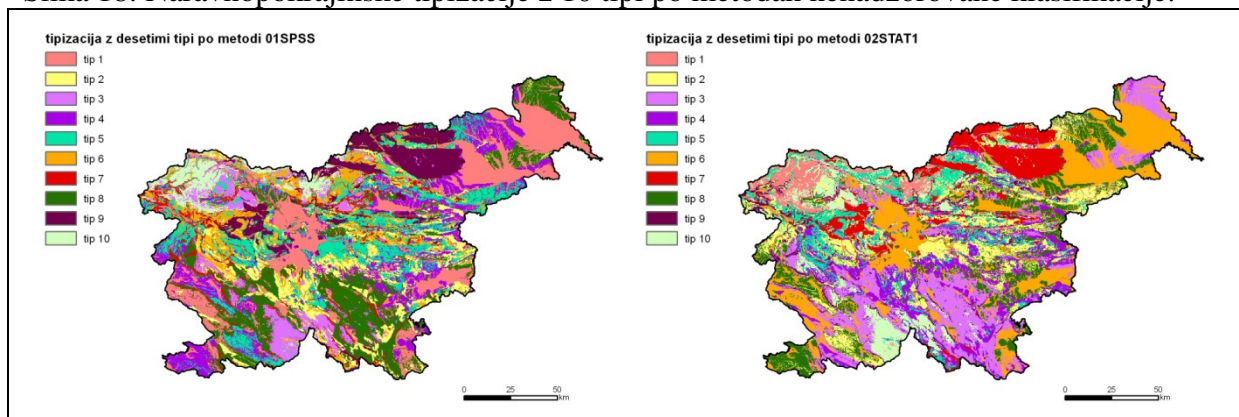


Slika 17: Naravnopokrajinske tipizacije s 5 tipi po metodah nenadzorovane klasifikacije.






Slika 18: Naravnopokrajinske tipizacije z 10 tipi po metodah nenadzorovane klasifikacije.




tipizacija z desetimi tipi po metodi 03STAT2

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 04SPSS2

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 05KM1

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 06KM2

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 07KM3

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 08CL

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10




tipizacija z desetimi tipi po metodi 09ISO

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10

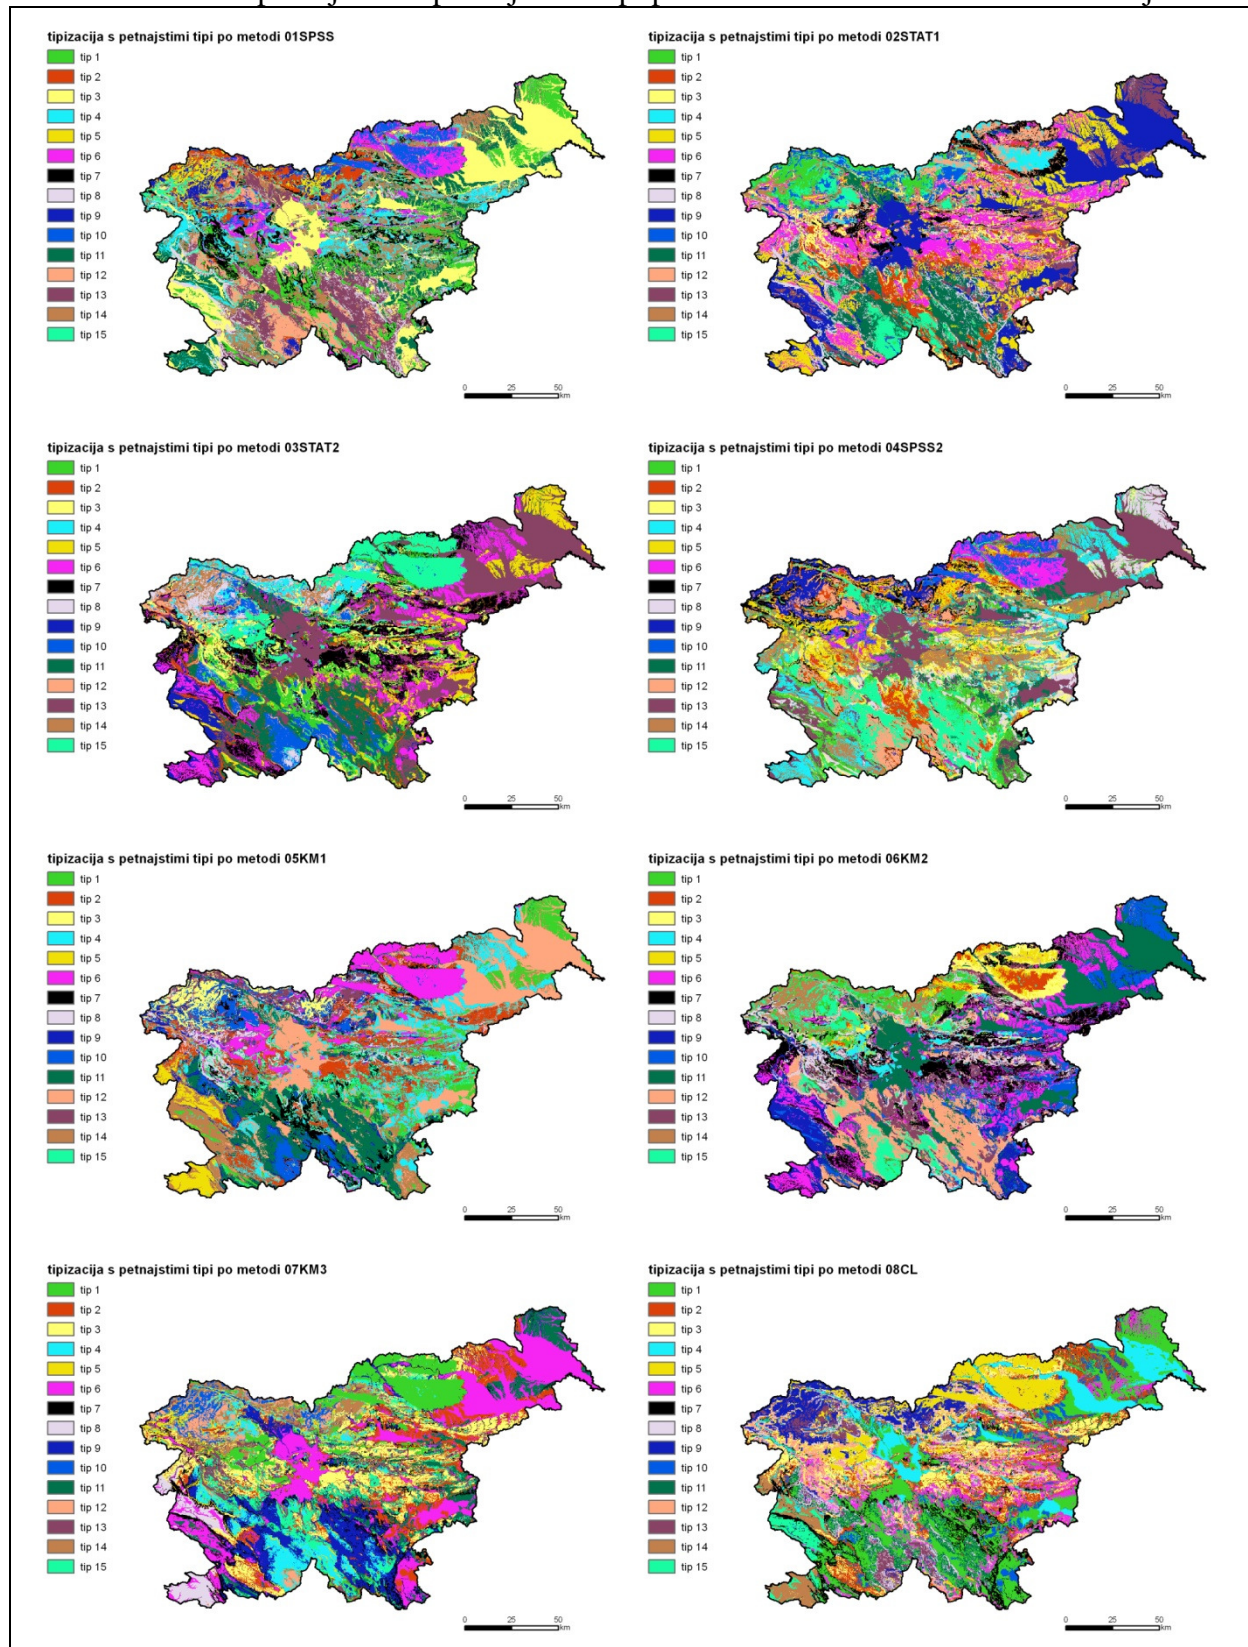


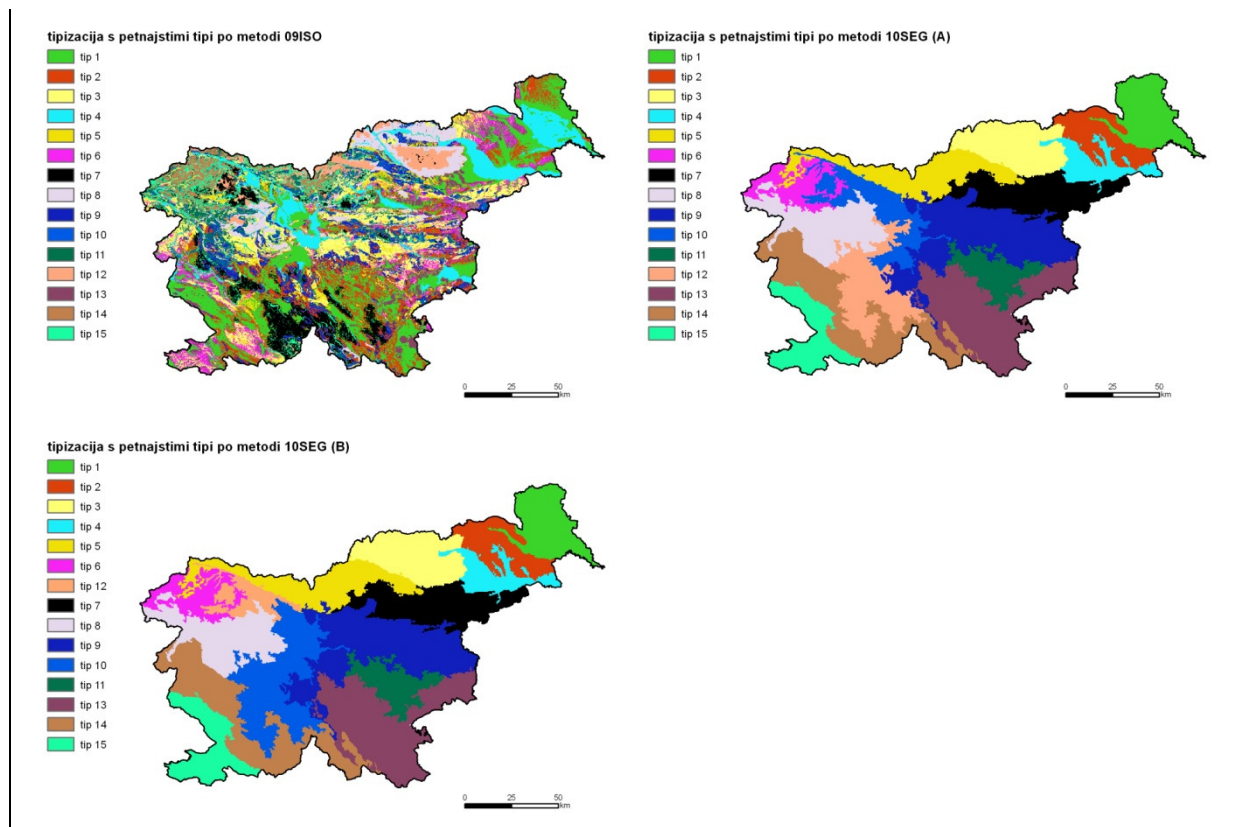
tipizacija z desetimi tipi po metodi 10SEG

- tip 1
- tip 2
- tip 3
- tip 4
- tip 5
- tip 6
- tip 7
- tip 8
- tip 9
- tip 10



Slika 19: Naravnopokrajinske tipizacije s 15 tipi po metodah nenadzorovane klasifikacije.





7.3 Vrednotenje naravnopokrajinskih tipizacij s pomočjo vhodnih podatkovnih slojev

Vrednotenje modeliranih naravnopokrajinskih tipizacij oziroma rezultatov metod nenadzorovane klasifikacije s pomočjo vhodnih podatkovnih slojev smo opravili v dveh sklopih.

V prvem sklopu smo klasifikacije vrednotili z vidika posameznega podatkovnega sloja (ki je bil vključen v klasifikacijo), kar pomeni, da smo računali, kako posamezen podatkovni sloj pojasnjuje posamezno tipizacijo oziroma kako dobro sta tipizacija in podatkovni sloj povezana. Uporabili smo naslednje načine vrednotenja:

- delež enako klasificiranih celic glede na model odločitvenega drevesa (različica CT),
- razmerje informacijskega prispevka,
- informacijski prispevek,
- povprečni umerjeni koeficient variacije,
- koeficient F,
- koeficient η^2 .

Pri vrednotenju posamezne tipizacije smo za vsak način vrednotenja izračunali tudi povprečne ocen z vidika vseh podatkovnih slojev. Iz informacijskega prispevka za naklon, informacijskega prispevka za povprečno letno temperaturo in informacijskega prispevka za prepustnost smo na primer za vsako tipizacijo izračunali povprečni informacijski prispevek. Ker je to dejansko ocena, ki upošteva vse podatkovne sloje, smo take povprečne ocene vključili k vrednotenju v drugem sklopu.

V drugem sklopu smo vrednotili, kako dobro se posamezna tipizacija povezuje oziroma odraža vse podatkovne sloje, ki so bili uporabljeni za njeno izdelavo, hkrati. Uporabili smo naslednje načine vrednotenja:

- delež enako klasificiranih celic glede na model odločitvenega drevesa (različica CT),
- povprečna oddaljenost posamezne celice od najbližjega centroida,
- delež enako klasificiranih celic po diskriminanci analizi,

- povprečje ocen, ki smo jih izračunali pri vrednotenju na podlagi posameznega podatkovnega sloja.

Za preverjanje objektivnosti vrednotenja smo izračunali, kako se posamezne ocene oziroma rangiranja med seboj ujemajo. Za to smo uporabili Pearsonov in Spearmanov koeficient povezanosti. Oba koeficienta smo izračunali z upoštevanjem vseh tipizacij skupaj ter tudi ločeno le za posamezno serijo tipizacij z enakim številom tipov. Ugotavljanje usklajenosti vrednotenja je pomemben del, saj se nanaša na prvo hipotezo.


7.3.1 Različni načini vrednotenja modeliranih naravnopokrajinskih tipizacij s pomočjo uporabljenih podatkovnih slojev

7.3.1.1 Različni načini vrednotenja glede na posamezni podatkovni sloj

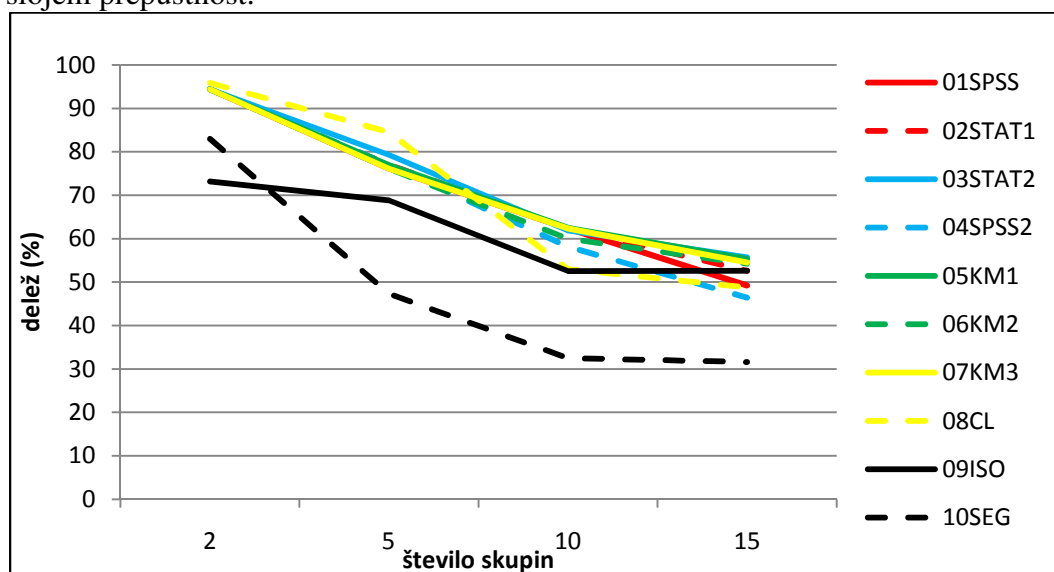
Delež enako klasificiranih celic po modelu odločitvenega drevesa

Pri vrednotenju na podlagi deleža celic, ki so enako klasificirane z odločitvenim drevesom, je vidno, da so klasifikacije z manj tipi v povprečju bolje ocenjene. Z večanjem števila tipov pada natančnost gradnje drevesa s podatkovnim slojem naklon (slika 20) in tudi s podatkovnim slojem prepustnost (slika 21), pri večjem številu tipov so pri obeh podatkovnih slojih precej opazne nižje vrednosti za klasifikacije, ki so narejene po metodi segmentacije. Tudi pri podatkovnem sloju temperatura odstotek pravilno klasificiranih celic s številom tipov pada (slika 22). Pri dveh tipih pozitivno izstopata klasifikaciji z metodama segmentacije in metodo iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (preglednica je na voljo v prilogi 8).


Slika 20: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem naklon.



Slika 21: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem prepustnost.




Slika 22: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem temperatura.




Razmerje informacijskega prispevka

Pri vrednotenju na podlagi razmerja informacijskega prispevka je vidno, da so tipizacije z manj tipi v povprečju slabše ocenjene. Z večanjem števila tipov zato vrednosti razmerja informacijskega prispevka rastejo, to velja za večino klasifikacij pri vseh podatkovnih slojih (naklon, prepustnost, temperatura; slike 23, 24 in 25). Pri razmerju informacijskega prispevka za podatkovni sloj naklon pri 5, 10 in 15 tipih z nizko vrednostjo izstopajo tipizacije po metodi segmentacije, pri 10 in 15 pa z visoko vrednostjo izstopa tipizacija z metodo analize vrhov v histogramu. Pri 2 skupinah pozitivno odstopa tipizacija po metodi ISOCLUST. Pri podatkovnem sloju prepustnost pri vseh številih tipov negativno odstopajo tipizacije po metodi segmentacije. Pri 2 tipih negativno odstopa še tipizacija po metodi ISOCLUST, pri 5 tipih pa pozitivno tipizacija po metodi analize vrhov v histogramu (preglednica je na voljo v prilogi 8).


Slika 23: Razmerje informacijskega prispevka podatkovnega sloja naklon.



Slika 24: Razmerje informacijskega prispevka podatkovnega sloja prepustnost.




Slika 25: Razmerje informacijskega prispevka podatkovnega sloja temperatura.




Informacijski prispevek

Pri vrednotenju na podlagi informacijskega prispevka so klasifikacije z manj tipi slabše ocenjene. Z večanjem števila tipov raste ocena za vse vključene podatkovne sloje (naklon, prepustnost, temperatura; slike 26, 27 in 28). Z nižjimi ocenami glede na sloj naklon in prepustnost izstopajo tipizacije po metodi segmentacije. Glede na sloj prepustnost pri 2 tipih negativno odstopa tudi tipizacija po metodi ISOCLUST (preglednica je na voljo v prilogi 8).


Slika 26: Informacijski prispevek podatkovnega sloja naklon.



Slika 27: Informacijski prispevek podatkovnega sloja prepustnost.




Slika 28: Informacijski prispevek podatkovnega sloja temperatura.




Povprečni umerjeni koeficient variacije

Pri vrednotenju s povprečnim umerjenim koeficientom variacije (PUKV) so najbolj ocenjene tipizacije z večjim številom tipov (slike 29, 30 in 31; preglednica je na voljo v prilogi 8), kar velja za vse podatkovne sloje. Nižja vrednost pomeni boljše oceno. Izstopajo slabše ocene za tipizacije po metodi segmentacije (predvsem glede na podatkovna sloja prepustnost in naklon). Glede na podatkovni sloj naklon je pri 2 tipih tipizacija po metodi ISOCLUST dobro ocenjena, glede na prepustnost pa precej slabše.

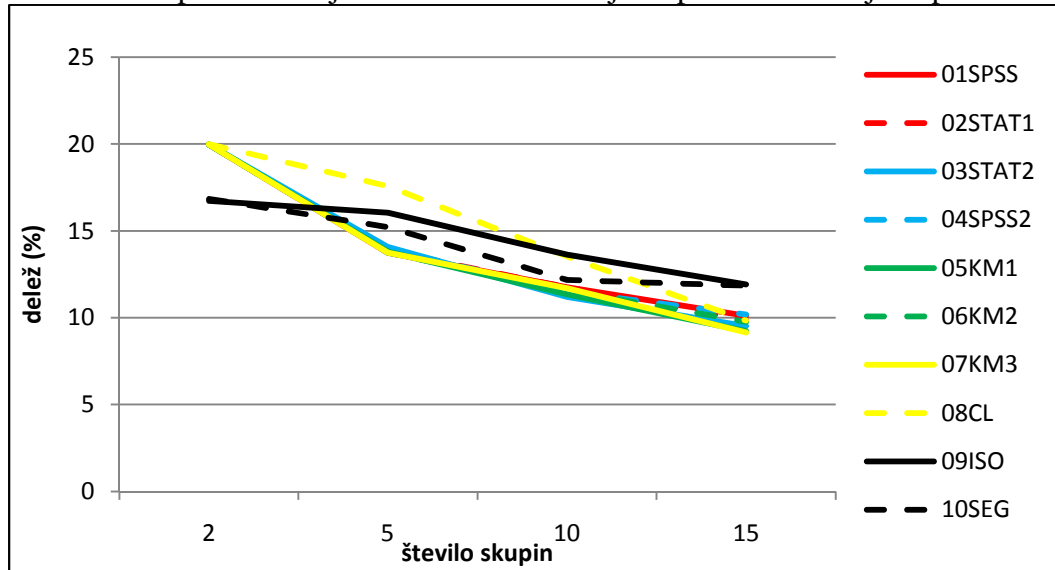
Slika 29: Povprečni umerjeni koeficient variacije za podatkovni sloj naklon.



Slika 30: Povprečni umerjeni koeficient variacije za podatkovni sloj prepustnost.



Slika 31: Povprečni umerjeni koeficient variacije za podatkovni sloj temperatura.




Koeficient F (analiza variance)

Pri vrednotenju tipizacij na podlagi koeficienta F je vpliv števila skupin precej manj opazen kot pri ostalih metodah vrednotenja. Kot najslabše so največkrat ocenjene tipizacije po metodi ISOCLUST, metodi segmentacije in metodi analize vrhov v histogramu.


Ob pregledu vrednotenja (slike 32, 33 in 34; preglednica je na voljo v prilogi 8), ki prikazujejo, kako se koeficient F za posamezen način klasifikacije spreminja s številom tipov, je opazno, da je tu trend najmanj izrazit oziroma celo zelo različen od podatkovnega sloja do podatkovnega sloja.

Glede na naklon in temperaturo graf ne kaže jasnega trenda. Pri 2 tipih pri naklonu močno pozitivno odstopa tipizacija po metodi ISOCLUST, pri temperaturi pa pri istem številu tipov segmentacija. Glede na prepustnost pri večini tipizacij vrednost F pada, pri nekaterih pa vrednost narašča (ISOCLUST) ali pa ohranja enako vrednost (segmentacija).


Slika 32: Koeficient F za podatkovni sloj naklon.



Slika 33: Koeficient F za podatkovni sloj prepustnost.




Slika 34: Koeficient F za podatkovni sloj temperatura.




Eta²

Pri vrednotenju na podlagi η^2 je vidno, da so v povprečju kot najboljše (višja vrednost pomeni boljšo oceno) ovrednotene tipizacije z večjim številom tipov. Pri podatkovnem sloju prepustnost je opazno, da imajo tipizacije po metodi segmentacije izjemno nizke vrednosti. Pri ostalih dve slojih takega odstopanja ni (slike 35, 36 in 37; preglednica je na voljo v prilogi 8).

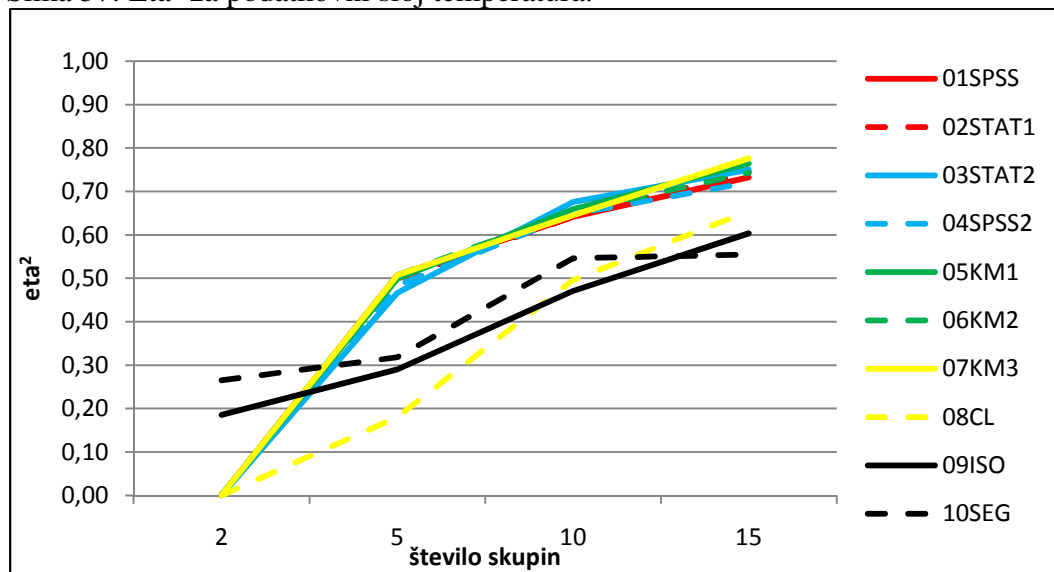
Slika 35: Eta² za podatkovni sloj naklon.



Slika 36: Eta² za podatkovni sloj prepustnost.



Slika 37: Eta² za podatkovni sloj temperatura.




7.3.1.2 Različni načini vrednotenja glede na vse podatkovne sloje hkrati

Delež enako klasificiranih celic po modelu odločitvenega drevesa

Pri vrednotenju na podlagi deleža celic, ki so enako klasificirane glede na model odločitvenega drevesa, je vidno, da so tipizacije z manj skupinami boljše ocenjene. Z večanjem števila tipov pada natančnost drevesa, precej nižje vrednosti so opazne za tipizacije po metodi segmentacije (slika 38; preglednica je na voljo v prilogi 8). Tipizacije z manj skupinami je očitno lažje opisati z modelom drevesa.

Slika 38: Delež enako klasificiranih celic po modelu odločitvenega drevesa z vsemi tremi podatkovnimi sloji (pri segmentaciji 15 je prikazana različica A).




Povprečna oddaljenost posamezne celice od najbližjega centroida tipa

Pri vrednotenju na podlagi oddaljenosti celic od najbližjih centroidov je vidno, da so tipizacije z manj skupinami slabše ocenjene. To je normalno, saj je z večjim številom tipov tudi več centroidov, zato se razdalje manjšajo. Z večanjem števila tipov pada povprečna razdalja,

precej višje vrednosti so opazne za tipizacije po metodi segmentacije (slika 39; preglednica je na voljo v prilogi 8).


Slika 39: Povprečna oddaljenost celic po posameznih številih tipov.



Delež enako klasificiranih po modelu diskriminančne analize

Pri vrednotenju na podlagi deleža enako klasificiranih celic po modelu diskriminančne analize so ocene zelo visoke za večino tipizacij ne glede na število tipov. Kot najslabše ocenjene odstopajo tipizacije po metodi segmentacije, nekoliko slabše so ocenjene tudi tipizacije po metodi analize vrhov v histogramu in metodi iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (slika 40; preglednica je na voljo v prilogi 8).

Slika 40: Delež enako klasificiranih celic po modelu diskriminančne analize.



Povprečne vrednosti mer vrednotenja z vidika posameznih podatkovnih slojev

Pri vrednotenju na podlagi deleža celic, ki so enako klasificirane po modelu odločitvenega drevesa, je vidno, da so tipizacije z manj skupinami v povprečju bolje ocenjene. Pri vrednotenju na podlagi razmerja informacijskega prispevka, informacijskega prispevka, povprečnega umerjenega koeficienta variacije, koeficienta η^2 je vidno, da so tipizacije z

manj skupinami v povprečju slabše ocenjene. Pri vrednotenju tipizacij na podlagi koeficienta F je vsaj pri povprečnih vrednostih še vedno prisoten, a manj kot pri ostalih vrednotenjih, vpliv števila skupin (kot najboljše so ocenjene tipizacije z manjšim številom, opazno pa je, da so poleg tipizacij z velikim številom skupin slabše ocenjene tipizacije po metodi iterativnega samoorganizirajočega nenadzorovanega klasifikatorja, segmentacija in delno tudi po metodi analize vrhov v histogramu) (preglednica 20).

Preglednica 20: Povprečne vrednosti vseh mer vrednotenja na podlagi posameznih podatkovnih slojev. Statistična značilnost posameznega povprečnega koeficienta η^2 in koeficienta F je $p=0,003$.

oznaka metode (tipizacije)	število skupin	povprečja					
		koeficient η^2	koeficient F	PUKV (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	delež enako klasificiranih celic z odločitvenim drevesom (%)
01SPSS	2	0,29	503398,8	34,61	0,37	0,15	74,8
01SPSS	5	0,67	472655,1	23,08	0,86	0,20	60,8
01SPSS	10	0,79	443777,8	16,84	1,27	0,28	48,0
01SPSS	15	0,84	364833,2	14,97	1,45	0,31	40,5
02STAT1	2	0,29	503398,8	34,61	0,37	0,15	74,8
02STAT1	5	0,67	453321,2	22,58	0,90	0,21	59,9
02STAT1	10	0,79	443789,9	16,84	1,27	0,28	48,0
02STAT1	15	0,84	363196,1	15,13	1,44	0,31	42,4
03STAT2	2	0,29	503398,8	34,61	0,37	0,15	74,8
03STAT2	5	0,63	320986,6	23,76	0,88	0,22	61,2
03STAT2	10	0,80	428374,4	17,10	1,28	0,29	47,2
03STAT2	15	0,84	355776,9	15,08	1,46	0,32	42,7
04SPSS2	2	0,29	501179,8	34,59	0,37	0,14	74,9
04SPSS2	5	0,66	465840,3	22,72	0,90	0,21	59,9
04SPSS2	10	0,79	401210,7	16,88	1,29	0,29	45,5
04SPSS2	15	0,84	303893,6	14,71	1,48	0,32	39,3
05KM1	2	0,29	503413	34,61	0,37	0,15	74,8
05KM1	5	0,67	453243,9	22,59	0,90	0,21	59,9
05KM1	10	0,79	428442	17,20	1,30	0,29	46,8
05KM1	15	0,85	365461,2	14,92	1,50	0,33	42,3
06KM2	2	0,29	503426,4	34,61	0,37	0,15	74,8
06KM2	5	0,67	472649,3	23,07	0,86	0,20	60,8
06KM2	10	0,79	413196,1	17,59	1,23	0,28	47,6
06KM2	15	0,84	333828,8	15,55	1,67	0,31	42,4
07KM3	2	0,29	503413	34,61	0,37	0,15	74,8
07KM3	5	0,67	472596,6	23,07	0,86	0,20	60,8
07KM3	10	0,79	449965,2	16,95	1,28	0,29	47,5
07KM3	15	0,85	364676,3	15,08	1,48	0,32	42,4
08CL	2	0,29 ¹⁵	758289,3 ¹⁶	34,98	0,35	0,18	74,9
08CL	5	0,50	289167,2	26,20	0,91	0,29	60,3
08CL	10	0,72	237102	18,07	1,32	0,30	45,1
08CL	15	0,79	186846,4	16,12	1,49	0,33	40,6
09ISO	2	0,29	239452,9	31,82	0,38	0,10	78,7
09ISO	5	0,54	182567,7	23,79	0,88	0,21	56,0
09ISO	10	0,71	204892,8	17,80	1,25	0,28	44,2
09ISO	15	0,79	233313,2	15,43	1,44	0,32	40,9
10SEG	2	0,20	145098,1	36,50	0,18	0,03	85,4
10SEG	5	0,30	61935,5	32,79	0,53	0,09	49,2

¹⁵ Statistična značilnost koeficienta η^2 je 0,012.

¹⁶ Statistična značilnost koeficienta F je 0,014.

10SEG	10	0,45	49995	29,93	0,77	0,15	32,9
10SEG	15	0,49	35996,28	28,59	0,89	0,18	27,1
10SEG	15	0,49	37470,71	28,51	0,88	0,18	27,2

7.3.2 Usklajenost različnih načinov vrednotenja naravnopokrajinskih tipizacij

7.3.2.1 Usklajenost različnih načinov vrednotenja s pomočjo posameznega podatkovnega sloja

Kako dobro so usklajeni posamezni načini vrednotenja (slike 20–37) med seboj (oziroma kako dobro se ujemajo različne lestvice ocen tipizacij v prilogi 8), smo ugotavljali z izračunom Pearsonovega in Spearmanovega koeficienta povezanosti. Izračunali smo povezanost za načine vrednotenja na podlagi posameznega podatkovnega sloja. Povezanost smo računali večkrat:

- z upoštevanjem vseh tipizacij hkrati,
- z upoštevanjem le tistih tipizacij, ki imajo enako število tipov.

Pri primerjavi posameznih parov vrednotenj na podlagi podatkovnega sloja **naklon** smo ugotovili (preglednici 21 in 22), da je pri $p=0,05$ statistično neznačilnih 5 od 75 Pearsonovih koeficientov in pa 22 od 75 Spearmanovih koeficientov povezanosti¹⁷. Pri upoštevanju vseh tipizacij (z različnim številom tipov) so povezanosti pri $p=0,05$ statistično značilne praktično vedno, a to je zaradi vpliva števila tipov, po katerem se tipizacije lepo rangirajo od tistih z več skupinami proti tistim z manj ali obratno. Med temi stopnjami povezanosti, izračunanimi na podlagi vseh tipizacij (z različnimi števili tipov), so zelo visoke tiste pri primerjavah informacijskega prispevka, razmerja informacijskega prispevka, koeficienta η^2 in povprečnega umerjenega koeficienta. Pri upoštevanju tipizacij z enakim številom tipov so tudi zelo močno povezani načini vrednotenja s koeficientom η^2 , povprečnim umerjenim koeficientom variacije in koeficientom F.

Pri primerjavi posameznih parov vrednotenj na podlagi podatkovnega sloja **prepustnost** smo ugotovili (preglednici 23 in 24), da je pri $p=0,05$ statistično neznačilnih 5 od 75 Pearsonovih koeficientov povezanosti in 25 od 75 Spearmanovih koeficientov povezanosti. Tudi tukaj so stopnje povezanosti, izračunane z vsemi tipizacijami (z različnimi števili tipov), zelo visoke pri primerjavah informacijskega prispevka, razmerja informacijskega prispevka, koeficienta η^2 in povprečnega umerjenega koeficienta. Pri upoštevanju tipizacij z istim številom skupin sta zelo močno povezana načina vrednotenja s koeficientom η^2 in koeficientom F ter delež enako klasificiranih celic z odločitvenim drevesom in razmerje informacijskega prispevka.

Pri primerjavi posameznih parov vrednotenj na podlagi podatkovnega sloja **temperatura** smo ugotovili (preglednici 25 in 26), da je pri $p=0,05$ statistično neznačilnih 8 od 75 Pearsonovih koeficientov in 30 od 75 Spearmanovih koeficientov povezanosti. Tudi tu so (tako kot pri naklonu) pri upoštevanju vseh tipizacij (z različnim številom tipov) povezanosti statistično značilne skoraj vedno. Stopnje povezanosti, izračunane z vsemi tipizacijami (z različnimi števili tipov), zelo visoke pri primerjavah deleža pravilno klasificiranih z odločitvenim drevesom, informacijskega prispevka, razmerja informacijskega prispevka, koeficienta η^2 in povprečnega umerjenega koeficienta. Pri upoštevanju tipizacij z istim številom tipov so zelo močno povezani koeficient η^2 , povprečni umerjeni koeficient variacije in koeficient F.

Na podlagi teh rezultatov lahko sklenemo, da je ujemanje različnih načinov vrednotenja majhno. Ob kar velikem deležu neznačilnih povezanosti glede na Spearmanov koeficient zato

¹⁷ Ker je sklepanje o točnem številu statistično značilnih koeficientov podvrženo večjemu tveganju (ki se z večanjem števila posameznih koeficientov zvišuje), da napravimo napako (McKillup in Dyar 2010), število statistično neznačilnih koeficientov jemljemo zgolj okvirno oziroma za približno predstavo, saj so nekatere posamezne statistične (ne)zanesljivosti tudi večje (o tem problemu smo na izbranem primeru pisali v poglavju 4.5).

ne moremo zaključiti, da so vrednotenja med seboj zadovoljivo usklajena. Ob uporabi in primerjavi več načinov (ali pa ob drugačnem naboru metod vrednotenja) tipizacij bi mogoče dobili drugačne stopnje povezanosti, zato dopuščamo možnost, da obstajajo (še) bolj usklajeni načini vrednotenja od teh, ki so zajeti v tem delu naše raziskave.

Pri upoštevanju vseh tipizacij (ne glede na število skupin) je pri $p=0,05$ po Pearsonovem koeficientu statistično neznačilno povezanih 6 od 45 kombinacij in po Spearmanovem koeficientu 8 od 45, vendar domnevamo (ob pregledu vseh grafikonov in preglednic), da je visoka stopnja povezanosti posledica vpliva števila tipov!

Ob tem dodajamo, da je numerus pri računanju povezanosti z vsemi tipizacijami 41, pri posameznih serijah tipizacijah z enakim številom tipov pa le 10 (pri tipizaciji s 15 tipi je numerus 11). Pri majhnem numerusu je težje priti do statistično značilnih rezultatov.

Sicer pa so pri vrednotenju vseh tipizacij naenkrat (ne glede na število tipov) dobro usklajeni informacijski prispevek, razmerje informacijskega prispevka in koeficient η^2 , pri vrednotenju tipizacij z enakim številom tipov pa koeficient η^2 in koeficient F.

Preglednica 21: Preverjanje usklajenosti vrednotenja na podlagi naklona (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informacijskega prispevka	informac. prispevek	povprečni umerjeni koeficient variacije	koeficient F	koeficient η^2
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,608	-0,653	0,700	0,191	-0,711
	2 skupini	1	0,776	0,800	-0,934	0,925	0,964
	5 skupin	1	0,726	0,794	-0,754	0,669	0,664
	10 skupin	1	0,916	0,972	-0,927	0,905	0,896
	15 skupin	1	0,950	0,881	-0,971	0,939	0,968
razmerje informacijskega prispevka	VSI		1	0,956	-0,952	0,494	0,929
	2 skupini		1	0,999	-0,948	0,954	0,913
	5 skupin		1	0,977	-0,577	0,476	0,392
	10 skupin		1	0,963	-0,815	0,748	0,757
	15 skupin		1	0,792	-0,896	0,864	0,883
informacijski prispevek	VSI			1	-0,953	0,400	0,930
	2 skupini			1	-0,958	0,963	0,927
	5 skupin			1	-0,732	0,635	0,566
	10 skupin			1	-0,936	0,896	0,898
	15 skupin			1	-0,853	0,809	0,856
povprečni umerjeni koeficient variacije	VSI				1	-0,481	-0,995
	2 skupini				1	-1,000	-0,995
	5 skupin				1	-0,976	-0,974
	10 skupin				1	-0,976	-0,995
	15 skupin				1	-0,989	-0,999
koeficient F	VSI					1	0,491
	2 skupini					1	0,993
	5 skupin					1	0,986
	10 skupin					1	0,974
	15 skupin					1	0,986
koeficient η^2	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

*Za 15 skupin in za VSE sta upoštevani obe segmentaciji s 15 skupinami!

Preglednica 22: Preverjanje usklajenosti vrednotenj na podlagi naklona (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informacijskega prispevka	informacijski prispevek	povprečni umerjeni koeficient variacije	koeficient F	koeficient η^2
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,634	-0,653	0,697	0,046	-0,706
	2 skupini	1	0,616	1,000	-1,000	0,901	1,000
	5 skupin	1	0,178	0,193	-0,203	0,239	0,237
	10 skupin	1	0,699	0,732	-0,829	0,644	0,646
	15 skupin	1	0,497	0,618	-0,487	0,400	0,388
razmerje informacijskega prispevka	VSI		1	0,975	-0,958	0,521	0,938
	2 skupini		1	0,616	-0,616	0,726	0,616
	5 skupin		1	0,979	-0,537	0,255	0,247
	10 skupin		1	0,979	-0,918	0,733	0,723
	15 skupin		1	0,647	-0,842	0,683	0,703
informacijski prispevek	VSI			1	-0,968	0,489	0,952
	2 skupini			1	-1,000	0,901	1,000
	5 skupin			1	-0,535	0,252	0,249
	10 skupin			1	-0,951	0,742	0,744
	15 skupin			1	-0,579	0,436	0,457
povprečni umerjeni koeficient variacije	VSI				1	-0,499	-0,994
	2 skupini				1	-0,901	-1,000
	5 skupin				1	-0,912	-0,901
	10 skupin				1	-0,863	-0,866
	15 skupin				1	-0,943	-0,950
koeficient F	VSI					1	0,509
	2 skupini					1	0,901
	5 skupin					1	0,985
	10 skupin					1	0,997
	15 skupin					1	0,995
koeficient η^2	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

Preglednica 23: Preverjanje usklajenosti vrednotenj na podlagi prepustnosti (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informacijskega prispevka	informac. prispevek	povpr. umerjeni koeficient variacije	koeficient F	koeficient η^2
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,127	-0,425	0,051	0,733	0,058
	2 skupini	1	0,912	0,901	-0,900	0,933	0,891
	5 skupin	1	0,920	0,985	-0,956	0,739	0,948
	10 skupin	1	0,962	0,957	-0,972	0,929	0,963
	15 skupin	1	0,970	0,966	-0,957	0,884	0,953
razmerje informac. prispevka	VSI		1	0,912	-0,936	0,358	0,922
	2 skupini		1	0,972	-0,973	0,978	0,974
	5 skupin		1	0,946	-0,790	0,485	0,764
	10 skupin		1	1,000	-0,996	0,811	0,997
	15 skupin		1	1,000	-0,997	0,890	0,996
informacijski prispevek	VSI			1	-0,914	0,078	0,850
	2 skupini			1	-10,000	0,997	0,999

	5 skupin			1	-0,938	0,662	0,918
	10 skupin			1	-0,996	0,799	0,997
	15 skupin			1	-0,998	0,886	0,997
povprečni umerjeni koeficient variacije	VSI			1	-0,446	-0,985	
	2 skupini			1	-0,996	-1,000	
	5 skupin			1	-0,850	-0,997	
	10 skupin			1	-0,840	-0,999	
	15 skupin			1	-0,901	-0,999	
koeficient F	VSI					1	0,559
	2 skupini					1	0,995
	5 skupin					1	0,879
	10 skupin					1	0,821
	15 skupin					1	0,886
koeficient eta ²	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

*Za 15 skupin in za VSE sta upoštevani obe segmentaciji s 15 skupinami!

Preglednica 24: Preverjanje usklajenosti vrednotenj na podlagi prepustnosti (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informac. prispevka	informacijski prispevek	povprečni umerjeni koeficient variacije	koeficient F	koeficient eta ²
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,291	-0,478	0,352	0,739	-0,271
	2 skupini	1	0,662	0,231	-0,231	0,596	0,899
	5 skupin	1	0,987	0,991	-0,384	0,043	0,103
	10 skupin	1	0,926	0,929	-0,966	0,914	0,947
	15 skupin	1	0,932	0,881	-0,805	0,717	0,816
razmerje informac. prispevka	VSI		1	0,932	-0,902	-0,024	0,891
	2 skupini		1	0,569	-0,569	0,901	0,916
	5 skupin		1	0,997	-0,404	0,067	0,140
	10 skupin		1	0,997	-0,936	0,855	0,880
	15 skupin		1	0,982	-0,843	0,745	0,814
informacijski prispevek	VSI			1	-0,956	-0,135	0,917
	2 skupini			1	-1	0,513	0,445
	5 skupin			1	-0,399	0,062	0,140
	10 skupin			1	-0,939	0,851	0,883
	15 skupin			1	-0,774	0,700	0,749
povprečni umerjeni koeficient variacije	VSI				1	-0,047	-0,973
	2 skupini				1	-0,513	-0,445
	5 skupin				1	-0,656	-0,749
	10 skupin				1	-0,960	-0,988
	15 skupin				1	-0,966	-0,979
koeficient F	VSI					1	0,154
	2 skupini					1	0,825
	5 skupin					1	0,966
	10 skupin					1	0,985
	15 skupin					1	0,977
koeficient eta ²	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

Preglednica 25: Preverjanje usklajenosti vrednotenj na podlagi temperature (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informac. prispevka	informacijski prispevek	povprečni umerjeni koeficient variacije	koeficient F	koeficient η^2
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,823	-0,838	0,784	-0,146	-0,766
	2 skupini	1	0,789	0,868	-0,944	0,996	0,991
	5 skupin	1	0,858	0,886	-0,827	0,767	0,777
	10 skupin	1	0,786	0,750	-0,896	0,802	0,836
	15 skupin	1	0,557	0,347	-0,866	0,893	0,975
razmerje informac. prispevka	VSI		1	0,998	-0,978	0,557	0,950
	2 skupini		1	0,990	-0,947	0,829	0,859
	5 skupin		1	0,997	-0,897	0,758	0,814
	10 skupin		1	0,993	-0,783	0,578	0,618
	15 skupin		1	0,921	-0,837	0,768	0,628
informacijski prispevek	VSI			1	-0,973	0,534	0,946
	2 skupini			1	-0,983	0,901	0,923
	5 skupin			1	-0,886	0,748	0,801
	10 skupin			1	-0,719	0,490	0,534
	15 skupin			1	-0,632	0,527	0,419
povprečni umerjeni koeficient variacije	VSI				1	-0,686	-0,993
	2 skupini				1	-0,965	-0,978
	5 skupin				1	-0,967	-0,987
	10 skupin				1	-0,956	-0,968
	15 skupin				1	-0,989	-0,930
koeficient F	VSI					1	0,723
	2 skupini					1	0,999
	5 skupin					1	0,994
	10 skupin					1	0,995
	15 skupin					1	0,945
koeficient η^2	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

*Za 15 skupin in za VSE sta upoštevani obe segmentaciji s 15 skupinami!

Preglednica 26: Preverjanje usklajenosti vrednotenj na podlagi temperature (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		delež enako klasificiranih celic z odločitvenim drevesom	razmerje informacijskega prispevka	informacijski prispevek	povp. umerjeni koeficient variacije	koeficient F	koeficient η^2
delež enako klasificiranih celic z odločitvenim drevesom	VSI	1	-0,870	-0,870	0,817	-0,067	-0,747
	2 skupini	1	0,231	0,428	-0,428	0,513	0,569
	5 skupin	1	0,399	0,845	-0,847	0,837	0,850
	10 skupin	1	0,599	0,599	-0,532	0,616	0,618
	15 skupin	1	0,404	-0,037	-0,581	0,696	0,760
razmerje informac. prispevka	VSI		1	0,989	-0,965	0,358	0,935
	2 skupini		1	0,916	-0,916	0,596	0,662
	5 skupin		1	0,648	-0,242	0,264	0,274
	10 skupin		1	1,000	-0,609	0,571	0,572
	15 skupin		1	0,733	-0,866	0,779	0,688

informacijski prispevek	VSI			1	-0,962	0,358	0,933
	2 skupini			1	-1,000	0,810	0,899
	5 skupin			1	-0,623	0,616	0,616
	10 skupin			1	-0,609	0,571	0,572
	15 skupin			1	-0,673	0,545	0,464
povprečni umerjeni koeficient variacije	VSI			1	-0,455	-0,985	
	2 skupini			1	-0,810	-0,899	
	5 skupin			1	-0,988	-0,997	
	10 skupin			1	-0,985	-0,988	
	15 skupin			1	-0,945	-0,900	
koeficient F	VSI					1	0,517
	2 skupini					1	0,901
	5 skupin					1	0,985
	10 skupin					1	0,997
	15 skupin					1	0,973
koeficient η^2	VSI						1
	2 skupini						1
	5 skupin						1
	10 skupin						1
	15 skupin						1

7.3.2.2 Usklajenost različnih načinov vrednotenja s pomočjo vseh podatkovnih slojev hkrati

Kako dobro so usklajeni posamezni načini vrednotenja med seboj (oziroma, kako dobro se ujemajo lestvice različnih ocen; glej preglednico 20 in preglednice v prilogi 8), smo ugotavljali z izračunom Pearsonovega in Spearmanovega koeficienta. Izračunali smo torej stopnje povezanosti za pare posameznih vrednotenj na podlagi vseh podatkovnih slojev (preglednici 27 in 28). Povezanost smo računali večkrat:

- z upoštevanjem vseh tipizacij hkrati,
- z upoštevanjem le tistih tipizacij, ki imajo enako število tipov.

Po primerjavi posameznih parov vrednotenj na podlagi vseh podatkovnih slojev hkrati opazimo, da imajo tipizacije z več tipi bolj homogene tipe ter da so tipizacije z manj tipi lažje opisljive z modelom odločitvenega drevesa. Po izračunu povezanosti posameznih parov vrednotenj na podlagi vseh podatkovnih slojev vidimo, da je pri $p=0,05$ 30 od 225 Pearsonovih koeficientov statistično neznačilnih in da je kar 125 od 225 parov¹⁸ Spearmanovih koeficientov statistično neznačilnih. Pri ugotavljanju povezanosti različnih ocen je zopet treba upoštevati, da je numerus majhen.

Na podlagi teh rezultatov lahko tudi tukaj sklenemo, da je usklajenost različnih ocen kar dobra pri primerjavi velikosti ocene (Pearsonov koeficient), pri primerjavi ranga (Spearmanov koeficient) pa precej manj. Ob kar velikem deležu neznačilnih povezanosti glede na Spearmanov koeficient ne moremo zaključiti, da so vrednotenja med seboj zadovoljivo usklajena. Ob uporabi in primerjavi več načinov tipizacij bi mogoče dobili drugačne stopnje povezanosti, zato dopuščamo možnost, da obstajajo bolj usklajeni načini vrednotenja.

¹⁸ Ker je sklepanje o točnem številu statistično značilnih koeficientov podvrženo večjemu tveganju (ki se z večanjem števila posameznih koeficientov zvišuje), da napravimo napako (McKillup in Dyar 2010), število statistično neznačilnih koeficientov jemljemo zgolj okvirno oziroma za približno predstavbo, saj so nekatere posamezne statistične (ne)zanesljivosti tudi večje (o tem problemu smo na izbranem primeru pisali v poglavju 4.5).

Preglednica 27: Usklajenost vrednotenj glede na vse podatkovne sloje (Pearsonov koef.). Odebeljeni koeficienti so statistično značilni pri $p=0,05$.

		neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenje s posameznimi podatkovnimi sloji					
		delež enako klasificiranih celic po modelu diskriminancijske analize	delež enako klasificiranih celic z odločitvenim drevesom	povprečna oddaljenost celic od najbližjega centroida	koeficient η^2	koeficient F	PUKV	informacijski prispevek	razmerje informacijskega prispevka	delež enako klasificiranih celic z odločitvenim drevesom (povprečje)
delež enako klasificiranih celic po modelu diskriminancijske analize	VSI	1	0,869	-0,425	0,217	0,817	-0,209	0,082	0,255	0,487
	2	1	0,857	-0,965	0,692	0,853	0,146	0,644	0,888	-0,903
	5	1	0,852	-0,992	0,985	0,910	-0,967	0,889	0,629	0,949
	10	1	0,866	-0,985	0,996	0,944	-0,958	0,906	0,902	0,981
	15	1	0,928	-0,992	0,996	0,967	-0,982	0,953	0,952	0,976
delež enako klasificiranih celic z odločitvenim drevesom	VSI		1	-0,132	-0,085	0,716	0,066	-0,197	0,016	0,699
	2		1	-0,962	0,964	0,807	-0,374	0,939	0,961	-0,995
	5		1	-0,903	0,775	0,645	-0,875	0,984	0,904	0,890
	10		1	-0,933	0,902	0,680	-0,958	0,975	0,984	0,921
	15		1	-0,959	0,947	0,829	-0,965	0,930	0,957	0,952
povprečna oddaljenost celic od najbližjega centroida	VSI			1	-0,959	-0,181	0,952	-0,917	-0,949	0,568
	2			1	-0,856	-0,857	0,114	-0,818	-0,956	0,984
	5			1	-0,969	-0,885	0,980	-0,931	-0,690	-0,947
	10			1	-0,995	-0,887	0,990	-0,965	-0,961	-0,987
	15			1	-0,999	-0,931	0,997	-0,964	-0,982	-0,986
koeficient η^2 (povprečje)	VSI				1	-0,040	-0,990	0,964	0,913	-0,715
	2				1	0,678	-0,606	0,992	0,885	-0,935
	5				1	0,932	-0,964	0,817	0,496	0,892
	10				1	0,919	-0,975	0,938	0,935	0,985
	15				1	0,944	-0,994	0,964	0,975	0,983
koeficient F (povprečje)	VSI					1	0,093	-0,191	0,032	0,545
	2					1	0,079	0,587	0,934	-0,828
	5					1	-0,833	0,687	0,419	0,850
	10					1	-0,821	0,747	0,736	0,898
	15					1	-0,910	0,866	0,855	0,917
PUKV (povprečje)	VSI						1	-0,976	-0,926	0,714
	2						1	-0,663	-0,199	0,287
	5						1	-0,910	-0,610	-0,872
	10						1	-0,982	-0,978	-0,972
	15						1	-0,960	-0,988	-0,981

informatijski prispevek (povprečje)	VSI							1	0,941	-0,805
	2							1	0,828	-0,905
	5							1	0,878	0,894
	10							1	0,997	0,936
	15							1	0,955	0,963
razmerje informacijskega prispevka (povprečje)	VSI								1	-0,668
	2								1	-0,966
	5								1	0,773
	10								1	0,931
	15								1	0,973
delež enako klasificiranih celic z odločitvenim drevesom (povprečje)	VSI									1
	2									1
	5									1
	10									1
	15									1

Preglednica 28: Usklajenost vrednotenj glede na vse podatkovne sloje (Spearmanov koeficient). Odebeljeni so statistično značilni pri $p=0,05$.

		neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenje s posameznimi podatkovnimi sloji					
		delež enako klasificiranih celic po modelu diskriminancijske analize	delež enako klasificiranih celic z odločitvenim drevesom	povprečna oddaljenost celic od najbližjega centroida	koeficient η^2	koeficient F	PUKV	informatijski prispevek	razmerje informacijskega prispevka	delež enako klasificiranih celic z odločitvenim drevesom (povprečje)
delež enako klasificiranih celic po modelu diskriminancijske analize	VSI	1	0,521	-0,122	-0,107	0,859	0,164	-0,245	-0,154	0,505
	2	1	0,569	-0,610	0,588	0,513	-0,123	0,311	0,569	-0,996
	5	1	-0,111	-0,948	0,821	0,615	-0,975	0,399	0,090	0,158
	10	1	0,415	-0,693	0,877	0,693	-0,537	-0,024	0,110	0,768
	15	1	0,352	-0,900	0,913	0,855	-0,583	0,493	0,312	0,807
delež enako klasificiranih celic z odločitvenim drevesom	VSI		1	0,390	-0,588	0,669	0,608	-0,612	-0,446	0,836
	2		1	-0,222	0,588	0,901	0,308	-0,160	1,000	-0,625
	5		1	0,206	0,100	0,056	0,138	0,296	0,310	0,160
	10		1	-0,073	0,212	0,073	0,134	0,177	0,422	0,207
	15		1	-0,324	0,275	0,333	-0,153	0,314	0,403	0,387

7.3.2.3 Sklepna ugotovitev glede vrednotenja naravnopokrajinskih tipizacij po metodah nenadzorovane klasifikacije s pomočjo vhodnih podatkovnih slojev

Primerjava vrednotenij glede na število skupin je pokazala, da ima število tipov vpliv na vrednotenje. Na splošno smo iz grafikonov razbrali, da se z večanjem števila tipov praviloma:

- zmanjšuje oddaljenost med celicami in centriidi tipov,
- znižuje natančnost pri izdelavi odločitvenega drevesa (po posameznem in po vseh podatkovnih slojih skupaj),
- povečujeta razmerje informacijskega prispevka in informacijski prispevek,
- znižuje povprečni umerjeni koeficient variacije,
- povečuje vrednost koeficienta η^2 .

Opazno je, da so z večanjem števila tipov ti bolj homogeni, saj se nekatere mere izboljšujejo (recimo povprečni umerjeni koeficient variacije, povprečna oddaljenost od centroidov), hkrati pa so z večanjem števila tipi vse težje opisljivi (vsaj z vidika odločitvenih dreves), saj je delež pravilno klasificiranih celic nižji.

Do podobnega spoznanja je prišel tudi Krevs (1998), ki je v svoji raziskavi vpliva prostorskih enot na statistične analize preveril tudi »obnašanje« koeficienta variacije (kot primera mere spremenljivosti). Ugotovil je, da se mere spremenljivosti s povečevanjem osnovnih prostorskih enot zmanjšujejo. V našem primeru je osnovna enota vedno enaka (rastrska celica), a se s povečevanjem števila tipov spreminja povprečna velikost tipov; manjše število pomeni, da so posamezni tipi v povprečju večji in zaradi tega bolj spremenljivi (manj homogeni) in lažje opisljivi.

Primerjava tipizacij glede na izvedeno vrednotenje

Pri pregledu grafikonov je opazno, da vrednosti za tipizacije po metodi segmentacije večinoma izstopajo, a še vedno nakazujejo enak trend kot ostale. Razlog za slabše ocene je predvsem ta, da so s segmentacijo določene kategorije manj homogene z vidika podatkovnih slojev. To je posledica metode, ki temelji tudi na lokaciji v prostoru (obvezna sosedskost pri združevanju celic) in ne samo v »spektralnem« prostoru, kot to velja za ostale metode.

Usklajenost različnih načinov vrednotenja

Po vrednotenju glede na posamezni podatkovni sloj smo opazili:

- da je veliko Spearmanovih koeficientov povezanosti lestvic vrednotenja statistično neznačilnih in zato ne moremo potrditi splošnega ujemanja vseh načinov vrednotenja,
- da so nekateri načini vrednotenja med seboj v splošnem večinoma dobro povezani: vrednotenje po PUKV, koeficientu F in delno koeficientu η^2 ter vrednotenju po informacijskem prispevku in razmerju informacijskega prispevka,
- pri vrednotenju vseh tipizacij naenkrat (ne glede na število tipov) so usklajeni informacijski prispevek, razmerje informacijskega prispevka in koeficient η^2 , pri vrednotenju tipizacij z enakim številom tipov pa zelo podobne ocene dajeta koeficienta η^2 in F.

Po vrednotenju glede na vse podatkovne sloje smo opazili:

- da je veliko Spearmanovih koeficientov povezanosti lestvic vrednotenja statistično neznačilnih in zato ne moremo potrditi splošnega ujemanja vseh načinov vrednotenja,
- če upoštevamo vse tipizacije (ne glede na število tipov), je precej lestvic vrednotenja statistično značilno povezanih, a so razlog za to verjetno predvsem razlike v številu tipov.

7.4 Usklajenost različnih modeliranih naravnopokrajinskih tipizacij med seboj

Z izračunom Cramerjevega koeficienta povezanosti (Krevs, 2001a; Perko, 2001) v programu SPSS smo med seboj primerjali tipizacije z enakim številom tipov in ugotovili, kako dobro se med seboj ujemajo. V preglednicah povezanosti (preglednice 29–32) je mogoče opaziti, da:

- so stopnje povezanosti med tipizacijami (ne velja za stopnje povezanosti med tipizacijama po metodi iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (ISOCLUST) in po segmentaciji) največje pri 2 tipih;
- so stopnje povezanosti med tipizacijami po metodah ISOCLUST in segmentacija najmanjše pri tistih z 2 tipoma;
- so pri tipizacijah z 2 tipoma stopnje povezanosti 0,9 in več za vse kombinacije, razen za tiste s tipizacijama po ISOCLUST in segmentaciji – te so okrog 0,4 oziroma okrog 0,2;
- so pri tipizacijah s 5 tipi stopnje povezanosti večinoma med 0,6 in 0,8 (metoda analize vrhov v histogramu in ISOCLUST imata večinoma manj kot 0,7), nekatere dosegajo tudi 1,0; le stopnje povezanosti s tipizacijami po metodi segmentacije so med 0,3 in 0,4;
- so pri tipizacijah z 10 tipi stopnje povezanosti med tipizacijami med 0,75 in 1,0; nekoliko manjše (0,6–0,7) so povezanosti s tipizacijami po metodi analize vrhov v histogramu in ISOCLUST; povezanosti s tipizacijami po metodi segmentacije pa so okrog 0,4;
- so pri tipizacijah s 15 tipi stopnje povezanosti med 0,7 in 0,9; povezanosti s tipizacijami z metodama analize vrhov v histogramu in ISOCLUST so med 0,6 in 0,7; stopnje povezanosti pri tipizacijah po metodi segmentacije pa so 0,4 in manj.

Glede na ugotovitve lahko zaključimo, da se tipizacije po različnih metodah voditeljev v programih SPSS, Idrisi in Statistica med seboj dokaj dobro ujemajo. Manj se z njimi ujemajo tipizacije po metodah analize vrhov v histogramu, ISOCLUST in segmentacije. Tipizacije po metodi analize vrhov v histogramu in metodi ISOCLUST se med seboj povezujejo s stopnjo povezanosti okrog 0,7 in več (le pri 2 skupinah 0,4). Tipizacije po segmentaciji se ne povezujejo z večjo stopnjo povezanosti kot 0,41.

Rezultati primerjav so pričakovani, saj so si tipizacije, ki so narejene s podobnimi metodami (oziroma z različnimi nastavitvami enakih metod), med seboj bolj podobne kot v primerjavi s tipizacijami popolnoma drugačnih metod. V tem primeru je treba izpostaviti segmentacijo, pri kateri je pomembna tudi lega v prostoru (sosedska celica).

Preglednica 29: Cramerjev koeficient povezanosti za klasifikacije z 2 skupinama ($p=0,001$).

	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
01SPSS	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,93	0,44	0,18
02STAT1		1,00	1,00	1,00	1,00	1,00	1,00	0,93	0,44	0,18
03STAT2			1,00	1,00	1,00	1,00	1,00	0,93	0,44	0,18
04SPSS2				1,00	1,00	1,00	1,00	0,93	0,44	0,18
05KM1					1,00	1,00	1,00	0,93	0,44	0,18
06KM2						1,00	1,00	0,93	0,44	0,18
07KM3							1,00	0,93	0,44	0,18
08CL								1,00	0,40	0,17
09ISO									1,00	0,37
10SEG										1,00

Preglednica 30: Cramerjev koeficient povezanosti za klasifikacije s 5 skupinami (p=0,001).

	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
01SPSS	1,00	0,76	0,64	0,78	0,76	1,00	1,00	0,58	0,62	0,34
02STAT1		1,00	0,78	0,88	1,00	0,76	0,76	0,64	0,68	0,37
03STAT2			1,00	0,70	0,78	0,64	0,64	0,71	0,61	0,37
04SPSS2				1,00	0,88	0,78	0,78	0,62	0,66	0,35
05KM1					1,00	0,76	0,76	0,64	0,68	0,37
06KM2						1,00	1,00	0,58	0,62	0,34
07KM3							1,00	0,58	0,62	0,34
08CL								1,00	0,76	0,29
09ISO									1,00	0,36
10SEG										1,00

Preglednica 31: Cramerjev koeficient povezanosti za klasifikacije z 10 skupinami (p=0,001).

	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
01SPSS	1,00	1,00	0,84	0,82	0,80	0,77	0,93	0,65	0,64	0,39
02STAT1		1,00	0,84	0,82	0,81	0,77	0,93	0,65	0,64	0,39
03STAT2			1,00	0,83	0,84	0,89	0,88	0,66	0,64	0,40
04SPSS2				1,00	0,75	0,76	0,83	0,64	0,63	0,40
05KM1					1,00	0,77	0,81	0,65	0,65	0,40
06KM2						1,00	0,79	0,65	0,62	0,39
07KM3							1,00	0,65	0,62	0,39
08CL								1,00	0,73	0,36
09ISO									1,00	0,34
10SEG										1,00

Preglednica 32: Cramerjev koeficient povezanosti za klasifikacije s 15 skupinami (p=0,001).

	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG*
01SPSS	1,00	0,81	0,84	0,72	0,71	0,71	0,86	0,63	0,63	0,37
02STAT1		1,00	0,86	0,77	0,78	0,83	0,86	0,60	0,65	0,37
03STAT2			1,00	0,72	0,77	0,76	0,91	0,63	0,65	0,40
04SPSS2				1,00	0,72	0,71	0,72	0,60	0,62	0,38
05KM1					1,00	0,81	0,81	0,68	0,64	0,41
06KM2						1,00	0,74	0,61	0,65	0,40
07KM3							1,00	0,66	0,66	0,39
08CL								1,00	0,66	0,39
09ISO									1,00	0,35
10SEG*										1,00

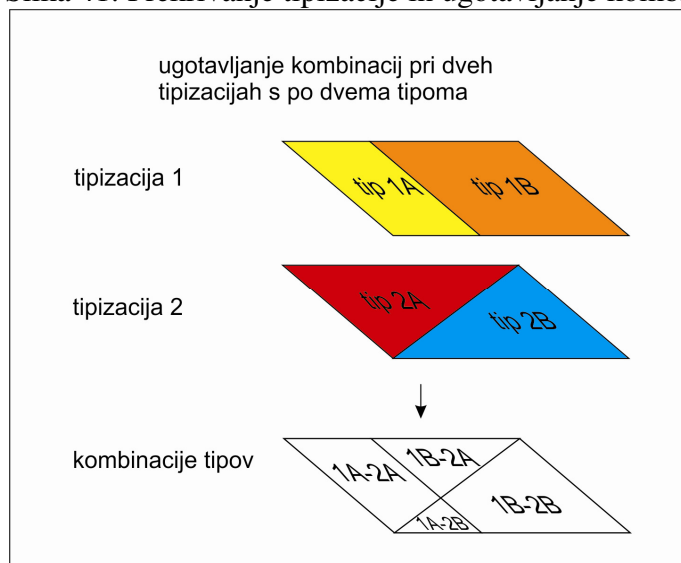
* Izračunane vrednosti so enake za različici A in B, zato nista navedeni ločeno.

7.5 Ugotavljanje števila kombinacij tipov različnih naravnopokrajinskih tipizacij

Ugotavljali smo, koliko različnih kombinacij se pojavlja zaradi (ne)uskklajenosti tipizacij z istim številom tipov. Z geoinformacijskim orodjem COMBINE smo v programu ArcGIS (slika 41) ugotovili, katere celice imajo enako kombinacijo tipov posamezne serije tipizacij; prekrili smo tipizacije po vseh 10 metodah za vsako število tipov: za 2, 5, 10 in 15. Ker smo

ugotovili, da so rezultati segmentacije najmanj podobni ostalim tipizacijami, smo prekrivanje izvedli dvakrat – prvič s tipizacijami po segmentaciji, drugič pa brez njih.

Slika 41: Prekrivanje tipizacije in ugotavljanje kombinacij.



Glede števila kombinacij posameznih serij tipizacij smo ugotovili, da se z večanjem števila tipov povečuje tudi neskladje med tipizacijami. Podobno smo ugotovili tudi za večino tipizacij pri računanju povezanosti s Cramerjevim koeficientom. Število kombinacij se z večanjem števila tipov zvišuje; še posebej veliko je kombinacij, če v analizo vključimo tipizacijo Slovenije po metodi segmentacije (preglednica 33). Pri tem je še vidno, da se z večanjem števila tipov zmanjšuje površina tistih kombinacij, ki pokrivajo vsaj 1 % površja Slovenije (preglednica 34).

Preglednica 33: Število kombinacij za posamezno serijo tipizacij.

število tipov	število kombinacij z upoštevanjem vseh tipizacij	število kombinacij brez upoštevanja tipizacije po metodi segmentacije
2	25	14
5	561	200
10	3028	784
15	-	1756
15 (A)	7114	-
15 (B)	7062	-

Preglednica 34: Skupen delež površine območij, ki pokrivajo vsaj 1 % površine Slovenije.

število tipov	delež površine z upoštevanjem vseh tipizacij	delež površine brez upoštevanja tipizacije po metodi segmentacije
2	98,1	99,5
5	69,4	83,2
10	30,5	65,4
15	-	49,3
15 (A)	16,2	-
15 (B)	16,6	-

7.6 Ugotavljanje oddaljenosti celic od najbližjih centroidov

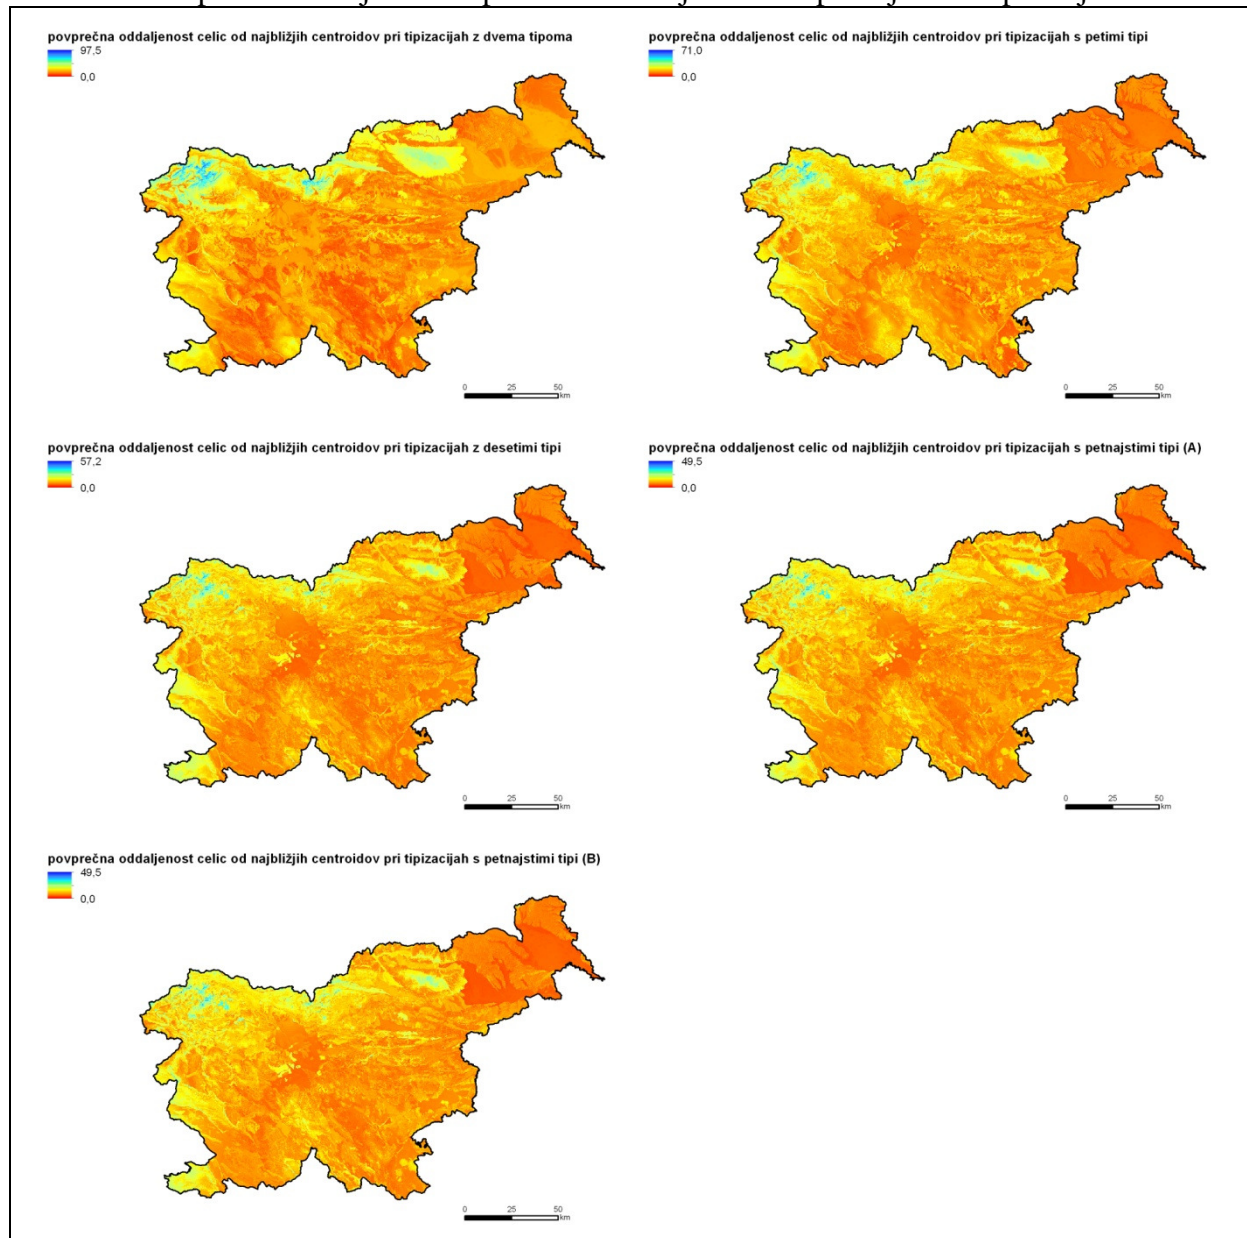
V tem delu smo za vsako tipizacijo izračunali oddaljenost posamezne celice od centroida tipa, ki mu celica pripada. Na ta način smo po preprostem principu (Evklidova razdalja) za vsako tipizacijo dobili zemljevid, ki prikazuje, katere celice so bolj na obrobju svojih tipov (z vidika vrednosti podatkovnih slojev!) in katere so bolj v središču, torej imajo neke povprečne značilnosti enega izmed tipov. Za tipizacije z enakim številom tipov smo nato izračunali tudi povprečno oddaljenost celice od najbližjega centroida. Tako smo poleg osnovnih 41 zemljevidov oddaljenosti dobili še 5 zemljevidov povprečnih oddaljenosti (za serije klasifikacij s po 2, 5, 10, 15 tipov; pri 15 tipih smo zemljevid izdelali z različico A in B). Nato smo preverili stopnje povezanosti (izračunali smo Pearsonov in Spearmanov koeficient) med povprečno oddaljenostjo celice in oddaljenostjo celice za vsako tipizacijo posebej.

Slikovno prikazujemo le povprečne oddaljenosti posamezne serije tipizacij (slika 42): za 2 tipa, za 5 tipov, za 10 tipov in za 15 tipov. Pri pregledu zemljevidov oddaljenosti celic od najbližjega centroida moramo upoštevati, da je bilo to izračunano iz tipizacij na podlagi temperature, prepustnosti in naklona. To pomeni, da zemljevidi prikazujejo najtežje uvrstljive celice z vidika teh treh podatkovnih slojev. Opazno kot zelo oddaljene celice izstopajo tiste v visokogorskem svetu (Julijske Alpe, Kamniško-Savinjske Alpe, Pohorje), obronki Trnovskega gozda in Nanosa ter Koprsko primorje. To je pričakovano, saj so to območja, ki izstopajo po temperaturi (najvišja nadmorska višina visokogorskega sveta oziroma najnižja submediteranskega sveta), naklonu (strma pobočja dinarskih planot) ali prepustnosti (magmatske in metamorfne kamnine na Pohorju in v okolici).

Ob analizi povezanosti¹⁹ posameznih oddaljenosti in povprečnih oddaljenosti (preglednica 35–39) je opazno, da je povprečna oddaljenost v povprečju relativno dobro povezana z veliko večino posameznih oddaljenosti (zadnji vrstici v omenjenih preglednicah). Zato lahko sklepamo, da je povprečna oddaljenost dober pokazatelj tega, katere celice se nahajajo blizu centroidov in katere celice so bolj oddaljene od centroidov oziroma zelo odstopajo od povprečja. Na tem mestu poudarjamo, da tukaj ne prikazujemo, koliko je povprečna celica oddaljena od izbranega centroida tipa, ampak od najbližjega. Ob pregledu zemljevidov zato ne moremo sklepati o tipih, ampak le o splošni oddaljenosti (oziroma težavnosti za klasifikacijo) posameznih celic. Manj je z ostalimi oddaljenostmi povezana oddaljenost po metodi segmentacije, kar ni presenetljivo, saj ta metoda tipe določa tudi na podlagi sosedskosti.

¹⁹ Posamezni izračunani povprečni koeficienti povezanosti so določeni s statistično značilnostjo $p=0,01$, določitev najvišjega povprečnega (primerjava med njimi) pa z $p=0,10$.

Slika 42: Povprečna oddaljenost za posamezno serijo naravnopokrajinskih tipizacij.



Preglednica 35: Koeficienti povezanosti za serijo tipizacij z 2 tipoma. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.

	povprečna oddaljenost (2 tipa)	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
povprečna oddaljenost (2 tipa)	1,000	0,987	0,987	0,987	0,987	0,987	0,987	0,987	0,980	0,762	0,631
	1,000	0,978	0,978	0,978	0,979	0,978	0,978	0,978	0,973	0,673	0,592
01SPSS	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
02STAT1	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
03STAT2	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
04SPSS2	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,996	0,669	0,514
	0,979	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,553	0,462
05KM1	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
06KM2	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
07KM3	0,987	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,997	0,666	0,513
	0,978	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,995	0,549	0,462
08CL	0,980	0,997	0,997	0,997	0,996	0,997	0,997	0,997	1,000	0,636	0,499
	0,973	0,995	0,995	0,995	0,995	0,995	0,995	0,995	1,000	0,522	0,473
09ISO	0,762	0,666	0,666	0,666	0,669	0,666	0,666	0,666	0,636	1,000	0,700
	0,673	0,549	0,549	0,549	0,553	0,549	0,549	0,549	0,522	1,000	0,638
10SEG	0,631	0,513	0,513	0,513	0,514	0,513	0,513	0,513	0,499	0,700	1,000
	0,592	0,462	0,462	0,462	0,462	0,462	0,462	0,462	0,473	0,638	1,000
povprečen Pearsonov koef.	0,928	0,916	0,916	0,916	0,917	0,916	0,916	0,916	0,909	0,676	0,542
povprečen Spearmanov koef.	0,909	0,899	0,899	0,899	0,899	0,899	0,899	0,899	0,893	0,568	0,494

Preglednica 36: Koeficienti povezanosti za serijo tipizacij s 5 tipi. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.

	povprečna oddaljenost (5 tipov)	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
povprečna oddaljenost (5 tipov)	1,000	0,854	0,889	0,842	0,874	0,889	0,854	0,854	0,862	0,844	0,598
	1,000	0,797	0,881	0,813	0,857	0,881	0,797	0,797	0,798	0,859	0,555
01SPSS	0,854	1,000	0,804	0,548	0,791	0,804	1,000	1,000	0,614	0,616	0,299
	0,797	1,000	0,760	0,467	0,730	0,761	1,000	1,000	0,484	0,610	0,259
02STAT1	0,889	0,804	1,000	0,731	0,957	1,000	0,803	0,803	0,683	0,613	0,310
	0,881	0,760	1,000	0,725	0,945	1,000	0,760	0,760	0,649	0,694	0,281
03STAT2	0,842	0,548	0,731	1,000	0,691	0,731	0,548	0,548	0,842	0,704	0,551
	0,813	0,467	0,725	1,000	0,681	0,725	0,467	0,467	0,833	0,684	0,442
04SPSS2	0,874	0,791	0,957	0,691	1,000	0,956	0,791	0,791	0,664	0,622	0,307
	0,857	0,730	0,945	0,681	1,000	0,944	0,730	0,730	0,599	0,679	0,287
05KM1	0,889	0,804	1,000	0,731	0,956	1,000	0,804	0,804	0,683	0,613	0,310
	0,881	0,761	1,000	0,725	0,944	1,000	0,760	0,760	0,649	0,694	0,281
06KM2	0,854	1,000	0,803	0,548	0,791	0,804	1,000	1,000	0,615	0,616	0,299
	0,797	1,000	0,760	0,467	0,730	0,760	1,000	1,000	0,484	0,610	0,259
07KM3	0,854	1,000	0,803	0,548	0,791	0,804	1,000	1,000	0,615	0,616	0,299
	0,797	1,000	0,760	0,467	0,730	0,760	1,000	1,000	0,484	0,610	0,259
08CL	0,862	0,614	0,683	0,842	0,664	0,683	0,615	0,615	1,000	0,809	0,509
	0,798	0,484	0,649	0,833	0,599	0,649	0,484	0,484	1,000	0,742	0,389
09ISO	0,844	0,616	0,613	0,704	0,622	0,613	0,616	0,616	0,809	1,000	0,569
	0,859	0,610	0,694	0,684	0,679	0,694	0,610	0,610	0,742	1,000	0,405
10SEG	0,598	0,299	0,310	0,551	0,307	0,310	0,299	0,299	0,509	0,569	1,000
	0,555	0,259	0,281	0,442	0,287	0,281	0,259	0,259	0,389	0,405	1,000
povprečen Pearsonov koef.	0,836	0,733	0,759	0,674	0,745	0,759	0,733	0,733	0,690	0,662	0,405
povprečen Spearmanov koef.	0,804	0,687	0,745	0,630	0,718	0,746	0,687	0,687	0,611	0,659	0,342

Preglednica 37: Koeficienti povezanosti za serijo tipizacij z 10 tipi. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.

	povprečna oddaljenost (10 tipov)	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
povprečna oddaljenost (10 tipov)	1,000	0,940	0,940	0,935	0,931	0,926	0,865	0,935	0,830	0,802	0,532
	1,000	0,924	0,924	0,924	0,900	0,896	0,828	0,917	0,784	0,759	0,507
01SPSS	0,940	1,000	1,000	0,913	0,903	0,892	0,808	0,977	0,751	0,701	0,340
	0,924	1,000	1,000	0,906	0,878	0,843	0,763	0,963	0,699	0,660	0,309
02STAT1	0,940	1,000	1,000	0,913	0,903	0,892	0,808	0,977	0,751	0,701	0,340
	0,924	1,000	1,000	0,906	0,878	0,842	0,763	0,963	0,699	0,660	0,309
03STAT2	0,935	0,913	0,913	1,000	0,930	0,907	0,889	0,929	0,714	0,687	0,360
	0,924	0,906	0,906	1,000	0,910	0,879	0,859	0,935	0,676	0,636	0,322
04SPSS2	0,931	0,903	0,903	0,930	1,000	0,855	0,843	0,909	0,746	0,706	0,375
	0,900	0,878	0,878	0,910	1,000	0,782	0,784	0,889	0,664	0,657	0,341
05KM1	0,926	0,892	0,892	0,907	0,855	1,000	0,816	0,899	0,736	0,728	0,385
	0,896	0,843	0,842	0,879	0,782	1,000	0,776	0,853	0,675	0,684	0,374
06KM2	0,865	0,808	0,808	0,889	0,843	0,816	1,000	0,821	0,694	0,620	0,331
	0,828	0,763	0,763	0,859	0,784	0,776	1,000	0,795	0,651	0,553	0,303
07KM3	0,935	0,977	0,977	0,929	0,909	0,899	0,821	1,000	0,728	0,684	0,335
	0,917	0,963	0,963	0,935	0,889	0,853	0,795	1,000	0,654	0,623	0,309
08CL	0,830	0,751	0,751	0,714	0,746	0,736	0,694	0,728	1,000	0,744	0,294
	0,784	0,699	0,699	0,676	0,664	0,675	0,651	0,654	1,000	0,720	0,240
09ISO	0,802	0,701	0,701	0,687	0,706	0,728	0,620	0,684	0,744	1,000	0,298
	0,759	0,660	0,660	0,636	0,657	0,684	0,553	0,623	0,720	1,000	0,237
10SEG	0,532	0,340	0,340	0,360	0,375	0,385	0,331	0,335	0,294	0,298	1,000
	0,507	0,309	0,309	0,322	0,341	0,374	0,303	0,309	0,240	0,237	1,000
povprečen Pearsonov koef.	0,864	0,823	0,823	0,818	0,810	0,804	0,749	0,820	0,699	0,667	0,359
povprečen Spearmanov koef.	0,836	0,794	0,794	0,795	0,768	0,760	0,707	0,790	0,646	0,619	0,325

Preglednica 38: Koeficienti povezanosti za serijo tipizacij s 15 tipi (različica A). Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.

	povprečna oddaljenost (15 tipov, različica A)	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
povprečna oddaljenost (15 tipov, različica A)	1,000	0,859	0,885	0,903	0,859	0,877	0,866	0,891	0,741	0,821	0,619
	1,000	0,813	0,872	0,894	0,811	0,831	0,842	0,870	0,668	0,761	0,624
01SPSS	0,859	1,000	0,825	0,844	0,773	0,690	0,740	0,823	0,578	0,688	0,389
	0,813	1,000	0,776	0,795	0,708	0,594	0,648	0,787	0,519	0,618	0,380
02STAT1	0,885	0,825	1,000	0,866	0,810	0,756	0,885	0,819	0,534	0,701	0,393
	0,872	0,776	1,000	0,869	0,758	0,731	0,846	0,844	0,463	0,611	0,397
03STAT2	0,903	0,844	0,866	1,000	0,757	0,793	0,792	0,899	0,610	0,681	0,446
	0,894	0,795	0,869	1,000	0,714	0,753	0,764	0,909	0,551	0,646	0,437
04SPSS2	0,859	0,773	0,810	0,757	1,000	0,745	0,785	0,741	0,595	0,728	0,383
	0,811	0,708	0,758	0,714	1,000	0,697	0,726	0,698	0,462	0,591	0,377
05KM1	0,877	0,690	0,756	0,793	0,745	1,000	0,794	0,850	0,666	0,695	0,436
	0,831	0,594	0,731	0,753	0,697	1,000	0,796	0,782	0,567	0,616	0,423
06KM2	0,866	0,740	0,885	0,792	0,785	0,794	1,000	0,718	0,554	0,728	0,394
	0,842	0,648	0,846	0,764	0,726	0,796	1,000	0,693	0,483	0,647	0,404
07KM3	0,891	0,823	0,819	0,899	0,741	0,850	0,718	1,000	0,654	0,678	0,416
	0,870	0,787	0,844	0,909	0,698	0,782	0,693	1,000	0,574	0,628	0,394
08CL	0,741	0,578	0,534	0,610	0,595	0,666	0,554	0,654	1,000	0,696	0,313
	0,668	0,519	0,463	0,551	0,462	0,567	0,483	0,574	1,000	0,626	0,291
09ISO	0,821	0,688	0,701	0,681	0,728	0,695	0,728	0,678	0,696	1,000	0,336
	0,761	0,618	0,611	0,646	0,591	0,616	0,647	0,628	0,626	1,000	0,311
10SEG	0,619	0,389	0,393	0,446	0,383	0,436	0,394	0,416	0,313	0,336	1,000
	0,624	0,380	0,397	0,437	0,377	0,423	0,404	0,394	0,291	0,311	1,000
povprečen Pearsonov koef.	0,832	0,721	0,747	0,759	0,718	0,730	0,726	0,749	0,594	0,675	0,413
povprečen Spearmanov koef.	0,799	0,664	0,717	0,733	0,654	0,679	0,685	0,718	0,520	0,606	0,404

Preglednica 39: Koeficienti povezanosti za serijo tipizacij s 15 tipi (različica B). Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.

	povprečna oddaljenost (15 tipov, različica B)	01SPSS	02STAT1	03STAT2	04SPSS2	05KM1	06KM2	07KM3	08CL	09ISO	10SEG
povprečna oddaljenost (15 tipov, različica B)	1,000	0,860	0,885	0,904	0,859	0,876	0,865	0,891	0,742	0,820	0,614
	1,000	0,814	0,872	0,893	0,812	0,829	0,840	0,870	0,669	0,758	0,629
01SPSS	0,860	1,000	0,825	0,844	0,773	0,690	0,740	0,823	0,578	0,688	0,385
	0,814	1,000	0,776	0,795	0,708	0,594	0,648	0,787	0,519	0,618	0,390
02STAT1	0,885	0,825	1,000	0,866	0,810	0,756	0,885	0,819	0,534	0,701	0,388
	0,872	0,776	1,000	0,869	0,758	0,731	0,846	0,844	0,463	0,611	0,402
03STAT2	0,904	0,844	0,866	1,000	0,757	0,793	0,792	0,899	0,610	0,681	0,441
	0,893	0,795	0,869	1,000	0,714	0,753	0,764	0,909	0,551	0,646	0,438
04SPSS2	0,859	0,773	0,810	0,757	1,000	0,745	0,785	0,741	0,595	0,728	0,379
	0,812	0,708	0,758	0,714	1,000	0,697	0,726	0,698	0,462	0,591	0,382
05KM1	0,876	0,690	0,756	0,793	0,745	1,000	0,794	0,850	0,666	0,695	0,427
	0,829	0,594	0,731	0,753	0,697	1,000	0,796	0,782	0,567	0,616	0,415
06KM2	0,865	0,740	0,885	0,792	0,785	0,794	1,000	0,718	0,554	0,728	0,384
	0,840	0,648	0,846	0,764	0,726	0,796	1,000	0,693	0,483	0,647	0,399
07KM3	0,891	0,823	0,819	0,899	0,741	0,850	0,718	1,000	0,654	0,678	0,410
	0,870	0,787	0,844	0,909	0,698	0,782	0,693	1,000	0,574	0,628	0,397
08CL	0,742	0,578	0,534	0,610	0,595	0,666	0,554	0,654	1,000	0,696	0,312
	0,669	0,519	0,463	0,551	0,462	0,567	0,483	0,574	1,000	0,626	0,301
09ISO	0,820	0,688	0,701	0,681	0,728	0,695	0,728	0,678	0,696	1,000	0,325
	0,758	0,618	0,611	0,646	0,591	0,616	0,647	0,628	0,626	1,000	0,306
10SEG	0,614	0,385	0,388	0,441	0,379	0,427	0,384	0,410	0,312	0,325	1,000
	0,629	0,390	0,402	0,438	0,382	0,415	0,399	0,397	0,301	0,306	1,000
povprečen Pearsonov koef.	0,832	0,721	0,747	0,759	0,717	0,729	0,725	0,748	0,594	0,674	0,407
povprečen Spearmanov koef.	0,799	0,665	0,717	0,733	0,655	0,678	0,684	0,718	0,522	0,605	0,406

Primerjali smo tudi zemljevide povprečne oddaljenosti celic od najbližjih centroidov med serijami (preglednica 40). Zemljevidi povprečne oddaljenosti za različne tipe so med seboj kar dobro povezani, še najmanj je z ostalimi povezana povprečna oddaljenost pri 2 tipih. To pomeni, da se nekatera območja pojavljajo na obrobju svojih tipov ne glede na izbrano število tipov.

Preglednica 40: Koeficienti povezanosti povprečnih oddaljenosti celic od najbližjih centroidov med serijami. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p < 0,001$.

	povprečna oddaljenost (2 tipa)	povprečna oddaljenost (5 tipov)	povprečna oddaljenost (10 tipov)	povprečna oddaljenost (15 tipov, različica A)	povprečna oddaljenost (15 tipov, različica B)
povprečna oddaljenost (2 tipa)	1,000	0,807	0,690	0,650	0,650
	1,000	0,718	0,580	0,551	0,552
povprečna oddaljenost (5 tipov)		1,000	0,893	0,851	0,851
		1,000	0,842	0,791	0,791
povprečna oddaljenost (10 tipov)			1,000	0,962	0,962
			1,000	0,943	0,943
povprečna oddaljenost (15 tipov, različica A)				1,000	0,999
				1,000	0,999
povprečna oddaljenost (15 tipov, različica B)					1,000
					1,000

8. Vrednotenje različnih naravnopokrajinskih tipizacij Slovenije, izdelanih z metodami nadzorovane klasifikacije

8.1 Zasnova izdelave naravnopokrajinskih tipizacij z metodami nadzorovane klasifikacije

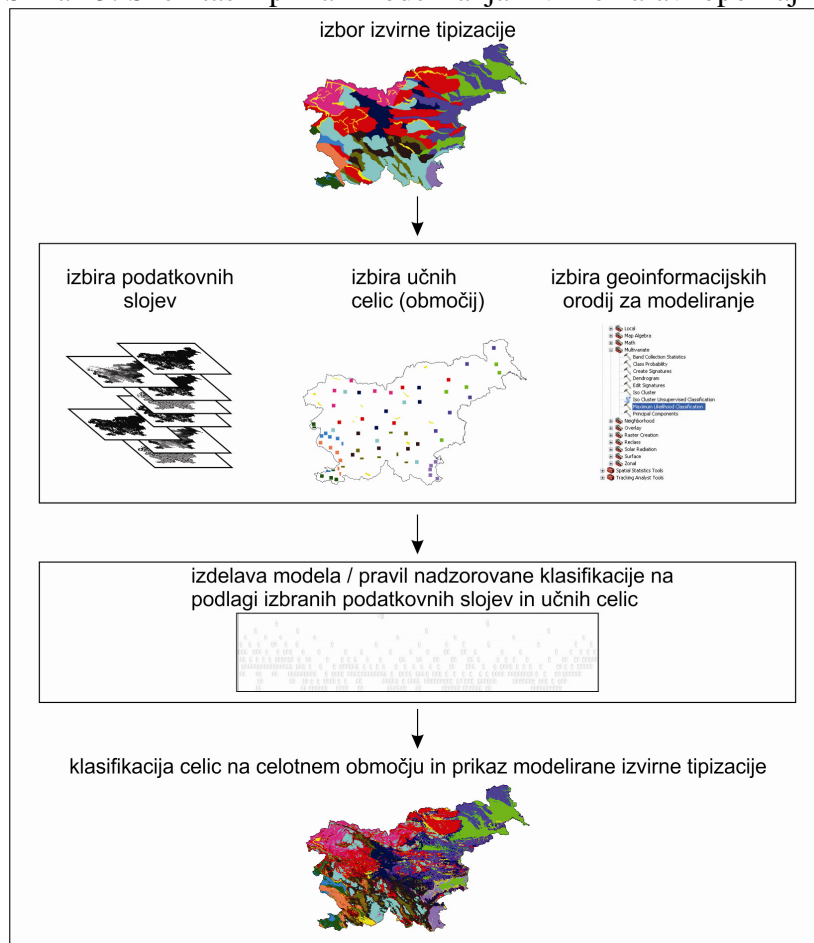
Glavni namen izdelave modeliranih naravnopokrajinskih tipizacij v drugem delu disertacije je ugotoviti, kako se tipizacije po različnih metodah nadzorovanih klasifikacij ujemajo oziroma kako dobro lahko modeliramo in se približamo izvornim tipizacijam (jih računalniško dokažemo). Na ta način želimo tudi ugotoviti, katera območja v Sloveniji se klasificirajo enako ne glede na izbrano metodo.

V tem poglavju prikazujemo, kako smo zasnovali celoten potek izdelave modeliranih tipizacij z metodami nadzorovane klasifikacije (slika 43). Izbrali smo:

- izvorno naravnopokrajinsko tipizacijo Slovenije (izbrali smo dve tipizaciji),
- podatkovne sloje, ki smo jih uporabili za modeliranje izvirnih tipizacij,
- geoinformacijska orodja, s katerimi smo skušali priti do izvirni tipizaciji podobnih rezultatov,
- dva načina vzorčenja učnih celic, na podlagi katerih smo izdelali klasifikacijska pravila oziroma modele.

Ob tem predpostavljamo, da so obstoječi tipi ustrezno zasnovani in da vzorci izbranih učnih celic odražajo tipe v tolikšni meri, da lahko na podlagi njihovih vrednosti izdelamo klasifikacijska pravila/modele in spektralne podpise, na podlagi katerih lahko z ustrezno metodo klasificiramo vse celice na območju Slovenije tako, da se lahko te modelirane tipizacije kar najbolj približajo izvirni tipizaciji.

Slika 43: Shematski prikaz modeliranja izvorne naravnopokrajinske tipizacije.



8.1.1 Izbor izvirnih naravnopokrajinskih tipizacij

Za predmet modeliranja oziroma izvedbo metod nadzorovane klasifikacije smo izbrali dve tipizaciji Slovenije:

- pokrajinskoekološki tipi (Špes s sod., 2002; slika 44),
- pokrajinski tipi (Perko, 1998a; Perko, 1998b; Perko, 2007b; slika 45).

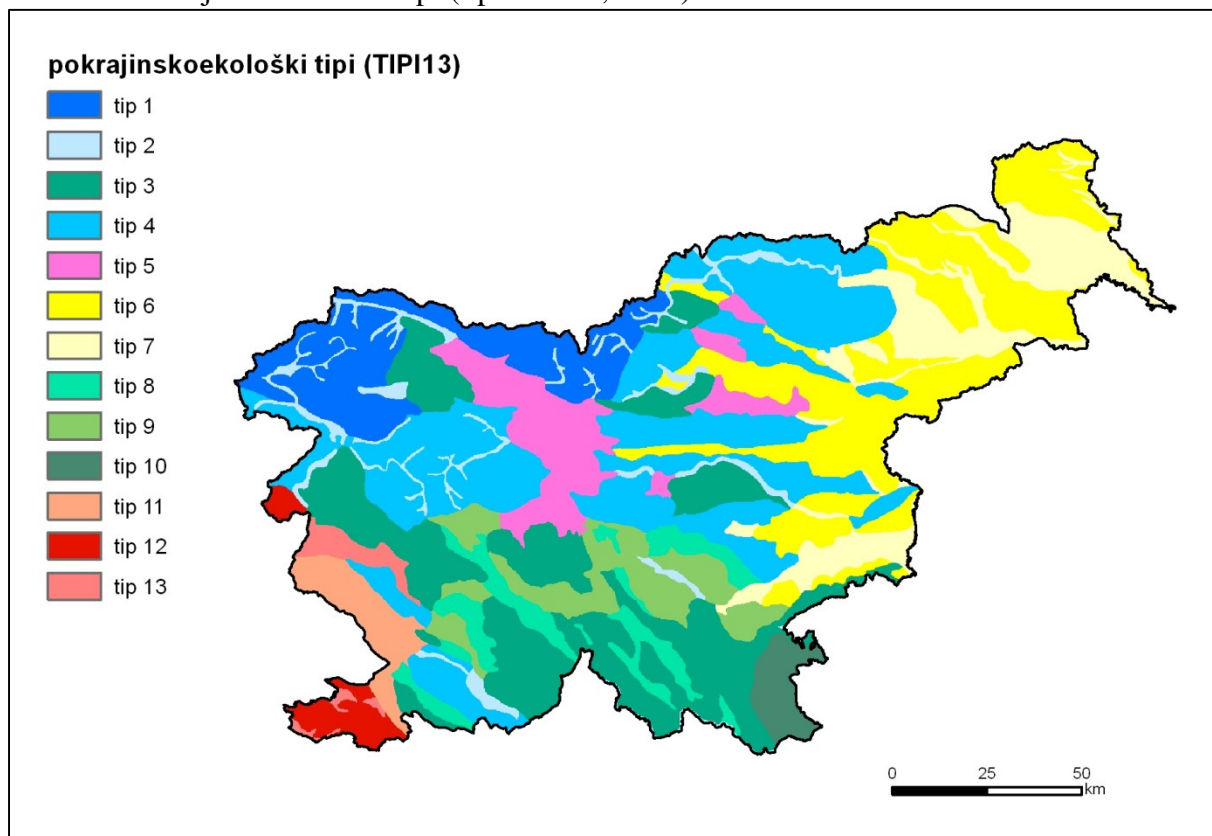
Izmed vseh klasifikacij Slovenije, ki smo jih pregledali (priloga 1), smo ju izbrali, ker gre za klasifikaciji na tipe ter ker sta dostopni v digitalnem zapisu. Zaradi lažjega dela smo obema tipizacijama dodelili oznako: tipizacijo s pokrajinskoekološkimi tipi smo označili s TIPI13, tipizacijo s pokrajinskimi tipi pa s TIPI9. Prav tako smo tipom v obeh primerih dodali oznake (preglednica 41, preglednica 42), ki jih zaradi lažje preglednosti uporabljamo v disertaciji. Za obe tipizaciji smo menili, da sta, kljub pretežno ekspertnemu določanju tipov, zadosti objektivni in jih lahko uporabimo pri računskem modeliranju. Objektivnost obeh tipizacij smo dejansko tudi dokazali²⁰ tako, da smo rezultate naših modelov (ki so predstavljeni v poglavju 8) primerjali z rezultati modeliranja popačenih tipizacij (priloga 14). Na ta način lahko tudi potrdimo, da sta tipizaciji kljub svoji abstrakciji narave še vedno lahko podprti z modelom podatkovnih slojev dejanskih naravnih dejavnikov.

Preglednica 41: Imena in oznake posameznih pokrajinskoekoloških tipov.

ime tipa	oznaka tipa
visokogorski svet	tip 1
širše rečne doline v visokogorju, hribovju in na krasu	tip 2
visoke kraške planote in hribovja v karbonatnih kamninah	tip 3
hribovja v pretežno nekarbonatnih kamninah	tip 4
medgorske kotline	tip 5
gričevje v notranjem delu Slovenije	tip 6
ravnine in širše doline v gričevju notranjega dela Slovenije	tip 7
kraška polja in podolja	tip 8
nizki kras Notranjske in Dolenjske	tip 9
nizki kras Bele krajine	tip 10
Kras in Podgorski kras	tip 11
gričevje v primorskem delu Slovenije	tip 12
širše doline in obalne ravnice v primorskem delu Slovenije	tip 13

²⁰ Analiza (priloga 14) s popačenima (neekspertno preoblikovanima) tipizacijama TIPI9 in TIPI13 je pokazala, da sta izvorni tipizaciji TIPI9 (Perko, 1998a; Perko, 1998b; Perko, 2007b) in TIPI13 (Špes s sod., 2002) dovolj kakovostni za modeliranje, saj lahko izdelamo precej boljše modelirane tipizacije kot pa pri modeliranju popačenih (naključnih) tipizacij. Pri modeliranju popačene izvorne tipizacije smo uspeli sicer z nekaterimi metodami (metoda najmanjše razdalje in metoda največje verjetnosti) priti do dobrih ocen z vidika podatkovnih slojev, a se sam rezultat teh metod sploh ne ujema z izhodiščno tipizacijo. Poleg tega pa nekatere metode (na primer odločitvena drevesa) sploh niso uspeli izdelati modela. Kot je razvidno v nadaljevanju disertacije, smo uspeli pri modeliranju izvorne (nepopačene) tipizacije z vsemi metodami izdelati model, ki se je neprimerljivo bolje ujemal z izvorno tipizacijo!

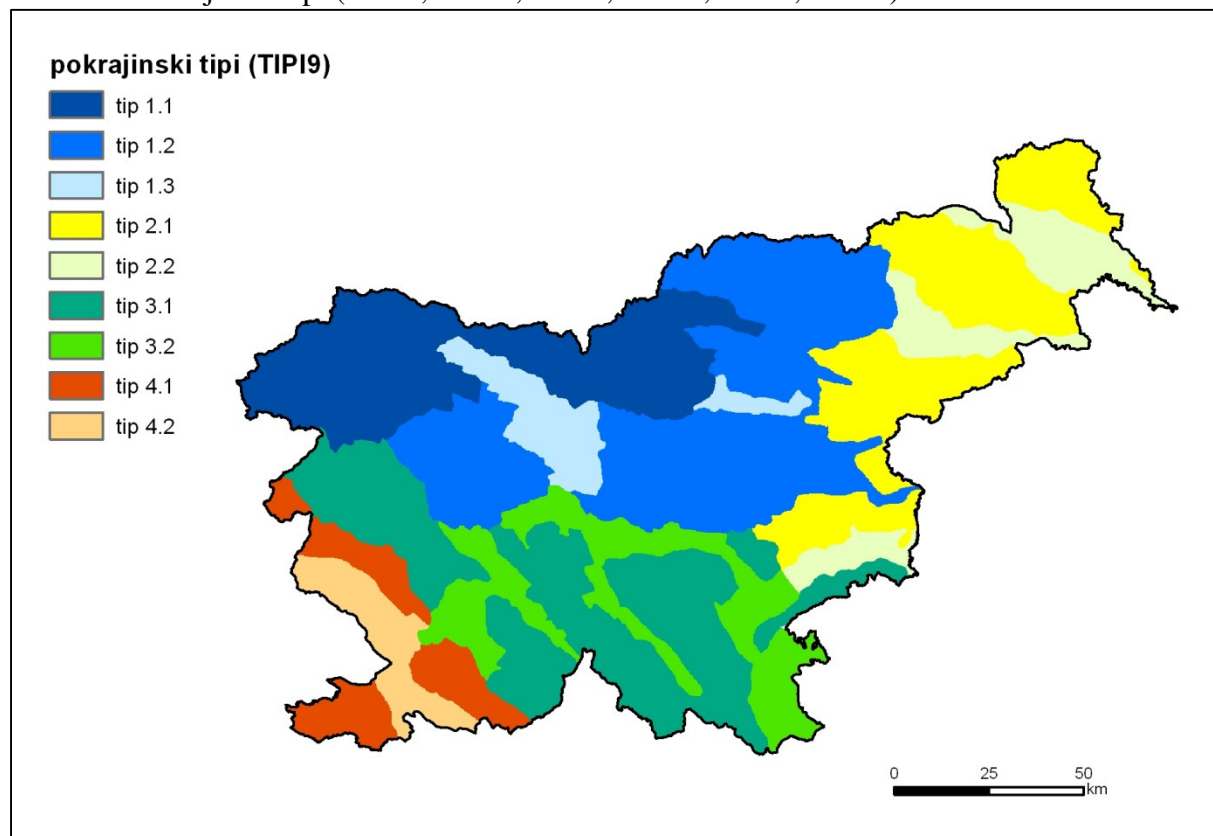
Slika 44: Pokrajinskoekološki tipi (Špes s sod., 2002)



Preglednica 42: Imena in oznake posameznih pokrajinskih tipov.

ime tipa	oznaka tipa
alpska gorovja	tip 1.1
alpska hribovja	tip 1.2
alpske ravnine	tip 1.3
panonska gričevja	tip 2.1
panonske ravnine	tip 2.2
dinarske planote	tip 3.1
dinarska podoljšja in ravniki	tip 3.2
sredozemska gričevja	tip 4.1
sredozemske planote	tip 4.2

Slika 45: Pokrajinski tipi (Perko, 1998a; Perko, 1998b; Perko, 2007b)



8.1.2 Izbor geoinformacijskih orodij

Za modeliranje obstoječih tipizacij smo izbrali več različnih geoinformacijskih orodij (preglednica 43; opis v prilogi 4). Za izdelavo spektralnih podpisov smo uporabili modul MAKESIG v programu Idrisi Taiga.

Preglednica 43: Izbrana geoinformacijska orodja za izvedbo metod nadzorovane klasifikacije.


oznaka metode (klasifikacije)	metoda	modul	računalniški program	nastavitve
CT	odločitveno drevo, različica CT	Decision tree (<i>Classification and Regression trees</i>)	SPSS	algoritem <i>Classification and Regression trees</i> , mera je Ginijev koeficient, deset ravni, 100 enot v notranjih vozliščih, 50 enot v zunanjih vozliščih, minimalno izboljšanje Ginijevega koeficienta: 0,0001, pruning SE = 1)
MDS	metoda najmanjše razdalje	MINDIST (in MAKESIG), SPSS (za mehko različico)	Idrisi Taiga, SPSS (za mehko različico)	tip razdalje ni dodatno standardiziran, najdaljša razdalja ni omejena
MXL	metoda največje verjetnosti	MAXLIKE (in MAKESIG)	Idrisi Taiga	enake apriorne (prvotne) verjetnosti za vsak tip, minimalna verjetnost za klasifikacijo je 0
KNN	metoda k najbližjih sosedov	KNN (in MAKESIG)	Idrisi Taiga	število sosedov k je 30 (privzeto), najvišja dovoljena vrednost celic iz posamezne kategorije je bila 2000 učnih celic
CTR	odločitveno drevo, različica CTR	CTA (Classification tree analysis)	Idrisi Taiga	algoritem CTA, mera rje azmerje informacijskega prispevka, obrezovanje

				(vozlišča z manj kot 1 % celic v tipu)
CTG	odločitveno drevo, različica CTG	CTA	Idrisi Taiga	algoritem CTA, mera je Ginijev koeficient, obrezovanje (vozlišča z manj kot 1 % celic v tipu)
CTE	odločitveno drevo, različica CTE	CTA	Idrisi Taiga	algoritem CTA, mera je informacijski prispevek, obrezovanje (vozlišča z manj kot 1 % celic v tipu)

Izbira ravni v programu SPSS

Gradnja odločitvenega drevesa v SPSS omogoča izbiro velikosti drevesa oziroma števila ravni. Z večjim drevesom (več pravil) pridemo do bolj natančnega rezultata, ki pa je (preveč) prilagojen učnim celicam. Da bi izbrali ustrezno velikost, smo najprej ugotovili, kolikšne so natančnosti klasifikacije, če drevo (pravila) izdelamo z vsemi celicami pri različnih ravneh²¹. Odstotek pravilno klasificiranih smo primerjali glede na velikost drevesa oziroma število ravni (slika 46 in ugotovili, da se pri obeh klasifikacijah približno pri desetih ravneh natančnost modeliranja ne povečuje več. Zato smo se odločili, da pri metodi odločitvenih dreves (različica CT) uporabimo deset ravni.

Slika 46: Delež pravilno klasificiranih celic z drevesom (različica CT) za TIPI9 (modra črta) in TIPI13 (rdeča črta) pri določenem številu ravni.



8.1.3 Izbor podatkovnih slojev

Podatkovne sloje smo izbrali na podlagi vrednotenja podatkovnih slojev, ki smo ga opravili na začetku naloge (razpon vrednosti oziroma izstopajoče vrednosti, medsebojna povezanost, pomen podatkovnega sloja na posamezni prostorski ravni ter posamična pojasnjevalna moč podatkovnih slojev glede na obstoječe klasifikacije; poglavje 6), hkrati pa smo se oprli še na dodatna teoretična priporočila o tem, kateri podatkovni sloji ustrezajo velikosti enotam, ki so bile določene znotraj izvornih tipizacij TIPI9 in TIPI13. Poleg naštetega nismo prezrli lastnosti podatkovnih slojev, kot so ločljivost izvornih podatkov, način zajema in priprave podatkov.

²¹ Pri tem smo uporabili privzete nastavitve za število enot v vozliščih (100 za notranja in 50 za zunanja vozlišča) in minimalno izboljšanje Ginijevega koeficienta 0,0001. Da se izdelana drevesa ne bi preveč prilagajala učnim celicam, smo uporabili tudi obrezovanje drevesa (pruning z nastavitvijo SE = 1).

Vrednotenje podatkovnih slojev

S kvantitativnim vrednotenjem podatkovnih slojev smo pregledali vse podatkovne sloje, ki bi jih potencialno lahko uporabili za modeliranje izvirnih tipizacij. Po vrednotenju smo izločili večino podatkovnih slojev, ki so kazali visoko stopnjo povezanosti (preglednica 13) z enim izmed drugih podatkovnih slojev, ki so imeli večjo moč pojasnjevanja (preglednica 14) in so se z vidika metapodatkov (prostorska ločljivost izvornega podatkovnega sloja) in literature zdeli bolj primerni. Na podlagi vrednotenja pomena prostorskih podatkov na posamezni ravni (preglednica 15, slika 14) smo izločili podatkovne sloje, ki lahko delujejo kot »šum«. V tej skupini imajo nekateri sloji ekstremno visoke vrednosti na vseh ravneh, kar dejansko lahko predstavlja neke vrste »šum« (na primer ekspozicija in ekspozicijska razgibanost). Upoštevali smo tudi vpliv odstopajočih vrednosti, kjer smo izločili tiste sloje z zelo izstopajočimi skrajnimi vrednostmi (preglednica 12).

Poleg navedenih načinov izbora smo se oprli tudi na rezultate sorodne analize (Ciglič, 2012), v kateri je za uspešnost modeliranja pokrajinskoekoloških tipov Slovenije oziroma tipizacije TIPI13 (Špes s sod., 2002) z odločitvenim drevesom za primerljive rezultate z velikimi podatkovnimi bazami zadostovalo že pet podatkovnih slojev (nadmorska višina, naklon, padavinski režim, gostota rečne mreže in vrsta kamnine). Glede na to, da smo v nalogi na podlagi podatkovnega sloja kamnin pripravili podatkovni sloj prepustnost, ki združuje podatka o kamninah in gostoti rečne mreže, smo se odločili, da oba (torej vrsta kamnine in gostota rečne mreže) zamenjamo s prepustnostjo ter tako uporabimo štiri podatkovne sloje. Klijn 1994²² in Bailey 1996²³ dajeta velik poudarek tudi ravnem klasifikacije (oziroma povprečni velikosti prostorskih enot). Zato smo izračunali tudi povprečne velikosti posamezne enote znotraj tipa pri izvorni tipizaciji TIPI9 in povprečne velikosti posamezne enote znotraj tipa pri izvorni tipizaciji TIPI13 ter nato pripisali, kateri naravni dejavniki naj bi se teoretično uporabili za klasifikacijo naravnih enot pri tej velikosti po obeh omenjenih avtorjih (preglednica 44, preglednica 45).

Preglednica 44: Povprečne velikosti enot znotraj tipov TIPI9 in teoretično ustrezni dejavniki razmejitev.

povprečna površina posamezne enote (km ²)	tip	ustrezni dejavniki klasifikacije po Klijnu (1994)	ustrezni dejavniki klasifikacije po Baileyu (1996)
3061,8	alpska gorovja	klima, kamnine, relief	reliefne oblike, topoklima in vlažnost prsti
2330,0	alpska hribovja	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
409,6	alpske ravnine	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
598,9	panonska gričevja	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
432,3	panonske ravnine	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
761,9	dinarske planote	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
948,5	dinarska podolja in ravniki	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti

²² Klijn za razmejitev na območja, ki so velika od 2500 do 62.500 km², predlaga uporabo podnebja, kamninske podlage in geomorfologije. Za območja, ki so velika od 100 do 2500 km², predlaga uporabo kamninske podlage, gomorfologije (reliefa), podzemne vode in površinske vode. Enake dejavnike predlaga za območja, ki so velika od 6,25 do 100 km². Za območja, ki so velika od 0,25 km² do 6,25 km², predlaga uporabo geomorfologije (reliefa), podzemne in površinske vode ter prsti (Klijn 1994, 94–97).

²³ Bailey za razmejitev na območja, ki so velika 10.000 km², predlaga uporabo reliefnih oblik, za območja, ki so velika 10 km², pa uporabo topoklimatskih značilnosti in vlažnosti prsti (Bailey 1996).

265,3	sredozemska gričevja	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
673,3	sredozemske planote	kamnine, relief, podzemna voda, površinska voda	reliefne oblike, topoklima in vlažnost prsti
810,9	skupno povprečje	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
17,2	najmanjša površina	kamnine, relief, podzemna voda, površinska voda	topoklima in vlažnost prsti
3681,5	največja površina	klima, kamnine, relief	reliefne oblike

Preglednica 45: Povprečne velikosti enot znotraj tipov za tipizacijo TIPI13 in teoretično ustrezni dejavniki razmejitev.

povprečna površina posamezne enote (km ²)	oznaka tipa ²⁴	ustrezni dejavniki klasifikacije po Klijnu (1994)	ustrezni dejavniki klasifikacije po Baileyu (1996)
839,0	1	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
41,1	2	kamnine, relief, podzemna voda, površinska voda	topoklima in vlažnost prsti
328,1	3	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
302,0	4	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
253,3	5	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
205,6	6	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
148,9	7	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
88,6	8	kamnine, relief, podzemna voda, površinska voda	topoklima in vlažnost prsti
217,5	9	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
339,5	10	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
500,2	11	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
168,7	12	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
60,0	13	kamnine, relief, podzemna voda, površinska voda	topoklima in vlažnost prsti
198,9	skupno povprečje	kamnine, relief, podzemna voda, površina voda	reliefne oblike, topoklima in vlažnost prsti
2,3	najmanjša površina	relief, podzemna voda, površinska voda, prst	topoklima in vlažnost prsti
1219,7	največja površina	kamnine, relief, podzemna voda, površina voda	reliefne oblike

Glede na pregled ustreznih teoretičnih dejavnikov za prostorsko raven oziroma velikost tipov v obeh tipizacijah lahko ugotovimo, da je priporočljivo upoštevati relief, podzemne in površinske vode ter tudi topoklimatske značilnosti in prst. V manjši meri bi se morali opreti tudi na klimatske značilnosti. Glede na nabor podatkovnih slojev (preglednica 11) bi torej lahko vključili številne podatkovne sloje (preglednica 46).

²⁴ Za poimenovanja glej preglednico 41.

Preglednica 46: Podatkovni sloji, ki ponazarjajo naravne dejavnike, ki jih lahko glede na velikost obstoječih enot posameznih tipov uporabimo za izdelavo tipizacij.

teoretični dejavniki	primerni podatkovni sloji
relief in reliefne oblike	naklon, višina, razgibanost (več vrst), tekstura površja
podzemne in površinske vode	gostota rečne mreže, prepustnost kamnin
prst	prepustnost kamnin
topoklimatske značilnosti	osončenost, ekspozicija, tudi padavine in temperatura (mesečno in letno povprečje)
klimatske značilnosti	višina, padavine (mesečno in letno povprečje), padavinski režim (več vrst), temperaturni režim (več vrst), temperatura (mesečno in letno povprečje)

Dokončen izbor je bil sicer subjektiven, a v precejšnji meri argumentiran (priloga 9) s kvantitativnim vrednotenjem in s teoretičnimi priporočili. Izbrali smo štiri podatkovne sloje:

- nadmorska višina (oznaka VISINA),
- prepustnost kamnin (oznaka PREP),
- padavinski režim (razmerje: poletje, jesen)²⁵ (oznaka PADRAZPJ),
- naklon (oznaka NAKLON).

Značilnosti izbranih podatkovnih slojev

Za izbrane sloje smo izračunali osnovne značilnosti (preglednica 47) in medsebojno povezanost (preglednica 48). Pearsonov koeficient le pri povezavi podatkovnih slojev naklon in višina malce preseže vrednost 0,5. Ostale povezanosti so manjše od 0,4. Spearmanov koeficient kaže podobno – le povezanost med naklonom in višino je nekoliko večja (0,6), ostale so precej nižje. Pregled histogramov (slika 47) kaže za padavinski režim, naklon in prepustnost večmodalno porazdelitev, kar je slabost, saj taka porazdelitev oteži prepoznavanje skupin in določanje spektralnih podpisov. Histograma višine in naklona sta asimetrična (zamaknjenost v levo).

Preglednica 47: Osnovne statistične značilnosti izbranih podatkovnih slojev (N=506.450 celic), izražene v normaliziranih vrednostih (0–100).

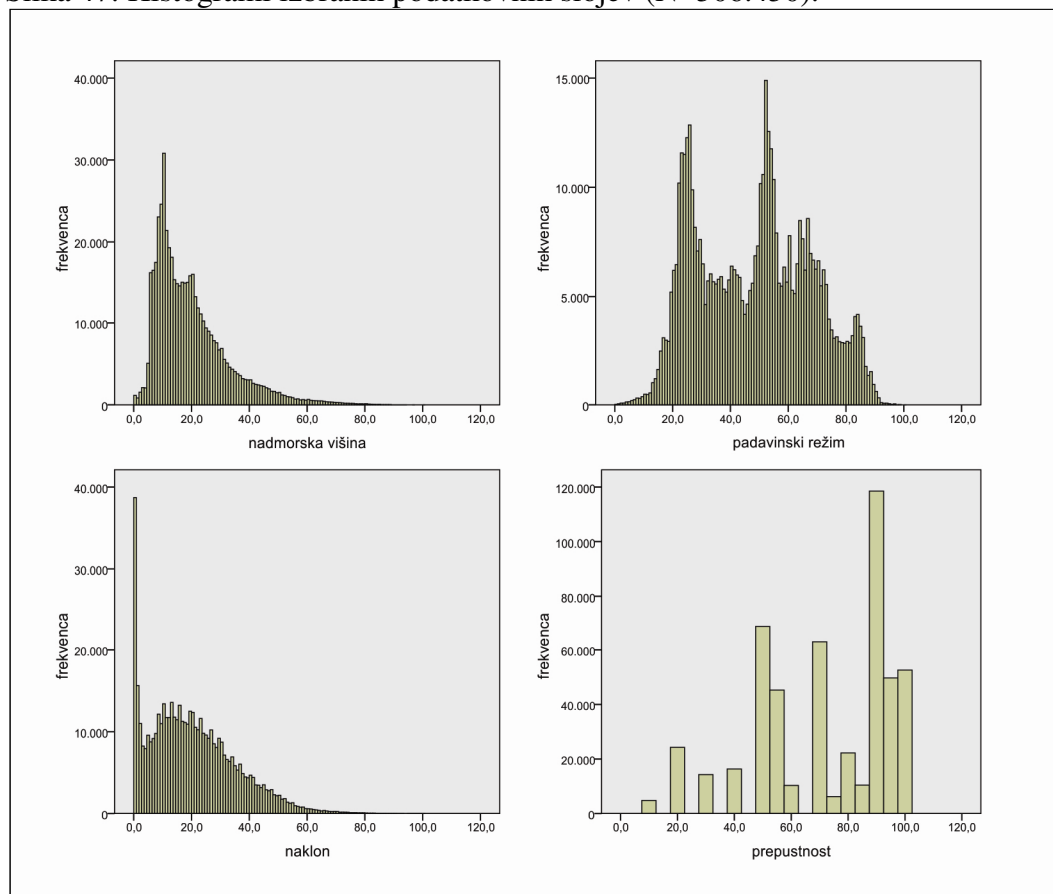
	NAKLON	PADRAZPJ	PREP	VISINA
povprečje	20,3	48,2	71,8	19,9
mediana	18,3	50,0	80,0	16,8
modus	0,4	52,6	90,0	10,3
standardni odklon	14,9	19,5	23,6	12,8
varianca	221,7	379,8	559,0	164,1

Preglednica 48: Pearsonov in Spearmanov koeficient povezanosti ($p < 0,01$).

	koeficient	NAKLON	PADRAZPJ	PREP	VISINA
NAKLON	Pearsonov k.	1,000	-0,206	-0,312	0,583
	Spearmanov k.	1,000	-0,194	-0,442	0,605
PADRAZPJ	Pearsonov k.	-0,206	1,000	-0,142	-0,362
	Spearmanov k.	-0,194	1,000	-0,081	-0,390
PREP	Pearsonov k.	-0,312	-0,142	1,000	-0,087
	Spearmanov k.	-0,442	-0,081	1,000	-0,218
VISINA	Pearsonov k.	0,583	-0,362	-0,087	1,000
	Spearmanov k.	0,605	-0,390	-0,218	1,000

²⁵ V nadaljevanju disertacije govorimo o padavinskem režimu, ki pomeni razmerje med padavinami poleti in jeseni, zato ne bomo več uporabljali celotnega poimenovanja.

Slika 47: Histogrami izbranih podatkovnih slojev (N=506.450).



Za vpogled v značilnosti posameznih tipov smo pregledali njihove povprečne vrednosti (preglednici 49 in 50) in histograme za vse štiri sloje za obe tipizaciji. Pri podatkovnih slojih naklon in višina se po posameznih tipih (obeh klasifikacij) izrišejo večinoma enomodalni histogrami, pri padavinskem režimu in prepustnosti pa ponekod ne, kar pomeni, da se po slednjih dveh tipi med seboj teže ločijo.

Preglednica 49: Povprečne vrednosti posameznih podatkovnih slojev po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).

	1.1	1.2	1.3	2.1	2.2	3.1	3.2	4.1	4.2
NAKLON	37,0	26,3	6,2	14,2	1,3	21,2	10,3	17,5	12,2
PADRAZPJ	39,5	58,3	50,4	69,3	68,2	34,0	40,6	23,3	23,7
PREPS	73,0	52,2	87,8	70,4	95,9	79,7	79,0	65,8	85,1
VISINA	37,8	20,8	13,4	10,3	7,0	23,9	14,4	10,9	15,2

Preglednica 50: Povprečne vrednosti posameznih podatkovnih slojev po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).

	1	2	3	4	5	6	7	8	9	10	11	12	13
NAKLON	43,5	23,7	23,0	28,5	8,2	15,8	3,0	9,3	14,9	8,5	11,3	19,2	10,4
PADRAZPJ	36,0	41,8	35,2	51,0	51,0	68,3	67,9	35,1	42,3	43,1	24,5	24,2	24,2
PREP	75,6	73,3	78,9	51,5	83,6	67,6	91,3	82,3	78,1	77,9	85,2	60,5	76,2
VISINA	45,0	16,8	27,7	22,2	13,5	11,3	7,6	17,8	17,9	7,5	12,8	7,4	4,2

8.1.4 Izbor učnih celic

Nadzorovana klasifikacija je definirana kot proces, pri katerem s pomočjo vzorca učnih celic klasificiramo celice z neznano identiteto (Campbell, 1996). Ker klasificiramo celice v različne tipe, ki so jih geografi že določili za celotno območje Slovenije, te tipe poznamo za vse celice znotraj Slovenije (če izvajamo napake zaradi ročnega risanja meja in podobno). Ker želimo potrditi izvirne tipizacije s pomočjo različnih metod nadzorovane klasifikacije, učne celice vseeno potrebujemo. Uporabili smo dva različna zajema učnih celic. Za dva nabora učnih celic (in zato podvojeno analizo) smo se odločili, ker je izbor učnih celic prav tako pomemben kot izbor geoinformacijskega orodja in prav tako vpliva na rezultat (Campbell, 1996, 333; Lillesand, Kiefer, Chipman, 2008, 557). Tako smo tudi uspešnost modeliranja preverili dvakrat.

Prvi vzorec učnih celic smo določili na podlagi stratificiranega naključnega vzorčenja znotraj posameznih tipov (razpršeno). Izbrali smo po 2000 celic²⁶ znotraj vsakega tipa.

Drugi vzorec učnih celic smo določili ekspertno, tako da smo za vsak tip izbrali celice znotraj dveh ali več homogenih kvadratnih območij²⁷ iz osrednjih delov posameznega tipa. Tudi v tem primeru smo izbrali po 2000 celic znotraj vsakega tipa.

Za enako število celic po posameznih kategorijah smo se odločili zaradi naslednjih dejstev:

- zaradi ročnega načina določanja tipov je lahko prišlo do napak, kar pomeni, da je število celic pri posameznem tipu morda neustrezno,
- pri nekaterih metodah ima število celic vpliv na rezultate klasifikacij (recimo pri gradnji odločitvenega drevesa ali pri metodi *k*-najbližjih sosedov).

Pri izboru učnih celic smo upoštevali priporočila iz literature (preglednica 51; priporočila so v prilogi 5). Upoštevali smo priporočila glede števila celic in tudi upoštevali, da je treba preveriti več načinov – najbolj skrajna načina sta ravno določitev na podlagi naključnega vzorca in določitev na podlagi ekspertnega znanja.

Preglednica 51: Usklajenost izbire učnih celic s priporočili iz literature.

priporočilo	upoštevanje priporočil pri posameznem vzorčenju	
	naključno	ekspertno
vsaj 10 ali 100 krat toliko celic kot je podatkovnih slojev	da	da
za vsako kategorijo je dobro določiti nekaj različnih ločenih učnih območij	da	da
posamezni deli učnih območij (učna polja) za en tip naj imajo 10–40 celic oziroma posamezno učno polje naj ima vsaj 3 krat 3 celice	ne	da
učna območja naj bodo določena naključno znotraj razredov (efekt podobnosti minimiziran)	da	ne
izogibati se je treba celicam blizu meje kategorij	delno	da
enako število učnih celic po tipih	da	da

8.1.4.1 Izbor učnih celic z naključnim vzorčenjem

Za učne celice, ki so izbrane po naključnem vzorčenju za TIPI9 (slika 48), smo pregledali nekatere značilnosti glede deleža celic posameznih tipov (preglednica 52) ter statistične značilnosti (preglednica 53) in histograme podatkovnih slojev (slika 49) in njihove povprečne vrednosti za učne celice po posameznih tipih TIPI9 (preglednica 54).

Tudi za učne celice, ki so izbrane po naključnem vzorčenju za TIPI13 (slika 50), smo pregledali nekatere značilnosti glede deleža celic posameznih tipov (preglednica 55) ter statistične značilnosti (preglednica 56) in histograme podatkovnih slojev (slika 51) in njihove

²⁶ 2000 celic predstavlja približno 1/3 vseh celic po površini najmanjšega tipa, ki se pojavlja pri obeh izvornih tipizacijah.

²⁷ Pri TIPI13 smo morali pri tipu 2 ekspertno določiti poligone različnih oblik, saj za večja kvadratna območja ni bilo prostora.

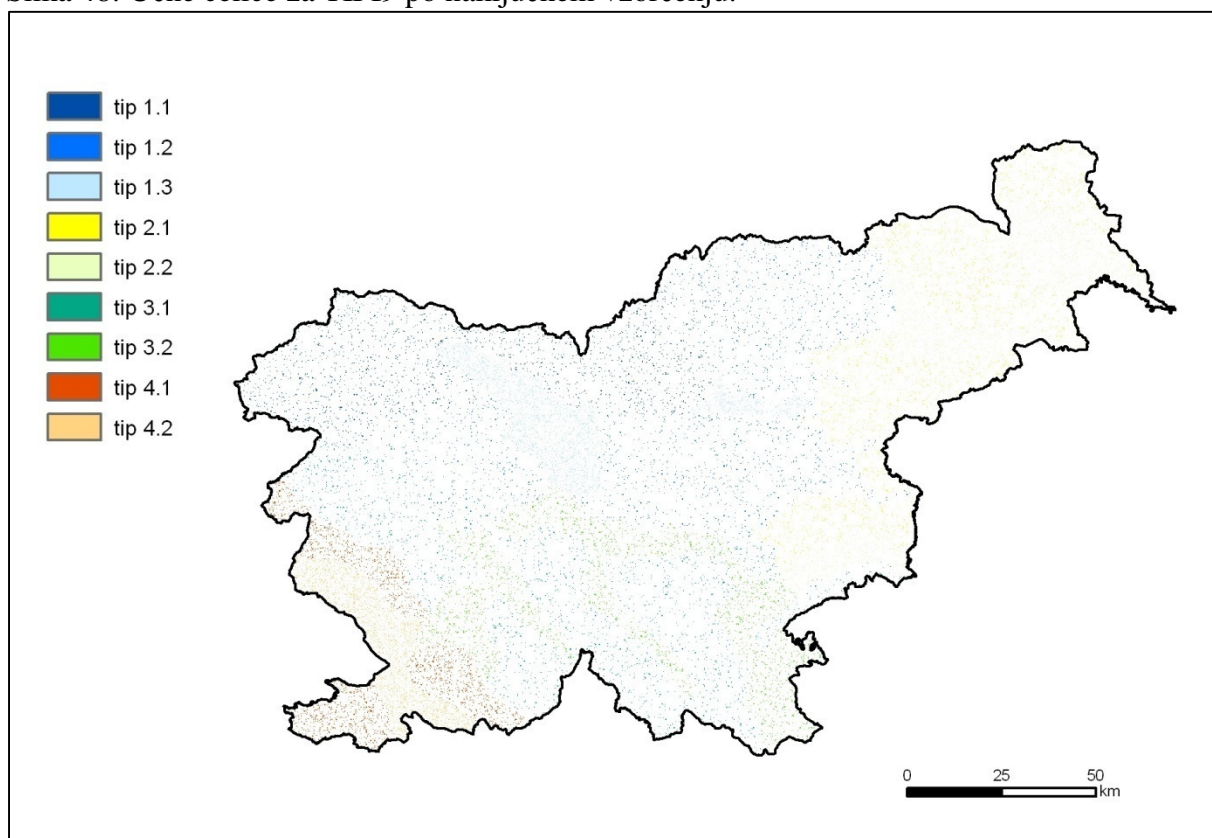
povprečne vrednosti za učne celice po posameznih tipih TIPI13 (preglednica 57). V vseh preglednicah so uporabljeni že normalizirani podatkovni sloji z vrednostmi 0–100.

Ob pregledu povprečnih vrednosti smo ugotovili, da povprečja po posameznih tipih za vse celice ne odstopajo od povprečja po posameznih tipih za učne celice za več kot 0,7 oziroma za manj kot 1 % vrednosti celotne merske lestvice (celoten razpon merske lestvice je 100). Pri večmodalnih histogramih je ta podatek sicer manj pomemben.

Za učne celice po naključnem vzorčenju smo preverili tudi histograme po posameznih tipih za posamezne podatkovne sloje in jih primerjali s histogrami za vse celice. Pregled histogramov učnih celic po tipih tipizacij TIPI9 in TIPI13 je pokazal, da so ti podobni tistim histogramom, ki so narejenimi na podlagi vseh celic. Opazno je, da nekateri histogrami kažejo večmodalno porazdelitev, nagnjenost v levo oziroma desno ali pa močno koničasto podobo. Tovrstne oblike niso v skladu s teoretičnimi pričakovanji, zato je končni uspeh pri nekaterih metodah, ki predvidevajo normalno razporeditev, zaradi tega manjši.

Učne celice po naključnem vzorčenju za TIPI9

Slika 48: Učne celice za TIPI9 po naključnem vzorčenju.



Preglednica 52: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI9 po naključnem vzorčenju.

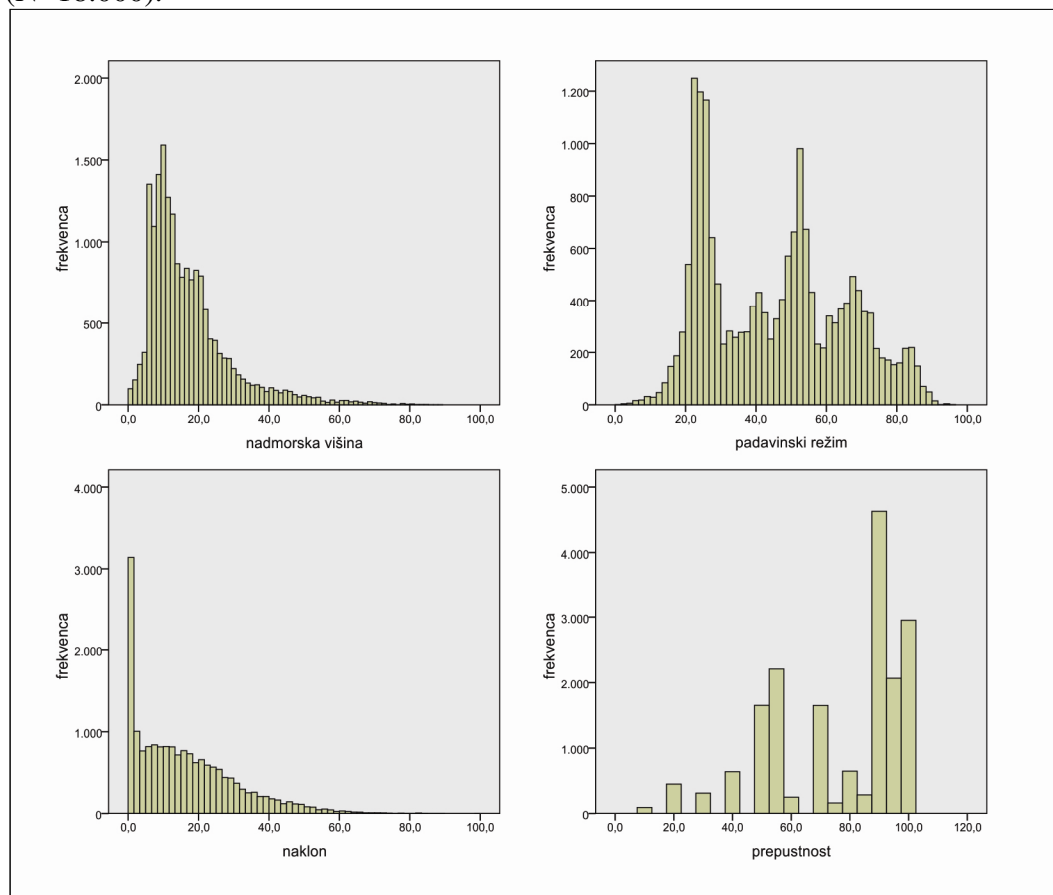
tip	vse celice		učne celice	
	število vseh celic v tipu	delež celic v tipu od vseh celic (%)	število izbranih učnih celic	delež izbranih učnih celic od vseh celic v tipu (%)
1.1	76.533	15,1	2000	2,6
1.2	116.478	23,0	2000	1,7
1.3	20.481	4,0	2000	9,8
2.1	74.719	14,8	2000	2,7

2.2	32.336	6,4	2000	6,2
3.1	95.190	18,8	2000	2,1
3.2	47.387	9,4	2000	4,2
4.1	26.490	5,2	2000	7,6
4.2	16.836	3,3	2000	11,9
skupaj	506.450	100,0	18.000	3,5

Preglednica 53: Osnovne statistične značilnosti učnih celic (N=18.000 celic), izražene v normaliziranih vrednostih (0–100).

	NAKLON	PADRAZPJ	PREP	VISINA
povprečje	16,2	45,2	76,4	17,1
mediana	13,3	45,8	90,0	13,7
modus	0,4	obstaja več modusov	90,0	10,3
standardni odklon	14,3	19,7	22,2	11,7
varianca	203,9	386,5	494,3	137,6

Slika 49: Histogrami podatkovnih slojev za učne celice po naključnem vzorčenju za TIPI9 (N=18.000).



Preglednica 54: Povprečne vrednosti podatkovnih slojev za učne celice po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).

	1.1	1.2	1.3	2.1	2.2	3.1	3.2	4.1	4.2
NAKLON	36,6	26,3	6,2	14,1	1,3	21,3	10,2	17,4	12,6
PADRAZPJ	40,1	58,4	50,3	69,1	68,1	33,6	40,6	23,4	23,6


PREP	72,9	51,9	88,3	69,8	95,6	79,7	78,7	66,1	85,0
VISINA	37,5	20,7	13,3	10,4	7,0	24,0	14,5	10,8	15,5

Učne celice po naključnem vzorčenju za TIPI13

Preglednica 55: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI13 po naključnem vzorčenju.

tip	vse celice		učne celice	
	število vseh celic v tipu	delež celic v tipu od vseh celic (%)	število izbranih učnih celic	delež izbranih učnih celic od vseh celic v tipu (%)
1	42.210	8,3	2000	4,7
2	18.174	3,6	2000	11,0
3	89.759	17,7	2000	2,2
4	113.363	22,4	2000	1,8
5	31.652	6,2	2000	6,3
6	82.034	16,2	2000	2,4
7	44.400	8,8	2000	4,5
8	22.141	4,4	2000	9,0
9	27.185	5,4	2000	7,4
10	8.272	1,6	2000	24,2
11	12.651	2,5	2000	15,8
12	8.431	1,7	2000	23,7
13	6.178	1,2	2000	32,4
skupaj	506.450	100,0%	26.000	5,1

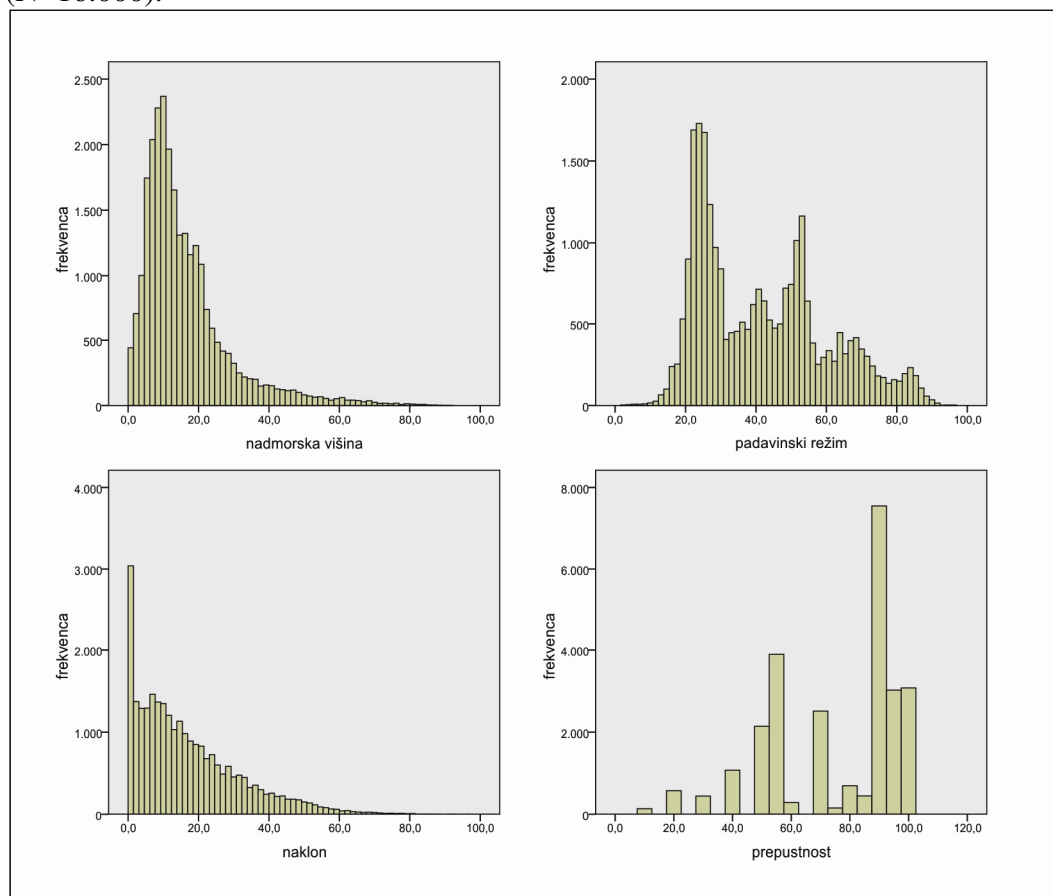
Slika 50: Učne celice za TIPI13 po naključnem vzorčenju.



Preglednica 56: Osnovne statistične značilnosti učnih celic (N=26.000 celic), izražene v normaliziranih vrednostih (0–100).

	NAKLON	PADRAZPJ	PREP	VISINA
povprečje	16,9	41,9	75,5	16,3
mediana	13,3	39,6	90,0	12,8
modus	0,4	25,5	90,0	10,3
standardni odklon	14,6	18,3	21,9	12,6
varianca	214,2	336,4	478,5	158,5

Slika 51: Histogrami podatkovnih slojev za učne celice po naključnem vzorčenju za TIPI13 (N=16.000).



Preglednica 57: Povprečne vrednosti podatkovnih slojev za učne celice po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).

	1	2	3	4	5	6	7	8	9	10	11	12	13
NAKLON	43,8	23,8	22,8	28,9	8,1	15,7	3,0	9,3	15,1	8,3	11,3	19,3	10,5
PADRAZPJ	35,8	42,0	35,0	51,1	50,8	68,1	68,0	34,9	42,5	43,3	24,5	24,2	24,1
PREP	75,5	73,1	78,8	50,8	83,4	67,6	91,7	82,2	78,1	77,8	85,0	60,8	76,2
VISINA	45,4	16,8	27,5	22,4	13,5	11,2	7,6	17,8	17,7	7,5	12,6	7,3	4,2

8.1.4.2 Izbor učnih celic z ekspertnim vzorčenjem

Za učne celice, ki so izbrane po ekspertnem vzorčenju za TIPI9 (slika 52), smo pregledali nekatere statistične značilnosti glede deleža celic posameznih tipov (preglednica 58) ter statistične značilnosti (preglednica 59) in histograme podatkovnih slojev (slika 53) in njihove povprečne vrednosti za učne celice po posameznih tipih TIPI9 (preglednica 60).

Tudi za učne celice, ki so izbrane po ekspertnem vzorčenju za TIPI13 (slika 54), smo pregledali nekatere značilnosti glede deleža celic posameznih tipov (preglednica 61) ter statistične značilnosti (preglednica 62) in histograme podatkovnih slojev (slika 55) in njihove povprečne vrednosti za učne celice po posameznih tipih TIPI13 (preglednica 63).

Ob pregledu povprečnih vrednosti smo ugotovili, da povprečja po posameznih tipih za vse celice od povprečja po posameznih tipih za učne celice odstopajo tudi okrog 10 in več oziroma za približno 10 % vrednosti celotne merske lestvice (celoten razpon merske lestvice je 100). Pri večmodalnih histogramih je ta podatek sicer manj pomemben. Povprečja pri ekspertnih celicah odstopajo precej več kot pri naključnih celicah.

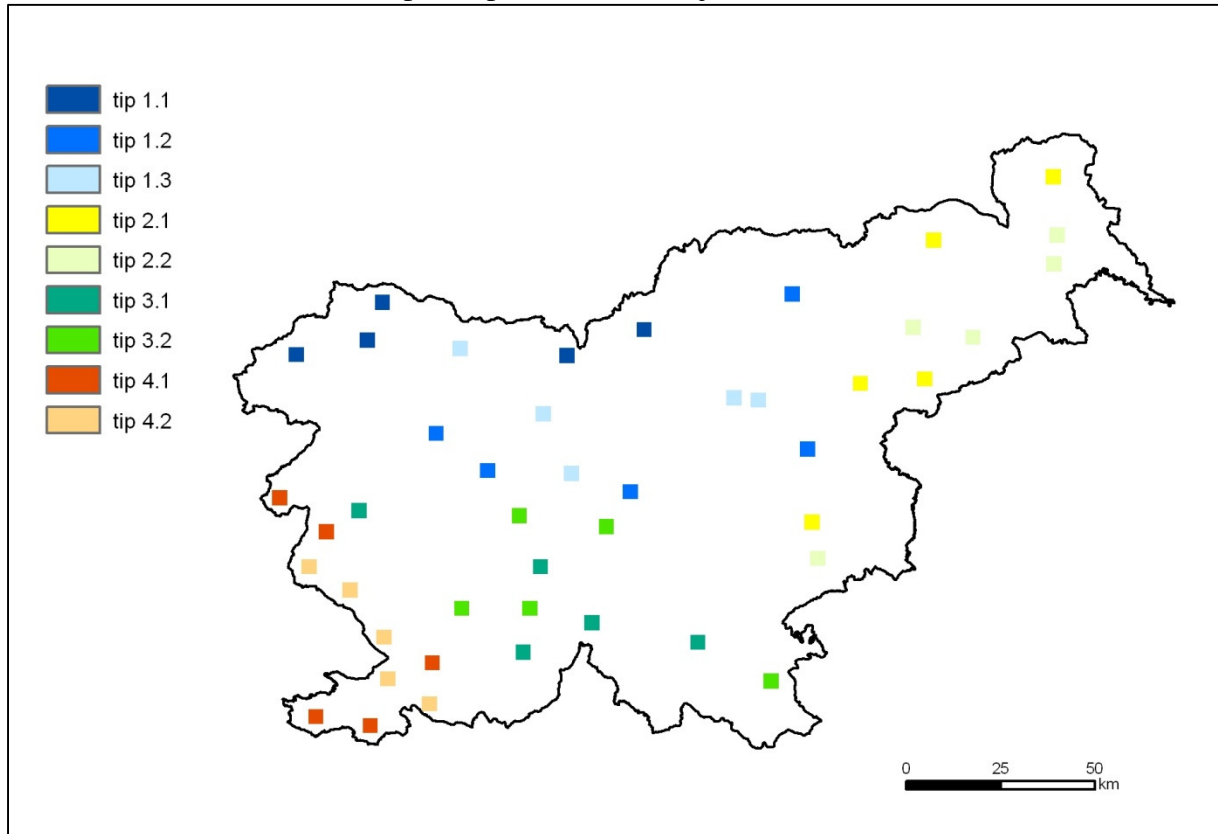
Za učne celice po ekspertnem vzorčenju smo preverili tudi histograme po posameznih tipih za posamezne podatkovne sloje in jih primerjali s histogrami za vse celice. Pregled histogramov učnih celic po tipih tipizacij TIPI9 in TIPI13 je pokazal, da so ti podobni tistim histogramom, ki so narejeni na podlagi vseh celic. Opazno je, da tudi po tem načinu vzorčenja učnih celic nekateri histogrami kažejo večmodalno porazdelitev, nagnjenost v levo oziroma desno ali pa močno koničasto podobo. Tovrstne oblike niso v skladu s teoretičnimi pričakovanji, zato je končni uspeh pri metodah, ki upoštevajo normalno razporeditev, zaradi tega manjši.

Učne celice po ekspertnem vzorčenju za TIPI9

Preglednica 58: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI9 po ekspertnem vzorčenju.

tip	vse celice		učne celice	
	število vseh celic v tipu	delež celic v tipu od vseh celic(%)	število izbranih učnih celic	delež izbranih učnih celic od vseh celic v tipu
11	76.533	15,1	2000	2,6%
12	116.478	23,0	2000	1,7%
13	20.481	4,0	2000	9,8%
21	74.719	14,8	2000	2,7%
22	32.336	6,4	2000	6,2%
31	95.190	18,8	2000	2,1%
32	47.387	9,4	2000	4,2%
41	26.490	5,2	2000	7,6%
42	16.836	3,3	2000	11,9%
skupaj	506.450	100,0		

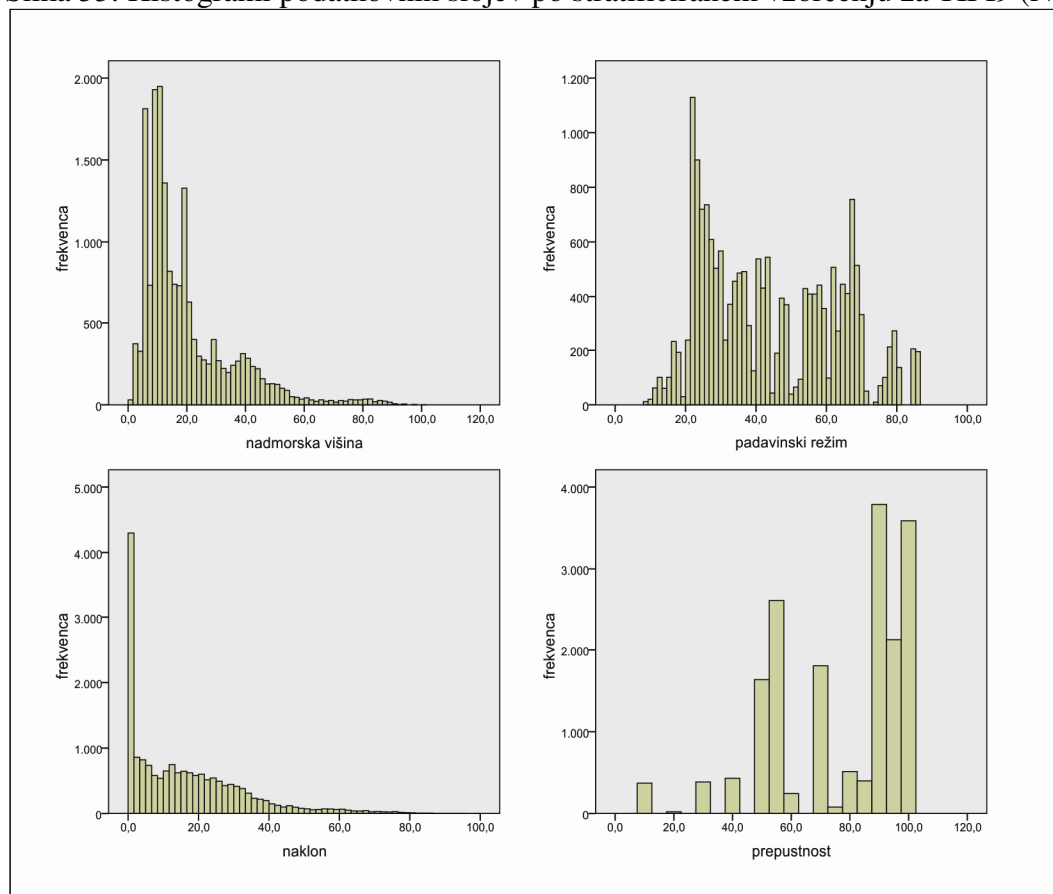
Slika 52: Učne celice za TIPI9 po ekspertnem vzorčenju.



Preglednica 59: Osnovne statistične značilnosti (N=18.000 celic), izražene v normaliziranih vrednostih (0–100).

	NAKLON	PADRAZPJ	PREP	VISINA
povprečje	16,477	43,938	76,773	19,796
mediana	12,900	40,900	90,000	14,200
modus	0,4	22,1	90,0	10,3
standardni odklon	16,2817	18,9846	22,4257	15,5887
varianca	265,094	360,415	502,913	243,009

Slika 53: Histogrami podatkovnih slojev po stratificiranem vzorčenju za TIPI9 (N=18.000).

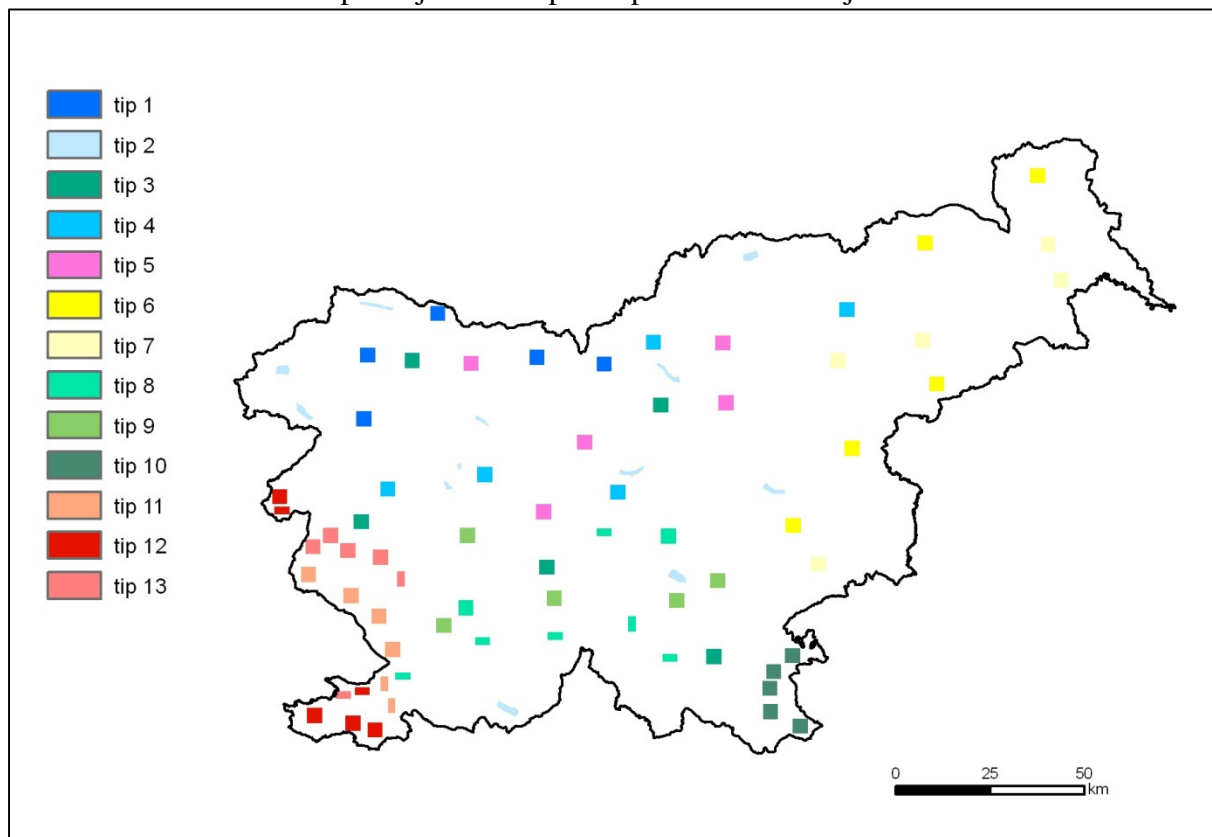


Preglednica 60: Povprečje po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).

	1.1	1.2	1.3	2.1	2.2	3.1	3.2	4.1	4.2
NAKLON	46,3	27,8	2,0	18,9	0,5	19,0	4,0	19,4	10,3
PADRAZPJ	38,3	47,1	54,0	70,6	66,2	32,3	38,3	25,0	23,8
PREP	80,1	46,5	97,0	63,8	98,8	82,6	78,8	60,2	83,1
VISINA	48,6	28,2	12,1	12,0	7,0	32,8	13,6	9,1	14,8

Učne celice po ekspertnem vzorčenju za TIPI13

Slika 54: Učne celice za tipizacijo TIPI13 po ekspertnem vzorčenju.



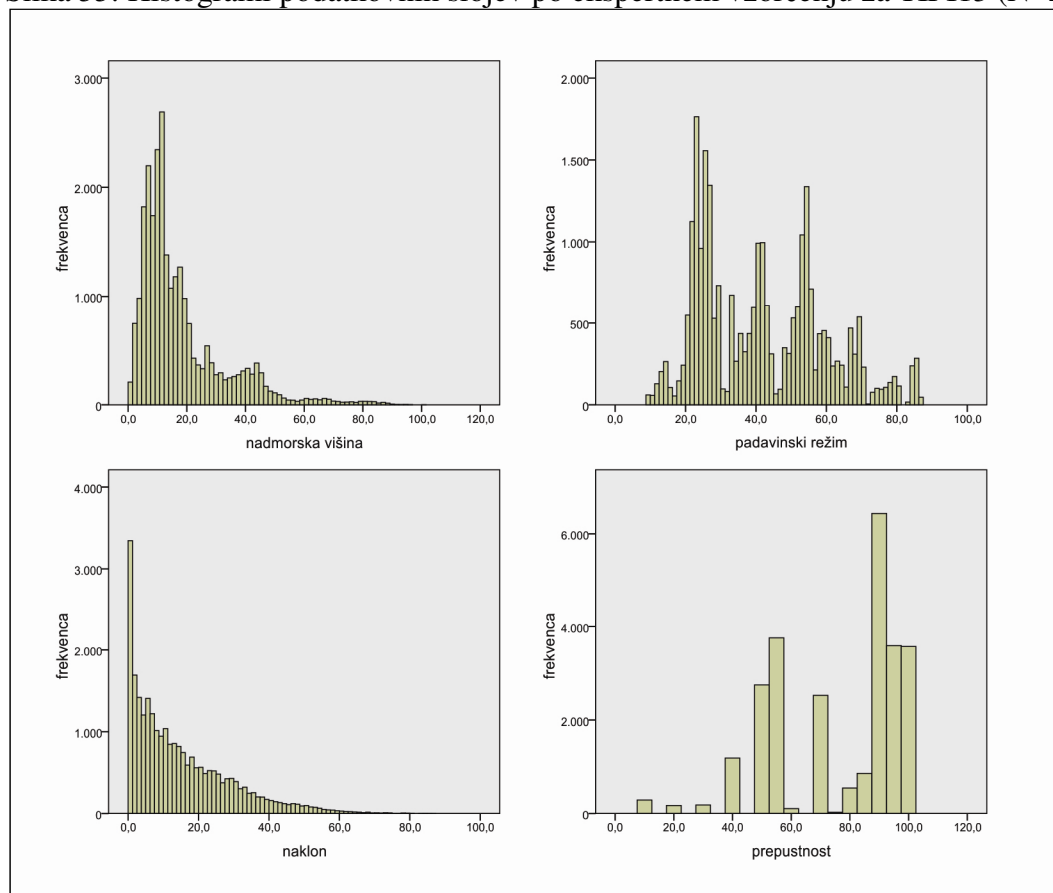
Preglednica 61: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI13 po ekspertnem vzorčenju.

tip	vse celice		trening celice	
	število vseh celic v tipu	delež celic v tipu od vseh celic (%)	število izbranih trening celic	delež izbranih trening celic od vseh celic v tipu (%)
1	42.210	8,3	2000	4,7
2	18.174	3,6	2000	11,0
3	89.759	17,7	2000	2,2
4	113.363	22,4	2000	1,8
5	31.652	6,2	2000	6,3
6	82.034	16,2	2000	2,4
7	44.400	8,8	2000	4,5
8	22.141	4,4	2000	9,0
9	27.185	5,4	2000	7,4
10	8.272	1,6	2000	24,2
11	12.651	2,5	2000	15,8
12	8.431	1,7	2000	23,7
13	6.178	1,2	2000	32,4
SKUPAJ	506.450	100,0	26.000	5,1

Preglednica 62: Osnovne statistične značilnosti (N=26.000 celic), izražene v normaliziranih vrednostih (0–100).

	NAKLON	PADRAZPJ	PREP	VISINA
povprečje	14,923	41,735	76,263	18,034
mediana	10,900	40,400	90,000	12,600
modus	0,4	22,1	90,0	10,3
standardni odklon	13,9725	17,8247	21,5260	14,9925
varianca	195,230	317,721	463,367	224,776

Slika 55: Histogrami podatkovnih slojev po ekspertnem vzorčenju za TIPI13 (N=26.000).



Preglednica 63: Povprečje po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).

	1	2	3	4	5	6	7	8	9	10	11	12	13
NAKLON	42,4	10,2	20,7	29,4	5,4	21,4	1,8	4,7	14,0	7,4	7,7	21,2	7,6
PADRAZPJ	38,8	41,9	37,1	43,7	53,5	68,9	66,9	37,0	38,3	42,7	24,4	24,8	24,5
PREP	72,1	87,6	76,5	48,4	86,6	63,8	90,8	80,8	80,2	80,8	86,0	58,0	79,7
VISINA	51,6	13,3	37,7	31,1	12,8	12,7	7,8	16,7	19,6	7,2	12,8	7,8	3,4

8.1.5 Povzetek zasnove

Modelirali smo dve izvorni naravnopokrajinski tipizaciji Slovenije:

- pokrajinskoekološki tipi – oznaka TIPI13 (Špes s sod., 2002) in
- pokrajinski tipi – TIPI9 (Perko, 1998a; Perko, 1998b; Perko, 2007b).

Izbrali smo sedem geoinformacijskih orodij oziroma metod nadzorovane klasifikacije:

- največja verjetnost (oznaka MXL),
- odločitveno drevo, različica CT (oznaka CT),
- metoda najmanjše razdalje (oznaka MDS),
- metoda najbližjih sosedov (oznaka KNN),
- odločitveno drevo, različica CTR (oznaka CTR),
- odločitveno drevo, različica CTG (oznaka CTG),
- odločitveno drevo, različica CTE (oznaka CTE).

Izbrali smo dva načina izbora učnih celic:

- naključni izbor in
- ekspertni izbor.

Za vsako izvirno tipizacijo smo preizkusili vsako izmed naštetih orodij ter pri tem upoštevali enkrat naključni, drugič pa ekspertni nabor učnih celic. To pomeni, da smo skupaj izdelali 28 modeliranih naravnopokrajinskih tipizacij ($28 = 2 \times 7 \times 2$).

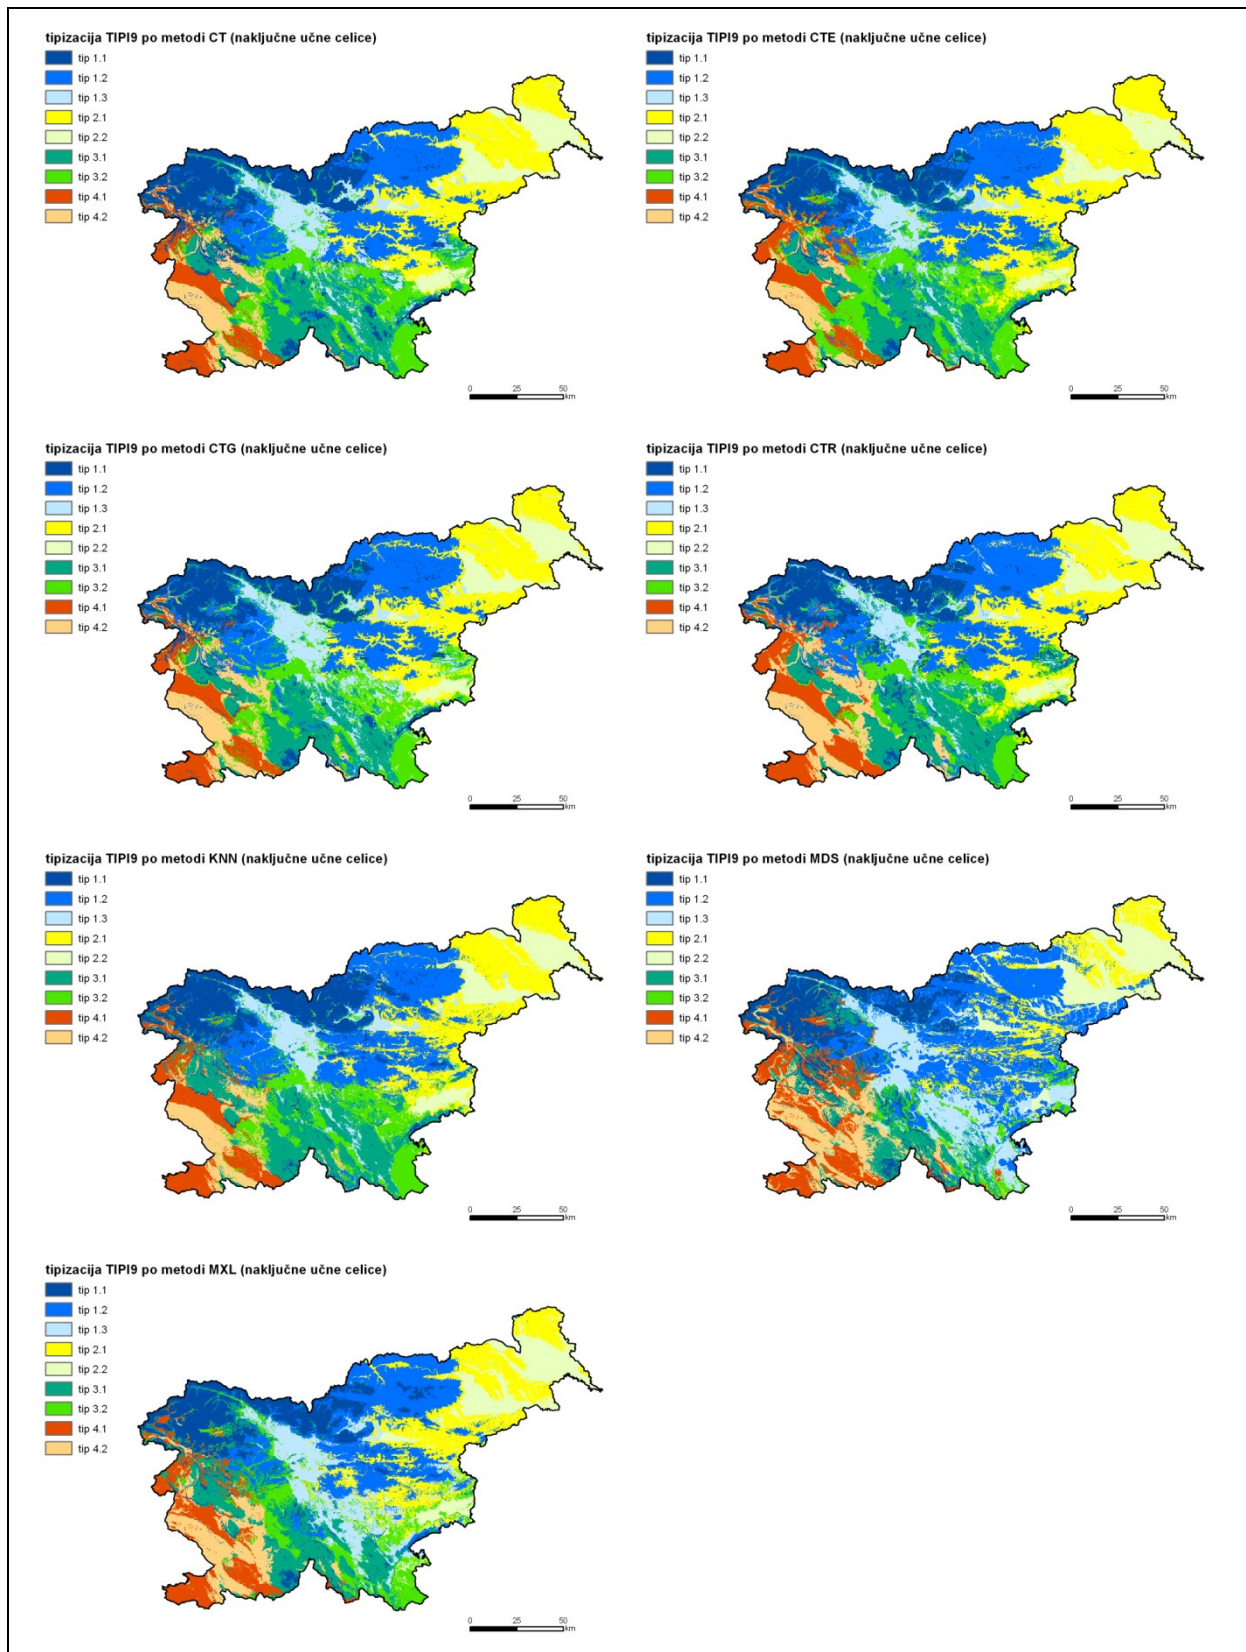
8.2 Modelirane naravnopokrajinske tipizacije po posameznih metodah nadzorovane klasifikacije

V poglavju 8.2.1 prikazujemo modelirane naravnopokrajinske tipizacije po vseh metodah nadzorovane klasifikacije za tipizacijo TIPI9 po naključnem in tudi po ekspertnem naboru učnih celic (sliki 56 in 57). Na primeru modeliranih tipizacij po metodi odločitvenega drevesa (različica CT) pa podajamo tudi pregleden opis odstopanj od izvirne tipizacije TIPI9 (priloga 10). Takšen opis bi lahko pripravili za vse modelirane tipizacije, a se nam to ne zdi smiselno, saj lahko bralec sam primerja posamezne modelirane tipizacije med seboj in tudi z izvirno tipizacijo.

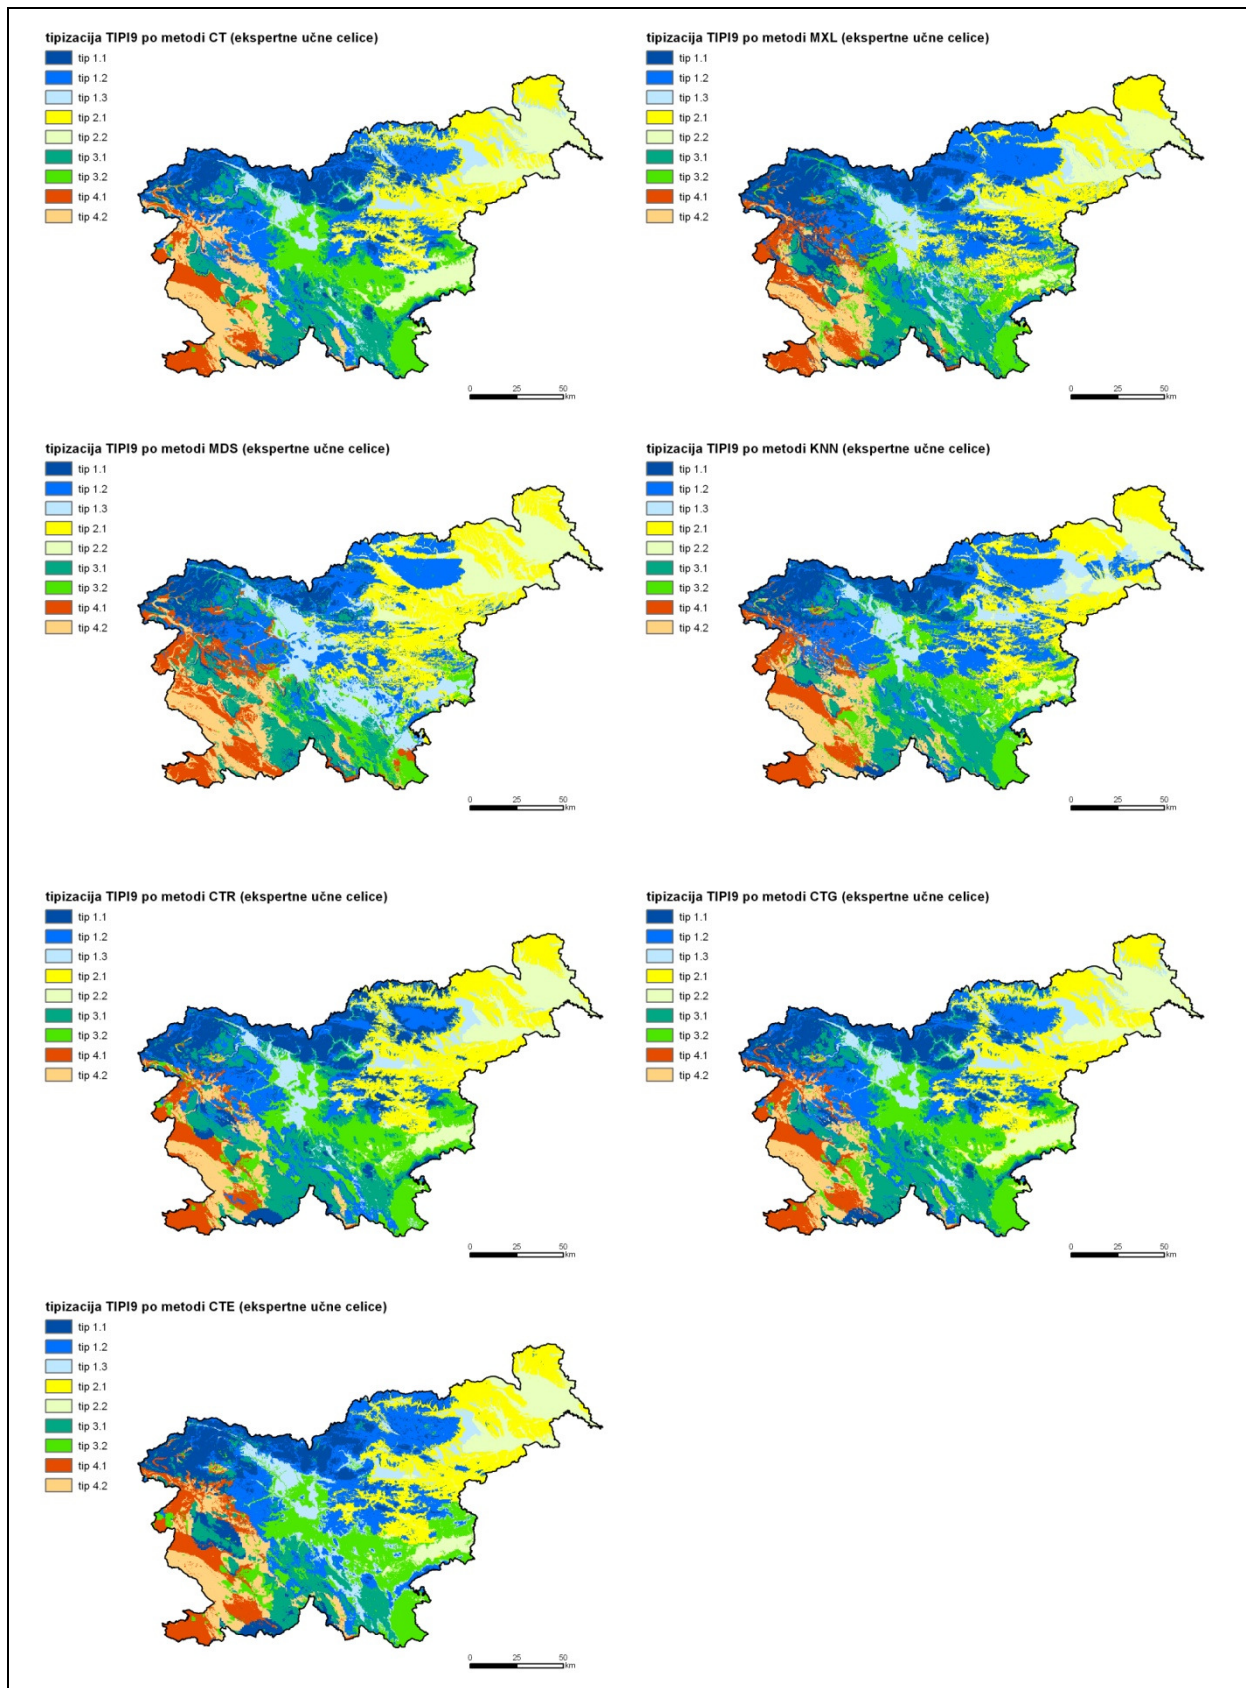
V poglavju 8.2.2 so prikazane modelirane naravnopokrajinske tipizacije po vseh metodah nadzorovane klasifikacije za tipizacijo TIPI13 (sliki 58 in 59).

8.2.1 Modelirane naravnopokrajinske tipizacije za TIPI9

Slika 56: Modelirane tipizacije TIPI9 po metodah nadzorovane klasifikacije z naključnim vzorcem učnih celic.

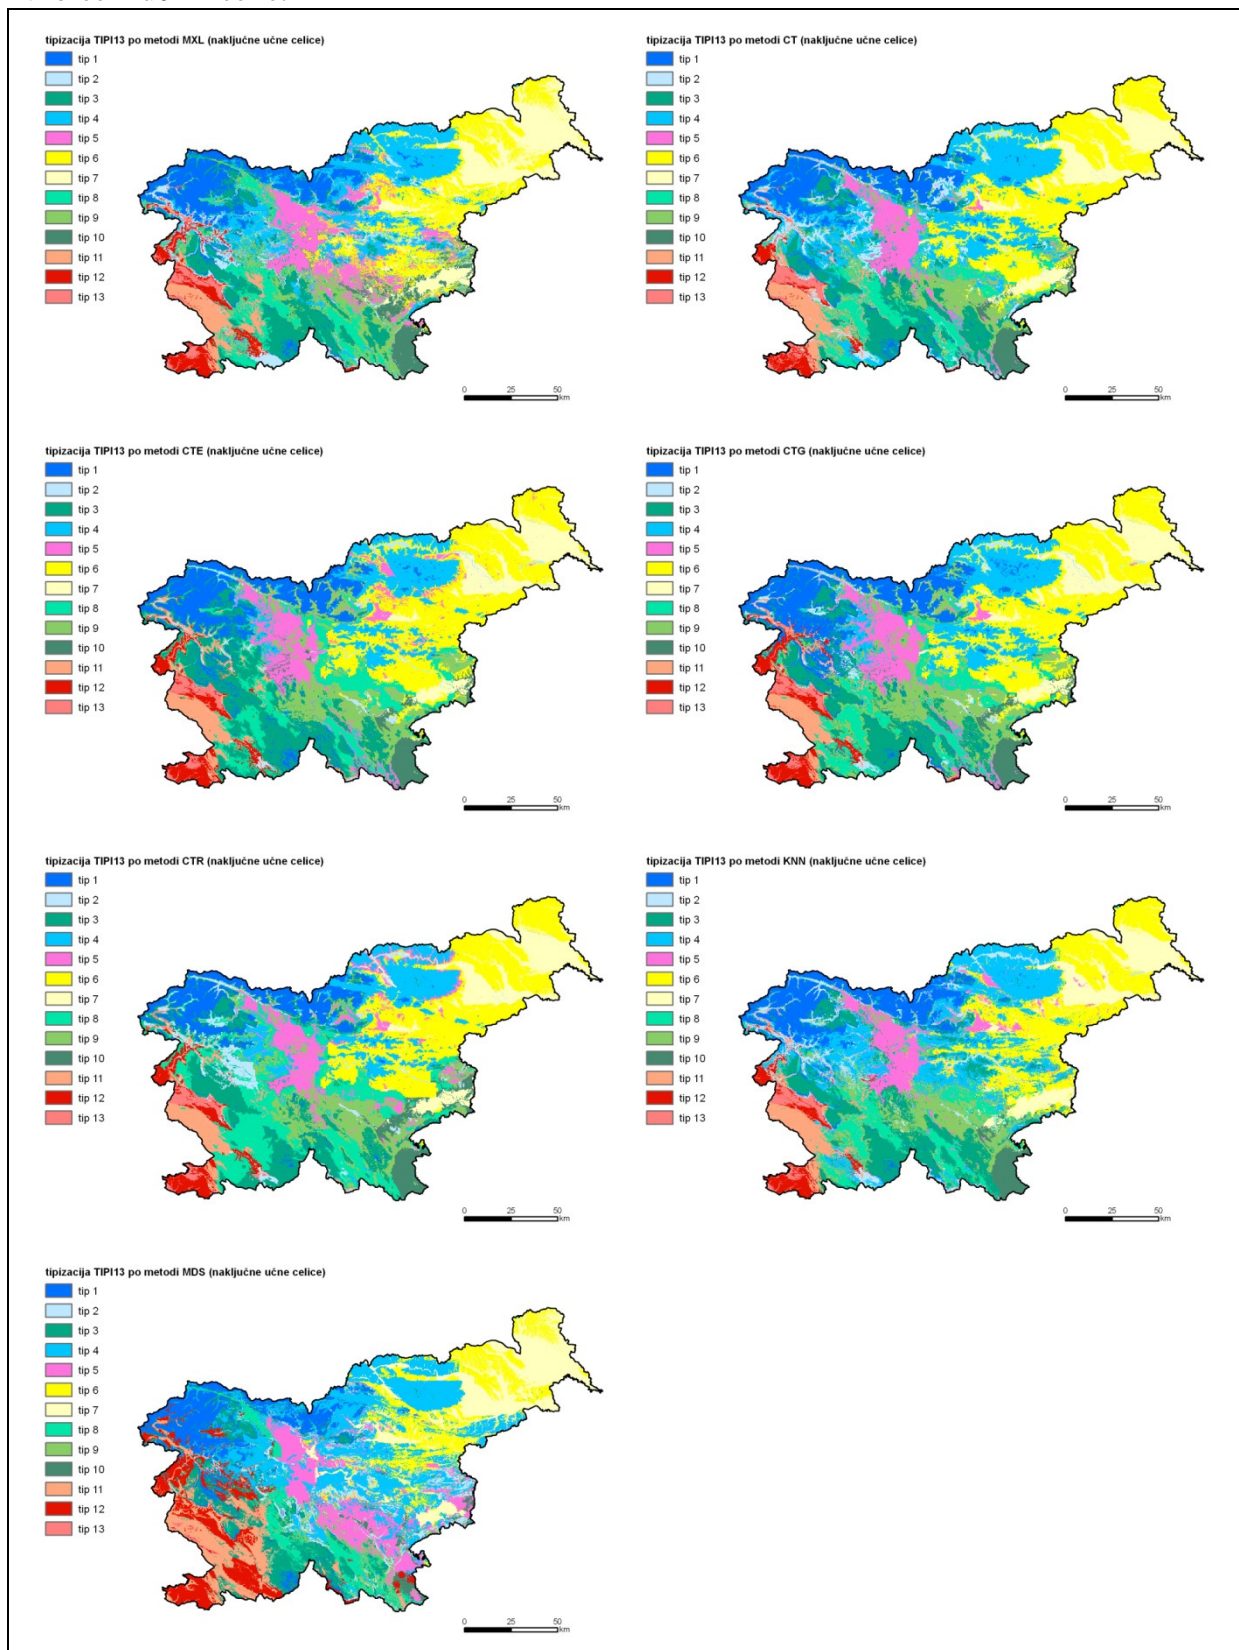


Slika 57: Modelirane tipizacije TIPI9 po metodah nadzorovane klasifikacije z ekspertnim vzorcem učnih celic.

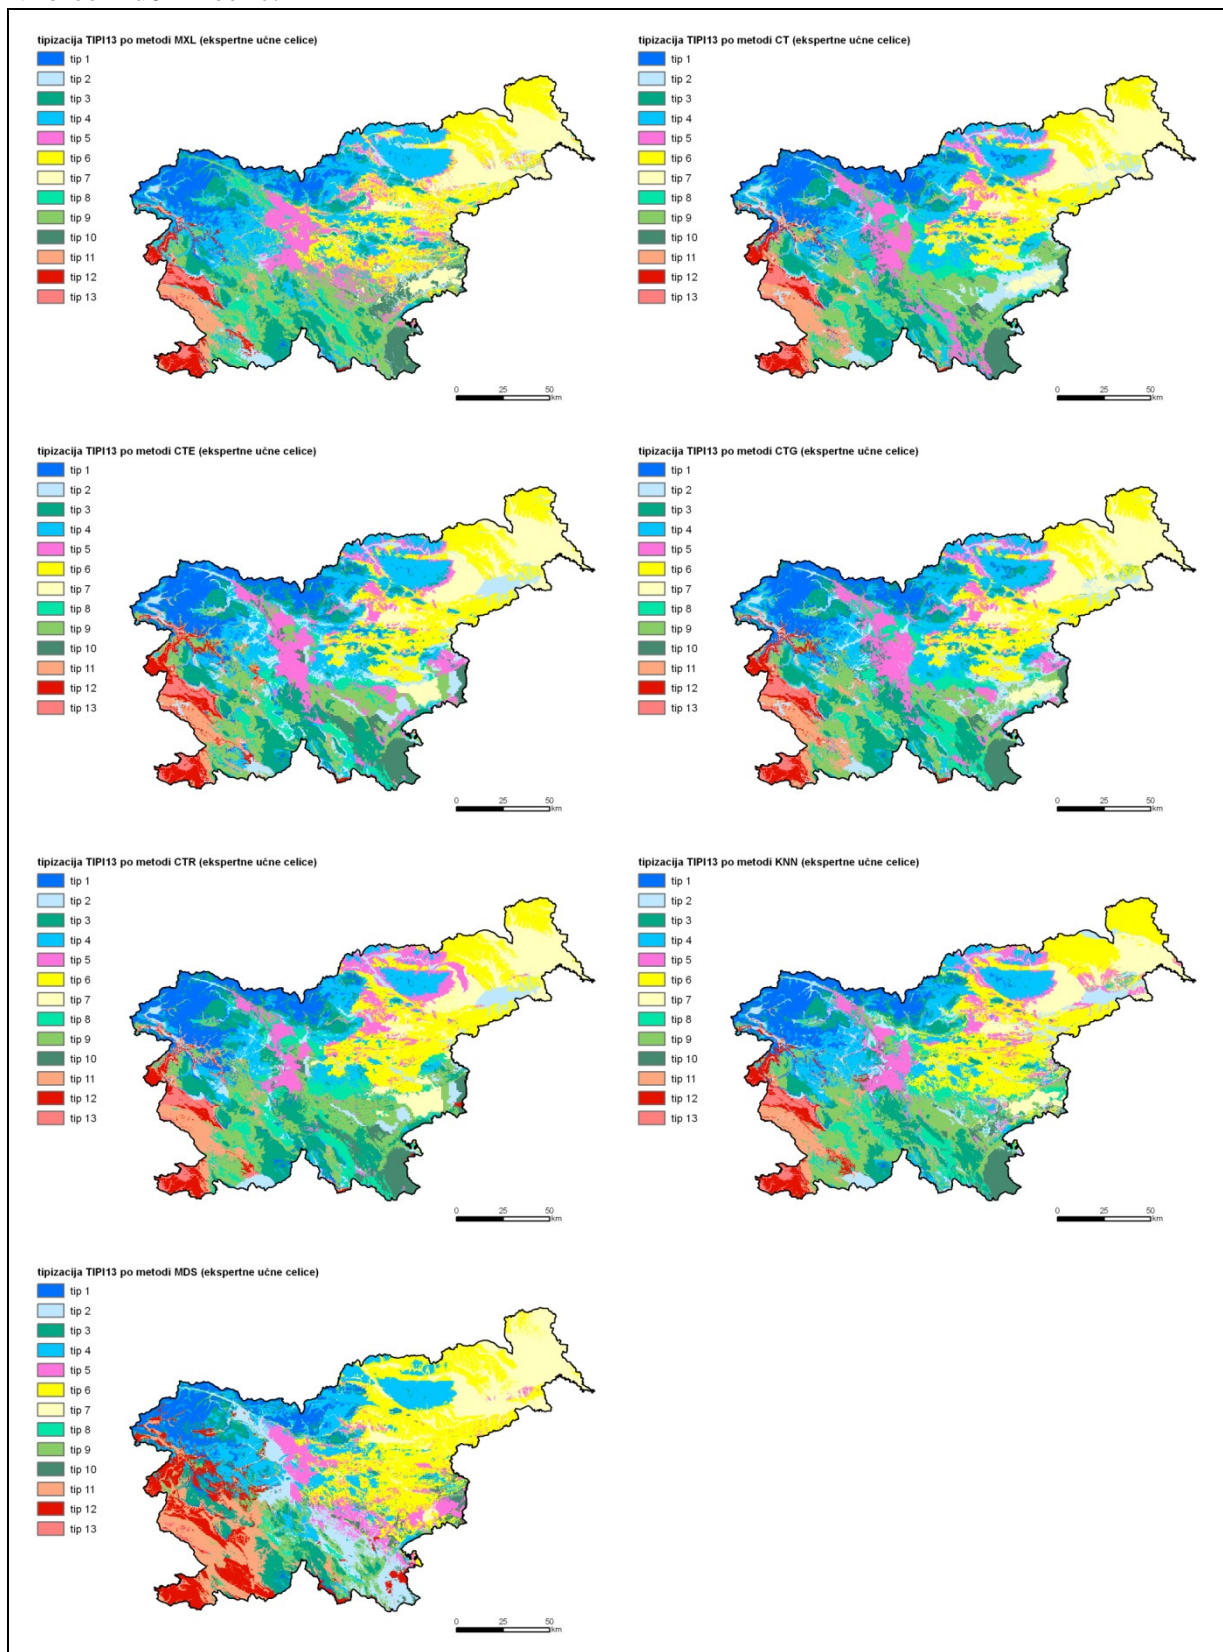


8.2.2 Modelirane naravnopokrajinske tipizacije za TIPI13

Slika 58: Modelirane tipizacije TIPI13 po metodah nadzorovane klasifikacije z naključnim vzorcem učnih celic.



Slika 59: Modelirane tipizacije TIPI13 po metodah nadzorovane klasifikacije z ekspertnim vzorcem učnih celic.



8.3 Vrednotenje modeliranih naravnopokrajinskih tipizacij

Splošnih pravil za vrednotenje ni (McCoy 2005), primerov vrednotenja klasifikacij pa je kar nekaj (Kampichler s sod., 2010). Vrednotenje modeliranih naravnopokrajinskih tipizacij (rezultatov metod nadzorovanih klasifikacij) smo v nalogi opravili v dveh sklopih (slika 60):

- vrednotenje na podlagi podatkovnih slojev (vrednotenje na podlagi posameznih podatkovnih slojev ter vrednotenje na podlagi vseh podatkovnih slojev hkrati),
- vrednotenje na podlagi izvirne tipizacije.

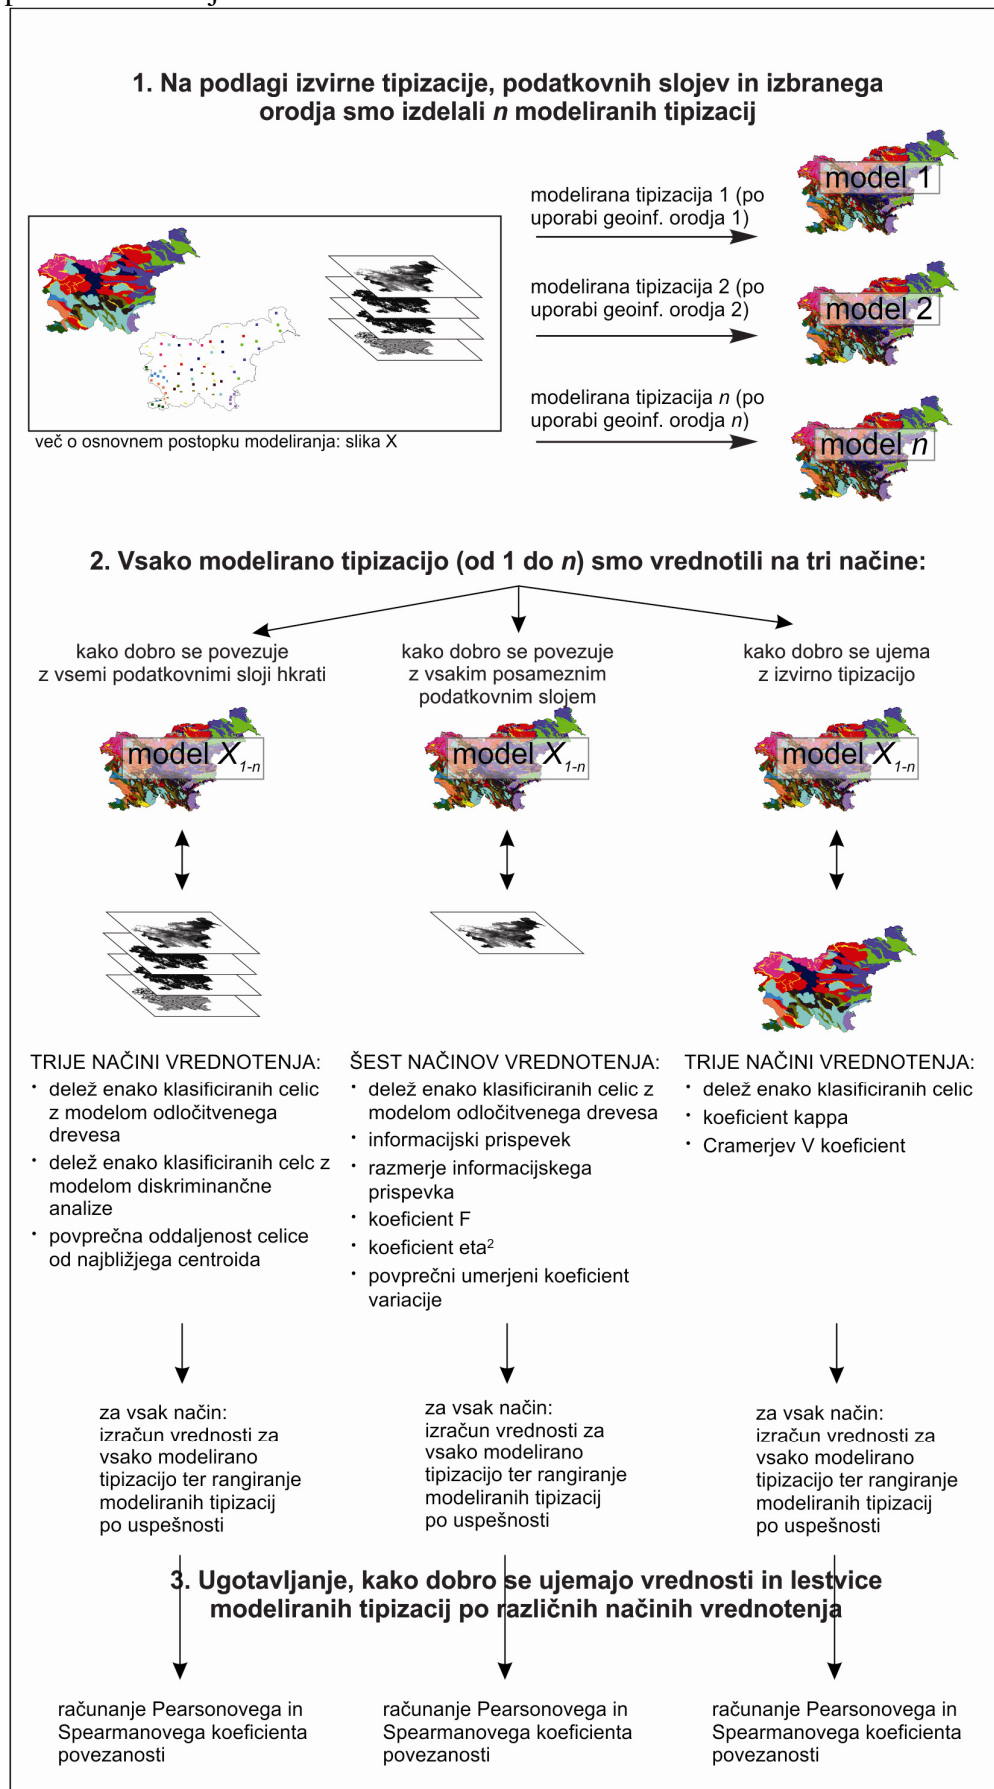
V **prvem sklopu** smo ugotavljali, kako dobra je posamezna modelirana naravnopokrajinska tipizacija z vidika posameznega podatkovnega sloja in kako dobra je z vidika vseh podatkovnih slojev hkrati. V tem sklopu smo ocenili tudi izvirni tipizaciji. Pri tem je treba omeniti, da računalnik pri klasifikaciji sledi določenim pravilom, ki so narejena na podlagi izbranih podatkovnih slojev, s katerimi smo tudi ocenjevali rezultat (stopnja povezanosti, informativnost ...). Zato smo že na začetku pričakovali, da bodo v prvem sklopu ocene za modelirane tipizacije boljše kot za izvirno tipizacijo. Pri vrednotenju tipizacij na podlagi podatkovnih slojev smo uporabili naslednje načine:

- povprečna oddaljenost celice od najbližjega centroida tipa (upoštevani vsi podatkovni sloji hkrati),
- delež enako klasificiranih celic po modelu diskriminančne analize (upoštevani vsi podatkovni sloji hkrati),
- delež enako klasificiranih celic po modelu odločitvenega drevesa CT (upoštevani vsi podatkovni sloji hkrati),
- delež enako klasificiranih celic po modelu odločitvenega drevesa CT (upoštevani le posamezni podatkovni sloj) in izračunano povprečje za vse podatkovne sloje,
- informacijski prispevek posameznega podatkovnega sloja in izračunano povprečje za vse podatkovne sloje,
- razmerje informacijskega prispevka posameznega podatkovnega sloja in izračunano povprečje za vse podatkovne sloje,
- koeficient η^2 za posamezni podatkovni sloj in izračunano povprečje za vse podatkovne sloje,
- koeficient F za posamezni podatkovni sloj in izračunano povprečje za vse podatkovne sloje,
- povprečni umerjeni koeficient variacije posameznega podatkovnega sloja (PUKV) in izračunano povprečje PUKV za vse podatkovne sloje.

V **drugem sklopu** smo ugotavljali, kako močno smo se z modelirano tipizacijo približali izvirni tipizaciji. To smo ugotavljali z izračunom koeficienta kappa, Cremerjevega koeficienta in deleža enako klasificiranih celic.

Med posameznimi merami vrednotenja v obeh sklopih smo izračunali tudi stopnjo povezanosti. Tako smo lahko videli, kako usklajeni so različni načini vrednotenja.

Slika 60: Vrednotenje modeliranih tipizacij in izvirne tipizacije s pomočjo uporabljenih podatkovnih slojev.



8.3.1 Različni načini vrednotenja modeliranih naravnopokrajinskih tipizacij s pomočjo uporabljenih podatkovnih slojev

8.3.1.1 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnih slojev

Povprečna oddaljenost celic od najbližjega centroida (oznaka ODDP)

Pri povprečni oddaljenosti celic od najbližjega centroida (torej centroida tipa, ki mu celica pripada) nižje vrednosti pomenijo boljši rezultat. Želimo namreč, da so si celice istega tipa v večrazsežnostnem prostoru podatkovnih slojev blizu, torej tudi blizu centroida tega tipa. Po tej oceni sta se, pričakovano, najbolje izkazali modelirani tipizaciji po načelu najmanjše oddaljenosti z ekspertnim in tudi naključnim vzorcem učnih celic. Za obe je povprečna oddaljenost 17,4 in je za 7,4 manjša od izvorne tipizacije, ki je zadnja na lestvici. Vmes so se najprej razvrstile modelirane tipizacije po metodi največje verjetnosti (z naključnim in ekspertnim vzorcem učnih celic), modelirani tipizaciji po metodi najbližjih sosedov, nato pa sledijo modelirane tipizacije po raznih metodah odločitvenih dreves z naključnim vzorcem učnih celic in na koncu še modelirane tipizacije po raznih metodah odločitvenih dreves z ekspertnim vzorcem učnih celic (preglednica 64).

Preglednica 64: Povprečna oddaljenost celic od najbližjega centroida.

metoda	nabor učnih celic	povprečna oddaljenost
metoda najmanjše razdalje	ekspertni	17,4
metoda najmanjše razdalje	naključni	17,4
metoda največje verjetnosti	naključni	20,9
metoda največje verjetnosti	ekspertni	21,7
metoda <i>k</i> najbližjih sosedov	ekspertni	22,7
metoda <i>k</i> najbližjih sosedov	naključni	22,9
odločitveno drevo CTR	naključni	23,2
odločitveno drevo CTE	naključni	23,2
odločitveno drevo CTG	naključni	23,6
odločitveno drevo CT	naključni	23,6
odločitveno drevo CTE	ekspertni	23,8
odločitveno drevo CTR	ekspertni	24,0
odločitveno drevo CTG	ekspertni	24,1
odločitveno drevo CT	ekspertni	24,1
izvirna TIPI9	/	24,8

Delež enako klasificiranih celic po modelu diskriminančne analize (oznaka DA)

Tipizacije smo analizirali s pomočjo diskriminančne analize. Pri tem smo vrednotili, kolikšen delež celic bi z njo enako klasificirali. Dejansko smo na podlagi vseh celic v modelirani tipizaciji izdelali diskriminančne funkcije in klasifikacijske funkcije ter ugotavljali, koliko se jih enako klasificira kot v posamezni modelirani tipizaciji.

Najuspešnejša modelirana tipizacija je bila tista po metodi najmanjše razdalje, saj imajo vrednosti precej visoke, tista z ekspertnim naborom ima 89,2 % in tista z naključnim naborom učnih celic 86,5 % enako klasificiranih celic (preglednica 65). Sledijo modelirane klasifikacije po metodi največje verjetnosti, nato pa si sledijo ostale metode z naključnim naborom učnih celic, nato pa še z ekspertnim naborom učnih celic. Izvirna tipizacija je najslabše ovrednotena.

Preglednica 65: Delež enako klasificiranih celic po modelu diskriminančne analize.

metoda	nabor učnih celic	delež (%)
metoda najmanjše razdalje	ekspertni	89,2
metoda najmanjše razdalje	naključni	86,5
metoda največje verjetnosti	naključni	76,2

metoda največje verjetnosti	ekspertni	68,4
odločitveno drevo CTE	naključni	65,5
metoda <i>k</i> najbližjih sosedov	naključni	65,0
odločitveno drevo CT	naključni	63,6
odločitveno drevo CTR	naključni	63,3
odločitveno drevo CTG	naključni	63,1
metoda <i>k</i> najbližjih sosedov	ekspertni	62,7
odločitveno drevo CT	ekspertni	62,3
odločitveno drevo CTR	ekspertni	62,0
odločitveno drevo CT	ekspertni	61,7
odločitveno drevo CTG	ekspertni	59,8
izvirna TIPI9	/	56,0

Delež enako klasificiranih celic po modelu odločitvenega drevesa z upoštevanjem vseh podatkovnih slojev (oznaka ODL(s))

Tipizacije smo ovrednotili tudi tako, da smo jih poskušali opisati s pomočjo odločitvenega drevesa²⁸ in ugotoviti, koliko celic je enako klasificiranih (torej tako kot pri diskriminanci analizi tudi tukaj še enkrat modeliramo že modelirane tipizacije). Predpostavljamo, da ob »čistih« tipih zlahka izdelamo natančno drevo z visokim deležem enako klasificiranih celic. Teste smo naredili z vsemi štirimi podatkovnimi sloji hkrati ter tudi z vsakim posamezno. Glede na delež enako klasificiranih celic pri izdelanem drevesu, izdelanem z vsemi štirimi sloji, se je najbolje izkazala modelirana tipizacija po metodi odločitvenih dreves (različica CTE) z ekspertno izbranimi učnimi celicami (88,5 %), sledi pa klasifikacija po metodi odločitvenih dreves CT (torej po metodi, ki jo uporabljamo tudi za vrednotenje modeliranih tipizacij!) z ekspertnim naborom trening celic (83 %). Presenetljivo sledita obe modelirani tipizaciji po metodi najmanjše razdalje ter šele nato druge modelirane tipizacije, ki temeljijo na drugih algoritmih odločitvenih dreves. Čisto na dnu lestvice so modelirane tipizacije po metodah največje verjetnosti in metodi najbližjega sosedu (preglednica 66).

Preglednica 66: Delež enako klasificiranih celic po modelu odločitvenega drevesa z upoštevanjem vseh uporabljenih podatkovnih slojev hkrati.

metoda	nabor učnih celic	delež (%)
odločitveno drevo CTE	ekspertni	88,5
odločitveno drevo CT	ekspertni	83,0
metoda najmanjše razdalje	naključni	82,2
metoda najmanjše razdalje	ekspertni	82,1
odločitveno drevo CTE	naključni	80,0
odločitveno drevo CTR	naključni	79,9
odločitveno drevo CT	naključni	78,6
odločitveno drevo CTG	naključni	78,1
odločitveno drevo CTG	ekspertni	76,8
metoda največje verjetnosti	ekspertni	76,2
odločitveno drevo CTR	ekspertni	73,6
metoda največje verjetnosti	naključni	73,3
metoda <i>k</i> najbližjih sosedov	ekspertni	72,6
metoda <i>k</i> najbližjih sosedov	naključni	72,6
izvirna TIPI9	/	66,2

²⁸ Uporabili smo odločitveno drevo (različica) CT z naslednjimi nastavitvami: pruning: 1 SE; maksimalno število ravni: 5; najmanjše število enot v notranjih vozliščih: 100; najmanjše število enot v robnih vozliščih: 50; mera nečistoče: Ginijev koeficient; minimalno izboljšanje: 0,0001. Za 5 ravni smo se odločili zato, da ne bi bilo enako kot pri gradnji drevesa, kjer smo jih uporabili 10. Enako število ravni (5) smo vzeli tudi pri vrednotenju nenadzorovanih klasifikacij in modeliranih popačenih tipizacij.

Delež enako klasificiranih z odločitvenim drevesom z upoštevanjem posameznega podatkovnega sloja (oznaka ODL)

Če izdelamo odločitveno drevo le s posameznimi sloji (naklon, padavinski režim, prepustnost, nadmorska višina), opazimo, da so deleži enako klasificiranih celic zelo različne (preglednica 67). Vrednotimo lahko torej z vidika posameznega dejavnika, povprečje pa vzamemo za sumarni podatek. Kot najslabša modelirana klasifikacija se potem izkaže prav klasifikacija po metodi odločitvenega drevesa CT z ekspertnim naborom učnih celic! Izvirna tipizacija je po posameznih ocenah in tudi pri povprečju le-teh boljša od več modeliranih tipizacij.

Z vidika naklona je najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim naborom. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z ekspertnim naborom učnih celic. Z vidika prepustnosti je najboljša modelirana tipizacija po metodi najmanjše razdalje z naključnim naborom učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z naključnim naborom učnih celic.

Preglednica 67: Delež enako klasificiranih celic po modelih odločitvenih dreves z upoštevanjem posameznih slojev.

metoda	nabor učnih celic	delež (%)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	naključni	39,8	41,0	52,3	39,8	43,2
odločitveno drevo CTR	naključni	37,9	40,2	46,5	48,2	43,2
metoda največje verjetnosti	ekspertni	43,1	37,8	43,7	46,0	42,7
metoda največje verjetnosti	naključni	38,5	37,9	44,2	48,7	42,3
odločitveno drevo CTE	naključni	38,5	38,6	42,1	50,0	42,3
izvirna TIPI9	/	37,5	40,0	44,8	45,5	42,0
odločitveno drevo CTE	ekspertni	36,6	44,3	37,3	48,8	41,8
odločitveno drevo CT	naključni	36,7	37,5	43,9	47,9	41,5
odločitveno drevo CTG	naključni	36,1	38,2	42,2	47,6	41,0
metoda najmanjše razdalje	ekspertni	36,2	38,7	49,0	39,8	41,0
metoda <i>k</i> najbližjih sosedov	naključni	38,8	36,2	41,0	45,9	40,5
metoda <i>k</i> najbližjih sosedov	ekspertni	37,8	40,2	41,7	41,5	40,3
odločitveno drevo CTR	ekspertni	32,2	43,9	37,1	42,1	38,8
odločitveno drevo CTG	ekspertni	32,3	42,4	36,8	43,4	38,7
odločitveno drevo CT	ekspertni	31,5	43,0	35,4	43,6	38,4

Informacijski prispevek (oznaka IG)

Glede na informacijski prispevek sta v povprečju najboljši modelirana tipizacija po metodi najmanjše razdalje z ekspertnim vzorcem učnih celic ter modelirana tipizacija največje verjetnosti z naključnim vzorcem učnih celic (obe imata povprečno vrednost 1,01 bita; preglednica 68). Z vidika naklona je najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi odločitvenega drevesa različica CTE z ekspertnim vzorcem učnih celic. Z vidika prepustnosti je najboljša modelirana tipizacija po metodi najmanjše razdalje z ekspertnim vzorcem učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa CT (z algoritmom *Classification and regression trees*) in ekspertnim vzorcem učnih celic.

Preglednica 68: Informacijski prispevek (v bitih) za posamezni podatkovni sloj ter povprečje.

metoda	nabor učnih celic	informacijski prispevek (bit)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	ekspertni	0,73	1,14	1,34	0,83	1,01

metoda največje verjetnosti	naključni	0,83	1,12	0,89	1,18	1,01
metoda najmanjše razdalje	naključni	0,74	1,14	1,35	0,71	0,98
odločitveno drevo CTR	naključni	0,71	1,10	1,04	1,06	0,98
odločitveno drevo CTE	ekspertni	0,65	1,23	0,80	1,17	0,96
odločitveno drevo CTG	naključni	0,62	1,08	0,96	1,16	0,96
odločitveno drevo CT	naključni	0,65	1,12	0,97	1,09	0,95
metoda največje verjetnosti	ekspertni	0,95	0,94	0,92	0,97	0,95
odločitveno drevo CTE	naključni	0,70	0,99	0,91	1,19	0,95
metoda <i>k</i> najbližjih sosedov	naključni	0,75	0,99	1,04	0,98	0,94
odločitveno drevo CT	ekspertni	0,56	1,11	0,83	1,21	0,93
odločitveno drevo CTR	ekspertni	0,63	1,12	0,83	1,10	0,92
metoda <i>k</i> najbližjih sosedov	ekspertni	0,76	1,02	1,04	0,85	0,92
odločitveno drevo CTG	ekspertni	0,58	1,06	0,86	1,13	0,91
izvirna TIPI9	/	0,57	0,97	0,85	0,83	0,81

Razmerje informacijskega prispevka (oznaka GR)

Ocene tipizacij so si po tem načinu vrednotenja zelo podobne. Še najbolj raznolike so glede na podatkovna sloja prepustnost in nadmorska višina (preglednica 69). Z vidika naklona je najboljše ovrednotena modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z ekspertnim vzorcem učnih celic. Z vidika prepustnosti je najboljša modelirana tipizacija po metodi najmanjše razdalje z naključnim vzorcem učnih celic, zelo blizu pa ji sledi ista metoda z ekspertnim vzorcem učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CT) z ekspertnim vzorcem učnih celic.

Glede na povprečje ocen z vidika posameznih dejavnikov sta najboljši modelirani tipizaciji po metodi najmanjše razdalje.

Preglednica 69: Razmerje informacijskega prispevka za posamezni podatkovni sloj ter povprečje.

metoda	nabor učnih celic	razmerje informacijskega prispevka				povprečje
		naklon	padavin-ski režim	prepustnost	nadmorska višina	
metoda najmanjše razdalje	ekspertni	0,14	0,14	0,40	0,14	0,20
metoda najmanjše razdalje	naključni	0,14	0,14	0,41	0,12	0,20
odločitveno drevo CTR	naključni	0,14	0,13	0,31	0,19	0,19
metoda največje verjetnosti	naključni	0,15	0,13	0,27	0,19	0,19
metoda <i>k</i> najbližjih sosedov	naključni	0,14	0,12	0,31	0,17	0,18
odločitveno drevo CTG	naključni	0,13	0,12	0,29	0,20	0,18
odločitveno drevo CT	naključni	0,13	0,13	0,29	0,19	0,18
odločitveno drevo CTE	naključni	0,14	0,12	0,27	0,21	0,18
odločitveno drevo CTE	ekspertni	0,13	0,15	0,24	0,21	0,18
metoda največje verjetnosti	ekspertni	0,17	0,11	0,28	0,16	0,18
metoda <i>k</i> najbližjih sosedov	ekspertni	0,14	0,12	0,31	0,14	0,18
odločitveno drevo CT	ekspertni	0,11	0,13	0,25	0,22	0,18
odločitveno drevo CTR	ekspertni	0,13	0,13	0,25	0,20	0,18
odločitveno drevo CTG	ekspertni	0,12	0,13	0,26	0,20	0,18
izvirna TIPI9	/	0,11	0,11	0,26	0,14	0,15

Koeficient η^2 (oznaka E2)

Glede na koeficient η^2 (preglednica 70) sta v povprečju najboljši modelirani tipizaciji po metodi najmanjše razdalje (tista z ekspertnim vzorcem učnih celic ima rahlo višjo vrednost). Z vidika naklona je po vrednosti η^2 najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic, blizu pa so tudi modelirana tipizacija po isti

metodi z naključnim vzorcem ter modelirani tipizaciji po metodi najmanjše razdalje. Z vidika padavinskega režima in prepustnosti sta najboljši modelirani tipizaciji po metodi najmanjše razdalje. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTG) z naključnim vzorcem učnih celic.

Preglednica 70: Koefficient η^2 za posamezni podatkovni sloj ter povprečje. Statistična značilnost posameznega η^2 je 0,001, kar pomeni, da je statistična značilnost posamezne lestvice 0,015, lestvice povprečnih vrednosti pa 0,059.

metoda	nabor učnih celic	η^2				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	ekspertni	0,61	0,72	0,79	0,61	0,68
metoda najmanjše razdalje	naključni	0,61	0,74	0,78	0,54	0,67
odločitveno drevo CTE	naključni	0,51	0,63	0,64	0,70	0,62
metoda največje verjetnosti	naključni	0,61	0,71	0,45	0,68	0,61
metoda največje verjetnosti	ekspertni	0,64	0,61	0,45	0,56	0,57
metoda <i>k</i> najbližjih sosedov	naključni	0,56	0,62	0,39	0,61	0,55
metoda <i>k</i> najbližjih sosedov	ekspertni	0,57	0,61	0,40	0,57	0,54
odločitveno drevo CTR	naključni	0,49	0,62	0,40	0,61	0,53
odločitveno drevo CTG	naključni	0,45	0,61	0,37	0,66	0,52
odločitveno drevo CT	naključni	0,46	0,64	0,35	0,62	0,52
odločitveno drevo CTE	ekspertni	0,44	0,63	0,30	0,62	0,50
odločitveno drevo CT	ekspertni	0,43	0,59	0,34	0,62	0,50
odločitveno drevo CTG	ekspertni	0,44	0,57	0,34	0,60	0,49
odločitveno drevo CTR	ekspertni	0,44	0,58	0,31	0,58	0,48
izvirna TIPI9	/	0,45	0,58	0,29	0,52	0,46

Koefficient F (oznaka F)

Pri vrednotenju s koefficientom F (preglednica 71) je z vidika naklona najboljša modelirana tipizacija z metodo največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi najmanjše razdalje z naključnim vzorcem učnih celic, z vidika prepustnosti pa modelirana tipizacija po isti metodi z ekspertnim vzorcem učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z naključnim vzorcem učnih celic. Glede na povprečno oceno sta najboljši obe modelirani tipizaciji po metodi najmanjše razdalje (z nekoliko boljšim rezultatom pri ekspertnem naboru).

Preglednica 71: Koefficient F glede na posamezni podatkovni sloj ter povprečje. Statistična značilnost posameznega koefficienta F je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$.

metoda	koefficient f				
	naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	$9,79 \cdot 10^4$	$1,67 \cdot 10^5$	$2,36 \cdot 10^5$	$9,72 \cdot 10^4$	$1,49 \cdot 10^5$
metoda najmanjše razdalje	$9,78 \cdot 10^4$	$1,82 \cdot 10^5$	$2,22 \cdot 10^5$	$7,33 \cdot 10^4$	$1,44 \cdot 10^5$
metoda največje verjetnosti	$9,99 \cdot 10^4$	$1,56 \cdot 10^5$	$5,13 \cdot 10^4$	$1,36 \cdot 10^5$	$1,11 \cdot 10^5$
odločitveno drevo CTE	$6,69 \cdot 10^4$	$1,07 \cdot 10^5$	$3,14 \cdot 10^4$	$1,49 \cdot 10^5$	$8,85 \cdot 10^4$
metoda največje verjetnosti	$1,13 \cdot 10^5$	$9,90 \cdot 10^4$	$5,18 \cdot 10^4$	$8,21 \cdot 10^4$	$8,64 \cdot 10^4$
metoda <i>k</i> najbližjih sosedov	$8,16 \cdot 10^4$	$1,03 \cdot 10^5$	$4,01 \cdot 10^4$	$1,01 \cdot 10^5$	$8,14 \cdot 10^4$
odločitveno drevo CTG	$5,28 \cdot 10^4$	$9,89 \cdot 10^4$	$3,68 \cdot 10^4$	$1,23 \cdot 10^5$	$7,78 \cdot 10^4$
metoda <i>k</i> najbližjih sosedov	$8,45 \cdot 10^4$	$9,71 \cdot 10^4$	$4,27 \cdot 10^4$	$8,35 \cdot 10^4$	$7,70 \cdot 10^4$
odločitveno drevo CT	$5,39 \cdot 10^4$	$1,14 \cdot 10^5$	$3,45 \cdot 10^4$	$1,04 \cdot 10^5$	$7,67 \cdot 10^4$
odločitveno drevo CTR	$6,20 \cdot 10^4$	$1,03 \cdot 10^5$	$4,15 \cdot 10^4$	$9,79 \cdot 10^4$	$7,61 \cdot 10^4$
odločitveno drevo CTE	$5,04 \cdot 10^4$	$1,08 \cdot 10^5$	$2,69 \cdot 10^4$	$1,04 \cdot 10^5$	$7,22 \cdot 10^4$
odločitveno drevo CT	$4,84 \cdot 10^4$	$9,11 \cdot 10^4$	$3,33 \cdot 10^4$	$1,02 \cdot 10^5$	$6,87 \cdot 10^4$

odločitveno drevo CTG	5,06*10 ⁴	8,39*10 ⁴	3,23*10 ⁴	9,64*10 ⁴	6,58*10 ⁴
odločitveno drevo CTR	5,03*10 ⁴	8,79*10 ⁴	2,85*10 ⁴	8,72*10 ⁴	6,35*10 ⁴
izvirna TIPI9	5,10*10 ⁴	8,88*10 ⁴	2,55*10 ⁴	6,81*10 ⁴	5,84*10 ⁴

Povprečni umerjeni koeficient variacije (oznaka PUKV)

Pri tej meri je nižja vrednost boljša. Najnižjo vrednost glede na naklon ima modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi najmanjše razdalje z ekspertnim vzorcem učnih celic. Z vidika prepustnosti sta najboljši modelirani tipizaciji po metodi najmanjše razdalje (tipizaciji z obema načinoma izbora učnih celic imata enako vrednost: 13,9 %). Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi največje verjetnosti z naključnim vzorcem učnih celic. V povprečju se najbolj izkažejo modelirana tipizacije po metodi najmanjše razdalje in po metodi največje verjetnosti. Izvirna tipizacija je glede na povprečje najslabše ocenjena, vendar to ne velja za posamezne podatkovne sloje – glede na naklon in nadmorsko višino je nekaj modeliranih tipizacij slabših od izvirne (preglednica 72).

Preglednica 72: Povprečni umerjeni koeficient variacije za posamezni podatkovni sloj in povprečje.

metoda	nabor učnih celic	PUKV (%)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	ekspertni	44,8	19,9	13,9	36,6	28,8
metoda največje verjetnosti	naključni	42,4	20,5	23,0	30,7	29,2
metoda najmanjše razdalje	naključni	44,5	19,4	13,9	40,1	29,5
metoda največje verjetnosti	ekspertni	40,1	23,8	22,3	35,9	30,5
odločitveno drevo CTE	naključni	48,7	23,6	26,1	30,8	32,3
metoda <i>k</i> najbližjih sosedov	naključni	45,8	23,7	24,9	34,8	32,3
metoda <i>k</i> najbližjih sosedov	ekspertni	45,1	24,0	24,0	37,4	32,6
odločitveno drevo CTR	naključni	49,5	23,3	24,6	34,8	33,1
odločitveno drevo CTG	naključni	52,2	23,7	25,2	32,3	33,3
odločitveno drevo CT	naključni	51,6	23,0	25,6	34,0	33,5
odločitveno drevo CTE	ekspertni	51,9	22,8	26,8	33,7	33,8
odločitveno drevo CT	ekspertni	53,6	24,0	26,4	33,9	34,5
odločitveno drevo CTG	ekspertni	52,9	24,7	26,4	34,7	34,7
odločitveno drevo CTR	ekspertni	52,0	24,3	26,7	35,8	34,7
izvirna TIPI9	/	52,1	25,1	27,1	39,1	35,9

8.3.1.2 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI13 s pomočjo podatkovnih slojev

Povprečna oddaljenost celic od najbližjega centroida (oznaka ODDP)

Po tej oceni sta se, pričakovano (tako kot pri TIPI9), najbolj izkazali modelirani tipizaciji po načelu najmanjše razdalje z ekspertnim in tudi naključnim vzorcem učnih celic. Najslabša je modelirana tipizacija z odločitvenim drevesom (različica CTR). Predzadnja je izvorna tipizacija. Vmes si od boljših proti slabšim sledijo najprej modelirani tipizaciji po metodi največje verjetnosti, nato pa metoda najbližjih sosedov z naključnim vzorcem učnih celic, razne modelirane tipizacije po metodah odločitvenih dreves pa so v spodnjem delu lestvice (preglednica 73).

Preglednica 73: Povprečna oddaljenost celic od najbližjega centroida.

metoda	nabor učnih celic	povprečna oddaljenost
metoda najmanjše razdalje	ekspertni	16,74
metoda najmanjše razdalje	naključni	16,76
metoda največje verjetnosti	naključni	20,00
metoda največje verjetnosti	ekspertni	22,20
metoda k najbližjih sosedov	naključni	22,54
odločitveno drevo CT	naključni	22,69
odločitveno drevo CTG	naključni	22,77
odločitveno drevo CTR	naključni	23,15
odločitveno drevo CTE	naključni	23,16
metoda k najbližjih sosedov	ekspertni	23,81
odločitveno drevo CTG	ekspertni	24,62
odločitveno drevo CT	ekspertni	24,71
odločitveno drevo CTE	ekspertni	24,77
izvirna TIPI13	/	24,79
odločitveno drevo CTR	ekspertni	24,89

Delež enako klasificiranih po diskriminančni analizi (oznaka DA)

Glede na delež enako klasificiranih po diskriminančni analizi (preglednica 74) je najuspešnejša modelirana tipizacija po metodi najmanjše razdalje z ekspertnim vzorcem učnih celic, sledi ji modelirana tipizacija z enako metodo z naključnim vzorcem učnih celic. Obe imata zelo visoko vrednost (nad 80 %). Med boljšimi sta še modelirani tipizaciji po metodi največje verjetnosti. Zanimivo je, da je izvorna tipizacija boljša od dveh modeliranih tipizacij.

Preglednica 74: Delež pravilno klasificiranih celic po diskriminančni analizi.

metoda	nabor učnih celic	delež (%)
metoda najmanjše razdalje	ekspertni	82,9
metoda najmanjše razdalje	naključni	81,6
metoda največje verjetnosti	naključni	74,8
metoda največje verjetnosti	ekspertni	68,9
odločitveno drevo CT	naključni	62,9
metoda k najbližjih sosedov	naključni	62,7
odločitveno drevo CTE	naključni	62,5
odločitveno drevo CTG	naključni	61,7
odločitveno drevo CTR	naključni	60,6
odločitveno drevo CTG	ekspertni	53,9
odločitveno drevo CT	ekspertni	53,8
metoda k najbližjih sosedov	ekspertni	53,2
izvirna TIPI13	/	52,1
odločitveno drevo CTE	ekspertni	51,0
odločitveno drevo CTR	ekspertni	48,0

Delež enako klasificiranih po modelu odločitvenega drevesa z upoštevanjem vseh podatkovnih slojev (oznaka ODL(s))

Modelirane tipizacije smo ocenili tako, da smo jih poskušali opisati s pomočjo odločitvenega drevesa in ugotoviti, koliko celic je enako klasificiranih. Teste smo naredili z vsemi štirimi uporabljenimi podatkovnimi sloji hkrati ter tudi z vsakim posamezno.

Glede na delež enako klasificiranih na podlagi tega drevesa, izdelanega z vsemi štirimi sloji hkrati (preglednica 75), se je kot najboljša izkazala modelirana tipizacija po metodi odločitvenih dreves (različica CTE) z naključno izbranimi učnimi celicami (81,7 %), sledita pa modelirani tipizaciji po metodi najmanjše razdalje ter šele nato druge tipizacije, ki temeljijo na odločitvenih drevesih. Čisto na dnu lestvice je modelirana tipizacija po metodi najbližjega soseda z ekspertnim vzorcem. Zanimivo je to, da so z eno izjemo v zgornjem delu lestvice samo modelirane tipizacije, ki so bile narejene na podlagi naključnih naborov učnih celic.

Preglednica 75: Delež enako klasificiranih celic po modelu odločitvenega drevesa z upoštevanjem vseh uporabljenih podatkovnih slojev hkrati.

metoda	nabor učnih celic	delež (%)
odločitveno drevo CTE	naključni	81,7
metoda najmanjše razdalje	naključni	78,8
metoda najmanjše razdalje	ekspertni	78,5
odločitveno drevo CTG	naključni	78,3
odločitveno drevo CTR	naključni	78,1
odločitveno drevo CT	naključni	75,1
metoda največje verjetnosti	naključni	74,2
odločitveno drevo CT	ekspertni	73,6
odločitveno drevo CTG	ekspertni	72,0
metoda največje verjetnosti	ekspertni	71,9
odločitveno drevo CTE	ekspertni	70,0
metoda <i>k</i> najbližjih sosedov	naključni	68,6
odločitveno drevo CTR	ekspertni	64,9
metoda <i>k</i> najbližjih sosedov	ekspertni	60,1
izvirna TIPI13	/	59,3

Delež enako klasificiranih po modelu odločitvenega drevesa z upoštevanjem posameznega podatkovnega sloja (oznaka ODL)

Če izdelamo odločitveno drevo le s posameznimi podatkovnimi sloji (naklon, padavinski režim, prepustnost, nadmorska višina), opazimo, da so deleži enako klasificiranih celic zelo različni. Vrednotimo torej z vidika posameznega dejavnika, povprečje pa lahko vzamemo za sumarni podatek (preglednica 76).

V povprečju je s tega vidika najboljša modelirana tipizacija po metodi, ki temelji na najmanjši razdalji z naključnim vzorcem učnih celic. Najslabše so (poleg tipizacij po metodi najbližjih sosedov z ekspertnim vzorcem učnih celic) prav vse modelirane tipizacije po metodi odločitvenih dreves z ekspertnim naborom učnih celic. Z vidika naklona je najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim naborom učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z naključnim vzorcem učnih celic. Z vidika prepustnosti je najboljša modelirana tipizacija po metodi najmanjše razdalje z naključnim naborom učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z naključnim naborom učnih celic. Izvirna tipizacija je po tem vrednotenju v povprečju zelo dobro ocenjena in je povsem blizu ostalim modeliranim tipizacijam pri vrhu.

Preglednica 76: Delež enako klasificiranih celic po modelih odločitvenih dreves z upoštevanjem posameznih slojev.

metoda	nabor učnih celic	delež (%)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	naključni	37,8	37,8	49,0	38,9	40,9
odločitveno drevo CTE	naključni	33,1	43,2	35,8	47,6	39,9
metoda najmanjše razdalje	ekspertni	34,0	39,1	47,0	38,9	39,8
izvirna TIPI13	/	37,7	34,8	42,6	43,5	39,7
odločitveno drevo CT	naključni	36,1	34,2	38,8	47,5	39,2
odločitveno drevo CTG	naključni	34,9	38,2	37,3	45,7	39,0
metoda <i>k</i> najbližjih sosedov	naključni	38,1	32,7	41,4	43,4	38,9
odločitveno drevo CTR	naključni	31,3	42,4	37,3	44,6	38,9
metoda največje verjetnosti	naključni	36,1	30,9	41,6	45,4	38,5
metoda največje verjetnosti	ekspertni	38,3	30,5	39,7	44,3	38,2
odločitveno drevo CT	ekspertni	32,8	36,4	32,1	41,4	35,7
metoda <i>k</i> najbližjih sosedov	ekspertni	31,0	35,5	37,0	35,5	34,8
odločitveno drevo CTG	ekspertni	29,7	34,9	33,0	39,8	34,4
odločitveno drevo CTR	ekspertni	28,5	35,5	33,5	39,0	34,1
odločitveno drevo CTE	ekspertni	28,8	32,9	32,1	39,5	33,3

Informacijski prispevek (oznaka GR)

Glede na povprečje informacijskega prispevka (preglednica 77) je najboljša modelirana tipizacija po metodi največje verjetnosti z naključnim naborom učnih celic. Z vidika naklona je najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima sta najboljši modelirani tipizaciji po metodi odločitvenega drevesa (različica CTR) z ekspertnim vzorcem in naključnim vzorcem učnih celic. Z vidika prepustnosti sta najboljši modelirani tipizaciji po metodi najmanjše razdalje (oba vzorca učnih celic). Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z ekspertnim naborom učnih celic.

Preglednica 77: Informacijski prispevek (v bitih) za posamezni podatkovni sloj ter povprečje.

metoda	nabor učnih celic	informacijski prispevek (bit)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda največje verjetnosti	naključni	0,944	1,060	1,004	1,410	1,104
odločitveno drevo CTE	naključni	0,685	1,292	0,866	1,480	1,081
odločitveno drevo CTR	naključni	0,627	1,319	1,014	1,358	1,079
odločitveno drevo CTG	naključni	0,762	1,210	0,939	1,403	1,079
metoda najmanjše razdalje	ekspertni	0,713	1,261	1,345	0,941	1,065
metoda najmanjše razdalje	naključni	0,806	1,224	1,387	0,837	1,064
odločitveno drevo CT	naključni	0,758	1,112	0,943	1,340	1,038
odločitveno drevo CT	ekspertni	0,678	1,177	0,859	1,397	1,028
metoda <i>k</i> najbližjih sosedov	naključni	0,896	0,971	1,088	1,154	1,027
metoda največje verjetnosti	ekspertni	1,007	0,864	0,852	1,312	1,009
odločitveno drevo CTR	ekspertni	0,638	1,318	0,890	1,184	1,008
odločitveno drevo CTG	ekspertni	0,635	1,170	0,852	1,340	0,999
odločitveno drevo CTE	ekspertni	0,564	1,236	0,846	1,291	0,984
metoda <i>k</i> najbližjih sosedov	ekspertni	0,706	1,049	1,028	0,998	0,945
izvirna TIPI13	/	0,663	0,927	0,821	0,957	0,842

Razmerje informacijskega prispevka (oznaka IG)

Ocene tipizacij so si pri vrednotenju z informacijskim prispevkom (preglednica 78) zelo podobne. Še najbolj raznolike so glede na podatkovna sloja prepustnost in nadmorska višina. Z vidika naklona je kot najboljša ocenjena modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima so si modelirane tipizacije zelo blizu, najboljše pa so tiste z metodami najmanjše razdalje in odločitvenega drevesa (različica CTR). Z vidika prepustnosti je najboljša modelirana tipizacija po metodi najmanjše razdalje z naključnim naborom učnih celic, zelo blizu pa ji sledi ista metoda z ekspertnim naborom učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z ekspertnim naborom učnih celic. Glede na povprečje ocen z vidika posameznih dejavnikov je najboljša modelirana tipizacija po metodi najmanjše razdalje (naključni vzorec učnih celic). Zelo blizu pa so tudi ostale metode, med katerimi so kot boljše ocenjene tiste, ki so narejene z naključnim vzorcem.

Preglednica 78: Razmerje informacijskega prispevka za posamezen podatkovni sloj ter povprečje.

metoda	nabor učnih celic	razmerje informacijskega prispevka				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	naključni	0,15	0,15	0,42	0,15	0,22
metoda najmanjše razdalje	ekspertni	0,14	0,15	0,41	0,16	0,21
odločitveno drevo CTR	naključni	0,13	0,15	0,31	0,25	0,21
odločitveno drevo CTG	naključni	0,16	0,14	0,28	0,25	0,21
metoda največje verjetnosti	naključni	0,17	0,12	0,30	0,23	0,21
odločitveno drevo CTE	naključni	0,14	0,15	0,26	0,26	0,20
odločitveno drevo CT	naključni	0,16	0,13	0,28	0,24	0,20
metoda k najbližjih sosedov	naključni	0,17	0,11	0,33	0,20	0,20
odločitveno drevo CT	ekspertni	0,14	0,14	0,26	0,25	0,20
odločitveno drevo CTR	ekspertni	0,14	0,15	0,27	0,22	0,19
odločitveno drevo CTG	ekspertni	0,13	0,13	0,26	0,25	0,19
metoda največje verjetnosti	ekspertni	0,18	0,10	0,26	0,22	0,19
odločitveno drevo CTE	ekspertni	0,12	0,14	0,26	0,23	0,19
metoda k najbližjih sosedov	ekspertni	0,14	0,12	0,31	0,17	0,18
izvirna TIPI13	/	0,14	0,10	0,25	0,16	0,16

Koeficient η^2 (oznaka E2)

Z vidika naklona je po vrednosti koeficienta η^2 (preglednica 79) najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic, blizu pa sta tudi modelirana tipizacija po isti metodi z naključnim naborom učnih celic ter modelirana tipizacija po metodi najmanjše razdalje z naključnim vzorcem učnih celic. Z vidika padavinskega režima in prepustnosti sta najboljši modelirani tipizaciji po metodi najmanjše razdalje. Z vidika nadmorske višine so najboljše modelirane tipizacije po metodi odločitvenega drevesa (različici CTE in CTR) ter po metodi največje verjetnosti; za vse velja, da so narejene z naključnim naborom učnih celic. Glede na povprečje sta najboljše ocenjeni modelirani tipizaciji po metodi najmanjše razdalje.

Preglednica 79: Koeficient η^2 za posamezni podatkovni sloj in povprečje. Statistična značilnost posameznega koeficienta η^2 je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$.

metoda	nabor učnih celic	η^2				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	ekspertni	0,60	0,75	0,79	0,67	0,70

metoda najmanjše razdalje	naključni	0,64	0,74	0,80	0,61	0,70
metoda največje verjetnosti	naključni	0,67	0,64	0,55	0,78	0,66
metoda največje verjetnosti	ekspertni	0,71	0,51	0,39	0,75	0,59
metoda <i>k</i> najbližjih sosedov	naključni	0,63	0,54	0,41	0,71	0,57
odločitveno drevo CT	naključni	0,54	0,57	0,39	0,76	0,56
odločitveno drevo CTG	naključni	0,53	0,65	0,35	0,72	0,56
odločitveno drevo CTE	naključni	0,46	0,68	0,30	0,78	0,56
odločitveno drevo CTR	naključni	0,42	0,66	0,35	0,78	0,55
metoda <i>k</i> najbližjih sosedov	ekspertni	0,56	0,56	0,32	0,67	0,53
odločitveno drevo CT	ekspertni	0,52	0,55	0,22	0,72	0,50
odločitveno drevo CTG	ekspertni	0,50	0,56	0,24	0,70	0,50
odločitveno drevo CTR	ekspertni	0,51	0,61	0,21	0,67	0,50
odločitveno drevo CTE	ekspertni	0,47	0,56	0,25	0,71	0,50
izvirna TIPI13	/	0,51	0,49	0,29	0,62	0,48

Koeficient F (oznaka F)

Po tem načinu vrednotenja je z vidika naklona najboljša modelirana tipizacija po metodi največje verjetnosti z ekspertnim vzorcem učnih celic. Z vidika padavinskega režima sta najboljši modelirani tipizaciji po metodi najmanjše oddaljenosti, prav tako z vidika prepustnosti. Z vidika nadmorske višine je najboljša modelirana tipizacija po metodi odločitvenega drevesa (različica CTE) z naključnim naborom učnih celic. Glede na povprečno oceno sta najboljši modelirani tipizaciji po metodi najmanjše oddaljenosti (preglednica 80).

Preglednica 80: Koeficient F glede na posamezen dejavnik in povprečje. Statistična značilnost posameznega koeficienta F je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$.

metoda	nabor učnih celic	koeficient F				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda najmanjše razdalje	ekspertni	64153	125559	157818	86231	108440
metoda najmanjše razdalje	naključni	74812	121410	166077	65986	107071
metoda največje verjetnosti	naključni	87345	73626	50886	148799	90164
metoda največje verjetnosti	ekspertni	105774	44505	26598	125155	75508
odločitveno drevo CTE	naključni	36505	90245	18464	152318	74383
odločitveno drevo CTR	naključni	30447	83670	23137	145834	70772
odločitveno drevo CT	naključni	50364	55118	26857	130007	65587
odločitveno drevo CTG	naključni	47129	80212	22268	110289	64974
metoda <i>k</i> najbližjih sosedov	naključni	70833	49043	29020	103600	63124
odločitveno drevo CT	ekspertni	46075	51668	12191	106215	54037
metoda <i>k</i> najbližjih sosedov	ekspertni	53999	53503	19474	86658	53409
odločitveno drevo CTG	ekspertni	42877	54277	12958	100528	52660
odločitveno drevo CTE	ekspertni	37631	53637	13727	104360	52339
odločitveno drevo CTR	ekspertni	43285	65588	11532	83904	51077
izvirna TIPI13		43583	40514	17208	69995	42825

Povprečni umerjeni koeficient variacije (oznaka PUKV)

Najnižjo vrednost (najboljšo oceno) glede na naklon ima modelirana tipizacija po metodi največje verjetnosti z ekspertnim naborom učnih celic. Z vidika padavinskega režima je najboljša modelirana tipizacija po metodi najmanjše razdalje z ekspertnim naborom učnih celic. Z vidika prepustnosti je najboljša modelirana tipizacija z metodo najmanjše razdalje z naključnim naborom učnih celic. Z vidika nadmorske višine je najboljša modelirana tipizacija

po metodi največje verjetnosti z naključnim naborom učnih celic. V povprečju se najbolj izkažejo modelirane tipizacije po metodi najmanjše razdalje in po metodi največje verjetnosti. Izmed teh je najboljša metoda največje verjetnosti z naključnim naborom učnih celic. Izvirna tipizacija je glede na povprečje najslabše ocenjena, vendar to ne velja za posamezne dejavnike – glede na naklon, prepustnost in nadmorsko višino je nekaj modeliranih tipizacij ocenjenih slabše (preglednica 81).

Preglednica 81: Povprečni umerjeni koeficient variacije za posamezen dejavnik in povprečje.

metoda	nabor učnih celic	PUKV (%)				
		naklon	padavinski režim	prepustnost	nadmorska višina	povprečje
metoda največje verjetnosti	naključni	39,1	22,5	21,1	25,1	26,9
metoda najmanjše razdalje	ekspertni	45,0	18,8	14,0	33,3	27,8
metoda najmanjše razdalje	naključni	42,6	19,1	13,7	36,4	28,0
metoda največje verjetnosti	ekspertni	36,8	26,3	24,8	27,1	28,8
metoda <i>k</i> najbližjih sosedov	naključni	41,8	25,8	24,6	30,1	30,6
odločitveno drevo CT	naključni	47,6	24,6	25,0	27,6	31,2
odločitveno drevo CTG	naključni	48,3	22,5	26,0	28,1	31,2
odločitveno drevo CTE	naključni	51,3	21,4	26,8	26,0	31,4
odločitveno drevo CTR	naključni	54,1	22,1	25,2	27,0	32,1
metoda <i>k</i> najbližjih sosedov	ekspertni	46,5	25,3	26,3	32,5	32,7
odločitveno drevo CT	ekspertni	49,5	25,4	28,3	28,5	32,9
odločitveno drevo CTG	ekspertni	50,5	25,0	28,2	29,3	33,2
odločitveno drevo CTR	ekspertni	49,9	23,9	28,0	32,4	33,6
odločitveno drevo CTE	ekspertni	52,1	25,1	28,0	29,9	33,8
izvirna TIPI13	/	49,7	27,2	27,4	34,7	34,7

8.3.2 Usklajenost različnih načinov vrednotenja naravnopokrajinskih tipizacij

Načini vrednotenja, ki smo jih uporabili, tipizacije različno ocenjujejo; po nekem načinu je neka tipizacija ocenjena kot dobra, po drugem pa ne. Zaradi tega smo se odločili raziskati, kako dobro so različni načini vrednotenja tipizacij med seboj usklajeni. To je tudi eden glavnih namenov disertacije. Uporabili smo dva načina izračunavanja stopnje povezanosti: Pearsonov koeficient stopnje povezanosti in Spearmanov koeficient stopnje povezanosti.

8.3.2.1 Usklajenost različnih načinov vrednotenja modeliranih naravnopokrajinskih tipizacij TIPI9

Obravnavali smo usklajenost različnih načinov vrednotenja tipizacij, ki upoštevajo vse podatkovne sloje, ter usklajenost različnih načinov vrednotenja tipizacij, ki upoštevajo posamezni podatkovni sloj.

Usklajenost različnih načinov vrednotenja s pomočjo vseh podatkovnih slojev hkrati

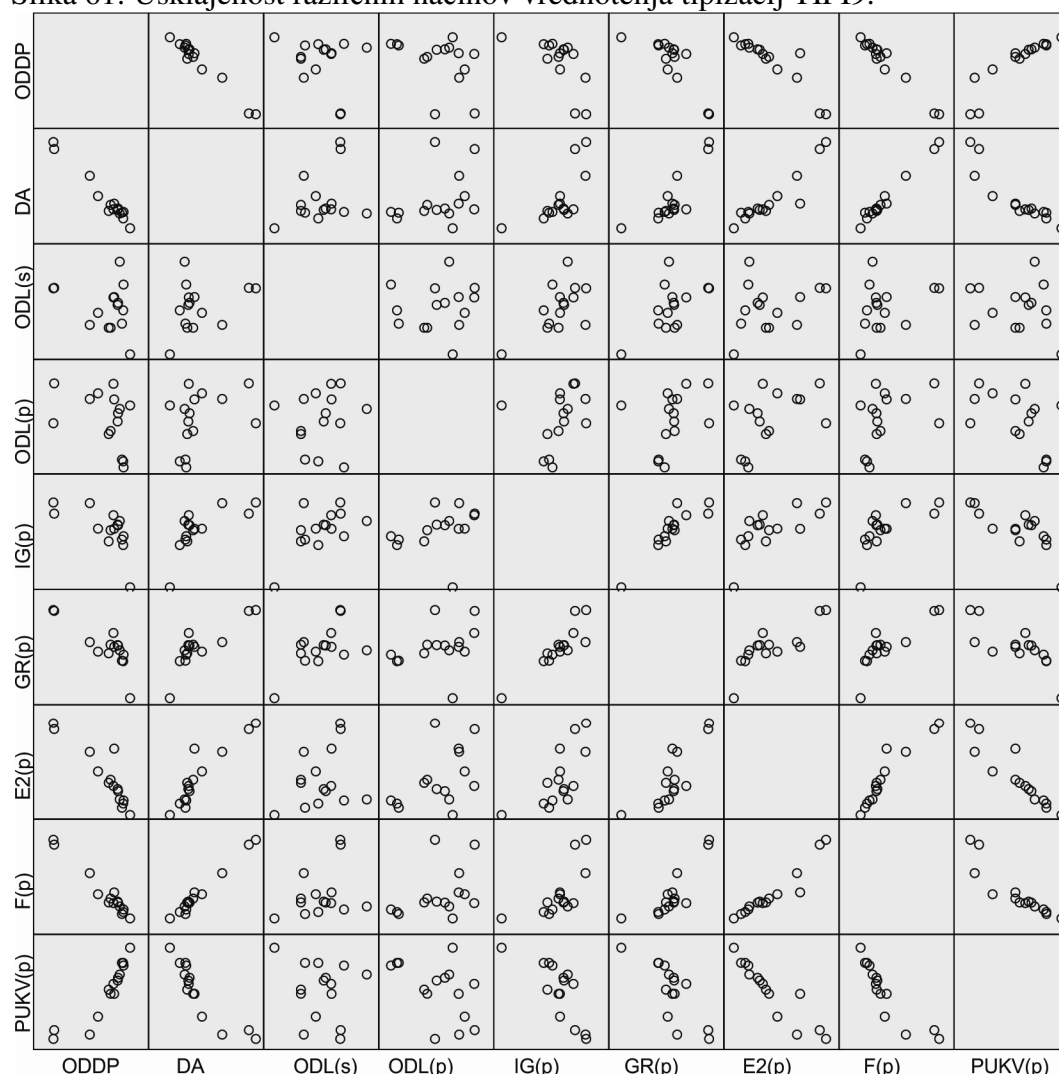
Izračunan Pearsonov koeficient stopnje povezanosti (preglednica 145 v prilogi 11) je (z izjemo enega primera²⁹) višji od 0,8 (oziroma manjši od -0,8) za povezanosti med naslednjimi načini vrednotenja (velja za $p=0,01$):

- oddaljenost od najbližjega centroida,
- delež enako klasificiranih po modelu diskriminančne analize,
- povprečno razmerje informacijskega prispevka,
- povprečni koeficient η^2 ,
- povprečni koeficient F,
- povprečni povprečni umerjeni koeficient variacije (povprečni PUKV).

²⁹ Pearsonov korelacijski koeficient med povprečnim informacijskim prispevkom in povprečnim povprečnim umerjenim koeficientom variacije znaša 0,782 in je statistično značilen pri 0,001.

Omenjene metode dajejo torej zelo podobne rezultate, kar je razvidno tudi iz izračunanih Spearmanovih koeficientov povezanosti (preglednica 146 v prilogi 11), kjer se ocene med seboj povezujejo s stopnjo vsaj $\pm 0,7$, večina celo prek $\pm 0,8$ in $\pm 0,9$. Povprečni delež enako klasificiranih celic pri gradnji drevesa s posameznimi podatkovnimi sloji (oznaka ODL(p)) ter delež enako klasificiranih celic pri gradnji drevesa z vsemi podatkovnimi sloji hkrati (oznaka ODL(s)) sta meri, ki se po izračunanem Pearsonovem in tudi Spearmanovem koeficientu z večino ostalih mer ne povezujeta statistično značilno ($p=0,01$). Pearsonov koeficient med informacijskim prispevkom in ostalimi načini vrednotenja znašajo od približno $\pm 0,7$ in več. Podobna stopnja povezanosti je izračunana tudi s Spearmanovim koeficientom. Povezanost med omenjenimi načini vrednotenja je opazna tudi ob prikazu grafikonov (slika 61).

Slika 61: Usklajenost različnih načinov vrednotenja tipizacij TIPI9.



Obrazložitev okrajšav: ODDP – delež enako klasificiranih celic po modelu diskriminancijske analize; DA – delež enako klasificiranih celic po diskriminancijski analizi; ODL(s) – delež enako klasificiranih celic z odločitvenim drevesom CT, narejenim z vsemi podatkovnimi sloji; ODL(p) – delež enako klasificiranih celic z odločitvenim drevesom CT, narejenim s posameznim podatkovnim slojem (povprečje vseh slojev); IG(p) – informacijski prispevek (povprečje vseh slojev); GR(p) – razmerje informacijskega prispevka (povprečje vseh slojev); E2(p) – koeficient η^2 (povprečje vseh slojev); F(p) – koeficient F (povprečje vseh slojev); PUKV(p) – povprečni umerjeni koeficient variacije (povprečje vseh slojev).

Na podlagi ujemanja večine mer lahko sklepamo, da lahko na podlagi izbranih podatkovnih slojev dokaj dosledno ovrednotimo uspešnost modeliranih tipizacij. Očitno je, da delež enako


klasificiranih celic po gradnji odločitvenega drevesa (z vsemi naenkrat ali pa posameznimi podatkovnimi sloji) ni ravno najboljši način vrednotenja, saj se z ostalimi načini vrednotenja ne ujema, kar se vidi tudi na grafih.

Po vrednotenju tipizacij (modeliranih in izvirne) se je zelo pogosto izkazala kot zelo dobra modelirana tipizacija po metodi najmanjše razdalje. Izvirna tipizacija je skoraj povsod pri dnu lestvice, kar je razumljivo, saj ni bila narejena računalniško na podlagi podatkovnih slojev, s katerimi smo tudi opravili vrednotenje. Izvirna tipizacija je v povprečju zelo dobro ovrednotena pri vrednotenju z deležem enako klasificiranih celic po odločitvenih drevesih, ki so izdelani s posameznimi podatkovnimi sloji.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja naklon

Pri primerjavi različnih načinov vrednotenja na podlagi podatkovnega sloja naklon opazimo, da je ujemanje med vsemi načini precejšnje tako po izračunu Pearsonovega koeficienta (preglednica 147 v prilogi 11) kot tudi po izračunu Spearmanovega koeficienta (preglednica 148 v prilogi 11). Najnižji izračunani Pearsonov koeficient znaša $\pm 0,725$, večina pa je višjih od $\pm 0,850$. Nižje vrednosti so le pri povezanostih, pri katerih je vključena primerjava z mero delež enako klasificiranih po odločitvenem drevesu. Podobne ugotovitve veljajo za izračun Spearmanovega koeficienta. Tudi iz grafikonov (slika 62) se lahko potrdi visoka stopnja izračunanih koeficientov.

Slika 62: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj naklon.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient eta²; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja padavinski režim

Pri primerjavi različnih načinov vrednotenja na podlagi podatkovnega sloja padavinski režim pridemo ob izračunu Pearsonovih koeficientov (preglednica 149 v prilogi 11) in Spearmanovih koeficientov (preglednica 150 v prilogi 11) do precej drugačnih zaključkov kot v prejšnjem primeru (naklon). To pomeni, da je izračunana izjemno visoka povezanost le med merami koeficient η^2 , koeficient F, povprečni umerjeni koeficient variacije ter povezanost med merama informacijski prispevek in razmerje informacijskega prispevka. Izmed ostalih primerjav različnih načinov vrednotenja je le nekaj takih, ki so statistično značilne (pri $p=0,05$), a redko presežejo vrednost $\pm 0,6$; takšna je povezanost med povprečnim umerjenim koeficientom variacije in razmerjem informacijskega prispevka. Za razliko od vrednotenja na podlagi naklona je tu ujemanje načinov vrednotenja precej slabše, kar dokazujejo tudi grafikoni (slika 63).

Slika 63: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj padavinski režim.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja prepustnost

Primerjava različnih načinov vrednotenja na podlagi podatkovnega sloja prepustnost je pokazala na visoko stopnjo povezanosti med večino različnih načinov vrednotenja, še posebej po izračunu Pearsonovega koeficienta (preglednica 151 v prilogi 11). Nekoliko nižje stopnje

povezanosti so le tiste z mero delež enako klasificiranih po modelu odločitvenega, to velja predvsem za izračun Spearmanovega koeficienta (preglednica 152 v prilogi 11). Povezanost je opazna tudi na grafikonih (slika 64).

Slika 64: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj prepustnost.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja višina

Tudi pri ugotavljanju usklajenosti različnih načinov vrednotenja na podlagi nadmorske višine se je izkazalo, da se način vrednotenja z deležem enako klasificiranih celic po modelu odločitvenega drevesa slabše povezuje z ostalimi načini vrednotenja. Med ostalimi je z izjemo ene kombinacije izračunana stopnja povezanosti po Pearsonovem koeficientu nad $\pm 0,7$ (preglednica 153 v prilogi 11), po izračunanem Spearmanovem koeficientu pa so vse povezanosti višje od $\pm 0,7$ (preglednica 154 v prilogi 11). Tudi z grafikonov je moč razbrati dokaj dobro povezanost med različnimi načini vrednotenja (slika 65).

Slika 65: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj nadmorska višina.



Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient eta²; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Po pregledu povezanosti oziroma usklajenosti različnih načinov vrednotenja (ocen/mer) na podlagi enega podatkovnega sloja smo prišli do nekaterih spoznanj:

- pri ocenjevanju na podlagi naklona, prepustnosti in nadmorske višine se ocene bolje ujemajo kot pri ocenjevanju na podlagi padavinskega režima,
- ocenjevanje na podlagi deleža enako klasificiranih celic z gradnjo odločitvenega drevesa je manj povezano z ostalimi načini vrednotenja.

Ti dejstvi opozarjata, da niso vsi načini vrednotenja dovolj dobro usklajeni med seboj, hkrati pa tudi to, da usklajenost ne velja za vse podatkovne sloje. To pomeni, da bi morali v praksi vsako vrednotenje rezultatov opraviti na več različnih načinov in z več različnimi podatkovnimi sloji (predvsem tistimi, ki so pomembni za predmet raziskave).

Po vrednotenju tipizacij se je v povprečju kot zelo dobra pogosto izkazala modelirana tipizacija po metodi najmanjše razdalje. Opazili smo tudi, da izvirna tipizacija ni povsod pri dnu lestvice, na primer po izračunanem koeficientu eta² za podatkovni sloj naklon, izračunanem razmerju informacijskega prispevka za podatkovni sloj prepustnost, izračunanem informacijskem prispevku za podatkovni sloj padavinski režim ...

8.3.2.2 Usklajenost različnih načinov vrednotenja modeliranih naravnopokrajinskih tipizacij TIPI13

Tako kot v prejšnjem primeru smo tudi za tipizacijo TIPI13 preverjali usklajenost različnih načinov vrednotenja tipizacij, ki upoštevajo vse podatkovne sloje, ter usklajenost različnih načinov vrednotenja tipizacij, ki upoštevajo posamezni podatkovni sloj.

Usklajenost različnih načinov vrednotenja s pomočjo vseh podatkovnih slojev hkrati


Izračunan Pearsonov koeficient stopnje povezanosti (preglednica 155 v prilogi 11) je višji od 0,8 (oziroma manjši od -0,8) za povezanosti med naslednjimi načini vrednotenja:

- oddaljenostjo od najbližjega centroida,
- delež enako klasificiranih po modelu diskriminančne analize,
- povprečni koeficient η^2 ,
- povprečni koeficient F,
- povprečni povprečni umerjeni koeficient variacije (povprečni PUKV).

Omenjeni načini vrednotenja dajejo torej zelo podobne ocene, kar je razvidno tudi iz izračunanih Spearmanovih koeficientov povezanosti (preglednica 156 v prilogi 11), kjer se ocene med seboj povezujejo s stopnjo vsaj $\pm 0,9$. Večina ostalih primerjav je pri izračunu obeh koeficientov statistično značilnih pri $p=0,05$ in različno visokih.

Povprečni delež enako klasificiranih celic pri gradnji drevesa z algoritmom CT s posameznimi podatkovnimi sloji (oznaka ODL(p)) ter delež enako klasificiranih celic po gradnji drevesa z vsemi podatkovnimi sloji hkrati (oznaka ODL(s)) sta načina vrednotenja, ki se po izračunanem Pearsonovem in tudi Spearmanovem koeficientu z večino ostalih načinov vrednotenja ne povezujeata zelo močno (v nekaterih primerih pri $p=0,05$ tudi nista statistično značilna). Povezanost med različnimi načini vrednotenja je prikazana tudi na grafikonih (slika 66).

Slika 66: Usklajenost različnih načinov vrednotenja tipizacij TIPI13.



Obrazložitev okrajšav: ODDP – delež enako klasificiranih celic po modelu diskriminančne analize; DA – delež enako klasificiranih celic po diskriminančni analizi; ODL(s) – delež enako klasificiranih celic z odločitvenim drevesom CT, narejenim z vsemi podatkovnimi sloji; ODL(p) – delež enako klasificiranih celic z odločitvenim drevesom CT, narejenim s posameznim podatkovnim slojem (povprečje vseh slojev); IG(p) – informacijski prispevek (povprečje vseh slojev); GR(p) – razmerje informacijskega prispevka (povprečje vseh slojev); E2(p) – koeficient η^2 (povprečje vseh slojev); F(p) – koeficient F (povprečje vseh slojev); PUKV(p) – povprečni umerjeni koeficient variacije (povprečje vseh slojev).


Ujemanje med merami je nekoliko manjše kot pri primerjavi vrednotenij tipizacije TIPI9. Na podlagi statistično značilnega ujemanja večine mer lahko sklepamo, da lahko na podlagi izbranih podatkovnih slojev dobro ovrednotimo tipizacije. Očitno pa je, da delež enako klasificiranih celic po gradnji odločitvenega drevesa (z vsemi naekrat ali pa posameznimi podatkovnimi sloji) ni najboljši način vrednotenja tudi v tem primeru, saj od ostalih načinov vrednotenja nekoliko odstopa. Povezanost med načini vrednotenja je opazna tudi ob prikazu grafikonov. Zelo dobro se povezujejo oddaljenost celice od najbližjega centroida, delež pravilno klasificiranih po modelu diskriminančne analize, povprečni koeficient η^2 , povprečni koeficient F in povprečni PUKV.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja naklon

Pri pregledu vrednotenij na podlagi podatkovnega sloja naklon opazimo, da je ujemanje med vsemi načini vrednotenja precejšnje tako po izračunu Pearsonovega koeficienta (preglednica

157 v prilogi 11) kot tudi po izračunu Spearmanovega koeficienta (preglednica 158 v prilogi 11). Najnižja absolutna vrednost Pearsonovega koeficienta znaša 0,662, večina pa je višjih od 0,8. Nižje vrednosti so le pri povezanostih, v katerih je vključena primerjava z mero delež pravilno klasificiranih po odločitvenem drevesu. Enaka ugotovitev (da delež pravilno klasificiranih celic po odločitvenem drevesu bolj odstopa od ostalih mer) velja tudi po pregledu izračunanih Spearmanovih koeficientov. Pregled grafikonov potrjuje visoko stopnjo izračunanih koeficientov (slika 67).

Slika 67: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj naklon.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja padavinski režim

Pri vrednotenju na podlagi podatkovnega sloja padavinski režim pridemo ob izračunu Pearsonovih koeficientov (preglednica 159 v prilogi 11) in Spearmanovih koeficientov (preglednica 160 v prilogi 11) do praktično enakih zaključkov. Izjemno visoka povezanost je prisotna med merami koeficient η^2 , koeficient F, povprečni umerjeni koeficient variacije ter med merama informacijski prispevek in razmerje informacijskega prispevka. Ostale povezanosti različnih mer imajo višje vrednosti kot v primeru TIPI9 in so vse statistično značilne (vsaj pri $p=0,05$). Najnižje stopnje povezanosti ima zopet vrednotenje z odločitvenim drevesom. Za razliko od vrednotenja na podlagi naklona je tu ujemanje načinov vrednotenja malce slabše, kar dokazujejo tudi grafikonu (slika 68).

Slika 68: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj padavinski režim.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja prepustnost

Usklajenost raznih načinov vrednotenja (slika 69) na podlagi podatkovnega sloja prepustnost kaže na visoko povezanost med večino načinov, še posebej po izračunu Pearsonovega koeficienta (preglednica 161 v prilogi 11). Nekoliko nižje stopnje povezanosti so le tiste z mero delež enako klasificiranih po odločitvenem drevesu, kar velja predvsem, če se osredotočimo na izračun Spearmanovega koeficienta (preglednica 162 v prilogi 11). Informacijski prispevek in razmerje informacijskega prispevka se z vrednotenjem po odločitvenem drevesu ne povezujeata statistično značilno ($p=0,05$).

Slika 69: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj prepustnost.




Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Usklajenost različnih načinov vrednotenja s pomočjo podatkovnega sloja nadmorska višina

Po primerjavi raznih načinov vrednotenja (slika 70) smo ugotovili, da so glede na izračunane Spearmanove koeficiente načini med seboj dobro usklajeni, kar dokazujejo visoke vrednosti tega koeficienta. Dokaj dobro povezanost se kaže tudi pri izračunu Pearsonovega koeficienta, kjer pa je vidno, da je zopet vrednotenje z odločitvenim drevesom manj usklajeno s preostalimi načini (preglednici 163 in 164 v prilogi 11). Vse povezanosti so sicer statistično značilne pri stopnji $p=0,05$.

Slika 70: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj nadmorska višina.



Obrazložitev okrajšav: ODL – delež enako klasificiranih celic z odločitvenim drevesom CT; IG – informacijski prispevek; GR – razmerje informacijskega prispevka; E2 – koeficient η^2 ; F – koeficient F; PUKV – povprečni umerjeni koeficient variacije.

Pri pregledu povezanosti oziroma usklajenosti različnih načinov vrednotenja na podlagi posameznega podatkovnega sloja smo opazili predvsem, da je vrednotenje na podlagi deleža enako klasificiranih celic po modelu odločitvenega drevesa manj povezano z ostalimi načini vrednotenja. Na splošno so vsi ostali načini precej bolj usklajeni, tudi če jih primerjamo z ujemanjem vrednotenja tipizacij TIPI9.

8.3.3 Vrednotenje modeliranih naravnopokrajinskih tipizacij s pomočjo izvirne naravnopokrajinske tipizacije

Pri prejšnjem načinu vrednotenja smo bili pozorni na to, kako dobro posamezna tipizacija ponazarja določen sklop podatkovnih slojev ali pa le posamezen podatkovni sloj. Vrednotenje smo izvedli za vsako modelirano in tudi izvirno tipizacijo.

Večina preverjanj klasifikacij primerja modelirano vrednost z resnično vrednostjo (Loveland, Merchant, 2004). V našem primeru smo za resnično vrednost določili izvirno tipizacijo. Pri tem pa je treba izpostaviti dejstvo, da je bila izvirna tipizacija narejena z določeno mero subjektivnosti. Subjektivnost pa otežuje primerjavo (Hazeu s sod., 2010).

V tem delu vrednotenja smo vsako posamezno modelirano tipizacijo primerjali z izvirno tipizacijo. To smo naredili tako, da smo preverili, koliko celic modelirane tipizacije je enako klasificiranih kot pri izvirni tipizaciji. Slednji izračun smo opravili dvakrat, enkrat vključujoč

vse celice, drugič pa samo učne celice. Poleg tega smo izračunali tudi povezanost med izvirno in vsako modelirano tipizacijo s Cramerjevim koeficientom in koeficientom kappa.

8.3.3.1 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI9

Pri pregledu enako klasificiranih učnih celic je opazno, da se učne celice po ekspertnem vzorcu učnih celic z izvirno tipizacijo v povprečju ujemajo kar 91 %, po nekaterih metodah se celice znotraj posameznega tipa ujemajo tudi do 99 %. Pri naključnem vzorcu učnih celic je ujemanje klasifikacije učnih celic slabše za približno 20 %, le trije tipi se v povprečju ujemajo za več kot 80 % z izvirnim stanjem. To kaže na to, da se po ekspertnem naboru učnih celic tipi lažje ločijo med seboj oziroma so vzorci tipov bolj homogeni in so modeli lahko zato bolj natančni (preglednica 82).

Ko izdelani model oziroma pravilo uporabimo za izdelavo tipizacije celotne Slovenije, se stopnja ujemanja pri ekspertnem vzorčenju precej zniža (v povprečju na 56 %) in je celo nižja kot pri modeliranju z naključnim vzorčenjem, ki znaša v povprečju 66 %! Iz tega lahko sklenemo, da so izdelani modeli po ekspertnem vzorčenju bolj (oziroma glede na rezultate vseh celic celo preveč) prilagojeni učnim celicam. Pri naključnem vzorčenju zajamemo namreč večjo variabilnost tipa in težje izdelamo »čista« klasifikacijska pravila ali pa spektralne podpise, a končno ujemanje z izvirno tipizacijo je še vedno večje (preglednica 83). Izmed učnih celic iz ekspertnega vzorca se z izvirno tipizacijo v povprečju najbolj ujemajo tipi: panonske ravnine (oznaka 2.2), dinarske planote (3.1), sredozemska gričevja (4.1), panonska gričevja (2.1) in sredozemske planote (4.2).

Izmed učnih celic iz naključnega vzorca se z izvirno tipizacijo v povprečju najbolj ujemajo tipi: panonske ravnine (2.2), sredozemska gričevja (4.1), sredozemske planote (4.2), alpske ravnine (1.3) in panonska gričevja (2.1).

Če upoštevamo vse celice, se pri ekspertnem vzorčenju v povprečju najbolj ujemajo tipi: panonske ravnine (2.2), sredozemske planote (4.2), sredozemska gričevja (4.1), alpske ravnine (1.3) in panonska gričevja (2.1).

Pri naključnem vzorčenju se najbolj ujemajo tipi: panonske ravnine (2.2), sredozemska gričevja (4.1), sredozemske planote (4.2), alpske ravnine (1.3), panonska gričevja (2.1).

Ob pregledu ujemanja celic je opazno, da gre za boljše ujemanje pri tistih tipih, ki so zaradi večjih ravnin bolj homogeni (alpske ravnine, panonske ravnine), prav tako je opazno, da gre za tipe, ki so na skrajnem jugozahodu (sredozemska gričevja in sredozemske planote) in skrajnem severovzhodu države (panonske ravnine in panonska gričevja). Večje je ujemanje pri tipih, ki so po površini manjši (preglednici 52 in 58), saj smo za izdelavo modelov in spektralnih podpisov vzeli enako število celic ne glede na velikost tipa. Manjše ujemanje je pri alpskih gorovjih, alpskih hribovjih, dinarskih podoljih in ravninah ter tudi pri dinarskih planotah. Sklepamo, da je zaradi velike površine teh tipov ujemanje manjše tudi zaradi tega, ker smo z učnimi celicami zajeli manjši delež. Poleg tega je razlog tudi v veliki heterogenosti omenjenih tipov – znotraj alpskega gorovja je poleg gorovja tudi precej dolin in planot, znotraj alpskih hribovij pa je tudi ogromno dolin. Vsi ti tipi so v osrednjem delu Slovenije, ki je tudi s podnebne vidika precej bolj prehodno kot pa skrajni zahodni in vzhodni deli države.

Pri primerjavi učnih celic v izvirni in modeliranih tipizacijah opazamo tudi razlike med modeliranimi tipizacijami. Opazneje z manjšim ujemanjem izstopata tipizaciji po metodah najmanjše razdalje in največje verjetnosti (velja za klasifikacije po ekspertnem in tudi po naključnem izboru učnih celic). Ta dva načina sta se pri vrednotenju z vidika podatkovnih slojev pogosto znašla pri vrhu, hkrati pa je bila izvirna tipizacija bolj pri dnu. Zaradi tega je večje odstopanje teh tipizacij od izvirne razumljivo. Obe metodi očitno bolj izrazito vsiljujeta svojo strukturo kot pa ostale metode, ki se bolj prilagajajo učnim celicam.

Glede na vse celice je ujemanje z izvornikom pri modeliranih tipizacijah z ekspertnim naborom po večini metod dokaj različno – vrednosti so med 51 in 61 %, najnižja vrednost velja za modelirano tipizacijo po metodi najmanjše razdalje, najvišja pa za modelirano tipizacijo po metodi najbližjega soseda. Pri naključnem naboru so razlike med modeliranimi tipizacijami večje in se gibljejo med 51 % (po metodi najmanjše razdalje) in 75 % (po metodi najbližjih sosedov) (preglednica 83).

Preglednica 82: Delež pravilno klasificiranih učnih celic za modelirane tipizacije TIPI9.

metoda	delež (%)										učne celice
	1.1	1.2	1.3	2.1	2.2	3.1	3.2	4.1	4.2	skupaj	
odločitveno drevo CT	89	92	99	92	99	96	92	95	97	94	ekspertne
odločitveno drevo CTE	96	93	98	96	99	97	98	99	95	97	
odločitveno drevo CTG	95	95	99	97	99	98	97	97	95	97	
odločitveno drevo CTR	96	91	99	96	99	98	98	96	94	96	
metoda <i>k</i> najbližjih sosedov	95	95	99	97	100	99	96	97	98	97	
metoda najmanjše razdalje	69	62	59	85	80	86	38	87	84	72	
metoda največje verjetnosti	86	80	69	93	95	95	79	92	89	86	
povprečje	89	87	89	94	96	96	85	95	93	91	
odločitveno drevo CT	69	66	78	76	92	59	69	84	83	75	naključne
odločitveno drevo CTE	63	68	77	88	84	52	74	84	66	73	
odločitveno drevo CTG	65	67	80	79	92	55	63	84	83	74	
odločitveno drevo CTR	62	66	74	81	88	62	49	90	87	73	
metoda <i>k</i> najbližjih sosedov	76	72	83	83	92	63	73	88	87	80	
metoda najmanjše razdalje	55	64	67	35	82	35	13	71	77	55	
metoda največje verjetnosti	62	59	70	68	94	47	42	80	83	67	
povprečje	65	66	76	73	89	53	55	83	81	71	

Preglednica 83: Delež pravilno klasificiranih vseh celic za modelirane tipizacije TIPI9.

metoda	delež (%)										učne celice
	1.1	1.2	1.3	2.1	2.2	3.1	3.2	4.1	4.2	skupaj	
odločitveno drevo CT	51	44	66	55	87	47	54	70	91	55	ekspertne
odločitveno drevo CTE	59	51	64	68	87	37	65	74	81	58	
odločitveno drevo CTG	55	41	66	63	87	48	62	76	81	57	
odločitveno drevo CTR	54	32	66	65	88	48	60	69	77	54	
metoda <i>k</i> najbližjih sosedov	53	63	66	66	75	47	60	78	90	61	
metoda najmanjše razdalje	42	47	62	62	78	45	24	72	83	51	
metoda največje verjetnosti	58	58	64	72	80	43	48	71	74	59	
povprečje	53	48	65	64	83	45	53	73	82	56	
odločitveno drevo CT	70	63	77	76	91	57	67	84	84	69	naključne
odločitveno drevo CTE	63	65	76	88	83	52	71	84	67	69	
odločitveno drevo CTG	66	64	79	78	91	54	62	84	84	68	
odločitveno drevo CTR	62	63	73	81	88	61	48	90	88	68	
metoda <i>k</i> najbližjih sosedov	75	71	82	83	92	65	70	88	87	75	
metoda najmanjše razdalje	56	63	67	36	83	36	13	72	77	51	
metoda največje verjetnosti	64	58	69	70	94	49	42	81	84	62	
povprečje	65	64	75	73	89	53	53	83	82	66	

Tudi analiza povezanosti med posameznimi modeliranimi tipizacijami in izvorno tipizacijo s Cramerjevim koeficientom ter koeficientom kappa (preglednica 84) daje zelo podobne rezultate kot delež pravilno klasificiranih vseh celic. Pearsonov in Spearmanov koeficient povezanosti teh lestvic znašata v vseh primerih več kot 0,99 pri $p=0,001$. Na ta način smo vrednotenje s pomočjo izvorne tipizacije potrdili na tri načine, ki se dobro ujemajo med seboj.

Preglednica 84: Cramerjev koeficient povezanosti ter koeficient kappa za primerjavo med izvorno tipizacijo in posamično modelirano tipizacijo. Vsi izračunani koeficienti so statistično značilni pri $p=0,001$.

metoda	Cramerjev koeficient	koeficient kappa (%)	delež (%) enako klasificiranih (upoštevane vse celice)	učne celice
odločitveno drevo CT	0,558	48	55	ekspertne
odločitveno drevo CTE	0,577	52	58	
odločitveno drevo CTG	0,570	50	57	
odločitveno drevo CTR	0,558	47	54	
metoda k najbližjih sosedov	0,602	55	61	
metoda najmanjše razdalje	0,515	44	51	
metoda največje verjetnosti	0,579	53	59	
odločitveno drevo CT	0,676	65	69	naključne
odločitveno drevo CTE	0,671	64	69	
odločitveno drevo CTG	0,668	63	68	
odločitveno drevo CTR	0,659	63	68	
metoda k najbližjih sosedov	0,726	71	75	
metoda najmanjše razdalje	0,502	43	51	
metoda največje verjetnosti	0,605	57	62	

8.3.3.2 Vrednotenje modeliranih naravnopokrajinskih tipizacij TIPI13

Pri pregledu pravilno klasificiranih učnih celic je opazno, da se učne celice po ekspertnem naboru z izvorno tipizacijo ujemajo v povprečju 84 %, po nekaterih metodah se posamezni tipi ujemajo tudi prek 90 %. Z manjšo natančnostjo izstopa ujemanje po modelih z metodo najmanjše razdalje (46 %) in največje verjetnosti (76 %). Pri naključnem izboru učnih celic je povprečno ujemanje učnih celic slabše za 20 %. Po večini metod je ujemanje modeliranih tipizacij z izvorno tipizacijo med 65 in 75 %, zopet izstopata metodi najmanjše razdalje (43 %) in največje verjetnosti (60 %) (preglednica 85).

Ko izdelani model oziroma pravilo uporabimo za izdelavo tipizacije celotne Slovenije in primerjamo ujemanje vseh celic, pride do spremembe. Stopnja ujemanja pri modeliranih tipizacijah z ekspertnem vzorcem učnih celic se v povprečju precej zniža (na 51 %) in je celo nižja kot pri naključnem vzorčenju učnih celic, ki znaša v povprečju 59 % (preglednica 86). Iz tega lahko sklenemo, da so izdelani modeli po ekspertnem vzorcu učnih celic bolj (oziroma glede na rezultate vseh celic celo preveč) prilagojeni učnim celicam oziroma so celice izbrane tako, da se med seboj tipi bolj razlikujejo. Pri naključnem vzorčenju zajamemo namreč večjo variabilnost tipa in težje izdelamo klasifikacijska pravila ali pa spektralne podpise, a ti so zato bolj splošni in pri primerjavi modelirane in izvorne tipizacije v celoti (torej z vsemi celicami) dobimo večje ujemanje.

Izmed učnih celic iz ekspertnega vzorca se z izvorno tipizacijo v povprečju najbolj ujemajo tipi: gričevja v notranjem delu Slovenije (oznaka 6), ravnine in širše doline v gričevju notranjega dela Slovenije (7), Kras in Podgorski kras (11), gričevja v primorskem delu Slovenije (12); vsi imajo vrednosti nad 90 %.

Izmed učnih celic iz naključnega vzorca se z izvorno tipizacijo v povprečju najbolj ujemajo tipi: ravnine in širše doline v gričevju notranjega dela Slovenije (7), nizki kras Bele krajine (10) ter Kras in Podgorski kras (11) (vsi nad 80 %), pa tudi gričevja v notranjem delu Slovenije (6), gričevja v primorskem delu Slovenije (12) in visokogorski svet (1); vsi nad 70 %.

Če upoštevamo vse celice, se pri ekspertnem vzorčenju v povprečju najbolj ujemajo tipi ravnine in širše doline v gričevju notranjega dela Slovenije (7), nizki kras Bele krajine (10), Kras in Podgorski kras (11), gričevja v primorskem delu Slovenije (12) (vsi nad 70 %).

Pri naključnem vzorčenju se najbolj ujemajo tipi visokogorski svet (1), gričevja v notranjem delu Slovenije (6), ravnine in širše doline v gričevju notranjega dela Slovenije (7), nizki kras Bele krajine (10), Kras in Podgorski kras (11) ter gričevje v primorskem delu Slovenije (12) (vsi nad 70 %).

Ob pregledu ujemanja celic je opazno, da gre za gričevnate ali ravninske tipe, ki so na vzhodu države (gričevja v notranjem delu Slovenije, ravnine in širše doline v gričevju notranjega dela Slovenije, nizki kras Bele krajine) ter za nekatere tipe na skrajnem jugozahodu države (Kras in Podgorski kras, gričevje v primorskem delu Slovenije). Nekateri vzroki za visoko ujemanje teh tipov so najbrž: lega v podnebno manj prehodnem območju, večji delež ravnin in visok delež učnih celic v primerjavi s celotno površino tipa (preglednici 55 in 61). Opazna je tudi dokaj visoka stopnja ujemanja celic znotraj tipa visokogorski svet; večja stopnja ujemanja je med drugim tudi posledica tega, da so izločene planote (na primer Jelovica, Pokljuka) in večje alpske doline (na primer dolina Soče, Save Dolinke).

Glede na vse celice (preglednica 86) je ujemanje z izvornikom pri modeliranih tipizacijah z ekspertnim naborom po večini metod zelo podobno – vrednosti so med 51 in 53 %, odstopa le tipizacija po metodi najmanjše razdalje, kjer je ujemanje le 43 %. Pri naključnem naboru so razlike med tipizacijami večje in se gibljejo med 47 % (za metodo najmanjše razdalje) in 69 % (metoda najbližjih sosedov).

Opazneje z manjšim ujemanjem izstopata tipizaciji po metodah najmanjše razdalje in največje verjetnosti (izjema: pri primerjavi vseh celic po ekspertnem naboru učnih celic je modelirana tipizacija po metodi največje verjetnosti celo rahlo boljša od ostalih). Ta dva načina sta se pri vrednotenju z vidika pojasnjevanja podatkovnih slojev pogosto znašla pri vrhu, hkrati pa je bila izvirna tipizacija bolj pri dnu. Zaradi tega je večje odstopanje teh klasifikacij od izvirne pričakovano (preglednici 85 in 86).

Preglednica 85: Delež pravilno klasificiranih učnih celic (ekspertni in naključni nabor) TIPI13.

metoda	delež (%)													skupaj	učne celice
	1	2	3	4	5	6	7	8	9	10	11	12	13		
odločitveno drevo CT	95	78	91	90	94	97	95	91	91	98	94	89	89	92	ekspertne
odločitveno drevo CTE	96	89	94	92	97	99	98	92	94	98	95	94	93	95	
odločitveno drevo CTG	96	84	97	92	95	97	97	92	95	98	95	90	95	94	
odločitveno drevo CTR	95	82	98	89	93	98	98	95	93	98	94	91	95	94	
metoda <i>k</i> najbližjih sosedov	94	85	98	94	94	99	97	95	92	97	95	92	93	94	
metoda najmanjše razdalje	59	12	60	70	18	76	70	13	21	11	85	92	05	46	
metoda največje verjetnosti	71	29	82	72	52	88	88	71	66	96	91	87	91	76	
povprečje	86	66	89	85	78	93	92	78	79	85	93	91	80	84	
odločitveno drevo CT	77	40	52	55	59	80	82	75	53	87	83	69	80	69	naključne
odločitveno drevo CTE	78	29	49	32	62	83	74	74	49	88	82	78	78	66	
odločitveno drevo CTG	83	30	50	39	58	82	78	72	61	87	80	77	76	67	
odločitveno drevo CTR	70	37	46	34	61	81	78	79	54	90	81	78	76	66	
metoda <i>k</i> najbližjih sosedov	83	51	59	63	71	83	85	76	67	91	88	77	79	75	
metoda najmanjše razdalje	68	06	36	56	42	46	81	28	10	28	80	84	00	43	
metoda največje verjetnosti	74	20	46	47	55	58	85	49	34	90	80	72	72	60	
povprečje	76	30	48	47	58	73	80	65	47	80	82	76	66	64	

Preglednica 86: Delež pravilno klasificiranih vseh celic TIPI13.

metoda	delež (%)														učne celice
	1	2	3	4	5	6	7	8	9	10	11	12	13	skupaj	
odločitveno drevo CT	69	34	40	39	53	52	79	42	68	86	78	66	72	52	ekspertne
odločitveno drevo CTE	71	36	43	40	50	56	69	45	52	85	67	73	78	52	
odločitveno drevo CTG	65	36	46	39	54	51	78	46	55	86	70	66	82	52	
odločitveno drevo CTR	71	32	46	27	48	58	67	54	63	85	81	69	77	51	
metoda <i>k</i> najbližjih sosedov	71	34	36	39	51	61	64	57	59	86	79	73	78	52	
metoda najmanjše razdalje	60	8	33	40	32	58	74	11	13	9	80	85	3	43	
metoda največje verjetnosti	62	16	36	49	54	57	82	49	52	85	71	73	66	53	
povprečje	67	28	40	39	49	56	73	43	52	75	75	72	65	51	
odločitveno drevo CT	76	38	50	53	58	79	80	72	51	87	82	69	79	63	naključne
odločitveno drevo CTE	77	28	48	31	60	82	73	72	49	88	80	77	77	58	
odločitveno drevo CTG	81	29	49	38	58	80	77	70	62	88	79	77	75	60	
odločitveno drevo CTR	69	36	44	33	60	80	76	77	53	90	80	78	76	58	
metoda <i>k</i> najbližjih sosedov	82	48	57	60	69	80	83	74	64	91	86	77	78	69	
metoda najmanjše razdalje	68	6	37	54	42	46	80	27	10	27	80	85	0	47	
metoda največje verjetnosti	74	20	46	47	55	59	85	48	36	89	80	73	71	55	
povprečje	75	29	47	45	58	72	79	63	46	80	81	77	65	59	

Usklajenost med vsako modelirano tipizacijo in izvorno tipizacijo smo analizirali tudi s Cramerjevim koeficientom povezanosti in koeficientom kappa (preglednica 87) in dobili podobno razvrstitev kot pri primerjavi deležev ujemanj vseh celic med modelirano in izvorno tipizacijo. Med vsemi tremi načini vrednotenja so ugotovljene zelo visoke stopnje povezanosti (vsi Pearsonovi in Spearmanovi koeficienti so višji od 0,9 pri $p=0,001$).

Preglednica 87: Cramerjev koeficient povezanosti ter koeficient kappa za primerjavo med izvorno tipizacijo in posamezno modelirano tipizacijo. Vsi izračunani koeficienti so statistično značilni pri $p=0,001$.

modelirana tipizacija	Cramerjev koeficient	koeficient kappa	delež enako klasificiranih (upoštevane vse celice)	učne celice
odločitveno drevo CT	0,547	47	52	ekspertne
odločitveno drevo CTE	0,528	47	52	
odločitveno drevo CTG	0,542	47	52	
odločitveno drevo CTR	0,535	45	51	
metoda <i>k</i> najbližjih sosedov	0,554	46	52	
metoda najmanjše razdalje	0,429	36	43	
metoda največje verjetnosti	0,555	47	53	
odločitveno drevo CT	0,619	58	63	
odločitveno drevo CTE	0,586	53	58	
odločitveno drevo CTG	0,599	55	60	
odločitveno drevo CTR	0,593	53	58	
metoda <i>k</i> najbližjih sosedov	0,672	65	69	
metoda najmanjše razdalje	0,441	40	47	
metoda največje verjetnosti	0,550	50	55	

8.4 Usklajenost različnih modeliranih naravnopokrajinskih tipizacij med seboj

Po vrednotenju modeliranih tipizacij s pomočjo izbranih podatkovnih slojev ter izvorne tipizacije smo preverili, kako močno se ujemajo tudi modelirane tipizacije med seboj. Za to smo za vsak par modeliranih tipizacij izračunali Cramerjev koeficient *V* in koeficient kappa (preglednice 88–91).

8.4.1 Usklajenost modeliranih naravnopokrajinskih tipizacij TIPI9

Opazno je, da se posamezne modelirane tipizacije med seboj kar razlikujejo. To pomeni, da so lahko kljub podobnemu ujemanju z izvorno klasifikacijo ali pa podobni oceni glede podatkovnih slojev modelirane tipizacije med seboj precej različne. Pri modeliranih tipizacijah TIPI9 Cramerjev koeficient le v dveh primerih dosega višino 0,9 oziroma koeficient kappa več kot 90 % (preglednici 88 in 89).

Preglednica 88: Cramerjev koeficient povezanosti za pare modeliranih tipizacij TIPI9 (p=0,001).

	(E) CT	(E) CTE	(E) CTG	(E) CTR	(E) KNN	(E) MXL	(E) MDS	(N) CT	(N) CTE	(N) CTG	(N) CTR	(N) KNN	(N) MXL	(N) MDS
(E) CT	1,00	0,71	0,91	0,79	0,64	0,60	0,55	0,64	0,62	0,65	0,65	0,63	0,59	0,51
(E) CTE		1,00	0,76	0,76	0,68	0,65	0,56	0,66	0,64	0,66	0,66	0,66	0,66	0,54
(E) CTG			1,00	0,81	0,67	0,61	0,54	0,64	0,64	0,65	0,65	0,65	0,61	0,51
(E) CTR				1,00	0,66	0,63	0,55	0,63	0,63	0,64	0,64	0,63	0,62	0,52
(E) KNN					1,00	0,68	0,61	0,65	0,65	0,66	0,65	0,71	0,65	0,57
(E) MXL						1,00	0,64	0,64	0,66	0,64	0,64	0,66	0,74	0,60
(E) MDS							1,00	0,57	0,57	0,57	0,58	0,60	0,67	0,80
(N) CT								1,00	0,80	0,92	0,79	0,77	0,67	0,55
(N) CTE									1,00	0,82	0,78	0,75	0,67	0,56
(N) CTG										1,00	0,81	0,76	0,66	0,55
(N) CTR											1,00	0,75	0,66	0,56
(N) KNN												1,00	0,70	0,57
(N) MXL													1,00	0,67
(N) MDS														1,00

CT – odločitveno drevo CT, CTE – odločitveno drevo CTE, CTG – odločitveno drevo CTG, CTR – odločitveno drevo CTR, KNN – metoda k najbližjih sosedov, MDS – metoda najmanjše razdalje, MXL – metoda največje verjetnosti; (E) pomeni modelirana tipizacija na podlagi ekspertnega vzorca učnih celic, (N) pomeni modelirana tipizacija na podlagi naključnega vzorca učnih celic.

Preglednica 89: Koeficient kappa (%) za pare modeliranih tipizacij TIPI9 (p=0,001).

	(E) CT	(E) CTE	(E) CTG	(E) CTR	(E) KNN	(E) MXL	(E) MDS	(N) CT	(N) CTE	(N) CTG	(N) CTR	(N) KNN	(N) MXL	(N) MDS
(E) CT	100	68	90	78	60	55	48	58	55	60	59	57	52	40
(E) CTE		100	72	71	64	62	50	62	60	62	61	61	62	45
(E) CTG			100	80	62	56	47	59	58	60	59	60	54	39
(E) CTR				100	59	57	50	57	55	57	56	56	53	40
(E) KNN					100	65	55	60	60	61	60	67	60	46
(E) MXL						100	59	61	62	60	61	63	72	52
(E) MDS							100	50	50	51	52	54	63	75
(N) CT								100	78	91	77	74	65	48
(N) CTE									100	80	76	73	64	47
(N) CTG										100	80	74	64	48
(N) CTR											100	73	64	48
(N) KNN												100	68	51
(N) MXL													100	62
(N) MDS														100

CT – odločitveno drevo CT, CTE – odločitveno drevo CTE, CTG – odločitveno drevo CTG, CTR – odločitveno drevo CTR, KNN – metoda k najbližjih sosedov, MDS – metoda najmanjše razdalje, MXL – metoda največje verjetnosti; (E) pomeni modelirana tipizacija na podlagi ekspertnega vzorca učnih celic, (N) pomeni modelirana tipizacija na podlagi naključnega vzorca učnih celic.

8.4.2 Usklajenost modeliranih naravnopokrajinskih tipizacij TIPI13

Posamezne modelirane tipizacije TIPI13 se med seboj razlikujejo. To pomeni, da so lahko kljub podobnemu ujemanju z izvorno tipizacijo ali pa podobni oceni glede podatkovnih slojev modelirane tipizacije med seboj precej različne. Cramerjev koeficient le v dveh primerih dosega višino 0,8 oziroma vrednost koeficient kappa več kot 80 % (preglednici 90 in 91).

Preglednica 90: Cramerjev koeficient povezanosti za pare modeliranih tipizacij TIPI13 (p=0,001).

	(E) CT	(E) CTE	(E) CTG	(E) CTR	(E) KNN	(E) MXL	(E) MDS	(N) CT	(N) CTE	(N) CTG	(N) CTR	(N) KNN	(N) MXL	(N) MDS
(E) CT	1,00	0,73	0,889	0,73	0,64	0,62	0,47	0,62	0,62	0,63	0,63	0,63	0,59	0,47
(E) CTE		1,00	0,79	0,74	0,65	0,58	0,46	0,59	0,58	0,58	0,60	0,60	0,56	0,46
(E) CTG			1,00	0,71	0,66	0,60	0,46	0,60	0,59	0,60	0,62	0,61	0,58	0,46

(E) CTR				1,00	0,641	0,58	0,47	0,59	0,59	0,60	0,62	0,61	0,57	0,47
(E) KNN					1,00	0,63	0,49	0,61	0,59	0,60	0,61	0,66	0,60	0,48
(E) MXL						1,00	0,54	0,62	0,60	0,61	0,62	0,64	0,74	0,53
(E) MDS							1,00	0,50	0,46	0,48	0,49	0,494	0,58	0,73
(N) CT								1,00	0,72	0,79	0,71	0,71	0,64	0,50
(N) CTE									1,00	0,82	0,75	0,67	0,61	0,48
(N) CTG										1,00	0,76	0,70	0,63	0,49
(N) CTR											1,00	0,69	0,63	0,49
(N) KNN												1,00	0,65	0,51
(N) MXL													1,00	0,59
(N) MDS														1,00

CT – odločitveno drevo CT, CTE – odločitveno drevo CTE, CTG – odločitveno drevo CTG, CTR – odločitveno drevo CTR, KNN – metoda k najbližjih sosedov, MDS – metoda najmanjše razdalje, MXL – metoda največje verjetnosti; (E) pomeni modelirana tipizacija na podlagi ekspertnega vzorca učnih celic, (N) pomeni modelirana tipizacija na podlagi naključnega vzorca učnih celic.

Preglednica 91: Koefficient kappa (%) povezanosti za pare modeliranih tipizacij TIPI13 ($p=0,001$).

	(E) CT	(E) CTE	(E) CTG	(E) CTR	(E) KNN	(E) MXL	(E) MDS	(N) CT	(N) CTE	(N) CTG	(N) CTR	(N) KNN	(N) MXL	(N) MDS
(E) CT	100	71	88	71	59	56	41	54	53	57	54	56	51	41
(E) CTE		100	79	72	61	53	38	52	48	51	53	55	49	39
(E) CTG			100	69	61	55	40	53	49	52	54	55	51	40
(E) CTR				100	61	51	39	50	49	51	53	54	48	38
(E) KNN					100	57	43	52	48	50	52	57	50	39
(E) MXL						100	50	54	50	54	53	57	69	47
(E) MDS							100	42	39	41	41	43	54	67
(N) CT								100	69	79	68	70	61	45
(N) CTE									100	80	71	62	55	41
(N) CTG										100	72	67	58	43
(N) CTR											100	63	58	42
(N) KNN												100	63	48
(N) MXL													100	58
(N) MDS														100

CT – odločitveno drevo CT, CTE – odločitveno drevo CTE, CTG – odločitveno drevo CTG, CTR – odločitveno drevo CTR, KNN – metoda k najbližjih sosedov, MDS – metoda najmanjše razdalje, MXL – metoda največje verjetnosti; (E) pomeni modelirana tipizacija na podlagi ekspertnega vzorca učnih celic, (N) pomeni modelirana tipizacija na podlagi naključnega vzorca učnih celic.

8.5 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvorno naravnopokrajinsko tipizacijo

Poleg tega, da smo analizirali usklajenost med vsako posamezno modelirano tipizacijo in izvorno tipizacijo (delež celic, ki so enako klasificirane), smo nato primerjali še ujemanje vseh modeliranih tipizacij hkrati z izvorno tipizacijo in tako ugotovili, kje so tista območja posameznega tipa, ki smo jih potrdili z vsemi uporabljenimi metodami nadzorovanih klasifikacij, in kje so območja, ki jih nismo uspeli potrditi z nobeno metodo. Ta del je pomemben za analizo druge hipoteze.

8.5.1 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvorno naravnopokrajinsko tipizacijo TIPI9

8.5.1.1 Ujemanje vseh modeliranih z izvorno naravnopokrajinsko tipizacijo

Pri prvem prekrivanju smo dobili za modelirane tipizacije, izdelane z naključnim vzorcem učnih celic, in za modelirane tipizacije, izdelane z ekspertnim vzorcem učnih celic, po en zemljevid, ki prikazuje celice, ki so bile z vsako metodo klasificirane enako kot pri izvorni tipizaciji (preglednica 92, sliki 71 in 72). Ob koncu poglavja smo prikazali tudi celice, ki so klasificirane enako kot v izvorni tipizaciji po vseh metodah z obema vzorcema učnih celic (slika 73).

Kot smo že v prejšnjem poglavju omenili, je opazno dejstvo, da je izvorna tipizacija bolj potrjena z naključnim vzorcem učnih celic; 36,6 % vseh celic je z vsako uporabljeno metodo

enako klasificiranih kot v izvorni tipizaciji. Pri ekspertnem vzorčenju je celic, ki so z vsemi metodami enako klasificirane, manj, in sicer 28,1 %. Glede na posamezne tipe je opazno, da se celice tipov, ki zajemajo manjše površine, bolj ujemajo s celicami izvorne tipizacije, vendar to ne velja vedno (na primer dinarska podolja in ravniki so precej manjši po površini kot pa alpska hribovja, a se po modeliranih tipizacijah v naključnem in ekspertnem primeru slabše ujemajo z izvorno tipizacijo).

Pri obeh načinih vzorčenja (naključnem in ekspertnem) je opazno, da so pri primerjavi s pravilno klasificiranimi celicami med boljšimi rezultati ravninski tipi³⁰. Pri naključnem so med prvimi štirimi kar trije, ki imajo povprečen naklon manjši od 10°; poleg sredozemskih gričevij so še alpske ravnine, panonske ravnine in sredozemske planote. Pri ekspertnem vzorčenju so med prvimi petimi štirje taki tipi; poleg omenjenih še panonska gričevja.

Preglednica 92: Delež celic, ki se po vseh modelih ujemajo z izvorno tipizacijo TIPI9.

oznaka tipa	vse celice v tipu	delež (%) vedno pravilno klasificiranih celic glede na izvorno tipizacijo od vseh celic v tipu izvorne tipizacije (naključni izbor učnih območij)	delež (%) vedno pravilno klasificiranih celic glede na izvorno tipizacijo od vseh celic v tipu izvorne tipizacije (ekspertni izbor učnih območij)
1.1	76.533	45,1	30,4
1.2	116.478	36,3	13,9
1.3	20.481	52,8	36,3
2.1	74.719	32,4	35,3
2.2	32.336	71,1	54,7
3.1	95.190	23,1	23,5
3.2	47.387	4,2	12,6
4.1	26.490	65,2	50,1
4.2	16.836	55,0	58,1
skupaj	506.450	36,6	28,1

Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvorno tipizacijo TIPI9

Vsi modeli so potrdili tip **alpsko gorovje (1.1)** na območju grebenov z višjo nadmorsko višino Julijskih Alp, Kamniško-Savinjskih Alp in Karavank ter Menine planine, Pece, Olševe, opazno je tudi, da vmesne doline večinoma niso potrjene (na primer doline zgornje Soče, Save Dolinke, Save Bohinjke, Savinje, doline Kot, Krma, Vrata, Planica).

Vsi modeli so potrdili tip **alpskega hribovja (1.2)** na območju Pohorja (z izjemo vršnega dela okoli Rogle), Kozjaka, Strojne ter posamezni deli Posavskega, Škofjeloškega in Polhograjskega hribovja. Doline večjih rek, kot so Drava, Mislinja, Sava, Savinja, Meža, so izvzete.

Modeli so tip **alpskih ravnin (1.3)** potrdili praktično samo v Ljubljanski kotlini, kjer pa so izvzeti hriboviti deli med Medvodami, Mostami, Domžalami in Ljubljano (na primer Šmarna gora, Rašica), Tunjiško gričevje, Udin boršt ter območje med Brezjami in Tržičem, kjer je relief bolj razgiban. V Celjski kotlini je potrjenih le nekaj celic na zahodnem robu.

Tip **panonskih gričevij (2.1)** je bil potrjen v veliki meri na Goričkem, v Lendavskih goricah, Slovenskih goricah, kjer so vidno izvzeti dolinski deli, v okolici Šentjurja, Rogaške Slatine ter manjših zaplatah v Krškem gričevju. Skoraj v celoti so izvzete Haloze, Dravinjske gorice, Kozjansko in Bizeljsko ter južno obrobje Pohorja.

Tip **panonskih ravnin (2.2)** je skoraj v celoti potrjen na območju Dravske in Murske ravni, a le delno na območju Krške ravni (med Šentjernejem in Krškim).

³⁰ Po povprečnem naklonu si tipi sledijo takole: panonske ravnine (0,9°), alpske ravnine (4,3°), dinarska podolja in ravniki (7,2°), sredozemske planote (8,5°), panonska gričevja (9,9°), sredozemska gričevja (12,2°), dinarske planote (14,8°), alpska hribovja (18,4°) in alpska gorovja (25,8°).

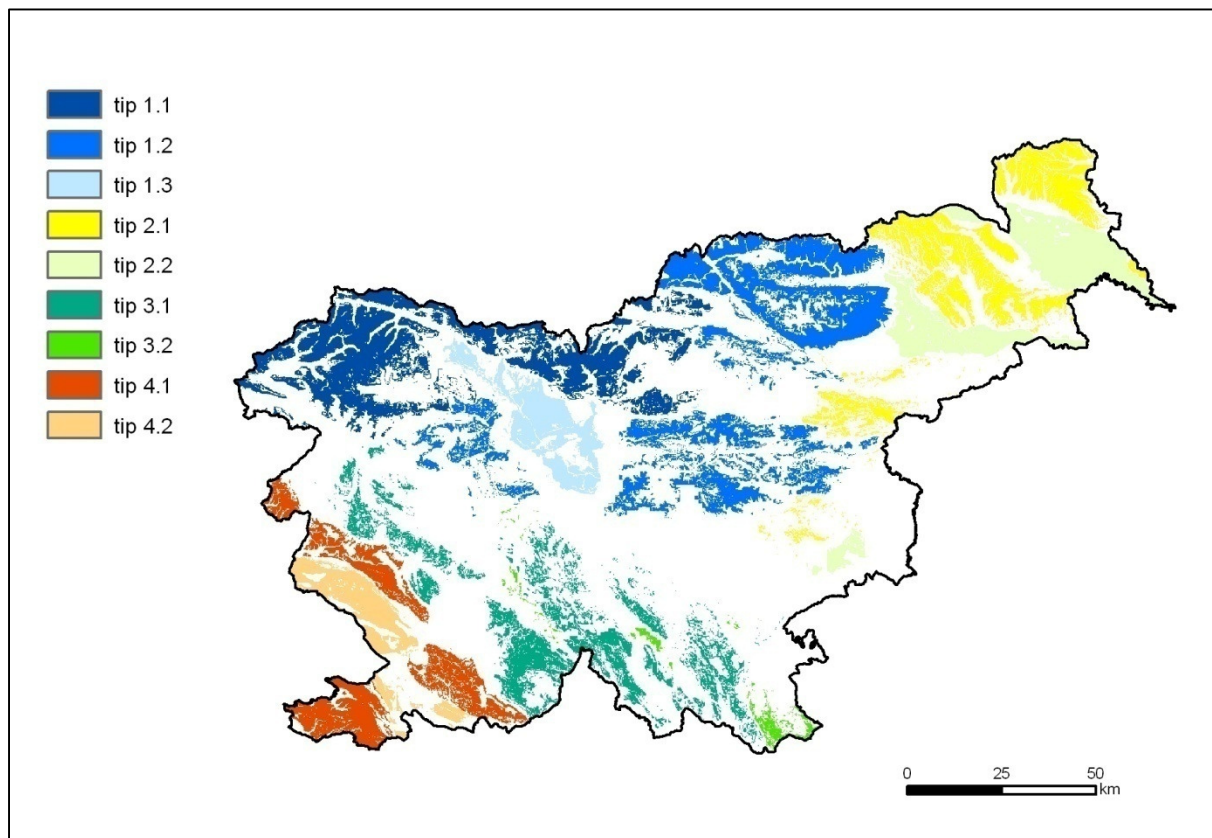
Tip **dinarskih planot (3.1)** je potrjen po vseh modelih na višjih delih Trnovskega gozda, Hrušice, Nanosa, Idrijskega hribovja, Javornikov, Goteniške gore, Ribniške Male gore, Stojne in na nekaterih manjših delih Blok, Krma, Poljanske gore in Kočevskega Roga. Povsem izvzeto je območje Gorjancev in Raduljskega hribovja, Kočevskoreški ravniki, Loški Potok, Suha krajina, Banjšice ter najvišji deli Snežniškega pogorja.

Tip **dinarskih podolij in ravnikov (3.2)** je tip z najslabšim ujemanjem modeliranih in izvornih celic. Praktično so modeli potrdili le manjše območje med Ribnico in Kočevjem ter na skrajnem jugu Bele krajine. Ostala Bela krajina, okolica Novega mesta, Dolenjsko podolje, Ljubljansko barje, Notranjsko podolje, Pivška kotlina ter Ribniško in Kočevsko polje so izvzeti.

Tip **sredozemskih gričevij (4.1)** je potrjen z dvema tretjinama celic. Izvzeta so predvsem bolj ravninska območja v Vipavski dolini ter doline ob večjih vodotokih v Goriških brdih in Koprskem primorju. Izvzeti so tudi severno obrobje Brkinov ter deli Kraškega roba.

Tip **sredozemskih planot (4.2)** je v večji meri potrjen predvsem na Krasu (izjema je okolica Sežane) ter v okolici Podgrada. Izvzeti so precejšnji deli Podgorskega krasa, Podgrajskega podolja in Čičarije.

Slika 71: Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvorno tipizacijo TIPI9.



Opazna je odsotnost ujemanja med modeliranimi in izvornimi tipi na območju Celjske kotline, srednje Soške doline, območja med Vrhniko in Idrijo, Pivške kotline, Ljubljanskega barja, Dolenjskega podolja, Suhe krajine, Bizeljskega, večjega dela Krške kotline, Gorjancev, večjega dela Bele krajine.

Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI9

Vsi modeli so potrdili tip **alpsko gorovje (1.1)** na območju grebenov z višjo nadmorsko višino Julijskih Alp, Kamniško-Savinjskih Alp in Karavank ter Pece, Olševe, obrobja Menine planine, opazno je tudi, da vmesne doline večinoma niso potrjene (na primer doline zgornje Soče, Save Dolinke, Save Bohinjke, Savinje, doline Kot, Krma, Vrata, Planica). V celoti sta izvzeti tudi Pokljuka in Jelovica.

Vsi modeli so potrdili tip **alpskega hribovja (1.2)** na osrednjem območju Pohorja (ravno obratno kot pri modeliranih tipizacijah z naključnim vzorcem učnih celic) ter le posamezna območja v Posavskem in nekoliko večja v Škofjeloškem in Polhograjskem hribovju.

Precejšen del območja, ki je po izvirni tipizaciji označen kot alpsko hribovje, je izvzet.

Modeli so tip **alpskih ravnin (1.3)** potrdili praktično samo v Ljubljanski kotlini, kjer pa so izvzeti hriboviti deli med Medvodami, Mostami, Domžalami in Ljubljano (na primer Šmarna gora, Rašica), Tunjiško gričevje, Udin boršt ter območje med Brezjami in Tržičem, ki ima prav tako bolj razgiban relief, ter okolica Vodice. V Celjski kotlini je potrjenih praktično le nekaj celic na zahodnem robu.

Tip **panonskih gričevij (2.1)** je bil potrjen v veliki meri na Goričkem, Halozah ter v severnem delu Slovenskih goric. Pri vseh navedenih so vidno izvzeti dolinski deli. Potrjeno je tudi območje med Žičami in Rogaško Slatino, del Dravinjskih goric, skrajni severni del Kozjanskega ter del Krškega gričevja. Skoraj v celoti so izvzete Bizeljsko, južno obrobje Pohorja ter precejšen del Krškega gričevja in Kozjanskega.

Tip **panonskih ravnin (2.2)** je skoraj v celoti potrjen na območju Murske ravnine, polovično na območju Dravske ravnine (manjka severni del), v celoti pa je izvzeta Krška ravan.

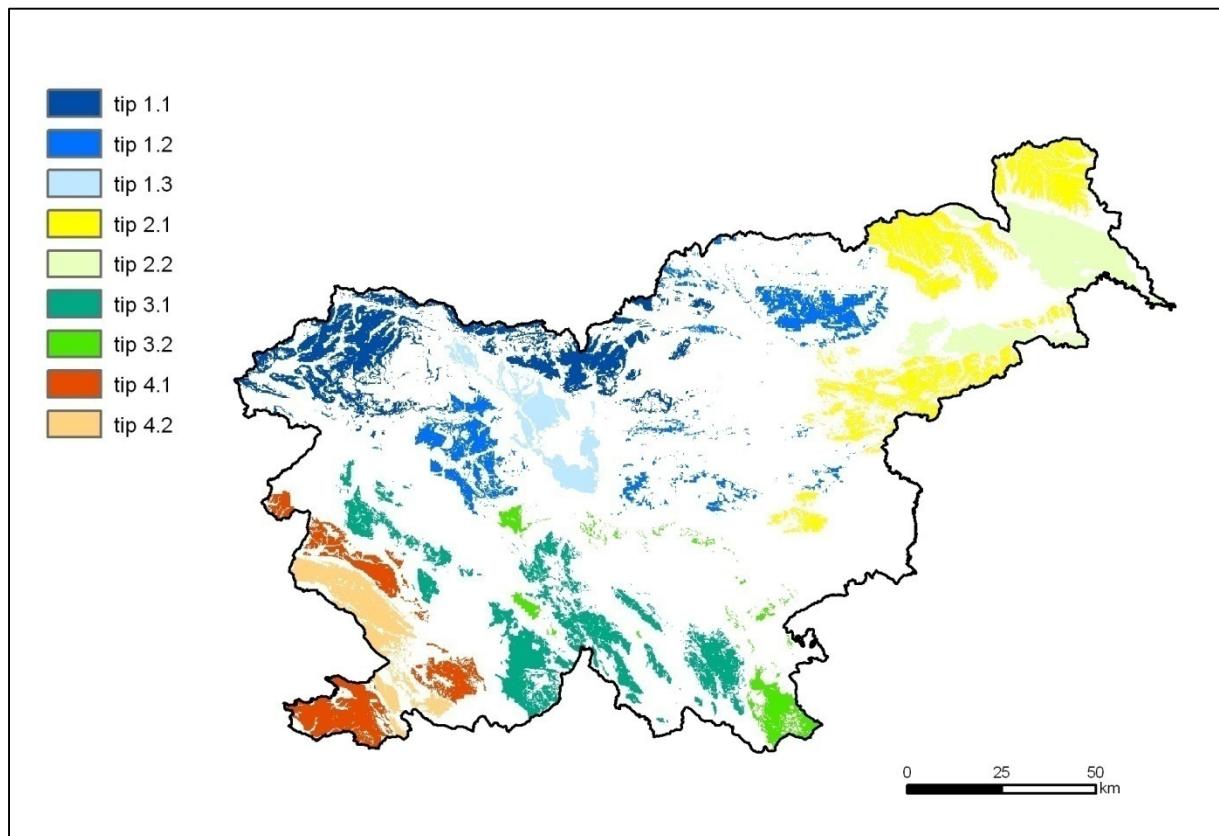
Tip **dinarskih planot (3.1)** je potrjen po vseh modelih na višjih delih Trnovskega gozda, manjšem delu Hrušice, Nanosa, manjšem delu Idrijskega hribovja, Javornikov, Goteniške gore, Ribniške Male gore, Ribniške Velike gore, Stojne, precejšen del Kočevskega Roga in na nekaterih manjših delih Blok, Krma in Poljanske gore. Povsem izvzeto je območje Gorjancev in Raduljskega hribovja (vpliv je imelo gotovo dejstvo, da tu ni bilo zajetih učnih celic), Kočevskoroški ravniki, Loški Potok, Suha krajina, Banjšice ter najvišji deli Snežniškega pogorja.

Tip **dinarskih podolij in ravnin (3.2)** je tip z najslabšim ujemanjem modeliranih in izvirnih celic. Praktično so modeli potrdili ta tip le v Beli krajini ter manjše dele na zahodu Ljubljanskega barja in osrednji del Cerkniškega polja. Severna Bela krajina, okolica Novega mesta, Dolenjsko podolje, preostalo Ljubljansko barje, Notranjsko podolje, Pivška kotlina ter Ribniško in Kočevsko polje so praktično v celoti izvzeti.

Tip **sredozemskih gričevij (4.1)** je potrjen za polovico vseh celic. Izvzeta so predvsem bolj ravninska območja v Vipavski dolini ter doline ob večjih vodotokih v Goriških brdih in Koprskem primorju. Izvzeti so tudi severno obrobje in velik del južnega dela Brkinov ter deli Kraškega roba in Goriških brd na severnem koncu.

Tip **sredozemskih planot (4.2)** je v večji meri potrjen predvsem na Krasu (izjema je okolica Sežane) ter na območju Kraškega roba in območju zahodno od Podgrada. Izvzeti so precejšnji deli Podgorskega krasa, Podgrajskega podolja in Čičarije. Izvzet je tudi zahodni del Krasa (zahodno od Komna do državne meje) in robni del Krasa, ki se spušča v Vipavsko dolino.

Slika 72: Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI9.



Opazna je odsotnost ujemanja med modeliranimi in izvirnimi tipi na območju Celjske kotline, srednje Soške doline, območja med Vrhniko in Idrijo, Pivške kotline, Ljubljanskega barja, Dolenjskega podolja, Suhe krajine, Bizeljskega, Kozjanskega, Krške kotline, Gorjancev, severnega dela Bele krajine in Kozjaka ter južnega dela Slovenskih goric.

Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI9

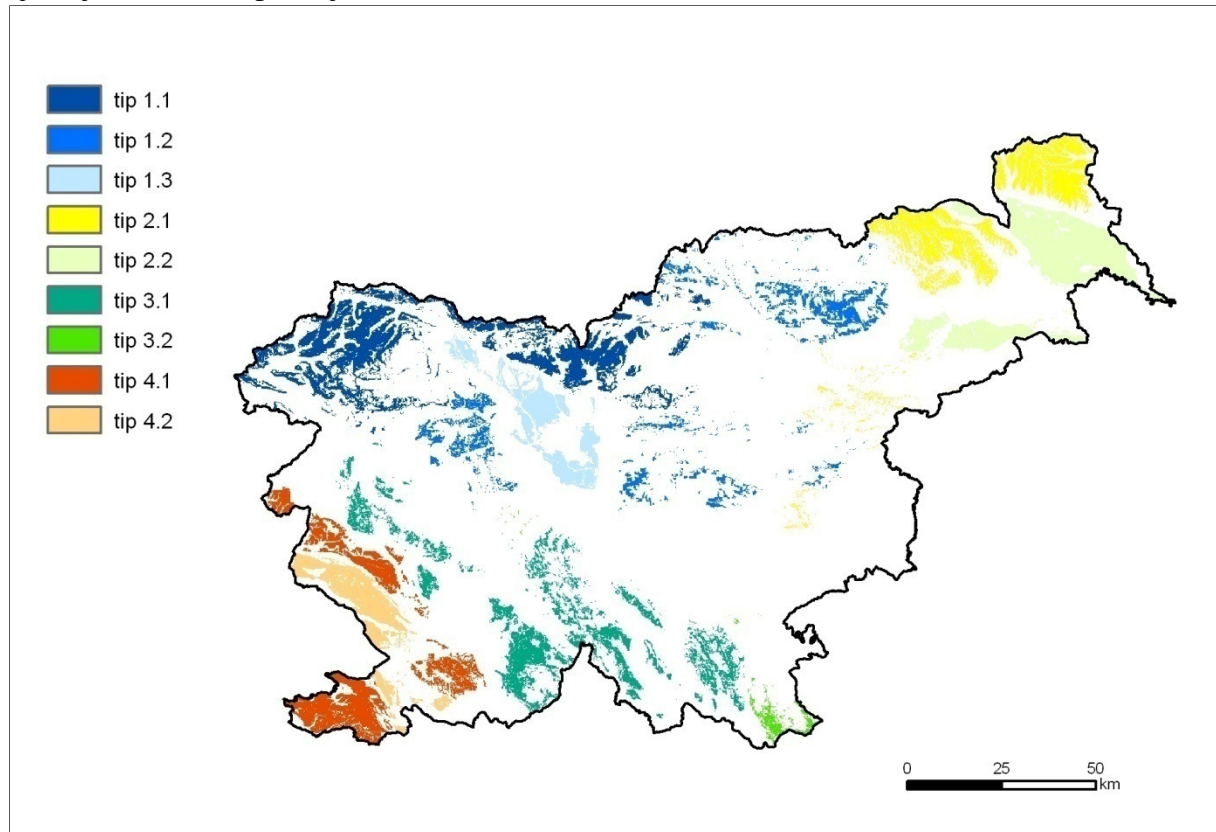
V tem delu ne bomo še enkrat opisovali, kje so potrjena območja, saj gre zgolj za presek zgornjih pregledov. Na tem mestu prikazujemo zato le zemljevid s kratkim komentarjem. Območja, ki so z vsemi metodami in z obema načinoma vzorčenja učnih območij klasificirana enako kot pri izvorni tipizaciji, so predvsem:

- za tip alpskih gorovij (1.1): najvišji deli Julijskih Alp, Karavank, Kamniško-Savinjskih Alp ter Peca, Olševa in Golte;
- za tip alpskih hribovij (1.2): osrednji deli Pohorja in njegovo jugovzhodno obrobje, deli Posavskega hribovja, deli Škofjeloškega hribovja;
- za tip alpskih ravnin (1.3): nerazgibani (ravni) deli Ljubljanske kotline;
- za tip panonskih gričevij (2.1): severni del Slovenskih goric, Goričko (brez vmesnih dolin);
- za tip panonskih ravnin (2.2): Murska ravan, južni del Dravske ravnin,
- za tip dinarskih planot (3.1): nekateri strnjeni deli Trnovskega gozda, Banjšic, Idrijskega hribovja, Nanos, Javorniki, deli Blok, Kočevskega Roga, Krma, Stojne, Ribniška Mala gora, Goteniška gora (za vse veljajo območja z višjo nadmorsko višino);
- za tip dinarskih podolij in ravnin (3.2): južno obrobje Bele krajine;

- za tip sredozemskih gričevij (4.1): Goriška brda in Koprsko primorje brez večjih dolin, razgibani deli Vipavske doline, osrednji del Brkinov;
- za tip sredozemskih planot (4.2): večji del Krasa, del Kraškega roba, okolica Podgrada.

Opazna je odsotnost ujemanja modeliranih in izvirnih tipov na območju Kozjaka, Celjske kotline, pretežnega dela Posavskega hribovja, Dolenjskega podolja, Bizeljskega, Kozjanskega, Krške kotline, srednje Soške doline, Kozjanskega, Pivške kotline, Cerkljanskega in Idrijskega hribovja, osrednje Kočevske, Suhe krajine.

Slika 73: Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvorno tipizacijo TIPI9.



8.5.1.2 Neujemanje vseh modeliranih z izvorno naravnopokrajinsko tipizacijo

V tem delu smo izpostavili celice modeliranih tipizacij, ki niso bile niti po eni metodi enako klasificirane kot pri izvorni tipizaciji. Takih celic, ki niso bile niti po eni metodi klasificirane tako kot v izvorni, je več pri klasifikacijah na podlagi ekspertnega vzorca učnih celic (19,4 %) (slika 75). Pri tipizacijah, ki so narejene z naključnim vzorcem učnih celic, je takih celic manj, in sicer 11,8 % (slika 74). To velja tudi v večini primerov za deleže posameznih tipov, izjema sta le tip panonskih ravnin in tip sredozemskih planot (preglednica 93).

Preglednica 93: Delež celic, ki se po nobenem modelu ne ujemajo z izvorno tipizacijo TIPI9.

oznaka tipa	število celic v tipu izvorne tipizacije	delež (%) vedno nepravilno klasificiranih celic glede na izvorno tipizacijo od vseh celic v tipu izvorne tipizacije (naključni vzorec učnih območij)	delež (%) vedno nepravilno klasificiranih celic glede na izvorno tipizacijo od vseh celic v tipu izvorne tipizacije (ekspertni vzorec učnih območij)
1.1	76.533	15,4	22,9
1.2	116.478	12,2	19,3
1.3	20.481	7,5	12,4

2.1	74.719	6,0	13,9
2.2	32.336	2,3	1,0
3.1	95.190	19,3	34,8
3.2	47.387	10,7	16,8
4.1	26.490	8,3	10,4
4.2	16.836	6,7	5,1
skupaj	506.450	11,8	19,4

Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI9

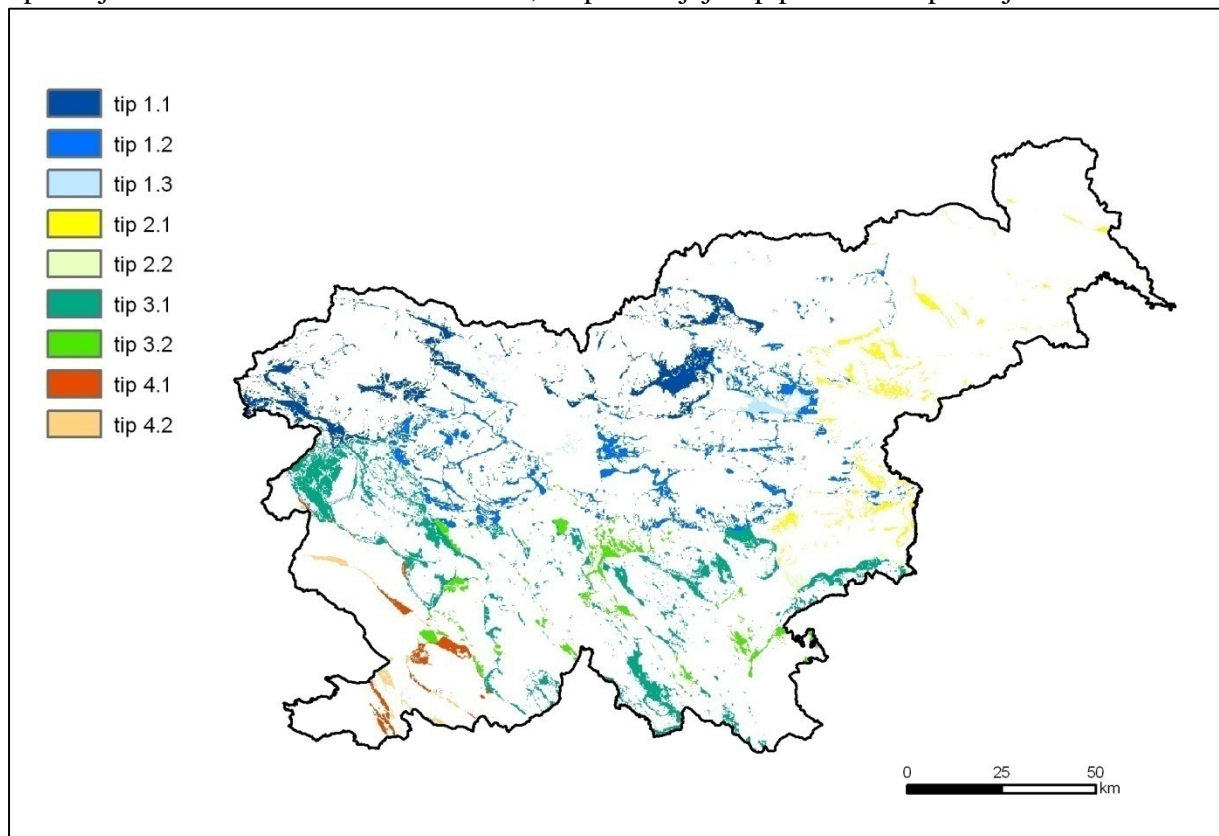
Pri modeliranih tipizacijah, ki so izdelane na podlagi naključnega vzorca učnih celic, je opazno, da so območja, ki po nobenem modelu niso klasificirana enako kot pri izvorni tipizaciji, predvsem območja dolin, kotlin, manjših kraških polj in drugih depresij. Znotraj tipov **alpskih gorovij (1.1)** in **alpskih hribovij (1.2)** so izločene Soška dolina, Bovška kotlina, Bohinj, dolina Save Dolinke, Save Bohinjke, dolina Savinje (z razširjenim delom pri Nazarjah in Mozirju), Save v Posavskem hribovju (z razširjenim delom pri Litiji), dolina Selške in Poljsanske Sore, Horjulščice, Kamniške Bistrice in druge. Zanimivo je dejstvo, da se znotraj **alpskih ravnin (1.3)** z izvirno tipizacijo nikoli ne ujema vzhodni del Celjske kotline. Znotraj **panonskih gričevij (2.1)** so območja ob Sotli, Bistrici (Kozje), Voglajni, okolici Slovenske Bistrice in Miklavža na Dravskem polju, obrobje Pohorja; znotraj **panonskih ravnin (2.2)** pa obrobni deli pod Gorjanci in še ponekod drugod.

Znotraj **dinarskih planot (3.1)** se nikoli ne ujemajo celice na območju Banjšic, obrobja Trnovskega gozda, Nanosa in Javornikov, Čepovanskega dola, nekaterih dolin v Idrijskem hribovju, vršni deli Snežniškega pogorja, Kočevskoreški ravniki, dolina Kolpe pri Petrini, Dobropolje, deli Suhe krajine, Gorjancev in Raduljskega hribovja. Znotraj **dinarskih podolij in ravnin (3.2)** se z izvirnikom nikoli ne ujemajo Vremščica, okolica Babnega polja, okolica Godoviča, deli Hrušice, Iški vršaj, severno obrobje Bele krajine, vzhodni del Kočevskega polja ter območje južno od Grosuplja.

Znotraj tipa **sredozemska gričevja (4.1)** nikoli niso v skladu z izvirnikom deli Kraškega roba, južno obrobje Brkinov, severni rob Krasa, okolica Košane in Škocjana ter rob Trnovskega gozda. Znotraj **sredozemskih planot (4.2)** so takšna območja severni rob Krasa, Podgrajskega podolja, Slavnik, Plešivica in okolica zahodno od Hrpelj. Pri sredozemskih tipih se neskladje pojavlja predvsem zaradi kamnin.

Pri vseh območjih, ki so na stikih tipov, se neskladja pojavijo preprosto zato, ker izvirna tipizacija ni bila izdelana na tako natančnem merilu, kot ga uporabljamo v nalogi.

Slika 74: Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI9.



Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI9

Pri modeliranih tipizacijah na podlagi ekspertnega vzorca učnih celic je opazno, da je območij, ki po modelih niso nikoli klasificirana enako kot v izvirni tipizaciji, nekoliko več kot v prejšnjem primeru. Opazno je, da gre za območja na robnih delih tipov (recimo pobočja Nanosa), precej je tudi dolin in kotlin znotraj goratega in hribovitega sveta, a takih primerov je manj, saj smo pri ekspertnem izboru vzorčnih celic skušali zajeti tudi doline znotraj gorovij oziroma hribovij.

Znotraj tipov **alpskih gorovij (1.1)** in **alpskih hribovij (1.2)** so izločene Soška dolina na več mestih, Bohinj, dolina Savinje (z razširjenim delom pri Nazarjah in Mozirju), Drave, Save v Posavskem hribovju (z razširjenim delom pri Litiji), Ložniško in Hudinjsko gričevje, okolica Šoštanja, Paški Kozjak, dolina Selške in Poljanske Sore, Horjulščice, Kamniške Bistrice in druga območja. Znotraj **alpskih ravnin (1.3)** so vedno nepravilno klasificirani Tunjiško gričevje, razgibano območje med Mengšem, Medvodami in Ljubljano, okolica Tržiča ter obrobni deli ravnin.

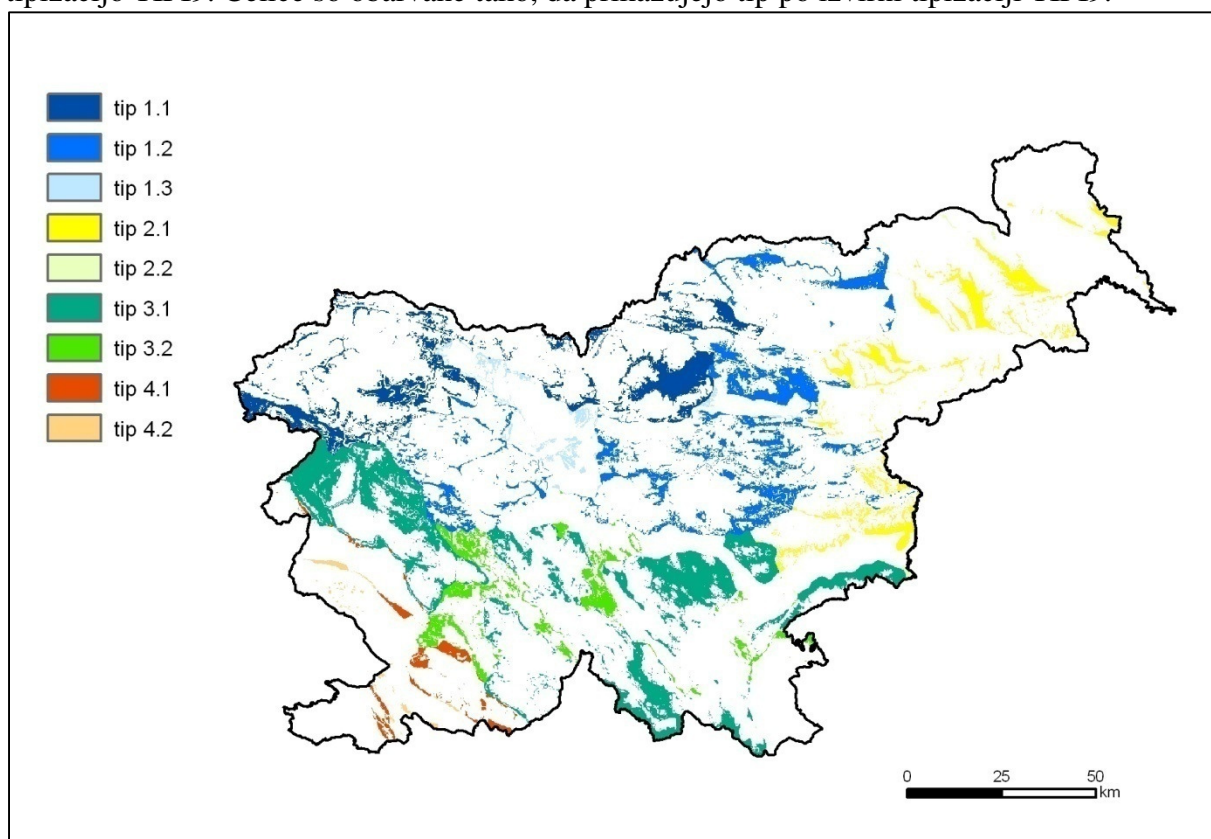
Pri **panonskih gričevjih (2.1)** nikoli niso bile potrjene doline Kobiljanskega potoka, Ščavnice, Pesnice, nekateri deli dolin Dravinje, Voglajne, Sotle, Save, deli Dravinjskih gor, Kozjega, Bizeljskega, obrobni deli Krškega gričevja. **Panonske ravnine (2.2)** imajo izjemno malo takih območij, ki niso bila nikoli pravilno klasificirana; ta so predvsem na obrobju ravnin.

Pri **dinarskih planotah (3.1)** nismo potrdili nižjih delov Gorjancev in Dobruljskega hribovja, Bele krajine, Dobropolja, Kočevskoreškega ravnika, doline Kolpe s Poljansko dolino, precejšen del Banjšic in Idrijskega hribovja ter obrobne dele po celotnem območju tipa. Pri **dinarskih podoljih in ravninah (3.2)** so ostali nepotrjeni severno obrobje Bele krajine,

Slemena (nad Ribnico), Iški vršaj, obrobje Pivške kotline ter obrobje Notranjskega podolja in del Hrušice.

Znotraj **sredozemskega gričevja (4.1)** so nepotrjene okolica Košane, obrobni del Brkinov, karbonatni deli Kraškega roba. Nepotrjen je tudi manjši del Krasa na jugovzhodu. Pri vseh je razlog verjetno v kamninski sestavi. Pri **sredozemskih planotah (4.2)** so potrjeni vršni deli Čičarije ter obrobni deli na severu Krasa.

Slika 75: Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvorno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI9.



8.5.1.3 Ujemanje območij modeliranih tipizacij, ki niso enaka izvorni naravnopokrajinski tipizaciji

Zanimivo je, da je med tisti celicami, ki z modeliranjem nikoli niso bile klasificirane tako kot v izvorni tipizaciji, nekaj takih, ki imajo po vseh modeliranih tipizacijah enak tip (sliki 76 in 77). Pri modeliranih tipizacijah na podlagi naključnega vzorca je 4,2 % celic takšnih, ki imajo po vseh modelih enako uvrstitev, pri modeliranih tipizacijah na podlagi ekspertnega vzorca pa je takih celic 5,5 % (preglednica 94).

Preglednica 94: Celice, ki so v vseh modeliranih tipizacijah enako klasificirane, a niso enake izvorni tipizaciji TIPI9.

oznaka tipa	modeli z naključnim vzorcem		modeli z ekspertnim vzorcem	
	število celic	delež <u>od celotnega ozemlja Slovenije (%)</u>	število celic	delež <u>od celotnega ozemlja Slovenije (%)</u>
1.1	2099	0,4	1298	0,3
1.2	3113	0,6	3925	0,8
1.3	2970	0,6	1021	0,2
2.1	2539	0,5	8866	1,8
2.2	1656	0,3	1196	0,2
3.1	1903	0,4	1902	0,4

3.2	386	0,1	1890	0,4
4.1	3977	0,8	3421	0,7
4.2	2917	0,6	4438	0,9
skupaj	21.560	4,2	27.957	5,5

Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvirno tipizacijo TIPI9

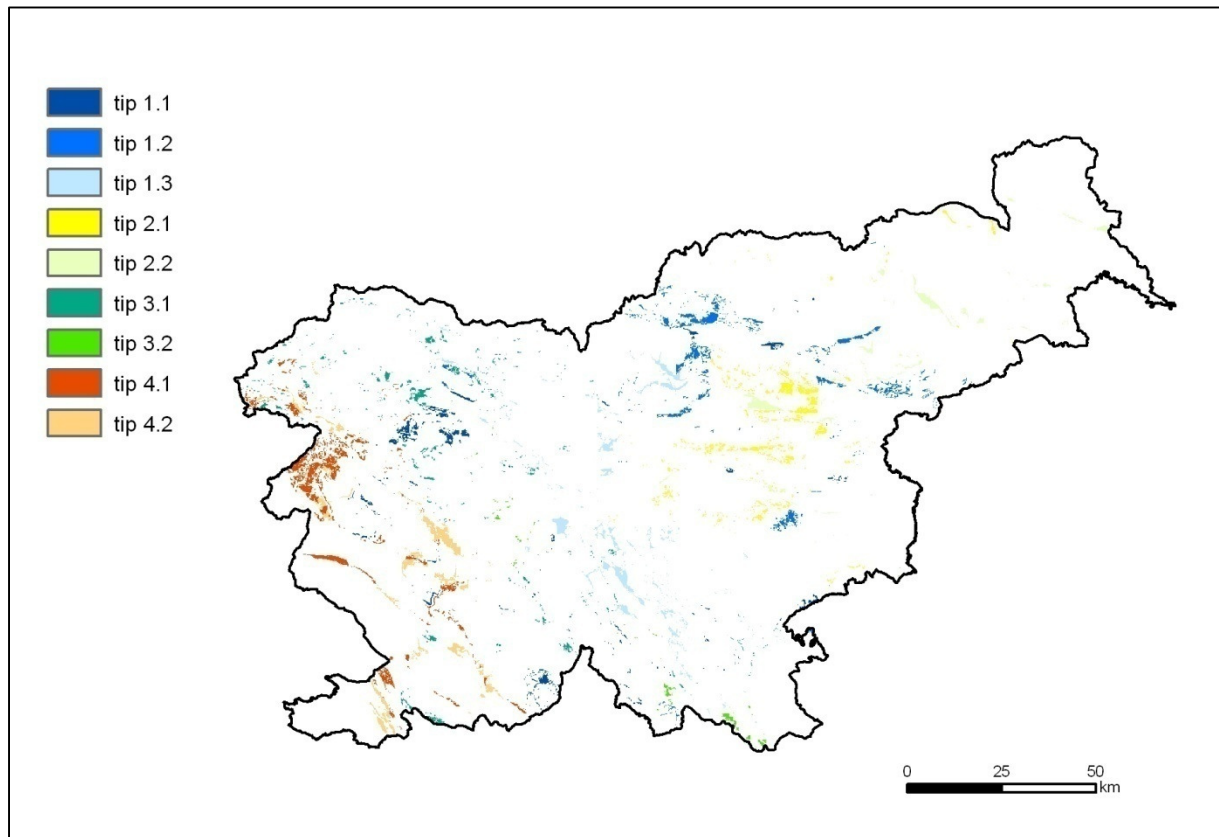
Pri naključnem vzorčenju gre predvsem za manjše zaplate in posamezne celice. Izpostaviti je treba večja območja.

K **alpskemu gorovju (1.1)** modeli prištevajo denimo višje dele alpskih hribovij in dinarskih planot, kot so Porezen, Blegoš, Paški Kozjak, Kum, Trdinov vrh in Veliki Snežnik, skalnato obrobje Nanosa. Med **alpska hribovja (1.2)** se klasificirajo obrobja Pohorja, Plešivca, Golt, Boča, Menine planine in Krškega gričevja. Gre predvsem za območja, ki so pri izvorni tipizaciji klasificirana kot alpsko gorovje ali pa panonsko gričevje. K **alpskim ravninam (1.3)** bi glede na usklajenost modeliranih tipizacij morali prišteti Iški vršaj, Dobropolje ter ravnice ob Savinji in Dreti ter okolico Doba in Dola. K **panonskim gričevjem (2.1)** modeli klasificirajo precejšnje dele Voglajnskega in Hudinjskega gričevja ter manjša območja v Posavskem hribovju. K **panonskim ravninam (2.2)** modeli klasificirajo območja okoli Miklavža na Dravskem polju, južni osrednji del Celjske kotline, dolino Dravinje in še nekaj manjših območij. Med **dinarske planote (3.1)** modeli prištevajo manjša območja v zahodni Sloveniji, recimo majhne dele Pokljuke, Mežakle, Notranjskega podolja (med Babnim poljem in Ložem). Med **dinarska podolja in ravnike (3.2)** modeli soglasno klasificirajo le malo območij – predvsem manjši del Kočevskoreškega ravnika, Bele krajine, Poljanske doline nad Kolpo in okolice Vrhnike.

Območje med Hotedršico in Črnim vrhom modeli klasificirajo k **sredozemskim planotam (4.1)**, prav tako dele Kraškega roba, okolico Košane, Cola in Ilirske Bistrice ter Ravniško polje in območje Grgarja nad Novo Gorico. Med **sredozemska gričevja (4.2)** bi po modelih spadali deli Kambreškega in Banjšic (predvsem pobočja nad Sočo), severni del Krasa (pri Dornberku) in območje med državni mejo in Hrpeljami.

Glede na število celic je največ območij, ki so jih modeli soglasno potrdili, a niso enaki izvorniku, klasificiranih kot tip sredozemskih gričevij, alpskih hribovij, alpskih ravnin in sredozemskih planot. Le nekaj takih celic je klasificiranih kot tip dinarska podolja in ravniki (preglednica 94).

Slika 76: Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI9.



Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI9

Pri ekspertnem vzorčenju gre prav tako za manjše zaplate in posamezne celice. Izpostaviti je treba večja območja.

Kot **alpska gorovja (1.1)** modeli po ekspertnem vzorčenju klasificirajo strme robove alpskih gorovjih in dinarskih planot, na primer Trnovskega gozda, Nanosa, Ratitovca, Dražgoške gore, Borovške gore, Kuma in Paškega Kozjaka. Med **alpska hribovja (1.2)** pa modeli klasificirajo nekatere dele alpskih gorovij: Planina pod Golico, Jezersko, Smrekovec ter dele Slemen in Blok. Med **alpske ravnine (1.3)** se klasificirajo Iški vršaj, Dobropolje s Ponikvami in manjši del ob Dreti.

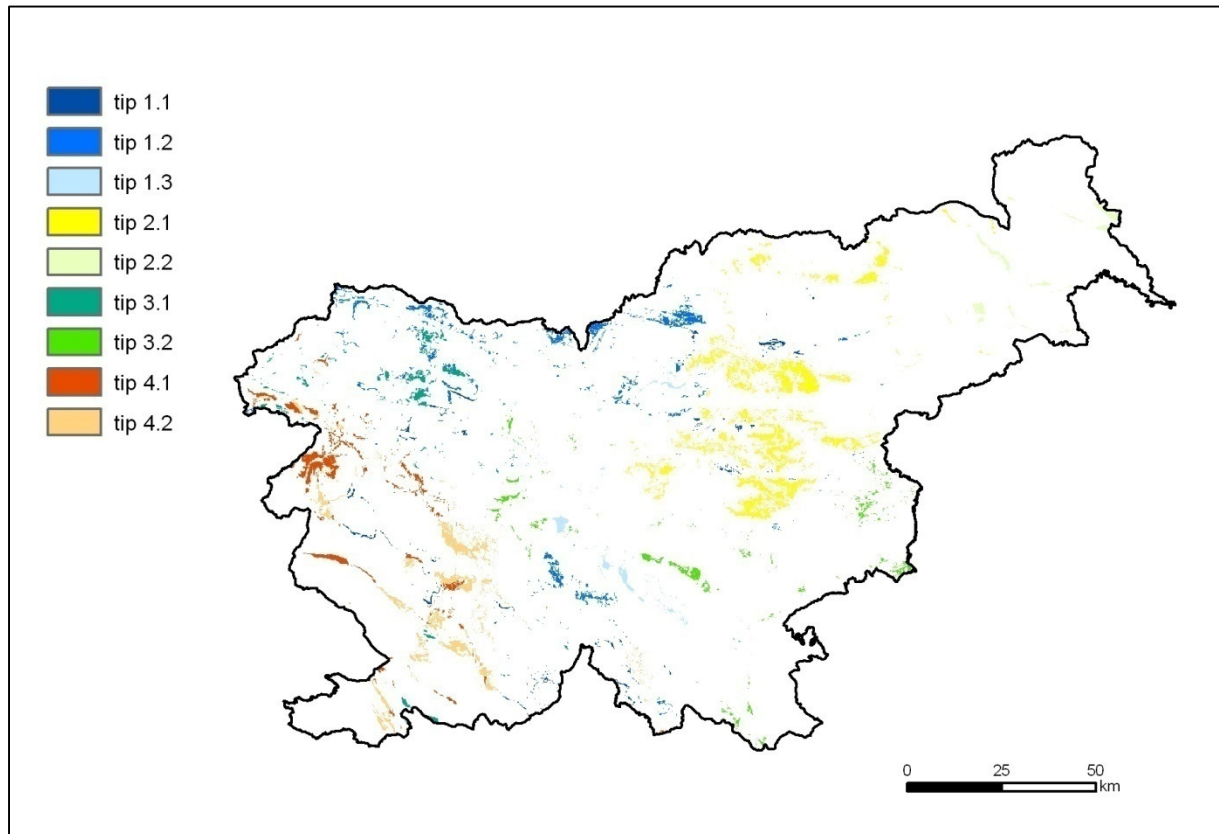
Med **panonska gričevja (2.1)** se klasificirajo razpršena območja znotraj Posavskega hribovja, Ložniškega in Hudinjskega gričevja, Kozjanskega in obrobni deli Pohorja (predvsem na severu). Med **panonske ravnine (2.2)** se klasificira predvsem nekaj območij ob Kobiljanskem potoku, Ščavnici in Pesnici.

Kot **dinarske planote (3.1)** modeli prepoznajo nekatere dele Pokljuke, Mežakle in Jelovice ter Čičarije (Slavnik), Vremščico in nekaj manjših območij v zgornjem Posočju. Kot **dinarska podolja in ravniki (3.2)** so prepoznani povirni deli Krke, manjši deli Suhe krajine in Bele krajine ter zahodno obrobje Ljubljanskega barja.

Kot **sredozemsko gričevje (4.1)** so prepoznani Kambreško in Banjšice, Breginjski kot, okolica Dornberka. Med Sredozemske planote so modeli soglasno klasificirali karbonatni del Kraškega roba, dele Brkinov in Pivške kotline, Hrušice, okolico Grglja (nad Novo Gorico), Ravniško polje, Vrhe ter območja med Kalcami in Godovičem.

Glede na število celic je največ območij, ki so jih modeli soglasno potrdili, a niso enaki izvorni tipizaciji, klasificiranih kot tip panonska gričevja, sredozemske planote, alpska hribovja in sredozemska gričevja. Najmanj takih celic je klasificiranih kot tip alpske ravnine in panonske ravnine (preglednica 94).

Slika 77: Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI9.



8.5.2 Geografska primerjava vseh modeliranih naravnopokrajinskih tipizacij z izvorno naravnopokrajinsko tipizacijo TIPI13

8.5.2.1 Ujemanje vseh modeliranih z izvorno naravnopokrajinsko tipizacijo

Pri prvem prekrivanju smo dobili za modelirane tipizacije, ki so izdelane z naključnim vzorcem učnih celic, in za modelirane tipizacije, ki so izdelane z ekspertnim vzorcem učnih celic, po en zemljevid, ki prikazuje celice, ki so bile z vsako metodo klasificirane tako kot pri izvorni tipizaciji (preglednica 95, sliki 78 in 79). Ob koncu poglavja smo prikazali tudi celice, ki so po prav vseh metodah (z obema načinoma določanja učnih celic) klasificirane enako kot v izvorni tipizaciji (slika 80).

V večini primerov je izvorna tipizacija bolj potrjena z modeliranimi tipizacijami, izdelanimi na podlagi naključnega vzorca učnih celic, saj je 30,1 % vseh celic z vsako metodo enako klasificiranih. Pri ekspertnem vzorčenju je celic, ki so z vsemi metodami enako klasificirane, manj, in sicer le 22,0 %. Velikost tipov v tem sklopu ne igra pomembne vloge, saj se nekateri površinsko manjši tipi po modelih ne ujemajo z izvornikom (na primer širše doline in obalne ravnice v primorskem delu Slovenije).

Največ ujemanja (pri obeh sklopih modeliranih tipizacij) je pri naslednjih tipih: visokogorski svet, ravnine in širše doline v gričevju notranjega dela Slovenije, Kras in Podgorski kras ter gričevje v primorskem delu Slovenije.

Preglednica 95: Delež celic, ki se po vseh modelih ujemajo z izvirno tipizacijo TIPI13.

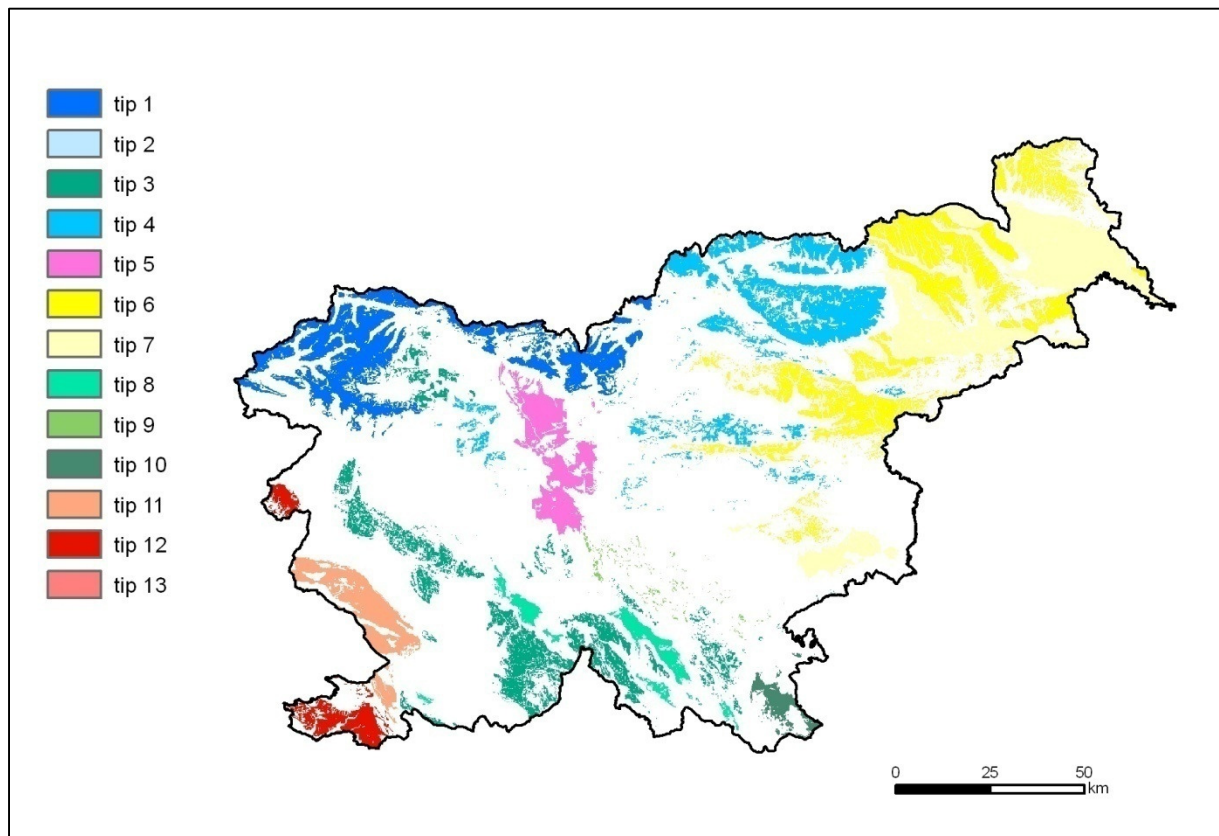
oznaka tipa	vse celice v tipu	delež (%) vedno pravilno klasificiranih celic glede na izvirno tipizacijo od vseh celic v tipu izvirne tipizacije (naključni izbor učnih celic)	delež (%) vedno pravilno klasificiranih celic glede na izvirno tipizacijo od vseh celic v tipu izvirne tipizacije (ekspertni izbor učnih celic)
1	42.210	55,7	40,1
2	18.174	0,1	0,0
3	89.759	20,5	18,9
4	113.363	19,3	12,5
5	31.652	29,3	13,2
6	82.034	36,4	29,1
7	44.400	67,1	46,6
8	22.141	19,9	6,3
9	27.185	2,7	3,5
10	8272	26,4	7,3
11	12.651	61,8	52,1
12	8431	56,8	57,1
13	6178	0,0	3,0
skupaj	506.450	30,1	22,0

Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvirno tipizacijo TIPI13

Pri pregledu je opazno, da so vedno pravilno klasificirana približno enaka območja kot po ekspertnem naboru. Vedno pravilno so klasificirani predvsem najvišji deli **visokogorska sveta (1)** Julijskih Alp, Kamniško-Savinjskih Alp in Karavank. **Visoke kraške planote in hribovja v karbonatnih kamninah (3)** so vedno potrjena na območju Trnovskega gozda, Nanosa, Javornikov, Snežnika in višjih delov Kočevske ter ponekod na območju Jelovice, Mežakle in Pokljuke. **Hribovja v pretežno nekarbonatnih kamninah (4)** so potrjena večinoma na Pohorju, Kozjaku, Strojni ter manjša območja Polhograjskega, Škofjeloškega in Posavskega hribovja, Bohorja, Boča, Uršlje gore in Paškega Kozjaka. Območja **medgorskih kotlin (5)** so potrjena le v Ljubljanski kotlini brez reliefno razgibanih območij (z vzhodnim delom Ljubljanskega barja). **Gričevja v notranjem delu Slovenije (6)** se vedno ujemajo z izvirnikom na območju Goriškega, Lendavskih gor, Slovenskih gor, Dravinjskih gor, severnega Kozjanskega, manjšega dela Krškega gričevja, Ložniškega in Hudinjskega gričevja ter v osredju Posavskega hribovja. **Ravnine in širše doline v gričevju notranjega dela Slovenije (7)** se ujemajo na Murski ravni, Dravski ravni (z dolino Pesnice) ter na vzhodnem delu Krške ravni. **Kraška polja in podolja (8)** so potrjena na delih Notranjskega podolja (Loška dolina, Cerknjsko polje, Unško polje, Kočevskoribniško polje, Kočevskoreški ravniki, Poljanska dolina ter manjši del Matarskega podolja). **Nizki kras Bele krajine (10)** je potrjen v osrednjem delu ter na vzhodnem robu. **Kras in Podgorski kras (11)** ter **gričevja v primorskem delu Slovenije (12)** so v več kot 50 % potrjeni. Nepotrjene pri gričevjih so predvsem nekatere doline.

Pri ostalih tipih (širše rečne doline v visokogorju, hribovju in na krasu (2), širše doline in obalne ravnice v primorskem delu Slovenije (13)), ki jih tu nismo posebej izpostavili, je le manjši del območja po vseh modelih klasificiran tako kot pri izvirni tipizaciji.

Slika 78: Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.

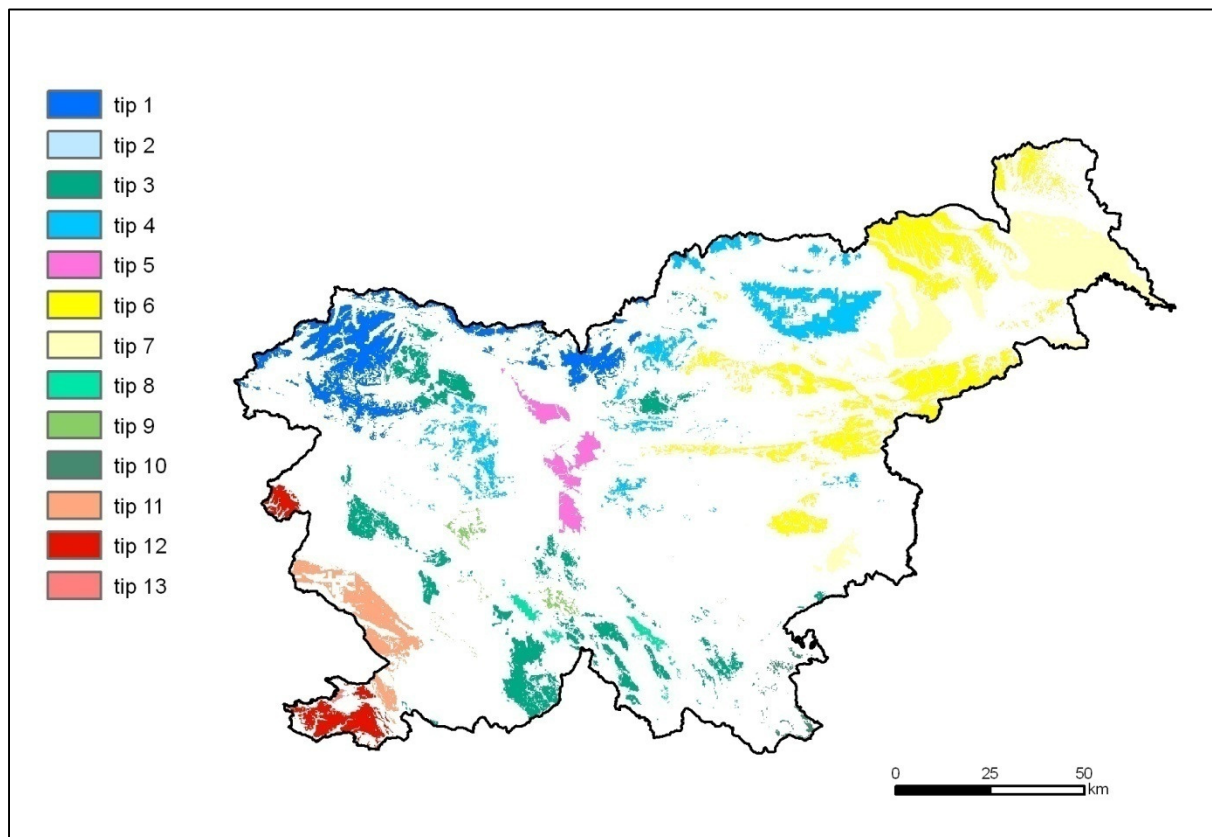


Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13

Vedno pravilno so klasificirani predvsem najvišji deli **visokogorska sveta (1)** Julijskih Alp, Kamniško-Savinjskih Alp in Karavank. **Visoke kraške planote in hribovja v karbonatnih kamninah (3)** so vedno potrjena na območju Trnovskega gozda, Nanosa, Javornikov, Snežnika in višjih delov Kočevske ter na majhnem vršnem delu Gorjancev, prav tako na območju Jelovice, Menine planine in precejšnjem delu Mežakle in Pokljuke. **Hribovja v pretežno nekarbonatnih kamninah (4)** so potrjena večinoma na Pohorju (brez najvišjih, osrednjih delov), Smrekovcu in Golteh ter na manjših območjih Polhograjskega, Škofjeloškega in Posavskega hribovja, Kozjaka in Bohorja. Območja **medgorskih kotlin (5)** so potrjena le v Ljubljanski kotlini (z Ljubljanskim barjem). **Gričevja v notranjem delu Slovenije (6)** se vedno ujemajo z izvirno tipizacijo na območju zahodnega Goriškega, severa Slovenskih goric, Haloz, severnega Kozjanskega, Krškega gričevja, Ložniškega in Hudinjskega gričevja ter v osredju Posavskega hribovja. **Ravnine in širše doline v gričevju notranjega dela Slovenije (7)** se ujemajo na Murski ravni, zahodnem delu Dravske ravni ter manjšem delu Krške ravni. **Kraška polja in podolja (8)** so bila potrjena v večji meri na Kočevskoribniškem polju ter na Cerkniskem polju. **Kras in Podgorski kras (11)** ter **gričevja v primorskem delu Slovenije (12)** so v več kot 50 % potrjene, **nizki kras Bele krajine (10)** pa v nekaj več kot 26 %. Nepotrjene pri gričevjih so predvsem nekatere doline.

Pri ostalih tipih je le manjši del območja po modelih vedno tako klasificiran kot pri izvirni tipizaciji. Zanimivo je, da se kar nekaj območij znotraj **širših rečni dolin v visokogorju, hribovju in na krasu (2)** ter **medgorskih kotlin (5)** ne ujema z izvirnikom po vseh modelih, kljub temu da so bile tudi tam izbrane učne celice.

Slika 79: Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.



Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13

V tem delu gre zgolj za presek zgornjih pregledov. Na tem mestu prikazujemo zato le zemljevid (slika 80) s kratkim komentarjem. Območja, ki so z vsemi metodami in z obema načinoma zajema učnih celic klasificirana enako kot na izvirni tipizaciji, so predvsem:

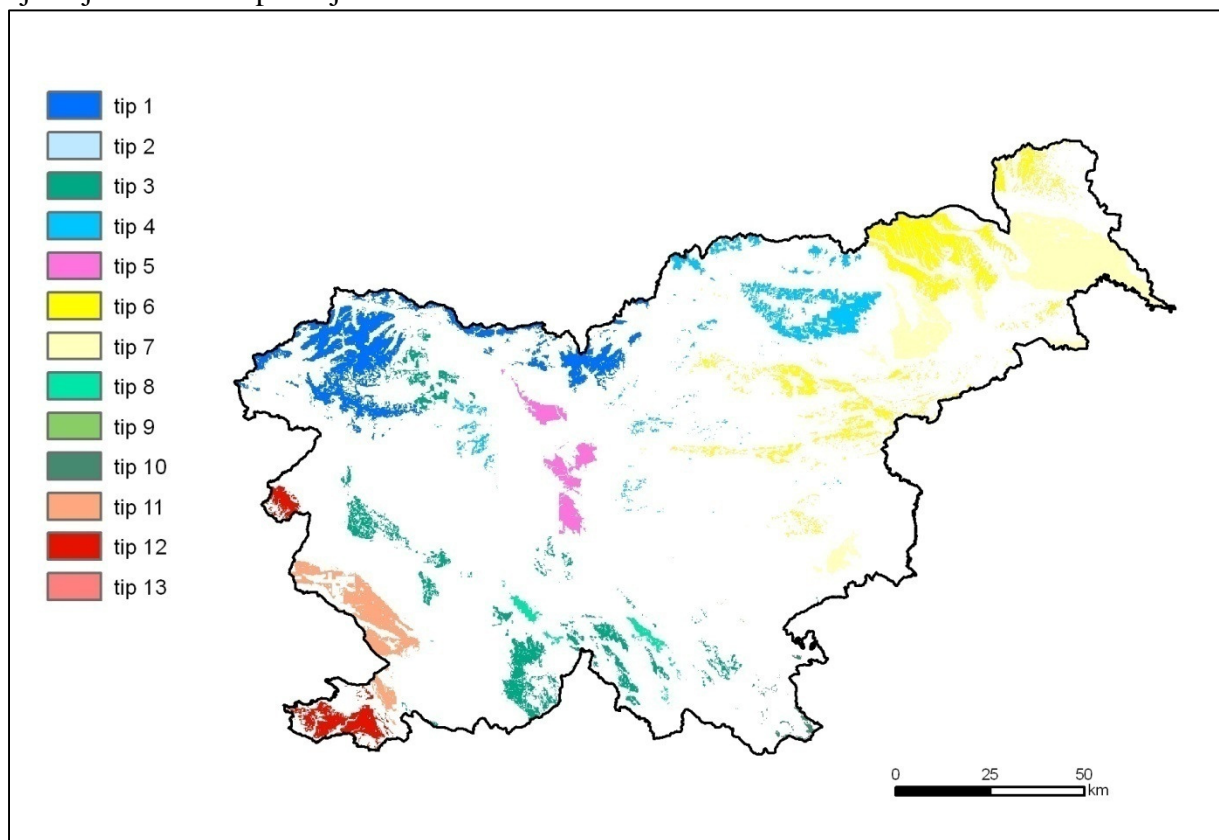
- za tip **visokogorski svet (1)**: najvišji deli Julijskih Alp, Karavank, Kamniško-Savinjskih Alp, Peca;
- za tip **visokih kraških planot in hribovja v karbonatnih kamninah (3)**: deli Pokljuke, Mežakle, Jelovice, Trnovskega gozda, Nanosa, Hrušice, Javornikov, Snežnika (brez najvišjega dela), višji deli Kočevske;
- za tip **hribovja v pretežno nekarbonatnih kamninah (4)**: Pohorje (brez vrhnjega dela), deli Kozjaka ter manjši sklop celic v Škofjeloškem in Posavskem hribovju;
- za tip **medgorskih kotlin (5)**: osrednji, predvsem najbolj ravninski deli Ljubljanske kotline;
- za tip **gričevja v notranjem delu Slovenije (6)**: severni del Slovenskih goric, zahodni del Goričkega, manjši del Ložniškega in Hudinjskega gričevja, Kozjanskega, Haloz, Dravinjskih goric in Krškega gričevja;
- za tip **ravnine in širše doline v gričevju notranjega dela Slovenije (7)**: Murska ravan, dolina Pesnice, osrednja Dravska ravan, vzhodni del Krške kotline;
- za tip **kraška polja in podolja (8)**: Cerknjsko polje, Loško polje, del Kočevskoribniškega polja;
- tip **Kras in Podgorski kras (11)**: večji del Krasa in zahodni del Podgorskega krasa;

- tip gričevja v primorskem delu Slovenije (12): jug Koprskega primorja in severna polovica Goriških brd.

Tipi širše rečne doline v visokogorju, hribovju in na krasu (2), nizki kras Notranjske in Dolenjske (9), širše doline in obalne ravnice v primorskem delu Slovenije (13) se praktično nikjer ne ujemajo po vseh metodah (in z obema vzorcema učnih celic) z izvirno tipizacijo. Tip nizki kras Bele krajine (10) ima takih le nekaj celic.

Opazna je odsotnost ujemanja modeliranih in izvirnih tipov na območju Celjske kotline, pretežnega dela Posavskega hribovja, Dolenjskega podolja, Bizeljskega, Kozjanskega, Krške kotline, srednje Soške doline, Pivške kotline, Cerkljanskega in Idrijskega hribovja, osrednje Kočevske, Suhe krajine, Kolpske doline, Gorjancev, Bele krajine, Brkinov, Vipavske doline, severne Ljubljanske kotline, Haloz.

Slika 80: Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.



8.5.2.2 Neujemanje vseh modeliranih z izvirno naravnopokrajinsko tipizacijo

Celic, ki niso bile niti po eni metodi klasificirane tako kot v izvirni tipizaciji (sliki 81 in 82), je več pri modeliranih tipizacijah na podlagi ekspertnega vzorca učnih celic (24,1 %). Pri modeliranih tipizacijah z naključnim vzorcem je takih celic manj (v povprečju 16,2 %). To velja tudi za večino deležev posameznih tipov, izjema je le tip nizki kras Notranjske in Dolenjske (preglednica 96).

Preglednica 96: Delež celic, ki se po nobenem modelu ne ujemajo z izvirno tipizacijo TIPI13.

oznaka tipa	število celic v tipu izvirne klasifikacije	delež (%) vedno nepravilno klasificiranih celic glede na izvirno tipizacijo od vseh celic v tipu izvirne tipizacije (naključni izbor učnih celic)	delež (%) vedno nepravilno klasificiranih celic glede na izvirno tipizacijo od vseh celic v tipu izvirne tipizacije (ekspertni izbor učnih celic)
1	42.210	10,5	13,8
2	18.174	32,2	48,1
3	89.759	24,9	41,0
4	113.363	22,4	31,6
5	31.652	15,8	16,8
6	82.034	8,2	15,8
7	44.400	9,0	9,5
8	22.141	6,8	23,0
9	27.185	16,0	15,4
10	8272	5,2	8,0
11	12.651	5,2	6,7
12	8431	7,5	7,9
13	6178	8,9	12,2
skupaj	506.450	16,2	24,1

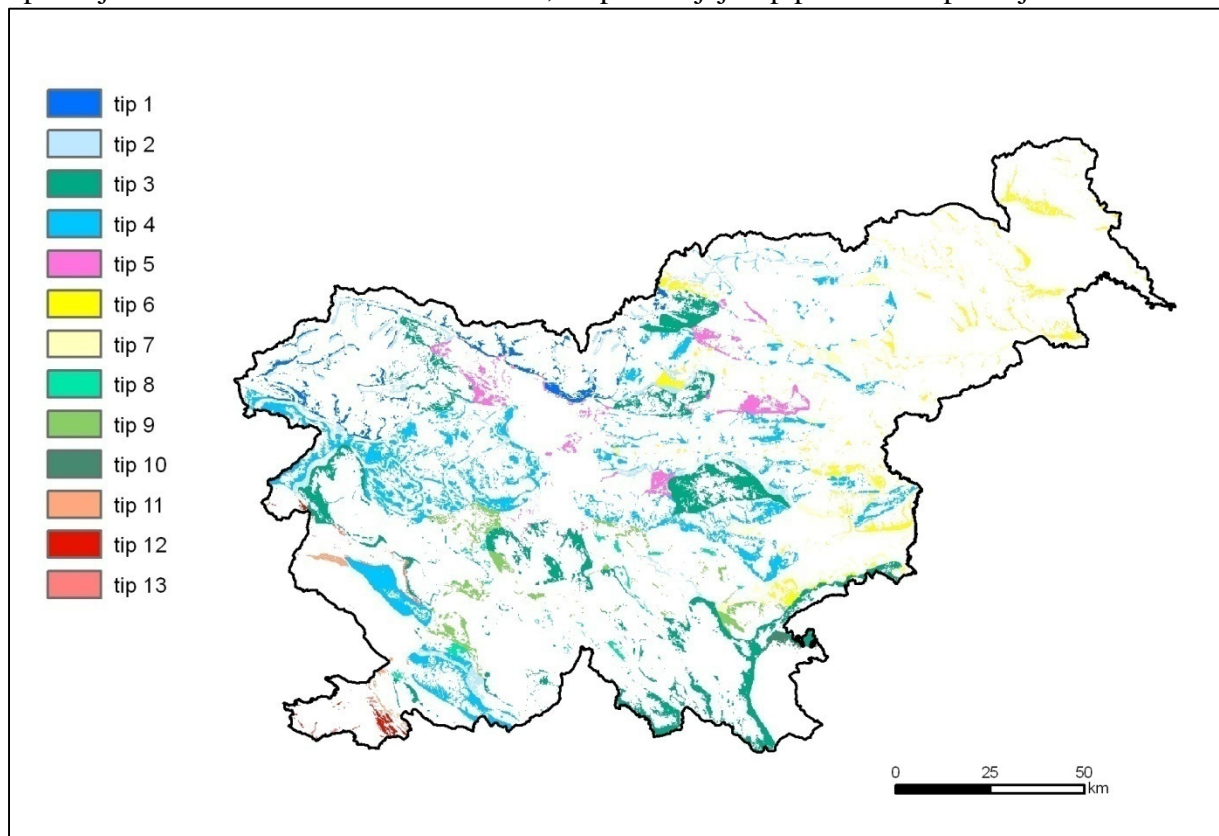
Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13

Pri tipu **visokogorski svet (1)** so nepotrjeni predvsem robni deli na celotnem območju.

Pri tipu **širše rečne doline v visokogorju, hribovju in na krasu (2)** so nepotrjeni predvsem povirni deli dolin, nekatera pobočja (na primer ob Savi in Dravi) ter večje območje zahodno od Ilirske Bistrice. Pri tipu **visoke kraške planote in hribovja v karbonatnih kamninah (3)** so zopet nepotrjeni predvsem robni deli tega tipa (recimo vznožje Gorjancev, Nanosa). Večje nepotrjeno območje je le v okolici Smrekovca in Uršlje gore, v osrednjem delu Posavja, jugu Banjšic. Pri tipu **hribovja v pretežno nekarbonatnih kamninah (4)** so nepotrjeni nekateri vrhovi (Golte, Veliki Rogatec, Porezen, Blegoš, Matajur), predvsem pa gre za doline in robne dele (na primer dolina Savinje, Horjulščice). Nepotrjena so Vipavska brda in osrednji del Brkinov. Pri tipu **medgorske kotline (5)** so nepotrjeni robni deli ter tri večja območja: Litijska kotlina, vzhodni del Celjske kotline in zahodno obrobje Velenjske kotline.

Pri tipu **gričevja v notranjem delu Slovenije (6)** so zopet nepotrjeni predvsem nekateri robni deli ter večje doline (na primer doline Dramlje, Rogoznice in Turje). Povsem nepotrjena sta območje med Nazarji in Gornjim Gradom (Hom) ter okolica Mežice. Pri tipu **ravnine in širše doline v gričevju notranjega dela Slovenije (7)** so nepotrjeni predvsem robni deli dolin in ravninskega sveta. Nepotrjeni so nekateri gričevnati deli ob vznožju Pohorja (okoli Zreč, Slovenske Bistrice, Maribora). Nepotrjena je v celoti dolina Bistrice pri Kozjem. Pri tipu **kraška polja in podolja (8)** so nepotrjeni okolica Košane, Hrpelj ter obrobni deli na Dobrepolju, pri Trebnjem, Grosuplju in Gotenici. Pri tipu **nizki kras Notranjske in Dolenjske (9)** je nepotrjena reliefno razgibana okolica Dolenjskih Toplic ter Novega mesta (Podgorje), nepotrjeni so Globodol, okolica Grosuplja ter več območij med Logatcem in Pivko. Pri tipu **Nizki kras Bele krajine (10)** je nepotrjen le skrajni severni rob Bele krajine. Pri tipu **Kras in Podgorski kras (11)** so nepotrjeni območje na severu, med Trsteljem in Prvačino ter nekaj območij na Kraškem robu. Pri tipu **gričevje v primorskem delu Slovenije (12)** je nepotrjenih nekaj obrobni delov, največ je nepotrjenih na Kraškem robu, kjer se menjavajo različne kamnine. Pri tipu **širše doline in obalne ravnice v primorskem delu Slovenije (13)** so nepotrjeni izključno obrobni deli.

Slika 81: Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI13.

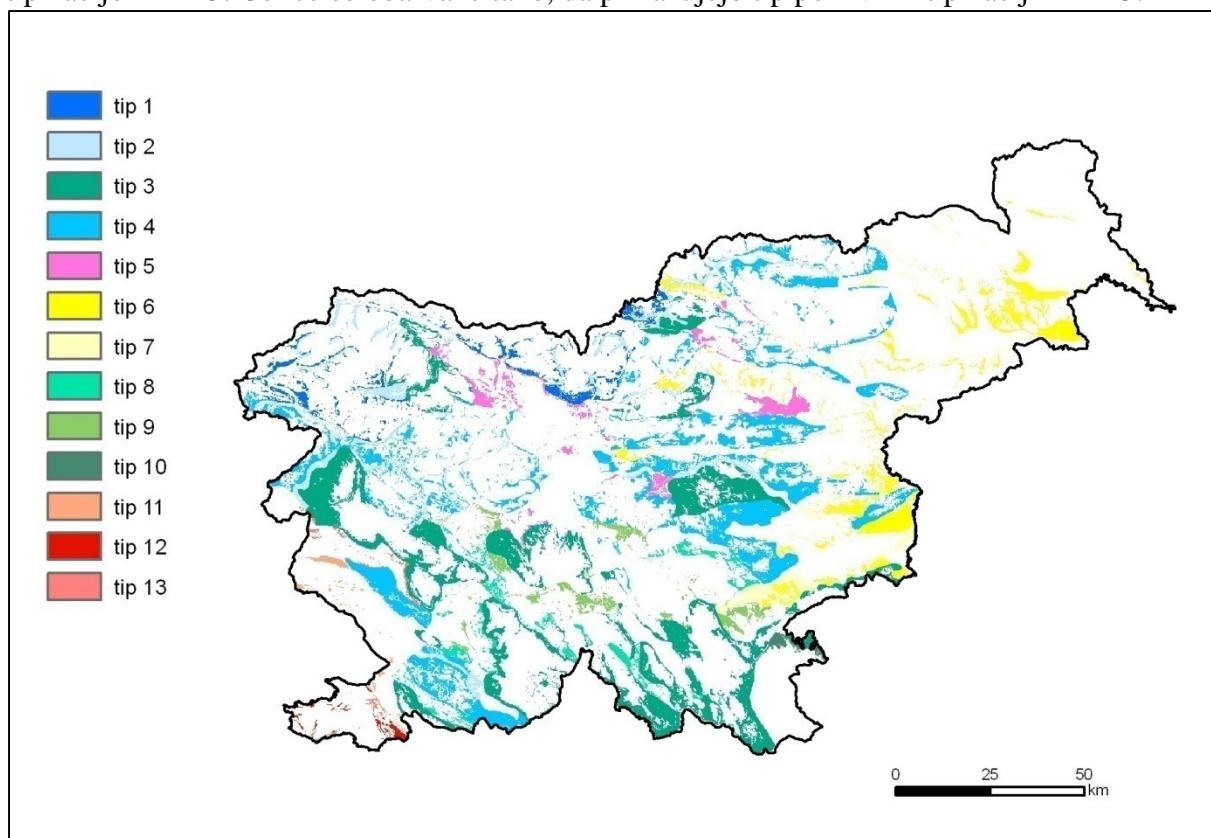


Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13

Pri **tipu visokogorski svet (1)** so nepotrjeni predvsem robni deli na celotnem območju ter nekatere doline, na primer dolina Tržiške Bistrice. Pri **tipu širše rečne doline v visokogorju, hribovju in na krasu (2)** so ostali nepotrjeni predvsem povirni deli številnih rek, nekateri ožji deli dolin (na primer ob Idrijci, Savi, Dravi, Meži, Soči) ter večje območje zahodno od Ilirske Bistrice. Nepotrjen je tudi Bohinj. Pri **tipu visoke kraške planote in hribovja v karbonatnih kamninah (3)** so zopet nepotrjeni predvsem robni deli tega tipa (vznožje Gorjancev in Nanosa). Večje nepotrjeno območje je v okolici Smrekovca in Uršlje gore, Dobrovelj, v osrednjem delu Posavja, na zahodu Banjšic, na območju dolin Radovne in Save Bohinjke, Menišije, okolice Godoviča, južnega dela Kočevskoreškega ravnika, Kočevske Male gore, nižjih delov Čičarije. Pri **tipu hribovja v pretežno nekarbonatnih kamninah (4)** so nepotrjeni nekateri vrhovi (Golte, Veliki Rogatec, Porezen, Blegoš, Matajur), predvsem pa gre za doline in robne dele, na primer dolino Savinje, Horjulščice, Radomlje. Nepotrjeni so Vipavska brda in obrobni deli Brkinov, obrobje Kambreškega, velik del Raduljskega gričevja, Posavskega hribovja (predvsem doline), Paškega Kozjaka, Konjiške gore ter okolica Lovrenca na Pohorju ter obrobje Pohorja in Kozjaka. Pri **tipu medgorske kotline (5)** so nepotrjeni robni deli ter nekatera večja območja: Litijska kotlina, vzhodni del Celjske kotline in zahodno obrobje Velenjske kotline, okolica Kroke, okolica Gorij. Pri **tipu gričevja v notranjem delu Slovenije (6)** so zopet nepotrjeni predvsem nekateri robni deli (na primer pod Gorjanci) ter večje doline (na primer Dramlje, Rogoznice in Turje). Povsem nepotrjeni so območje na jugu Slovenskih goric, Bizeljsko, območje med Nazarji in Gornjim Gradom (Hom) ter okolica Mežice. Pri **tipu ravnine in širše doline v gričevju notranjega dela Slovenije (7)** so nepotrjeni predvsem robni deli dolin in ravninskega sveta. Nepotrjeni so

nekateri gričevnati deli ob vznožju Pohorja (okoli Zreč, Maribora) ter zahodni del Krške kotline pri Novem mestu. Nepotrjena je v celoti dolina Bistrice pri Kozjem. Pri **tipu kraška polja in podolja (8)** so nepotrjeni okolica Košane, Postojne, Unca, Trebnjega, okolica Gotenice, Babnega polja ter obrobni deli na Dobropolju ter v okolici Grosupljega. Pri **tipu nizki kras Notranjske in Dolenjske (9)** so nepotrjeni reliefno razgibana okolica Dolenjskih Toplic ter Novega mesta (Podgorje), Slemena, Slivnica, del Menišije, pa tudi obrobje pri Grosupljem, Vrhniki in Pivki. Pri **tipu nizki kras Bele krajine (10)** je nepotrjen le skrajni severni rob Bele krajine. Pri **tipu Kras in Podgorski kras (11)** so nepotrjeni območje na severu, med Trsteljem in Prvačino ter nekaj manjših območij na Kraškem robu. Pri **tipu gričevje v primorskem delu Slovenije (12)** je nepotrjenih nekaj obrobni delov, največ je nepotrjenih na Kraškem robu, kjer se menjavajo različne kamnine. Pri **tipu širše doline in obalne ravnice v primorskem delu Slovenije (13)** so nepotrjeni izključno obrobni deli tega tipa.

Slika 82: Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po izvirni tipizaciji TIPI13.



8.5.2.3 Ujemanje območij modeliranih tipizacij, ki niso enaka izvirni naravnopokrajinski tipizaciji

Zanimivo je, da je med tisti celicami, ki z modeliranjem nikoli niso bile klasificirane tako kot v izvirni tipizaciji, nekaj takih, ki imajo po vseh modelih določen enak tip (sliki 83 in 84). Pri modeliranih tipizacijah na podlagi naključnega vzorca je takšnih celic 4,4 %, pri modeliranih tipizacijah na podlagi ekspertnega vzorca pa je takih celic 5,6 % (preglednica 97).

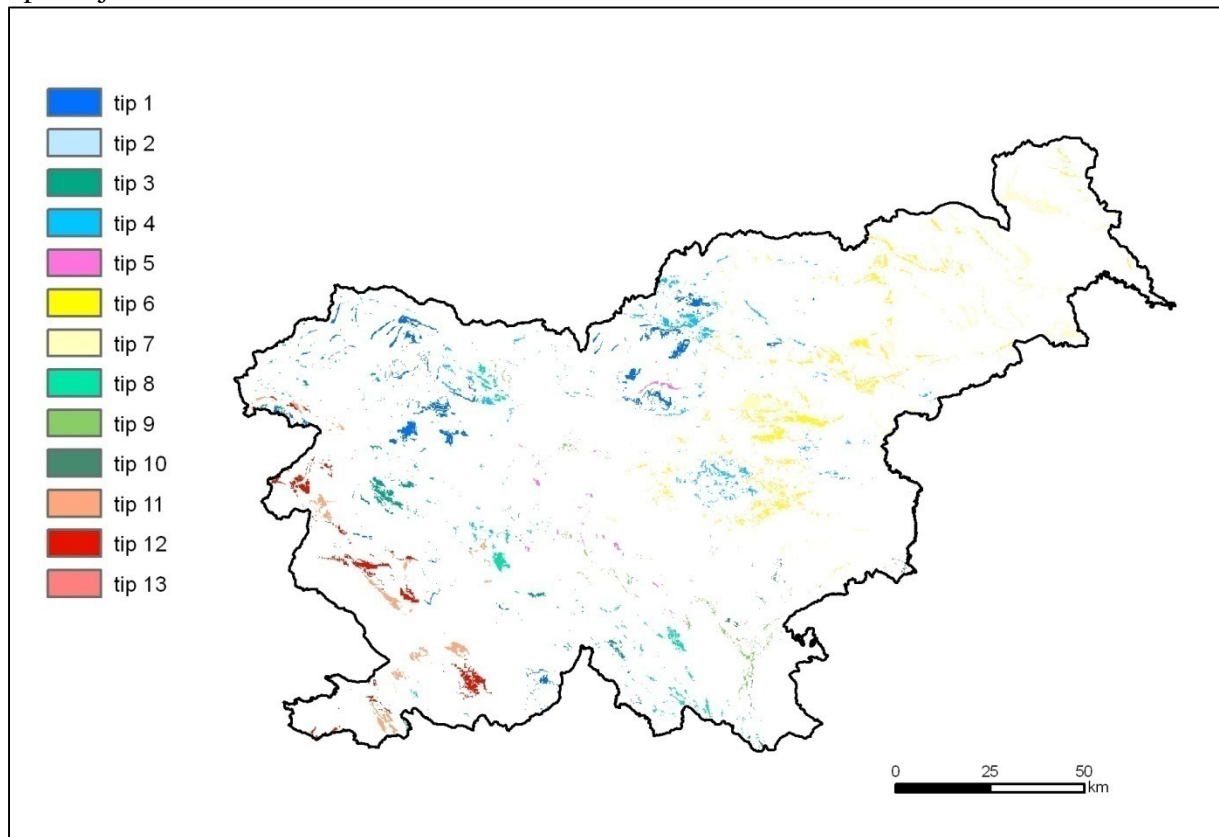
Preglednica 97: Celice, ki so v vseh modeliranih tipizacijah enako klasificirane, a niso enake izvorni tipizaciji TIP13.

oznaka tipa	modeli z naključnim vzorcem		modeli z ekspertnim vzorcem	
	število celic	delež od vseh celic v Sloveniji (%)	število celic	delež od vseh celic v Sloveniji (%)
1	4015	0,8	1868	0,4
2	3	0,0	10	0,0
3	1398	0,3	1979	0,4
4	2226	0,4	3300	0,7
5	394	0,1	122	0,0
6	4435	0,9	10254	2,0
7	3234	0,6	3510	0,7
8	1633	0,3	163	0,0
9	683	0,1	1772	0,4
10	221	0,0	149	0,0
11	1782	0,4	1414	0,3
12	2217	0,4	3641	0,7
13	0	0,0	77	0,0
skupaj	22.241	4,4	28.259	5,6

Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIP13

K **tipu visokogorski svet (1)** spadajo pobočja nekaterih dolin (na primer Planica) ter nekaterih vrhov (na primer Snežnik, Uršlja gora, Veliki Rogatec, Golte, Menina planina, Porezen, Ratitovec) in zelo strma pobočja (na primer Nanos, Jelovica). K **tipu širše rečne doline v visokogorju, hribovju in na krasu (2)** se klasificira le nekaj celic. K **tipu visoke kraške planote in hribovja v karbonatnih kamninah (3)** se klasificirajo manjši deli v visokogorju (del Matajurja ...), velik del Cerkljanskega hribovja, Slivnica, del Goteniške gore. K **tipu hribovja v pretežno nekarbonatnih kamninah (4)** se klasificirajo območje med Topolšico, Uršljo goro in Smrekovcem, manjša območja v Posavskem hribovju, Dobrovljah, na Kozjanskem, na Jelovici, dolina Tržiške Bistrice, Donačka gora. K **tipu medgorske kotline (5)** se klasificira le nekaj manjših območij z nekaj celicami (na primer Radensko polje, dolina Drete, dolina Borovniščiце s pritoki). K **tipu gričevja v notranjem delu Slovenije (6)** spadajo osrednji del Posavskega hribovja med Krmeljem, Sevnico in Radečami ter med Celjem, Laškim in Šentjurjem ter obrobni deli ravnin v severovzhodni Sloveniji in hribovij (na primer Boča). K **tipu ravnine in širše doline v gričevju notranjega dela Slovenije (7)** spadajo osrednji del Celjske kotline, nekatere doline v Slovenskih goricah in na Goričkem (na primer dolina Ledave) ter okolica Slovenske Bistrice. K **tipu kraška polja in podolja (8)** spadajajo manjši del Menišije, okolice Logatca, nekatere terase ob Savi med Radovljico in Naklim ter deli Kočevske (na primer obrobje Male gore). K **tipu nizki kras Notranjske in Dolenjske (9)** spadajo posamične celice na območjih dinarske pregrade (Kočevski Rog, Ribniška Mala gora). K **tipu nizki kras Bele krajine (10)** spadajo le posamezne celice obrobja Bele krajine, celice v okolici Dolenjskih Toplic, na Barju in v Krški kotlini. K **tipu Kras in Podgorski kras (11)** spadajo del Kraškega roba, okolica Košane, območje jugovzhodno od Štanjela ter Grgarskih Ravn in Grgarja. Posamezne zaplate celic se pojavljajo okoli Kobarida, Logatca in Hrpelj. K **tipu gričevje v primorskem delu Slovenije (12)** spadajo del Vipavskih brd, manjši del pobočij Soške doline med Kambreškimi in Banjšicami, okolica Ilirske Bistrice ter nekateri deli na Kraškem robu. K **tipu širše doline in obalne ravnice v primorskem delu Slovenije (13)** v tej kategoriji ne spada nobeno območje.

Slika 83: Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI13.



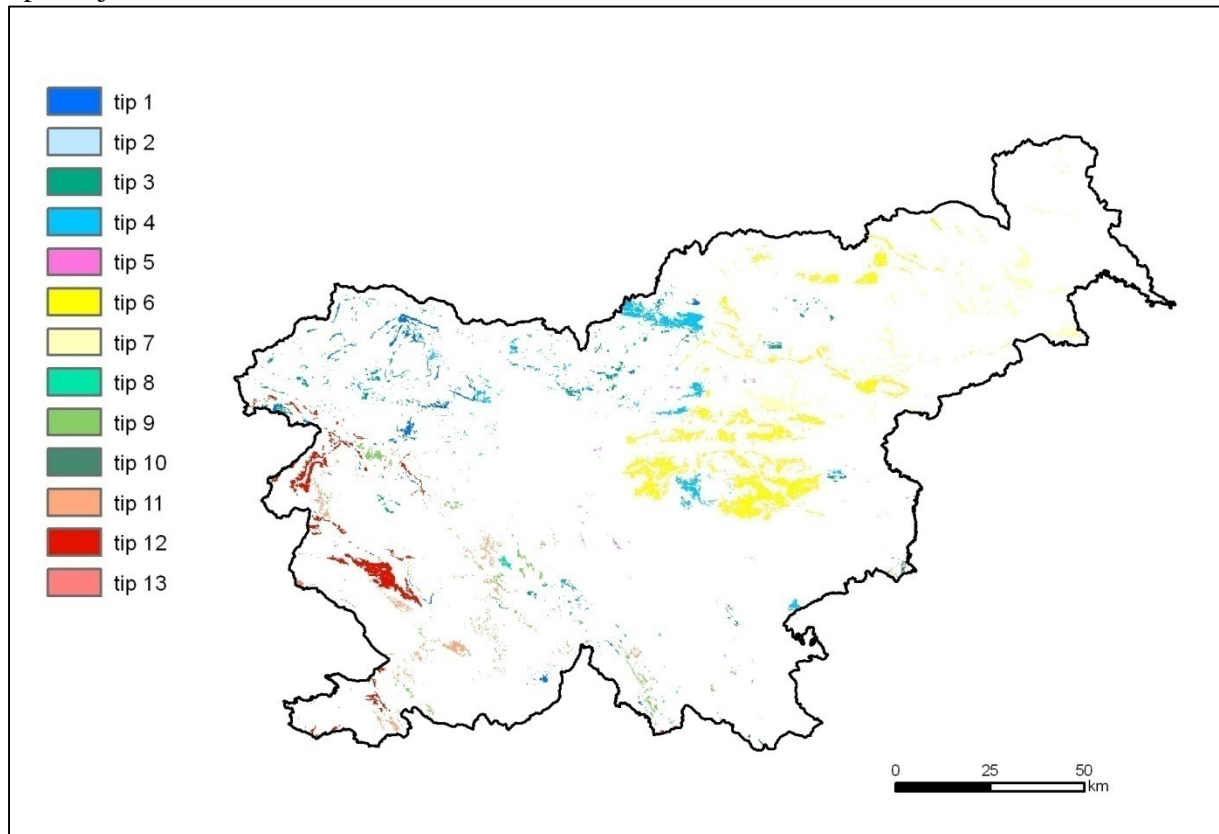
Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI13

K **tipu visokogorski svet (1)** spadajo pobočja nekaterih dolin (na primer Planica, dolina Kolpe) ter nekateri vrhov (na primer Snežnik, Uršlja gora, Veliki Rogatec, Porezen, Ratitovec) in zelo strma pobočja (na primer Nanos). K **tipu širše rečne doline v visokogorju, hribovju in na krasu (2)** se klasificira le nekaj celic. K **tipu visoke kraške planote in hribovja v karbonatnih kamninah (3)** se klasificirajo Paški Kozjak, vrh Bohorja ter manjši deli v visokogorju (del Matajurja, Velike planine ...). K **tipu hribovja v pretežno nekarbonatnih kamninah (4)** se klasificirajo območje med Topolšico, Peco in Olševo, najvišji deli osrednjih Gorjancev, del Dobrovelj in nekatera manjša območja v Posavskem hribovju. K **tipu medgorske kotline (5)** se klasificira le nekaj manjših območij z nekaj celicami (na primer Radensko polje). K **tipu gričevja v notranjem delu Slovenije (6)** spadajo precejšen del Posavskega hribovja ter obrobni deli okrog Pohorja ter hribovij med Slovenj Gradcem in Rogaško Slatino. K **tipu ravnine in širše doline v gričevju notranjega dela Slovenije (7)** spadajo vzhodni del Celjske kotline, nekatere doline v Slovenskih goricah ter okolica Slovenske Bistrice. K **tipu kraška polja in podolja (8)** spadajo manjši deli Menišije in nekaj celic drugod po Sloveniji. K **tipu nizki kras Notranjske in Dolenjske (9)** spadajo posamične celice na območju dinarske pregrade. Še največji območji sta del Cerkljanskega hribovja in Kočevskoreškega ravnika. K **tipu nizki kras Bele krajine (10)** spadajo le posamezni deli obrobja Bele krajine in okolice Dolenjskih Toplic. K **tipu Kras in Podgorski kras (11)** spada del Kraškega roba, okolica Košane, območje jugovzhodno od Štanjela ter Grgarskih Ravn in Gragarja. Posamezne celice se pojavljajo okoli Logatca. K **tipu**

gričevje v primorskem delu Slovenije (12) spadajo Vipavska brda, pobočja doline Soče med Kambreškimi in Banjšicami ter nekateri deli na Kraškem robu.

K tipu širše doline in obalne ravnice v primorskem delu Slovenije (13) spada le skrajni zahodni del Brestoviškega dola.

Slika 84: Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvorno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI13.



8.6 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij

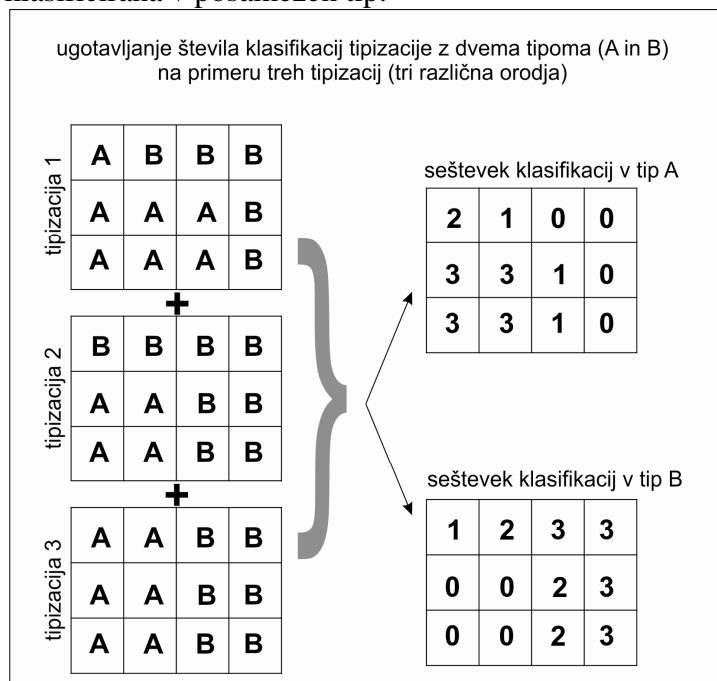
Vsako modelirano tipizacijo smo razdelili tako, da je bil na vsakem zemljevidu prikazan po en izmed tipov, nato pa smo zemljevide z enakimi tipi sešteli (slika 85).

Tako smo za TIPI9 za vsako metodo modeliranja dobili 9 zemljevidov. Za posamezno metodo so na prvem prikazane celice tipa alpska gorovja (oznaka 1.1), na drugem alpska hribovja (1.2), na tretjem alpske ravnine (1.3) itd. Zemljevide rezultatov različnih metod klasifikacij smo nato sešteli po posameznih tipih. Tako smo za vsak tip dobili zemljevid, ki prikazuje, kolikokrat je bila po uporabi vseh metod nadzorovane klasifikacije posamezna celica klasificirana v določen tip. Ker smo uporabili sedem metod, je najvišja možna vrednost 7, najnižja pa 0.

Pri analizi TIPI13 smo dobili za vsak način modeliranja 13 zemljevidov. Na prvem so bile prikazane celice tipa visokogorski svet (oznaka 1), na drugem tipa širše rečne doline v visokogorju, hribovju in na krasu (2), na tretjem tipa visoke kraške planote in hribovja v karbonatnih kamninah (3) itd. Zemljevide rezultatov različnih metod klasifikacij smo nato sešteli po posameznih tipih. Tako smo dobili za vsak tip zemljevid, ki prikazuje, kolikokrat je bila po uporabi vseh metod nadzorovane klasifikacije posamezna celica klasificirana v posamezen tip. Ker smo uporabili sedem metod, je najvišja možna vrednost 7, najnižja pa 0.

Zopet smo naredili analizo ločeno za modelirane tipizacije, ki so narejene na podlagi naključnega vzorca učnih celic, in modelirane tipizacije, ki so narejene na podlagi ekspertnega vzorca učnih celic.

Slika 85: Prekrivanje modeliranih tipizacij za ugotavljanje, kolikokrat je posamezna celica klasificirana v posamezen tip.

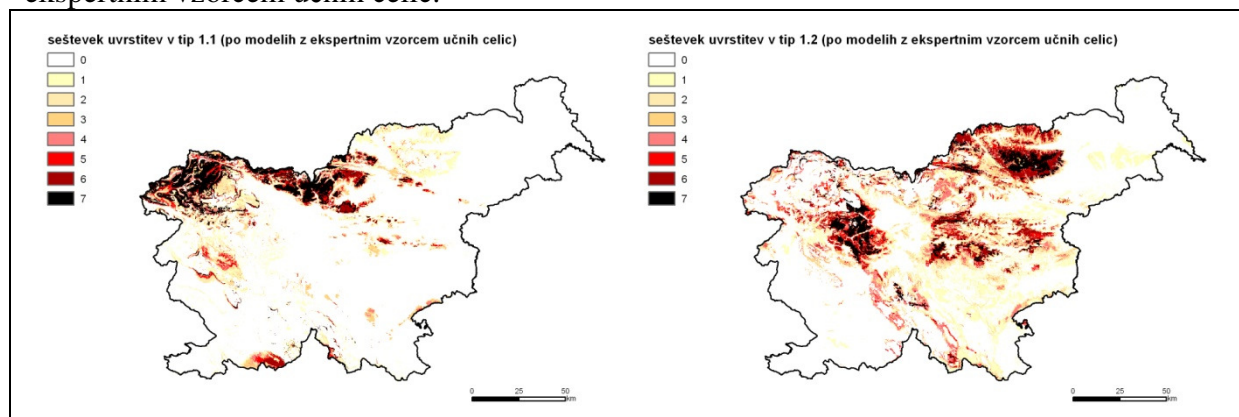


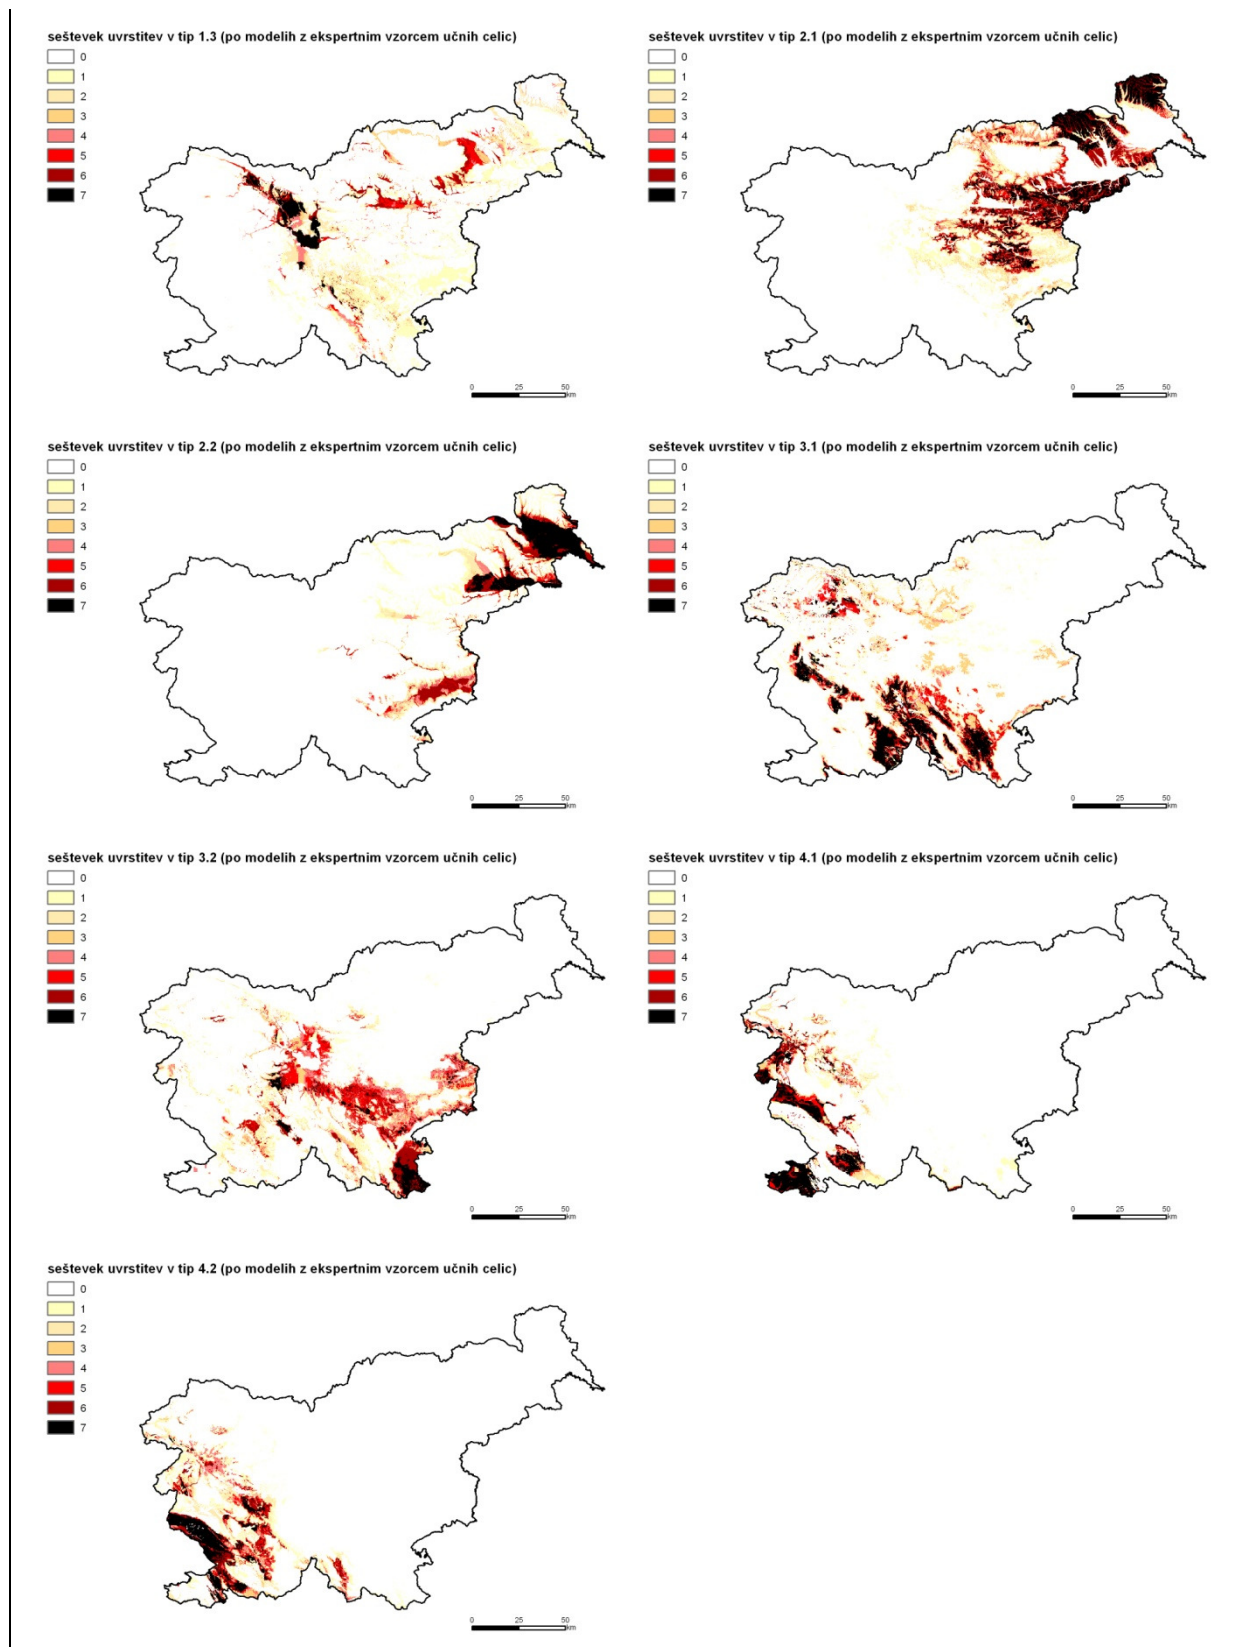
8.6.1 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij TIPI9

V tem poglavju so najprej prikazani zemljevidi in opis za modelirane tipizacije TIPI9, ki so narejene na podlagi ekspertnega vzorca učnih celic (slika 86), nato pa še modelirane tipizacije TIPI9, ki so narejene na podlagi naključnega vzorca učnih celic (slika 87). Ob koncu primerjamo, ali se rezultati razlikujejo zaradi različnega vzorčenja učnih celic (preglednica 98).

Pregled posameznih zemljevidov posameznih tipov modeliranih tipizacij TIPI9, ki so narejene z ekspertnim vzorcem učnih celic

Slika 86: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI9 z ekspertnim vzorcem učnih celic.





Kot **alpska gorovja (1.1)** so prepoznana območja Julijskih Alp, Kamniško-Savinjskih Alp, Karavank, Menine planine, Pece, Plešivca, zelo pogosto pa tudi višji, predvsem strmi, deli v sredogorju (Paški Kozjak, Boč, Kum) ter strma pobočja Trnovskega gozda, Nanosa, Kolpske doline. Nekoliko redkeje so kot alpska gorovja označene planote, kot sta Pokljuka in Jelovica,

obrobje Pohorja, Cerkljansko hribovje. Veliko območje, ki je južno od Ilirske Bistrice, je nepričakovano kar nekajkrat klasificirano kot alpsko gorovje. Razlog je verjetno ta, da ima to območje podobne vrednosti glede padavinskega režima in prepustnosti kot zahodni del Julijskih Alp. Gre torej predvsem za najvišje, zelo razgibane dele severne Slovenije, kjer so večinoma bolj prepustne kamnine. Sem spadajo tudi bolj strma pobočja drugih delov Slovenije.

Kot **alpsko hribovje (1.2)** so najpogosteje klasificirani Škofjeloško in Polhograjsko hribovje, Pohorje, osrednji deli Posavskega hribovja, Smrekovško pogorje, Kozjak, severni del Blok in Kočevskoroškega ravnika. Gre za območja z manj prepustnimi kamninami. Nekatere klasifikacije sem klasificirajo tudi dele Brkinov in Slovenskih goric. Gre predvsem za območja manj prepustnih kamnin v osrednji in severni Sloveniji, relief je razgiban.

Kot **alpske ravnine (1.3)** so zelo pogosto klasificirana območja Ljubljanske kotline, Celjske kotline in severnega dela Dravske ravni, pa tudi manjša uravnana območja v okolici Slovenj Gradca, Šoštanja in Mozirja. Sem pogosto spadajo tudi širši deli dolin v celotni severni, osrednji in vzhodni Sloveniji (na primer doline Poljanske Sore, Save, Savinje, Drave). Pogosto spadajo sem tudi Iški vršaj, Dobropolje, nekoliko manj pogosto Kočevskoribniško polje, Suha krajina, Krška ravan. Gre predvsem za uravnana, prodnata območja v severni Sloveniji.

Kot **panonska gričevja (2.1)** so pogosto klasificirana vsa bolj razgibana območja v severovzhodni Sloveniji (na primer Goričko, Haloze, Ložniško gričevje), pa tudi nižji deli Posavskega hribovja in Krško gričevje. Nekoliko manj pogosto so tako klasificirana vznožja Gorjancev in zahodnega dela Pohorja. Pogosto so izvzete rečne doline (predvsem širše), ki imajo bolj uravnano dno. Gre za povečini manj prepustna, bolj razgibana območja v severovzhodni Sloveniji na nižji nadmorski višini, kjer je padavinski režim bolj celinski. Intenzivnost klasifikacije **panonskih ravnin (2.2)** vidno upada v smeri SV–JZ. Osrednjim ravnem ob Muri in Dravi (ki sta največkrat klasificirani kot panonski ravnini) so pridruženi bolj uravnani deli rečnih dolin v okolici. Celjska kotlina ni pogosto označena kot panonska ravnina, nekoliko večkrat je tako označena Krška kotlina. Opazno je, da je severni del Dravske ravni redkeje klasificiran kot panonska ravnina; to območje se klasificira tudi kot alpska ravnina. Gre torej za območja, ki so v severovzhodni Sloveniji na ravnini ob večjih vodotokih. Kamninska podlaga je večinoma prod ali pesek.

Kot **dinarske planote (3.1)** so največkrat označeni Trnovski gozd, Nanos, Snežniško pogorje, Bloke, Ribniška Velika in Mala gora, Stojna, Borovška gora, Rog, del Banjšic, pa tudi planote Pokljuka, Mežakla, Jelovica. Nekoliko manj pogosto se sem klasificirajo tudi Gorjanci, deli Posavskega hribovja, obrobni deli alpskega gorovja. Sem spadata po modeliranih tipizacijah tudi Slavnik in Vremščica. Gre za območja v južnem delu Slovenije ter mestoma v severnem delu z nadmorsko višino okrog 1000 m, kjer so kamnine precej prepustne.

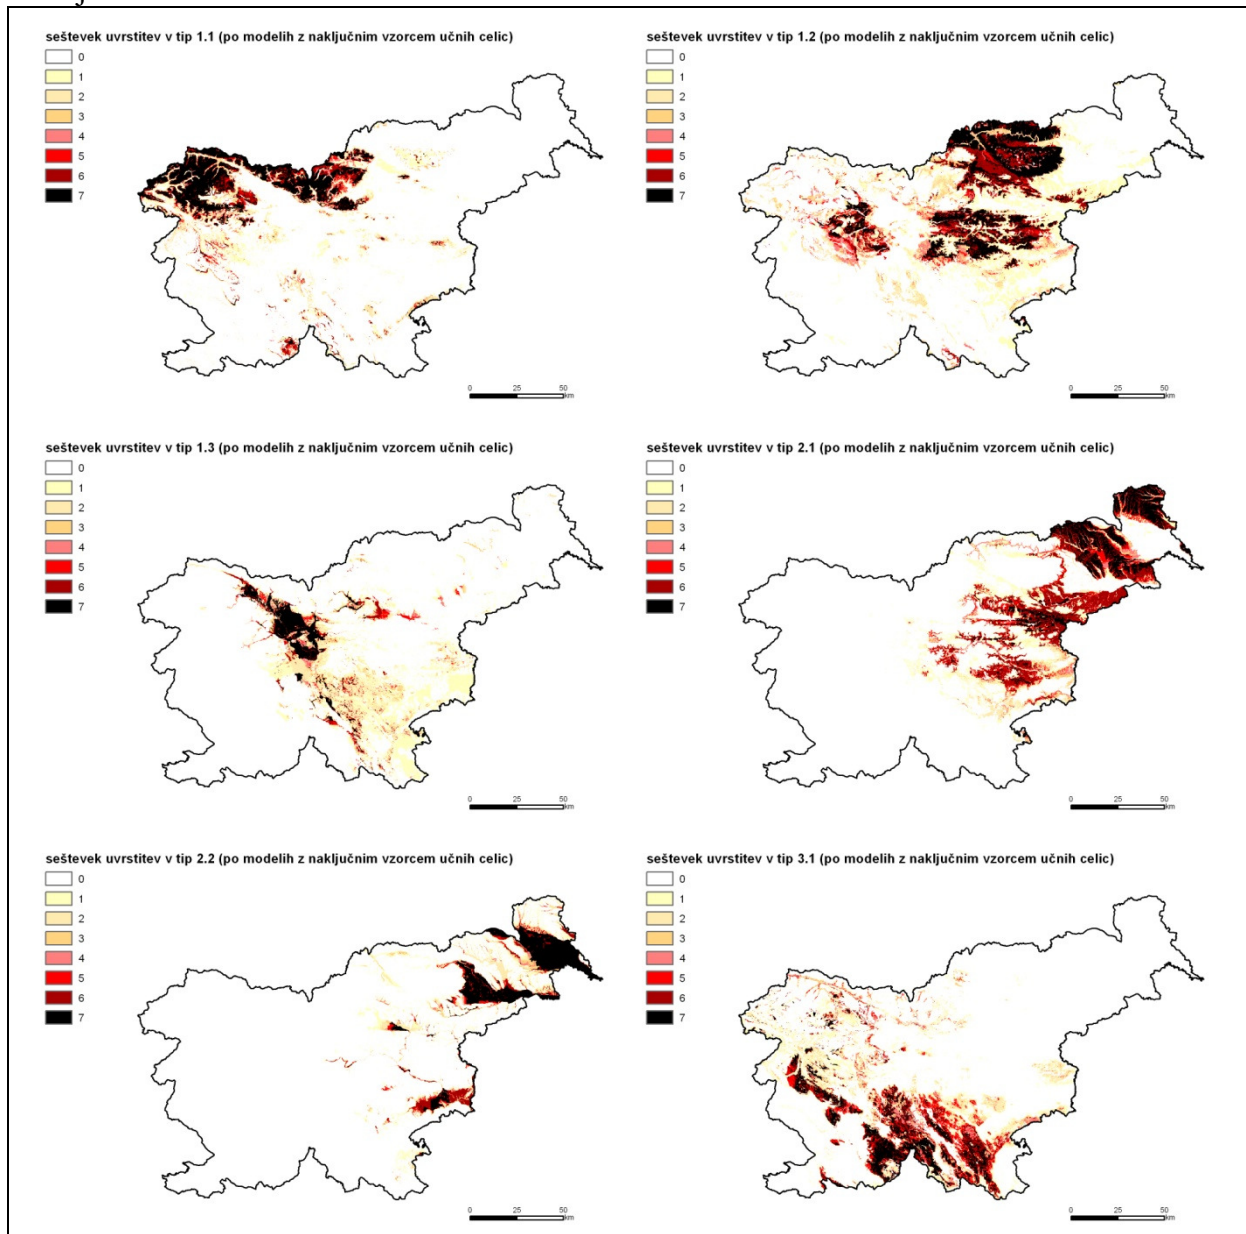
K **dinarskim podoljem in ravnikom (3.2)** glede na klasifikacije nedvoumno spadata Bela krajina in Cerkniško polje, nekoliko manj pa Ljubljansko barje, Dolenjsko podolje, Kočevskoribniško polje, zahodna Krška kotlina, Pivška kotlina in tudi Bohinj. Modeli sem pogosto klasificirajo tudi obrobje Ljubljanske kotline ter višje dele severno od Ljubljane. Sem so po nekaterih modelih prištete tudi rečne doline ob Soči, Poljanski Sori, Savi itd. Dokaj pogosto se sem klasificirata tudi Kozjansko in Bizeljsko. Gre za bolj uravnana ali manj razgibana območja v osrednji Sloveniji, kjer so kamnine bolj prepustne.

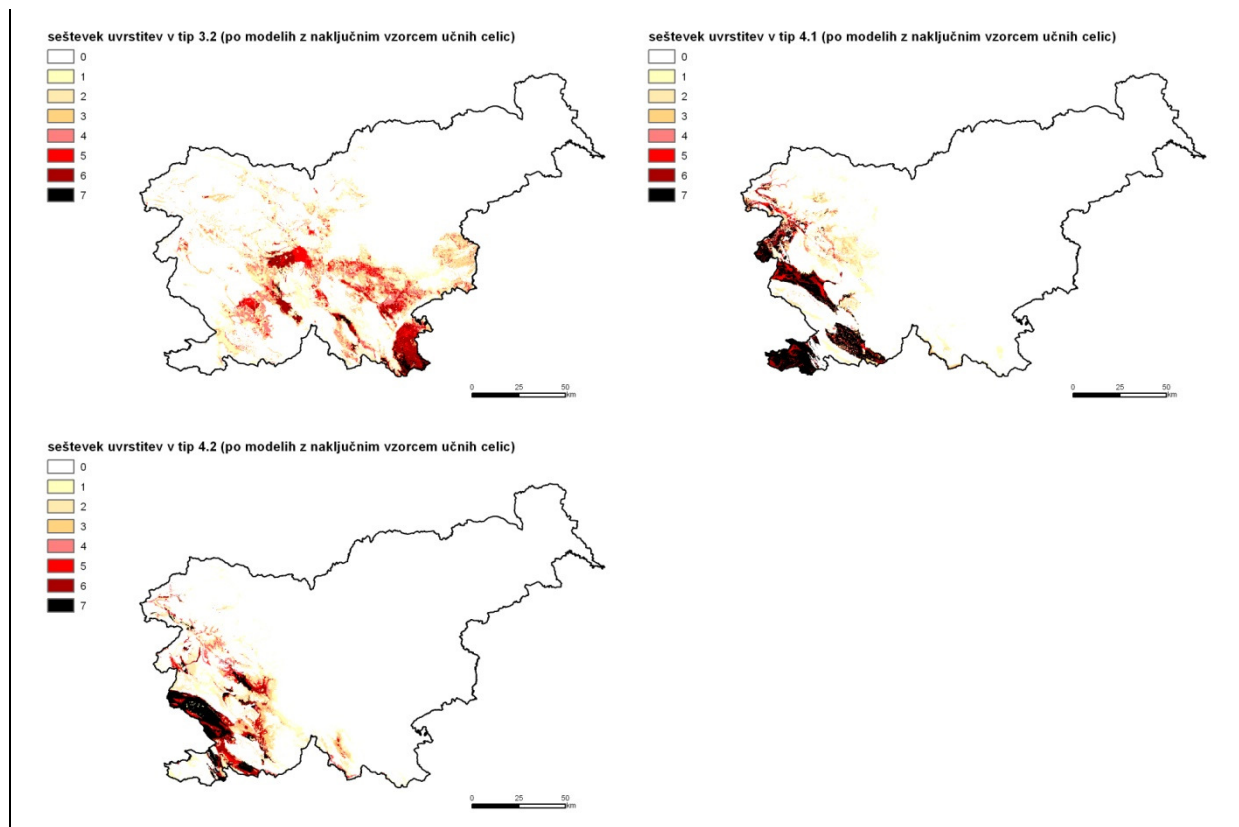
Pri klasificiranju tipa **sredozemska gričevja (4.1)** so si modeli dokaj enotni. Nedvoumno so to območja Goriških brd, Vipavske doline, Brkini (predvsem SZ polovica), Koprsko primorje, poleg tega pa modeli sem klasificirajo tudi Kambreško, dele Soške doline ter Idrijskega hribovja. Pogosto modeli klasificirajo kot sredozemsko gričevje tudi del Zgornjekolpske doline, Bohinj, redko tudi dele Bele krajine. V splošnem gre za območja v zahodni Sloveniji, kjer prevladuje bolj mediteranski padavinski režim in je relief dokaj razgiban, prepustnost kamnin pa manjša od okoliških kraških območij.

Kot **sredozemse planote (4.2)** so po modelih določeni Kras, Podgorski kras, Matarsko podolje (brez najvišjih delov Čičarije), manj intenzivno pa deli Cerkljanskega hribovja, okolice Logatca, Pivke, Postojne in Kočevskoreškega ravnika, del Banjšic (predvsem okolica Grgarja), Čepovski dol. Gre za območja v zahodni Sloveniji z bolj prepustnimi kamninami in manj razgibanim reliefom.

Pregled posameznih zemljevidov posameznih tipov modeliranih tipizacij TIPI9, ki so narejene z naključnim vzorcem učnih celic

Slika 87: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI9 z naključnim vzorcem učnih celic.





K alpskim gorovjem (1.1) so klasificirane Julijske in Kamniško-Savinjske Alpe, Karavanke (brez večjih dolin), pogosto tudi najvišji deli Snežniškega pogorja, Menine planine, Paškega Kozjaka, nekajkrat pa tudi vrhnji del Pohorja, Gorjance in najvišji deli Posavskega hribovja (Kum, Bohor) in Cerkljanskega hribovja. Prav tako so pogosto k alpskim gorovjem klasificirana strma pobočja (Trnovski gozd, Nanos, Kolpska dolina).

K alpskim hribovjem (1.2) spadajo Pohorje, Kozjak, Smrekovško pogorje, Paški Kozjak (brez višjega dela), Boč, Donačka gora, Macelj ter višji del Posavskega (brez Kuma in Bohorja), Škofjeloškega in Polhograjskega hribovja. Nekatere modelirane tipizacije sem uvrščajo tudi Haloze, Krško gričevje, Slemena, dele Bizeljskega, Gorjancev, Menišije in Blok, Dravinjske gorice, pa tudi nekatere alpske doline (na primer Soška) in njihova pobočja.

K alpskim ravninam (1.3) po modelih spada predvsem Ljubljanska kotlina, ob tem pa je treba dodati, da so najvišja in razgibana območja med Domžalami, Ljubljano in Medvodami manjkrajt klasificirana kot alpska ravnina, prav tako Udin Boršt, Tunjiško gričevje in podobna razgibana območja. K alpskim ravninam pogosto spadajo tudi zahodni in vzhodni del Celjske kotline, dolina Savinje med Ljubnim in Mozirjem, dolina Drete, ravnice pri Slovenskih Konjicah in Slovenski Bistrici, Iški vršaj, Dobropolje, del Kočevskoribniškega polja. Nekaj klasifikacij sem prišteva Ljubljansko barje, vzhodni rob Ljubljanske kotline, Krško ravan, Suho krajino, del Bele krajine, vznožje Gorjancev. Območja, ki so po modelih klasificirana kot alpske ravnine, se nahajajo izključno vzhodno od dinarske pregrade oziroma v povodju Črnega morja.

Kot **panonska gričevja (2.1)** so klasificirana vsa gričevnata območja na severovzhodu in vzhodu: Goričko, Lendavske gorice, Slovenske gorice, Dravinjske gorice, Haloze, Ložniško gričevje, severno Kozjansko, pogosto tudi Bizeljsko, južno Kozjansko, Krško gričevje, vznožje Gorjancev, obrobje Celjske in Krške kotline, Pohorja. Pogosto so sem klasificirani tudi pobočja širših rečnih dolin ali pa kar celotne (ožje) doline rek, kot so Drava, Sava, Savinja. Redko ali nikoli niso sem prišteti višji strmi deli (na primer Boč, Orlica, Bohor, Konjiška gora). Vsa naštetja območja se nahajajo vzhodno od Ljubljanske kotline.

Klasifikacija **panonskih ravnin (2.2)** je prav tako omejena na severovzhodni in vzhodni del Slovenije. Osrednjim ravnem ob Muri in Dravi, ki sta največkrat klasificirani kot panonski ravnini, so pridruženi tudi bolj uravnani deli rečnih dolin v okolici. Celjska kotlina je pogosto označena kot panonska ravnina v vzhodnem delu, manj pogosteje na zahodnem delu, pogosto je v ta tip klasificirana tudi Krška kotlina.

Kot **dinarske planote (3.1)** so pogosto klasificirana območja na višji nadmorski višini dinarske pregrade. Sem spadajo del Banjšic, Trnovski gozd, Nanos, Javniki, Snežniško pogorje, Bloke, višji deli Kočevske, Rog, Vremščica, višji deli Čičarije, manj pogosto pa Gorjanci, Suha krajina, Dobrulska gričevje, južno Kozjansko, Idrijsko hribovje, severno obrobje Ljubljane ter planote na severu (na primer Pokljuka). Po nekaterih modelih v ta tip spadajo tudi alpske doline.

Kot **dinarska podolja in ravniki (3.2)** se pogosto klasificirajo območja Notranjskega podolja, Ljubljanskega barja, Dolenjskega podolja, Bele krajine, Kočevskoribniškega polja in Pivške kotline. Sem se uvrščajo tudi zahodna Krška kotlina, Bizeljsko in južno Kozjansko, na zahodu tudi Matarsko podolje. Nepričakovano se v ta tip nekajkrat klasificirajo tudi obrobja hribovij z različnih koncev Slovenije.

K **sredozemskim gričevjem (4.1)** se klasificirajo Koprsko primorje, Brkini (brez okolice Škocjana), Vipavska dolina, Kambreško, Goriška brda in deli Soške doline. Sem spada pogosto tudi Bovška kotlina, redko tudi hribovje okoli Žirov.

Poleg Krasa, Matarskega podolja in Podgorskega krasa se med **sredozemske planote (4.2)** klasificirajo tudi Slavinski ravniki, del Pivške kotline, območje med Logatcem in Idrijo, vznožje Nanosa pri Vipavi, Čepovanski dol ter deli Soške doline in Cerkljanskega hribovja. Sem po nekaterih modeliranih tipizacijah spadajo tudi zgornja dolina Kolpe, Notranjsko podolje in Kočevskoreški ravniki. Tu so predvsem območja na prepustnih kamninah, kjer so razviti kraški pojavi, ter so na zahodu Slovenije, kjer prevladuje sredozemski padavinski režim. Gre tudi za bolj uravnana območja.

Povezanost seštevka klasifikacij v določen tip za posamezno celico po modeliranih tipizacijah TIPI9 z ekspertnimi učnimi celicami in seštevka klasifikacij v določen tip za posamezno celico po modeliranih tipizacijah TIPI9 z naključnimi učnimi celicami

Tak način seštevanja klasifikacij po posameznih tipih omogoča prehod iz več trdnih modeliranih tipizacij v mehko modelirano tipizacijo posameznega tipa. Zemljevidi (na slikah 86 in 87) za vsako celico prikazujejo, koliko uporabljenih metod jo je klasificiralo v posamezen tip. Na tak način lahko vidimo, kje so jedra posameznih tipov in kje obrobja. Z izračunom Pearsonovega in Spearmanovega koeficienta (preglednica 98) smo želeli ugotoviti, kolikšna je podobnost seštevka za posamezen tip med obema načinoma modeliranja (z ekspertnim in naključnim vzorčenjem). Najbolj se povezujejo rezultati za sredozemske planote, sredozemska gričevja in panonske ravnine. Če izvzamemo alpske ravnine, vidimo, da je razhajanje med seštevki klasifikacij po modeliranih tipizacijah z naključnim vzorčenjem in seštevki klasifikacij po modeliranih tipizacijah z ekspertnim vzorčenjem učnih celic večje pri tipih, ki so večji po površini. To je pričakovano, saj je pri manjšem tipu razhajanje med obema naboroma učnih celic manjše. Vse povezanosti so statistično značilne pri $p=0,01$.

Ujemanje je seveda manjše, če upoštevamo samo celice, ki so po vsaj eni modelirani tipizaciji pri posameznem tipu vsaj enkrat klasificirane. Pri upoštevanju vseh celice so povezanosti boljše zaradi velikega števila vrednosti 0 na obeh straneh.

Preglednica 98: Pearsonov in Spearmanov koeficient ($p=0,01$) povezanosti za posamezne seštevke trdnih modeliranih tipizacij TIPI9 po posameznih tipih za modelirane tipizacije, narejene z ekspertnim vzorcem, in modelirane tipizacije, narejene z naključnim vzorcem učnih celic.

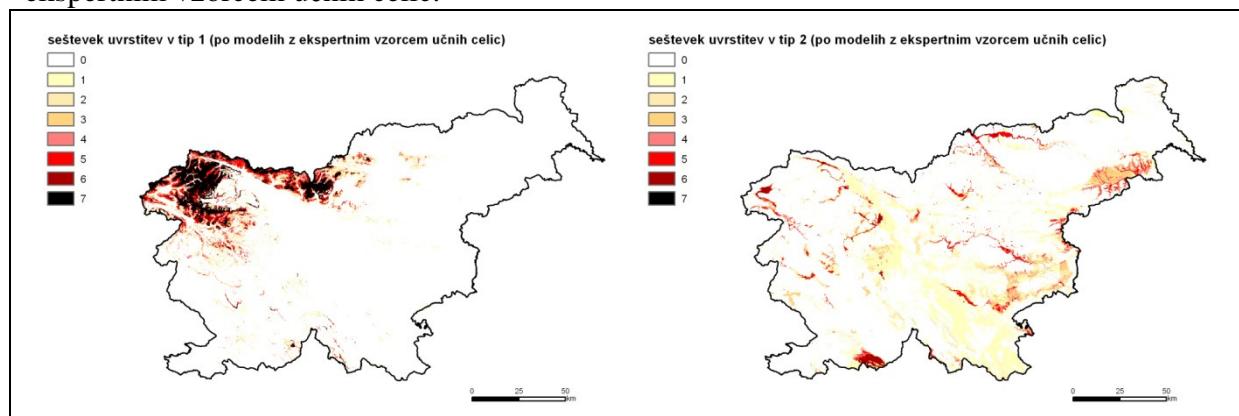
tip	število celic v tipu po izvirni klasifikaciji	upoštevane vse celice		upoštevane samo celice, ki so klasificirane v tip vsaj po eni od metod	
		Pearsonov koeficient	Spearmanov koeficient	Pearsonov koeficient	Spearmanov koeficient
alpska gorovja	76533	0,817	0,698	0,651	0,551
alpska hribovja	116478	0,739	0,698	0,559	0,494
alpske ravnine	20481	0,736	0,606	0,570	0,220
panonska gričevja	74719	0,826	0,788	0,611	0,587
panonske ravnine	32336	0,910	0,891	0,773	0,745
dinarske planote	95190	0,839	0,715	0,689	0,584
dinarska podolja in ravniki	47387	0,773	0,731	0,523	0,447
sredozemska gričevja	26490	0,923	0,874	0,792	0,786
sredozemske planote	16836	0,908	0,848	0,790	0,762

8.6.2 Celice po pripadnosti posameznim tipom modeliranih naravnopokrajinskih tipizacij TIPI13



V tem poglavju so najprej prikazani zemljevidi seštevke po posameznih tipih in njihov opis za modelirane tipizacije TIPI13, ki so narejene na podlagi ekspertnega vzorca učnih celic (slika 88), nato pa še zemljevidi in opisi za modelirane tipizacije TIPI13, ki so narejene na podlagi naključnega vzorca učnih celic (slika 89). Ob koncu ugotavljamo, ali so ti seštevki različni zaradi vzorčenja učnih celic (preglednica 99).

Pregled posameznih zemljevidov posameznih tipov modeliranih tipizacij TIPI13, ki so narejene z ekspertnim vzorcem učnih celic



Slika 88: Seštevke uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI13 z ekspertnim vzorcem učnih celic.





seštevek uvrstitev v tip 3 (po modelih z ekspertnim vzorcem učnih celic)





seštevek uvrstitev v tip 4 (po modelih z ekspertnim vzorcem učnih celic)





seštevek uvrstitev v tip 5 (po modelih z ekspertnim vzorcem učnih celic)





seštevek uvrstitev v tip 6 (po modelih z ekspertnim vzorcem učnih celic)





seštevek uvrstitev v tip 7 (po modelih z ekspertnim vzorcem učnih celic)





seštevek uvrstitev v tip 8 (po modelih z ekspertnim vzorcem učnih celic)

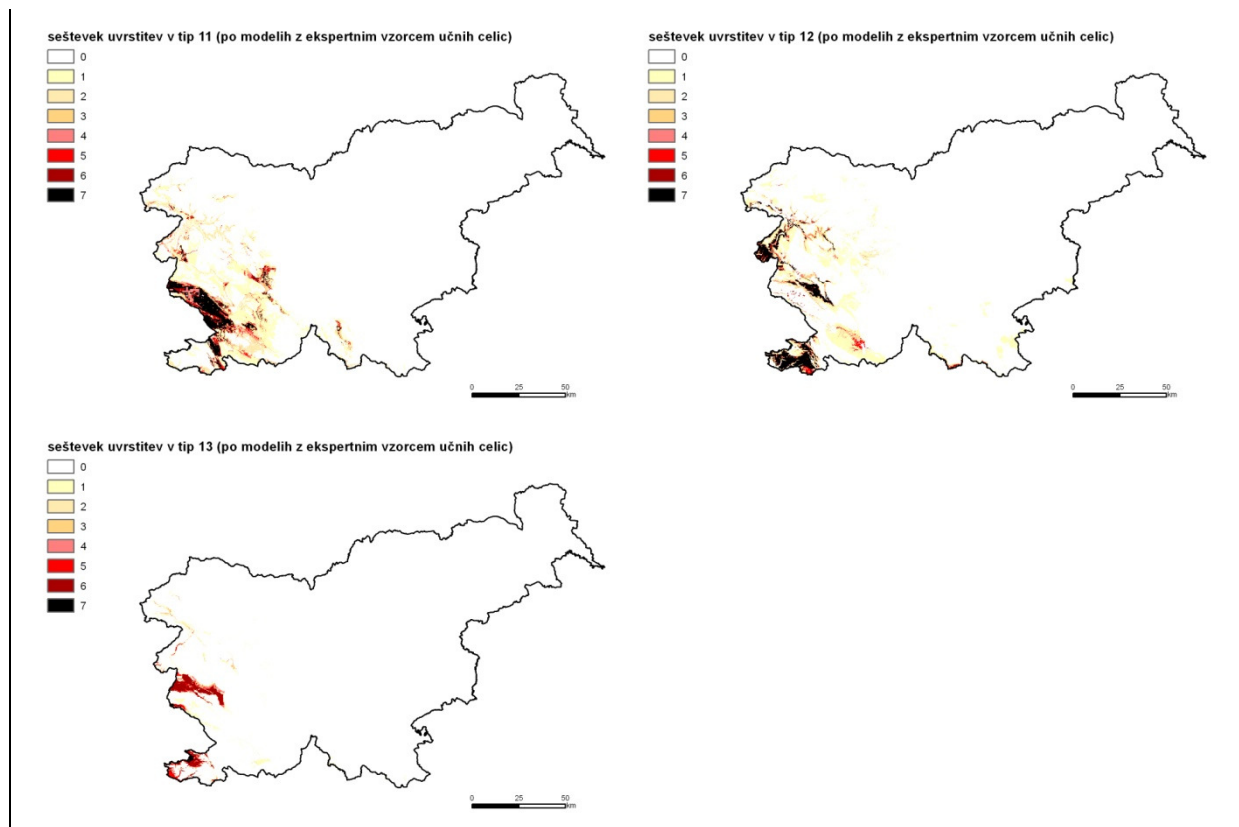


seštevek uvrstitev v tip 9 (po modelih z ekspertnim vzorcem učnih celic)



seštevek uvrstitev v tip 10 (po modelih z ekspertnim vzorcem učnih celic)





Tip visokogorski svet (1) je največkrat klasificiran v Julijskih in Kamniško-Savinjskih Alpah, Karavankah (brez dolin), na Snežniku in strmih pobočjih Nanosa, Kolpske doline, redko pa v najvišjih delih hribovij na severovzhodu Slovenije (na primer Pohorje, Paški Kozjak).

Tip širše rečne doline v visokogorju, hribovju in na krasu (2) je največkrat klasificiran v gorskih dolinah (ob Savi, Soči ...) in hribovjih v notranjem dele Slovenije (ob Krki, Savi, Dravi ...), presenetljivo pogosto tudi v okolici Ptuja, ob Sotli ter južno od Ilirske Bistrice. Slednje je verjetno posledica podatkovnega sloja padavinskega režima in prepustnosti.

Kot **tip visoke kraške planote in hribovja v karbonatnih kamninah (3)** je pogosto označeno območje dinarskih kraških planot, Gorjancev, alpskih planot (Pokljuka, Mežakla, Jelovica, Menina planina), kar precej pogosto pa tudi Paški Kozjak, Kum, Bohor, Uršlja gora, Matajur. Sem se klasificirajo tudi obrobni deli Karavank in Kamniško-Savinjskih Alp.

Kot **tip hribovja v pretežno nekarbonatnih kamninah (4)** je pogosto klasificirano Pohorje, Kozjak, Strojna, Smrekovec in hribovje okoli Črne, velik del Posavskega, Škofjeloškega in Polhograjskega hribovja (brez najvišjih delov) in dokaj pogosto tudi območje Idrijskega hribovja in Trnovskega gozda (vzhodni del). Sem se pogosto klasificirajo tudi Donačka gora, Macelj, vrhnji del Gorjancev in Loški Potok.

Kot **tip medgorske kotline (5)** so najpogosteje označeni območje Ljubljanske kotline (brez razgibanih in višjih delov, kot je denimo Rašica), zahodna Celjska kotlina, Velenjska kotlina, dokaj dobro tudi Slovenjgraška kotlina, obrobje Pohorja, Dobrepolje, konkavni deli Posavskega hribovja. Presenetljivo redko sem spadajo tudi Kozjansko, Dolenjsko podolje ter deli Dravske in Krške ravni.

Kot **tip gričevje v notranjem delu Slovenije (6)** so klasificirani izključno reliefno razgibani deli severovzhodne Slovenije, kot so Goričko, Slovenske gorice, Haloze, del Posavskega hribovja (predvsem pobočja nad Savo), Kozjansko, Ložniško in Hudinjsko gričevje, Dravinjske gorice in okolica Lovrenca na Pohorju ter Starega trga pri Slovenj Gradcu. Vmes so le redko klasificirane tudi doline v teh gričevjih. Redko sem spadajo tudi južno obrobje

Pohorja, južno Kozjansko, Bizeljsko, vznožje Gorjancev ter jugozahodni del Posavskega hribovja.

Kot **tip ravnine in širše doline v gričevju notranjega dela Slovenije (7)** so klasificirane večje ravne površine na severovzhodu in vzhodu Slovenije: Murska in Dravska ravan (slednja je na osrednjem jugovzhodnem delu klasificirana v ta tip nekoliko manj pogosto), vzhodna Celjska kotlina, Krška ravan ter večje doline (Ščavnice, Pesnice, Savinje, Sotle, Dravinje, Voglajne). Sem spadajo pogosto tudi dolina Mirne pri Mirni in Mokronogu ter dolina Laknice. Dolina Save (z Litijsko kotlino), Velenjska kotlina, Slovenjgraška kotlina in dolina Drave med Pohorjem in Kozjakom se po eni metodi prav tako klasificirajo kot tip ravnine in širše doline v gričevju notranjega dela Slovenije.

Kot **tip kraška polja in podolja (8)** se najpogostje klasificirajo območja Notranjskega in Dolenjskega podolja, Dobrepolje, Kočevskoribniško polje, Pivška kotlina, deli Kočevskoreškega ravnika, severni del Matarskega podolja. Presenetljivo se pogosto sem klasificirajo tudi vzhodni deli Ljubljanske kotline, nekatere terase ob Savi, dolina Horjulščice, Bohinj. Redkeje se sem klasificirajo zahodno Ljubljansko barje ter Dežela, obrobje Bizeljskega, Gorjancev in deli Kozjanskega.

Kot **tip nizki kras Notranjske in Dolenjske (9)** so najpogosteje klasificirani območja Suhe krajine, Banjšic, Brkinov (!), Čičarije, Slavinskega ravnika, obrobja Pivške kotline, okolice Logatca, Blok, del osrednje Dolenjske, del Kočevskoreškega ravnika, Dragarske doline, severno obrobje Bele krajine. Sem spadajo Bizeljsko (večina sicer redko), Breginjski kot, obrobje Bohinja, deli alpskih dolin in obrobja kotlin, dolin v južni in vzhodni Sloveniji.

Kot **tip nizki kras Bele krajine (10)** so klasificirani Bela krajina, okolica Dolenjskih Toplic, Kostel in vzhodni, obmejni del ob Sotli do sotočja s Savo. Redko se sem klasificirajo tudi nekatera območja Krške ravni, Bizeljskega, Kočevske Male gore in rob Ljubljanske kotline.

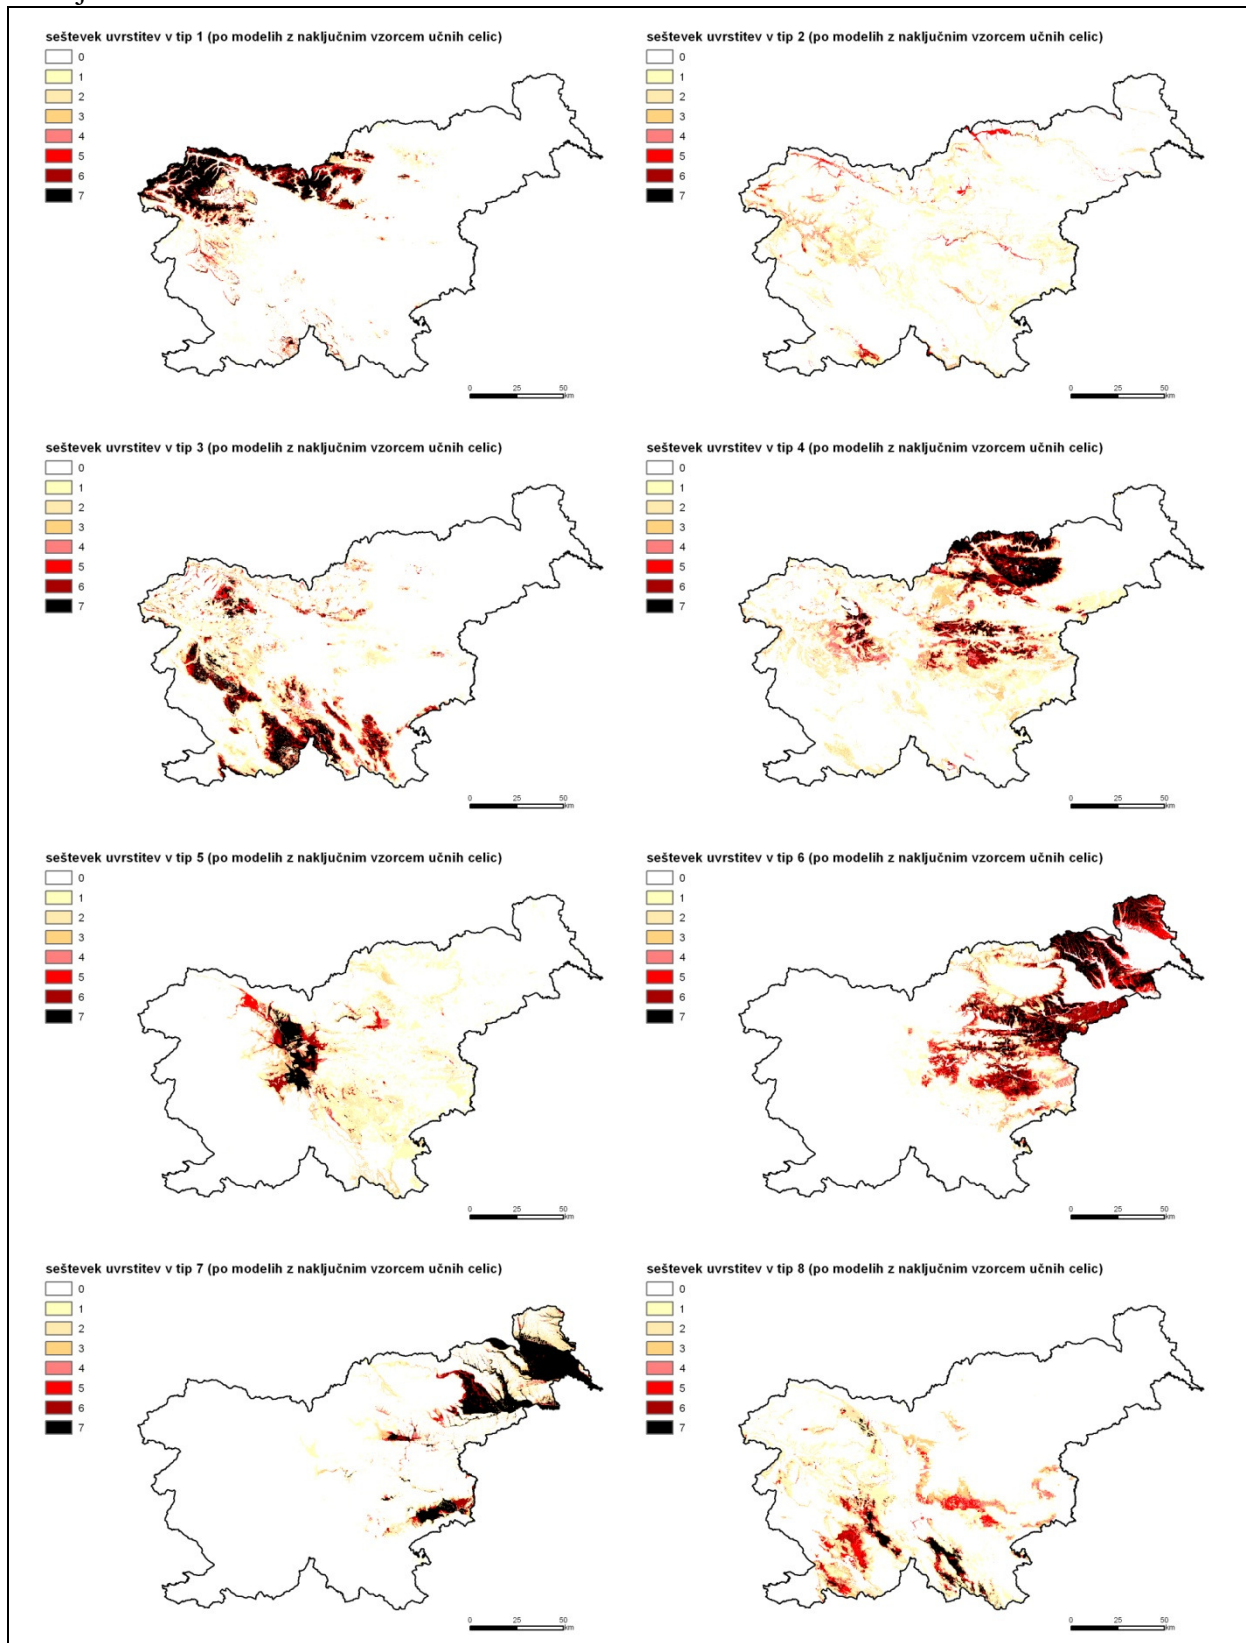
Tip Kras in Podgorski kras (11) je določen na območju Krasa, Podgorskega krasa, Kraškega roba, okolice Logatca, Košane, Grgarskih raven in Grgarja. Redko sem spadajo Pivška kotlina ter doline Jadranskega povodja (Idrijca, Soča, Bača ...). Deloma se sem klasificira tudi Kočevskoreški ravniki.

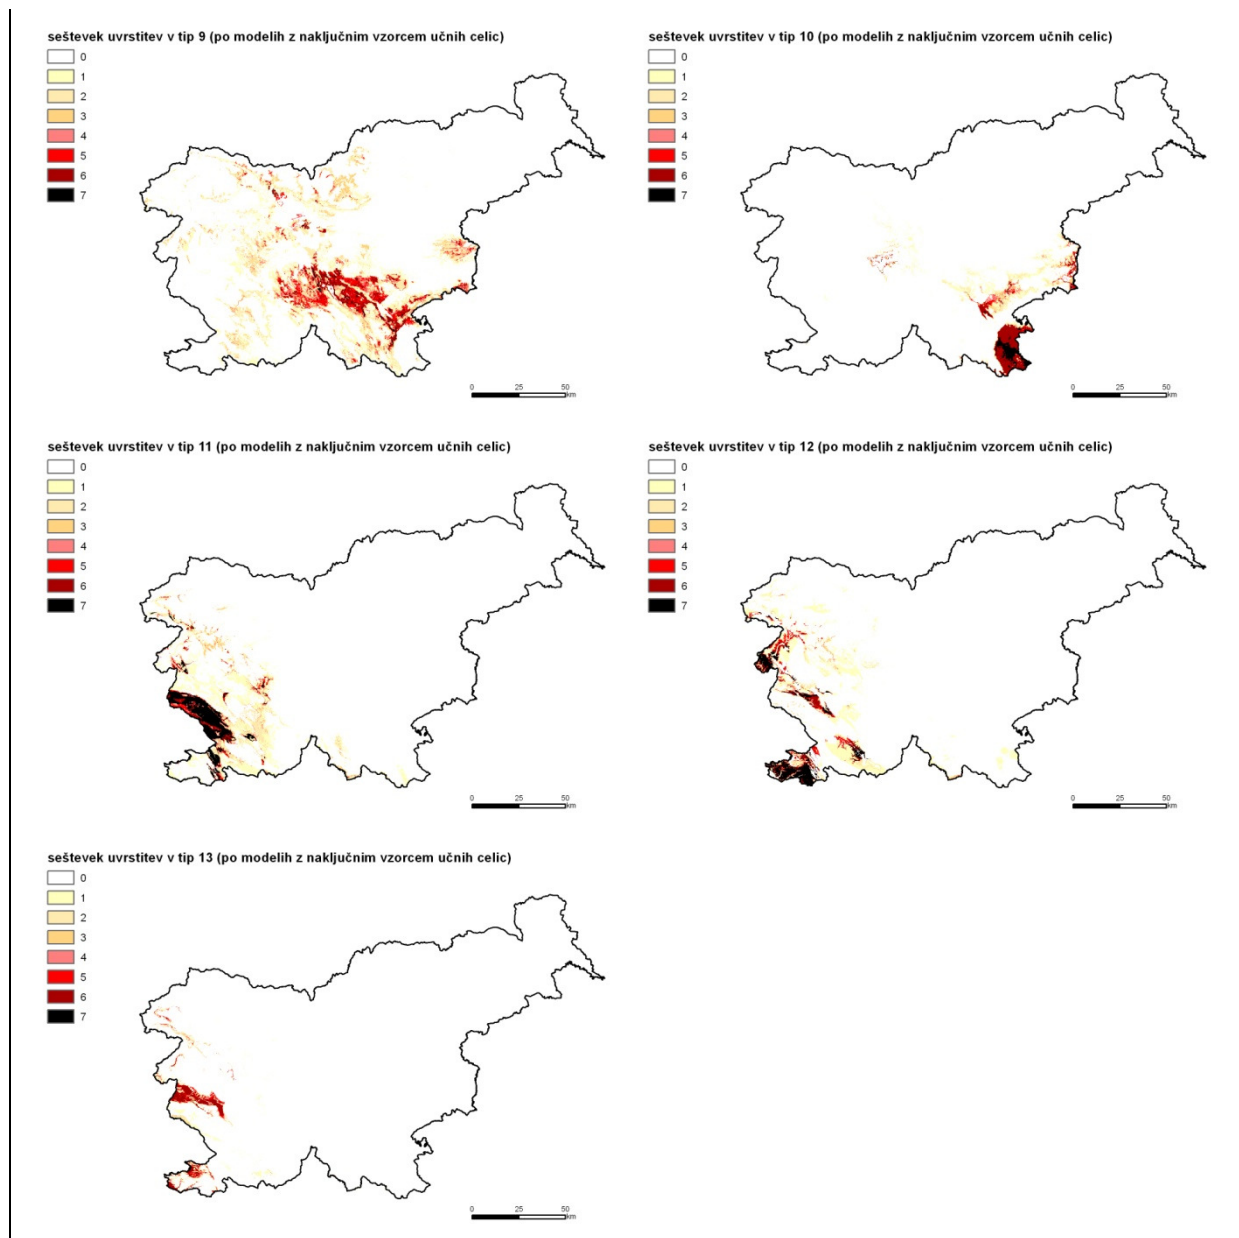
Tip gričevje v primorskem delu Slovenije (12) je določen na območju Vipavskih brd, Goriških brd, Koprškega primorja, pobočjih nad Sočo in delu Brkinov, delu doline Kolpe. Redko sem spadajo Bohinj, Bovška kotlina, večji del Brkinov, Pivška kotlina, deli Bele krajine.

Kot **tip širše doline in obalne ravnice v primorskem delu Slovenije (13)** so določeni Vipavska dolina, doline v Koprškem primorju, Brestovski dol, doline v Goriških brdih, redko tudi Soška dolina in okolica Ilirske Bistrice.

Pregled posameznih zemljevidov posameznih tipov modeliranih tipizacij TIPI13, ki so narejene z naključnim vzorcem učnih celic

Slika 89: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI13 z naključnim vzorcem učnih celic.





Tip visokogorski svet (1) je največkrat klasificiran v Julijskih in Kamniško-Savinjskih Alpah, Karavankah (brez dolin), Snežniku, Menini planini in strmih pobočjih Nanosa, Kolpske doline v najvišjih delih hribovij na severovzhodu Slovenije (na primer Paški Kozjak, Kum, Mrzlica). Redko se sem klasificira Pohorje.

Tip širše rečne doline v visokogorju, hribovju in na krasu (2) je največkrat klasificiran v gorskih dolinah Save, Soče in drugih (doline Krke, Save, Drave ...) v notranjem delu Slovenije, presenetljivo pogosto tudi v okolici Ilirske Bistrice. Slednja uvrstitev je verjetno posledica podatkovnega sloja padavinskega režima in prepustnosti.

Kot **tip visoke kraške planote in hribovja v karbonatnih kamninah (3)** so pogosto označeni območje dinarskih kraških planot, Gorjancev, alpskih planot (Pokljuka, Mežakla, Jelovica, Menina planina), Kraški rob in Čičarija, kar precej pogosto pa tudi Paški Kozjak, Kum, Bohor, Uršlja gora, Matajur. Sem se klasificirajo tudi obrobni deli Karavank in Kamniško-Savinjskih Alp.

Kot **tip hribovja v pretežno nekarbonatnih kamninah (4)** so pogosto klasificirani Pohorje, Kozjak, Strojna in hribovje okoli Črne, velik del Paškega Kozjaka, Posavskega, Škofjeloškega

in Polhograjskega hribovja (brez najvišjih delov), Dobrovlje. Sem se pogosto klasificirajo tudi Boč, Donačka gora, Macelj, Konjiška gora in Šibje pri Kočevju.

Kot **tip medgorske kotline (5)** so najpogosteje označeni območje Ljubljanske kotline (brez razgibanih in višjih delov, kot je na primer Rašica) s podaljški ob Poljanski in Selški Sori ter drugih vodotokih, zahodna Celjska kotlina, Dobropolje, dolina Drete in Savinje pri Mozirju. Redko sem spadajo tudi Velenjska kotlina, dokaj dobro pa Slovenjgraška kotlina, obrobje Pohorja, (presenetljivo) Kozjansko ter Dolenjsko podolje.

Kot **tip gričevje v notranjem delu Slovenije (6)** so klasificirani izključno reliefno razgibani deli severovzhodne Slovenije, kot so Goričko, Lendavske gorice, Slovenske gorice, Haloze, del Posavskega hribovja (predvsem pobočja nad Savo), del Kozjanskega, Ložniško in Hudinjsko gričevje, Dravinjske gorice in okolica Lovrenca na Pohorju ter Starega trga pri Slovenj Gradcu, južno obrobje Pohorja. Vmes so manj pogosteje klasificirane tudi doline v teh gričevjih. Redko sem spadajo tudi južno obrobje Pohorja, južno Kozjansko, Bizeljsko, vznožje Gorjancev.

Kot **tip ravnine in širše doline v gričevju notranjega dela Slovenije (7)** so klasificirane večje ravne površine na severovzhodu in vzhodu Slovenije: Murska in Dravska ravan, vzhodna Celjska kotlina, Krška ravan ter večje doline ob Ščavnici, Pesnici, Savinji, Sotli, Dravinji, Voglajni in Ledavi. Sem pogosto spadajo tudi dolina Mirne pri Mirni in Mokronogu. Dolina Save (z Litijsko kotlino), Velenjska kotlina, Slovenjgraška kotlina in dolina Drave med Pohorjem in Kozjakom se po eni metodi prav tako klasificirajo kot tip ravnine in širše doline v gričevju notranjega dela Slovenije.

Kot **tip kraška polja in podolja (8)** se najpogosteje klasificirajo območja Notranjskega podolja in Dolenjskega podolja, Dobropolje, Kočevskoribniško polje, Pivška kotlina, deli Kočevskoreškega ravnika ter Matarsko podolje. Presenetljivo pogosto se sem klasificirajo tudi obrobni deli Ljubljanske kotline, pogosteje nekatere terase ob Savi ter Bohinj. Redkeje se sem klasificirajo tudi zahodno Ljubljansko barje ter Dežela, Brkini, obrobje Gorjancev, deli Kozjanskega in okolica Ljubnega ob Savinji.

Kot **tip nizki kras Notranjske in Dolenjske (9)** so najpogosteje klasificirani območja Suhe krajine, Blok, večji del osrednje Dolenjske, Dragarske doline, severno obrobje Bele krajine, obrobje Gorjancev. Sem spadajo tudi Bizeljsko (večina območja sicer redko), Udin Boršt, Rašica, Šmarna gora, Kozjansko. Redko sem spadajo doline v visokorju, obrobja kraških polj, kotlin v osredju Slovenije, Brkini, deli Kočevske, Banjšic, Bohinja.

Kot **tip nizki kras Bele krajine (10)** so klasificirani Bela krajina, okolica Dolenjskih Toplic, Kostel in vzhodni, obmejni del ob Sotli do sotočja s Savo. Redko se sem klasificirajo tudi nekatera obrobna območja Krške ravni, Bizeljskega in Ljubljanskega barja.

Tip Kras in Podgorski kras (11) je določen na območju Krasa, Podgorskega krasa, Kraškega roba, okolice Logatca, Košane, Grgarskih raven in Grgarja. Redko sem spadajo Pivška kotlina ter doline Jadranskega povodja (doline Idrijce, Soče, Bače ...). Deloma se sem klasificirajo tudi Kočevskoreški ravniki, dolina Kolpe in Suha krajina na skrajnem jugu.

Tip gričevje v primorskem delu Slovenije (12) je določen na območju Vipavskih brd, Goriških brd, Koprškega primorja, na pobočjih nad Sočo, manjšem delu Brkinov in delu doline Kolpe. Redko sem spadajo Bohinj, Bovška kotlina, večji del Brkinov, Pivška kotlina, deli Bele krajine, Idrijskega hribovja in Banjšic.

Kot **tip širše doline in obalne ravnice v primorskem delu Slovenije (13)** so določeni Vipavska dolina, doline v Koprškem primorju, doline v Goriških brdih, redko tudi Brestovski dol, Soška dolina in okolica Ilirske Bistrice.

Povezanost seštevka klasifikacij v določen tip za posamezno celico po modeliranih tipizacijah TIPI13 z ekspertnimi učnimi celicami in seštevka klasifikacij v določen tip za posamezno celico po modeliranih tipizacijah TIPI13 z naključnimi učnimi celicami

Tak način seštevjanja klasifikacij po posameznih tipih omogoča prehod iz več trdnih modeliranih tipizacij v mehko modelirano tipizacijo za posamezen tip. Zemljevidi (sliki 88 in 89) za vsako celico prikazujejo, koliko uporabljenih metod jo je klasificiralo v posamezen tip. Na tak način lahko ugotovimo, kje so jedra posameznih tipov in kje obrobja.

Z izračunom Pearsonovega in Spearmanovega koeficienta (preglednica 99) smo želeli ugotoviti, kolikšna je podobnost med obema načinoma modeliranja (z ekspertnim in naključnim vzorčenjem) pri seštevku za posamezen tip. Ob upoštevanju vseh celic je ujemanje med seštevki klasifikacij modeliranih tipizacij, ki so izdelane z ekspertnim vzorcem, in seštevki klasifikacij modeliranih tipizacij, ki so izdelane z naključnim vzorcem, večinoma dobro (izjema je le tip širše rečne doline v visokogorju, hribovju in na krasu), a tu je treba upoštevati velik vpliv vrednosti 0, ki pri vsakem zemljevidu prekriva večino območja. Če upoštevamo samo celice, ki so bile vsaj po enem načinu klasificirane v določen tip, dobimo nižje stopnje povezanosti, kar kaže na velik vpliv načina vzorčenja na modeliranje tipizacij. Kljub temu da so vse povezave statistično značilne, ne moremo mimo nekaterih nizkih stopenj povezanosti. Izstopata po Spearmanovem koeficientu (celo!) negativna povezanost za tip širše rečne doline v visokogorju, hribovju in na krasu ter nizka (pozitivna) stopnja povezanosti pri tipu nizki kras Notranjske in Dolenjske. Torej, vzorčenje vpliva na rezultat.

Preglednica 99: Pearsonov in Spearmanov koeficient povezanosti ($p=0,01$) za posamezne seštevke trdnih modeliranih tipizacij TIPI13 po posameznih tipih za modelirane tipizacije, narejene z ekspertnim vzorcem, in modelirane tipizacije, narejene z naključnim vzorcem učnih celic.

tip	upoštevanje vseh celic		upoštevane samo celice, ki so klasificirane v tip vsaj po eni od metod		število celic v tipu po izvorni klasifikaciji
	Pearsonov koeficient	Spearmanov koeficient	Pearsonov koeficient	Spearmanov koeficient	
visokogorski svet	0,879	0,810	0,696	0,691	42.210
širše rečne doline v visokogorju, hribovju in na krasu	0,418	0,201	0,171	-0,281	18.174
visoke kraške planote in hribovja v karbonatnih kamninah	0,766	0,635	0,589	0,447	89.759
hribovja v pretežno nekarbonatnih kamninah	0,736	0,700	0,532	0,432	113.363
medgorske kotline	0,724	0,653	0,558	0,321	31.652
gričevje v notranjem delu Slovenije	0,804	0,825	0,551	0,539	82.034
ravnine in širše doline v gričevju notranjega dela Slovenije	0,878	0,853	0,695	0,687	44.400
kraška polja in podolja	0,697	0,568	0,514	0,286	22.141
nizki kras Notranjske in Dolenjske	0,599	0,610	0,305	0,198	27.185
nizki kras Bele krajine	0,886	0,730	0,773	0,568	8272
Kras in Podgorski kras	0,874	0,827	0,756	0,543	12.651
gričevje v primorskem delu Slovenije	0,909	0,847	0,822	0,636	8431
širše doline in obalne ravnice v primorskem delu Slovenije	0,910	0,853	0,748	0,715	6178

8.7 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij za preverjanje pripadnosti posameznim tipom

Analiza v tem delu je namenjena ugotavljanju, ali so v prejšnjem poglavju izdelani zemljevidi pripadnosti celic posameznim tipom (kolikokrat je posamezna celica klasificirana kot določen tip; poglavje 8.6) relevantni oziroma objektivni. V prejšnjem poglavju smo dobili neke vrste mehke klasifikacije za posamezne tipe tako, da smo seštevali trdne klasifikacije za posamezne tipe. Za dopolnitev in preveritev dobljenih zemljevidov smo v tem delu uporabili še nekaj geoinformacijskih orodij (preglednica 100), s katerimi smo neposredno izdelali prave mehke tipizacije. Te smo nato primerjali z ustreznimi seštevki modeliranih trdnih tipizacij po posameznih tipih in izračunali Pearsonove in Spearmanove koeficiente povezanosti.

Preglednica 100: Geoinformacijska orodja za izdelavo mehkih nadzorovanih klasifikacij.

oznaka	metoda	rezultat za posamezno celico
MXL	mehka različica metode največje verjetnosti	največja verjetnost posameznega tipa
MDS	mehka različica metode najmanjše razdalje (brez prestavljanja centroidov)	najmanjša razdalja od centroida posameznega tipa
CTE	mehka različica metode odločitvenega drevesa z (različica CTE)	verjetnost (delež) posameznega tipa v končnem vozlišču
CTG	mehka različica metode odločitvenega drevesa z (različica CTG)	verjetnost (delež) posameznega tipa v končnem vozlišču
CTR	mehka različica metode odločitvenega drevesa z (različica CTR)	verjetnost (delež) posameznega tipa v končnem vozlišču
KNN	mehka različica metode najbližjih sosedov	delež števila sosedov iz posameznega tipa

8.7.1 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij TIPI9

Pri neposredni izdelavi mehkih tipizacij na podlagi izvirne tipizacije TIPI9 (priloga 12) smo dobili za vsak način modeliranja in za vsak način izbire učnih celic po 9 zemljevidov, skupaj torej 108 zemljevidov (2 načina vzorčenja x 6 načinov modeliranja x 9 tipov).

8.7.2 Povezanost mehkih modeliranih naravnopokrajinskih tipizacij TIPI9 s seštevkom trdnih modeliranih naravnopokrajinskih tipizacij TIPI9

Dobljene mehke modelirane tipizacije (priloga 12) smo po posameznih tipih med seboj primerjali ter ugotavljali, kako dobro so med seboj povezane. Izračunali smo Pearsonov koeficient korelacije ter Spearmanov koeficient korelacije. V primerjavo smo vključili tudi seštevke trdnih klasifikacij v posamezen tip iz prejšnjega dela (poglavje 8.6; slike 86 in 87). Povezanost smo izračunali tako, da smo upoštevali le tiste celice, ki imajo po seštevku trdnih klasifikacij pri preučevanem tipu vrednost vsaj 1.

Za TIPI9 smo ugotovili, da se seštevke trdnih klasifikacij po posameznih tipih vedno statistično značilno ($p=0,001$) povezuje z različnimi mehкими modeliranimi tipizacijami, koeficienti pa so različno visoki (preglednica 165 v priloga 13), nekateri izmed njih so izjemno nizki ali celo rahlo negativni – na primer povezanost pri tipu alpska hribovja (na podlagi naključnega vzorčenja učnih celic) med seštevkom trdnih klasifikacij in mehko najmanjšo razdaljo od centroida tega tipa. Izmed ostalih kombinacij mehkih klasifikacij sta tudi dva primera, ko povezanosti nista statistično značilni³¹.

Po tem načinu izračunavanja je pri vseh tipih povprečna stopnja povezanosti Pearsonovih in Spearmanovih koeficientov najpogosteje najvišja ravno pri koeficientih stopnje povezanosti, ki vključujejo seštevke klasifikacij po posameznih tipih (predzadnja kolona v preglednici 165

³¹ Pearsonov koeficient pri stopnji povezanosti med verjetnostjo (deležem) v končnem vozlišču po odločitvenem drevesu CTE in najmanjšo razdaljo od centroida za tip alpska hribovja (po naključnem naboru učnih celic) ter Spearmanov koeficient pri stopnji povezanosti med verjetnostjo (deležem) v končnem vozlišču po odločitvenem drevesu CTE in največjo verjetnostjo za tip dinarska podolja in ravniki (po ekspertnem naboru učnih celic) sta statistično neznačilna. To pomeni, da o povezanosti v teh dveh primerih ne moremo sklepati.

v prilogi 13). To je pričakovano, saj je seštevek nekakšen sumarni rezultat vseh uporabljenih metod. Izjem je zato le malo, pojavljajo pa se le pri Pearsonovih koeficientih: pri tipu alpska hribovja, alpske ravnine in tipu sredozemska gričevja (vsi po naključnem naboru). Iz ugotovitev lahko zaključimo, da je število trdnih klasifikacij k določenemu tipu za posamezno celico lahko dokaj dober prikaz mehke tipizacije³².

8.7.3 Izdelava mehkih modeliranih naravnopokrajinskih tipizacij TIPI13

Pri neposredni izdelavi mehkih tipizacij na podlagi TIPI13 (priloga 12) smo dobili za vsak način modeliranja in za vsak način izbire učnih celic po 13 zemljevidov, skupaj torej 156 zemljevidov (2 načina vzorčenja x 6 načinov modeliranja x 13 tipov).

8.7.4 Povezanost mehkih modeliranih naravnopokrajinskih tipizacij TIPI13 s seštevkom trdnih modeliranih naravnopokrajinskih tipizacij TIP13

Dobljene zemljevide za TIPI13 (priloga 12) smo med seboj primerjali ter ugotavljali, kako dobro so med seboj povezani. Izračunali smo Pearsonov koeficient korelacije ter Spearmanov koeficient korelacije. V primerjavo smo vključili tudi seštevek trdnih klasifikacij v posamezen tip iz prejšnjega dela (poglavje 8.6; sliki 88 in 89). Povezanost smo izračunali tako, da smo upoštevali le tiste celice, ki imajo po seštevku trdnih klasifikacij pri preučevanem tipu vrednost najmanj 1.

Ugotovili smo, da se mehka klasifikacija, ki smo jo dobili s seštevanjem trdnih klasifikacij, vedno statistično značilno ($p=0,001$) povezuje z ostalimi mehкими klasifikacij, koeficienti pa so različno visoki, v nekaj primerih tudi negativni (preglednica 166 v prilogi 13). Izmed ostalih kombinacij mehkih klasifikacij je celo nekaj takšnih primerov, pri katerih ni statistično značilne povezanosti³³.

Po tem načinu imajo večinoma v povprečju najvišje stopnje povezanosti koeficienti, ki vključujejo seštevek trdnih klasifikacij v posamezen tip (predzadnja kolona v preglednici 166

³² Ob tem je treba omeniti, da je statistično sklepanje o povprečnem koeficientu stopnje povezanosti zaradi šestih posamičnih tveganj ($p=0,001$) enako $p=0,006$ ($0,999^6 = 0,994$). V nekaterih primerih je zaradi statističnih značilnostih, pri katerih je tveganje nekoliko večje ($>0,001$), tudi statistična značilnost povprečnega koeficienta večja. Končna lestvica povprečnih koeficientov je še nekoliko manj zanesljiva, saj gre zopet za sedem primerjav.

³³ O povezanosti ne moremo zanesljivo sklepati pri naslednjih primerjavah mehkih klasifikacij:

- pri tipu *širše rečne doline v visokogorju, hribovju in na krasu* o Spearmanovem koeficientu povezanosti med najmanjšo razdaljo od centroida tipa in največjo verjetnostjo tipa; po ekspertnem vzorčenju,
- pri tipu *hribovja v pretežno nekarbonatnih kamninah* o Spearmanovem koeficientu povezanosti med najmanjšo razdaljo od centroida tipa in verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTR); po ekspertnem vzorčenju,
- pri tipu *medgorske kotline* o Spearmanovem koeficientu povezanosti med najmanjšo razdaljo od centroida tipa in verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTG); po naključnem vzorčenju,
- pri tipu *nizki kras Notranjske in Dolenjske* o Spearmanovem koeficientu povezanosti med verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTE in največjo verjetnostjo tipa; po naključnem vzorčenju,
- pri tipu *širše doline in obalne ravnice v primorskem delu Slovenije* o Pearsonovem koeficientu povezanosti med verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTE in najmanjšo razdaljo od centroida tipa; po naključnem vzorčenju,
- pri tipu *širše doline in obalne ravnice v primorskem delu Slovenije* o Pearsonovem koeficientu povezanosti med verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTG in najmanjšo razdaljo od centroida tipa; po naključnem vzorčenju,
- pri tipu *širše doline in obalne ravnice v primorskem delu Slovenije* o Pearsonovem koeficientu povezanosti med verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTR in najmanjšo razdaljo od centroida tipa; po naključnem vzorčenju,
- pri tipu *širše doline in obalne ravnice v primorskem delu Slovenije* o Spearmanovem koeficientu povezanosti med verjetnostjo (deležem) tipa v končnem vozlišču po odločitvenem drevesu CTG) in najmanjšo razdaljo od centroida tipa; po naključnem vzorčenju.

v prilogi 13). Izjem je le nekaj, in sicer povezanost pri tipu visokogorski svet (ekspertni vzorec učnih celic), pri tipu medgorske kotline (ekspertni vzorec), pri tipu nizki kras Bele krajine (naključni vzorec), pri tipu širše doline in obalne ravnice v primorskem delu Slovenije (naključni vzorec). Vse izjeme se pojavljajo pri Pearsonovem koeficientu, v zadnjem primeru višji koeficient ni povsem relevanten zaradi statistične neznačilnosti (preglednici 166 v prilogi 13). V vseh navedenih primerih so razlike v povprečnih vrednostih koeficientov zelo majhne. Iz navedenih ugotovitev lahko zaključimo, da je število trdnih klasifikacij k določenemu tipu za posamezno celico lahko dokaj dober prikaz mehke tipizacije³⁴.

8.8 Število kombinacij tipov pri prekrivanju modeliranih naravnopokrajinskih tipizacij

Ob prekrivanju vseh modeliranih tipizacij (slika 41) dobimo veliko število kombinacij tipov, kar pomeni, da različni modeli različno klasificirajo posamezne celice.

Pri prekrivanju modeliranih tipizacij TIPI9, ki so bile narejene na podlagi naključnega vzorca učnih celic, smo dobili 3156 kombinacij, pri prekrivanju tistih modeliranih tipizacij TIPI9, ki so bile narejene na podlagi ekspertnega vzorca učnih celic, pa 2977 kombinacij.

Pri prekrivanju modeliranih tipizacij TIPI13, ki so bile narejene na podlagi naključnega vzorca učnih celic, smo dobili 6142 kombinacij, pri prekrivanju tistih modeliranih tipizacij TIPI13, ki so bile narejene na podlagi ekspertnega vzorca učnih celic, pa 6971 kombinacij.

Kot smo pričakovali, je pri modeliranih tipizacijah TIPI13 kombinacij precej več, saj ima TIPI13 v izvorniku 13 tipov, TIPI9 pa 9. Vseh možnih kombinacij je pri TIPI13 nekaj čez 62,7 milijona, pri TIPI9 pa skoraj 4,8 milijona³⁵.

³⁴ Ob tem je treba omeniti, da je statistično sklepanje o povprečnem koeficientu stopnje povezanosti zaradi šestih posamičnih tveganj ($p=0,001$) enako $p=0,006$ ($0,999^6 = 0,994$). V nekaterih primerih je zaradi statističnih značilnosti, pri katerih je tveganje nekoliko večje ($>0,001$), tudi statistična značilnost povprečnega koeficienta večja. Končna lestvica povprečnih koeficientov je še nekoliko manj zanesljiva, saj gre zopet za sedem primerjav.

³⁵ Tipizacija TIPI13 ima 13 tipov, kar pri primerjavi 7 načinov modeliranja pomeni 13^7 možnih kombinacij. Tipizacija TIPI9 ima 9 tipov, kar pri primerjavi 7 načinov modeliranja pomeni 9^7 možnih kombinacij.

8.9 Ujemanje med ugotovitvami analiz vrednotenja za naravnopokrajinsko tipizacijo TIPI9 in ugotovitvami analiz vrednotenja za naravnopokrajinsko tipizacijo TIPI13

V tem poglavju smo primerjali, kako podobni so rezultati analize vrednotenja tipizacij, ki smo jih opravili s tipizacijo TIPI9, tistim, ki smo jih opravili s tipizacijo TIPI13. Primerjavo smo naredili tako, da smo za posamezne načine vrednotenja izračunali Pearsonov in Spearmanov koeficient povezanosti med lestvicama vrednotenja po obeh analizah.

8.9.1 Vrednotenje s pomočjo podatkovnih slojev

Pri primerjavi vrednotenj na podlagi podatkovnih slojev smo opazili, da so se metode, s katerimi smo modelirali izvirno tipizacijo TIPI9 in dosegli dobre rezultate, dobro obnesle tudi v primeru modeliranja izvirne tipizacije TIPI13. To je dokazala zelo dobra povezanost med posameznimi načini vrednotenja (lestvicami modeliranih tipizacij) pri tipizaciji TIPI9 in posameznimi načini vrednotenja pri tipizaciji TIPI13. Le nekaj primerov je, v katerih povezanost ni statistično značilna pri $p=0,05$ (preglednica 101).

Preglednica 101: Pearsonovi in Spearmanovi koeficienti povezanosti med lestvicami vrednotenja po obeh analizah (TIPI9 in TIPI13) za posamezne načine vrednotenja s pomočjo podatkovnih slojev. V vrstici pod koeficienti so navedene tudi statistične značilnosti.

vsi podatkovni sloji hkrati			
način vrednotenja		Pearsonov koeficient	Spearmanov koeficient
povprečna oddaljenost celic od najbližjega centroida		0,970	0,859
		0,000	0,000
delež enako klasificiranih celic po modelu diskriminancijske analize		0,922	0,925
		0,000	0,000
delež enako klasificiranih celic z odločitvenim drevesom		0,480	0,552
		0,083	0,041
delež enako klasificiranih celic z odločitvenim drevesom (povprečje)		0,645	0,477
		0,013	0,085
informacijski prispevek (povprečje)		0,700	0,640
		0,005	0,014
razmerje informacijskega prispevka (povprečje)		0,832	0,833
		0,000	0,000
koeficient η^2 (povprečje)		0,919	0,846
		0,000	0,000
koeficient F (povprečje)		0,965	0,890
		0,000	0,000
povprečni umerjeni koeficient variacije (povprečje)		0,950	0,881
		0,000	0,000
posamezni podatkovni sloj			
način vrednotenja	podatkovni sloj	Pearsonov koeficient	Spearmanov koeficient
delež enako klasificiranih celic z odločitvenim drevesom	naklon	0,669	0,704
		0,009	0,005
delež enako klasificiranih celic z odločitvenim drevesom	padavinski režim	0,062	0,270
		0,832	0,351
delež enako klasificiranih celic z odločitvenim drevesom	prepustnost	0,907	0,841
		0,000	0,000

delež enako klasificiranih celic z odločitvenim drevesom	nadmorska višina	0,799	0,793
		0,001	0,001
informacijski prispevek	naklon	0,776	0,622
		0,001	0,018
informacijski prispevek	padavinski režim	0,579	0,425
		0,030	0,130
informacijski prispevek	prepustnost	0,962	0,859
		0,000	0,000
informacijski prispevek	nadmorska višina	0,922	0,824
		0,000	0,000
razmerje informacijskega prispevka	naklon	0,641	0,542
		0,014	0,045
razmerje informacijskega prispevka	padavinski režim	0,591	0,631
		0,026	0,016
razmerje informacijskega prispevka	prepustnost	0,963	0,859
		0,000	0,000
razmerje informacijskega prispevka	nadmorska višina	0,935	0,849
		0,000	0,000
koeficient η^2	naklon	0,807	0,734
		0,000	0,003
koeficient η^2	padavinski režim	0,698	0,550
		0,006	0,041
koeficient η^2	prepustnost	0,846	0,743
		0,000	0,002
koeficient η^2	nadmorska višina	0,702	0,703
		0,000	0,005
koeficient F	naklon	0,865	0,727
		0,000	0,003
koeficient F	padavinski režim	0,776	0,508
		0,001	0,064
koeficient F	prepustnost	0,989	0,829
		0,000	0,000
koeficient F	nadmorska višina	0,718	0,723
		0,004	0,003
povprečni umerjeni koeficient variacije	naklon	0,838	0,710
		0,000	0,004
povprečni umerjeni koeficient variacije	padavinski režim	0,758	0,596
		0,002	0,025
povprečni umerjeni koeficient variacije	prepustnost	0,970	0,868
		0,000	0,000
povprečni umerjeni koeficient variacije	nadmorska višina	0,862	0,741
		0,000	0,002

8.9.2 Vrednotenje s pomočjo obstoječe izvirne naravnopokrajinske tipizacije

Pri analizi ujemanja lestvic vrednotenja posameznih modeliranih tipizacij TIPI9 in TIPI13 s pomočjo ustrezne izvirne tipizacije smo ugotovili, da so boljše ocenjene modelirane tipizacije TIPI9 po tistih metodah, ki so dale dobre rezultate tudi pri modeliranju tipizacije TIPI13. Torej smo pri ugotavljanju, kateri način modeliranja je boljši oziroma daje izvirniku bolj podobne rezultate (modelirane tipizacije), prišli pri obeh analizah (TIPI9, TIPI13) do zelo podobnih ugotovitev (preglednica 102).

Preglednica 102: Pearsonovi in Spearmanovi koeficienti ($p=0,001$) povezanosti med lestvicami vrednotenja po obeh analizah (TIPI9, TIPI13) za posamezne načine vrednotenja s pomočjo izvirne tipizacije.

način vrednotenja	Pearsonov koeficient	Spearmanov koeficient
Cramerjev koeficient	0,939	0,931
koeficient kappa	0,942	0,921
delež ujemanja vseh celic	0,941	0,930
delež ujemanja učnih celic	0,954	0,982

9. Najpomembnejše ugotovitve glede uporabnosti geografskih informacijskih sistemov pri določanju naravnih pokrajinskih tipov Slovenije

V prvem delu tega poglavja smo se osredotočili na področja, ki spadajo v okvir preverjanja obeh hipotez, v drugem pa na uporabnost v nalogi uporabljenih geoinformacijskih orodij pri izdelavi naravnopokrajinskih tipizacij. Povsem na koncu tega poglavja smo izpostavili še nekatere pomembnejše ugotovitve s področja naravnopokrajinske tipizacije in uporabe geografskih informacijskih sistemov.

V okviru **prve hipoteze** smo analizirali različne načine vrednotenja tipizacij ter ugotavljali, kateri načini so se izkazali za bolj primerne in kateri za manj primerne. Pomemben del raziskave je bil namenjen odgovoru na vprašanje, ali so različni načini vrednotenja med seboj usklajeni. Na ta način skušamo ugotoviti, ali obstaja objektiven način vrednotenja, ki bi bil zato tudi najbolj uporaben. Ob koncu je glede na izsledke raziskave predlagan ustrezen način vrednotenja, ki zajema vrednotenje z vidika izbranih podatkovnih slojev in vrednotenje z vidika ujemanja izvirnih tipizacij z modeliranimi tipizacijami.

V okviru **druge hipoteze**, s katero smo preverjali, ali lahko določimo območja, ki se ne glede na uporabo različnih geoinformacijskih orodij uvrščajo v enake tipe, ter katera so tista območja, ki jih geoinformacijska orodja uvrščajo različno, smo izvedli analize na več področjih: a) analiza prekrivanja modeliranih tipizacij z ustrežno izvorno tipizacijo [(ne)ujemanje oziroma računsko (ne)potrditev obstoječih tipov]; b) analiza seštevka različnih trdnih modeliranih tipizacij po posameznih tipih ter njegova primerjava z mehкими modeliranimi tipizacijami po posameznih tipih; c) analiza oddaljenosti celic od najbližjih centroidov tipov pri tipizacijah, ki so narejene z metodami nenadzorovane klasifikacije.

9.1 Preverjanje hipotez

9.1.1 Objektivnost vrednotenja tipizacij

Prva hipoteza: *»Z ustrežno kombinacijo geoinformacijskih orodij tipizacij in vrednotenjem rezultatov tipizacij je mogoče objektivno oceniti kakovost tipizacij.«*

V poglavju 2, v katerem smo opisali teorijo klasifikacije pokrajine, smo izpostavili številne probleme oziroma znanstvene izzive, ki še niso v celoti rešeni. Njihovo reševanje zavira nedorečenost nekaterih področij; pogledi na klasifikacijo pokrajine se namreč še vedno v marsičem preveč razlikujejo (na primer pri vprašanju, ali naravne enote dejansko obstajajo ali ne). Če k nejasnostim v teoriji dodamo še dejstvo, da so klasifikacije pokrajine raznolike in odvisne tudi od namena, ki določa tudi, katere dejavnike je treba upoštevati, vidimo, da je objektivno vrednotenje izdelanih tipizacij zahtevno opravilo. Da bi premostili nekatere probleme in dosegli čim bolj splošna spoznanja na področju vrednotenja, smo zato načine vrednotenja preučevali za različne situacije (uporaba različnih metod klasifikacij, metod vrednotenja, vzorčenja ipd.).

S pomočjo metod nenadzorovane klasifikacije smo izdelali 41 modeliranih tipizacij, ki smo jih ovrednotili na različne načine. Vrednotili smo s pomočjo posameznega podatkovnega sloja, ki je bil vključen v klasifikacijo, in tudi s pomočjo vseh podatkovnih slojev naenkrat³⁶. Pri analizi usklajenosti vrednotenj na podlagi posameznega podatkovnega sloja smo ugotovili, da so pri vrednotenju vseh klasifikacij (ne glede na število skupin) usklajeni informacijski prispevek, razmerje informacijskega prispevka in koeficient η^2 , pri vrednotenju klasifikacij z

³⁶ Načini vrednotenja na podlagi posameznega podatkovnega sloja: delež enako klasificiranih z odločitvenim drevesom, informacijski prispevek, razmerje informacijskega prispevka, povprečni umerjeni koeficient variacije, koeficient F, koeficient η^2 .

Načini vrednotenja na podlagi več podatkovnih slojev hkrati: delež enako klasificiranih celic z odločitvenim drevesom, povprečna oddaljenost posamezne celice od najbližjega centroida, delež enako klasificiranih celic z modelom diskriminancne analize, povprečja vrednotenj na podlagi posameznih podatkovnih slojev.

enakim številom skupin pa zelo podobne ocene dajeta koeficienta η^2 in F. Pri analizi usklajenosti vrednotenj na podlagi vseh podatkovnih slojev hkrati smo ugotovili, da so glede na izračunane Pearsonove in Spearmanove koeficiente povezanosti med lestvicami različnih načinov vrednotenja prepogosto zelo majhne, pogosto tudi celo statistično neznačilne (pri $p=0,05$), kar pomeni, da si načini vrednotenja med seboj niso zadosti podobni. To pomeni, da se lahko po enem vrednotenju določena tipizacija označi kot dobra, po drugem pa ne. Zaradi navedenih dejstev usklajenosti vrednotenja med izbranimi načini ocenjevanja modeliranih tipizacij, ki so izdelane z metodami nenadzorovane klasifikacije, ne moremo potrditi. Različni načini vrednotenja dajo preveč različne ocene.

Ob teh ugotovitvah izpostavljamo še dejstvo, da število tipov nedvoumno vpliva na vrednotenje tipizacij. Iz grafikonov (poglavje 7) je razvidno, da je pri večini vrednotenj opazen močan trend. To pomeni, da primerjava dveh ali več tipizacij, ki imajo različno število tipov, nikakor ne more biti nepristranska.

Po analizi vrednotenj modeliranih tipizacij, ki so izdelane z metodami nenadzorovane klasifikacije, nimamo zadosti argumentov, da bi potrdili hipotezo. Eden izmed razlogov za zavrnitev hipoteze s tega vidika je gotovo tudi nizek numerus (predvsem število modeliranih nenadzorovanih tipizacij z istim številom tipov).

S pomočjo metod nadzorovane klasifikacije smo izdelali 14 modeliranih tipizacij, ki smo jih prav tako ovrednotili na različne načine. Vrednotili smo s pomočjo posameznega podatkovnega sloja, ki je bil vključen v klasifikacijo, in tudi s pomočjo vseh podatkovnih slojev hkrati³⁶.

Pri analizi usklajenosti vrednotenj na podlagi posameznega podatkovnega sloja smo ugotovili, da so načini vrednotenja precej dobro usklajeni. V obeh sklopih analiz naravnopokrajinskih tipizacij (TIPI9 in TIPI13) smo ugotovili, da je velika večina načinov vrednotenja dobro usklajenih, ponekod je nekoliko manj z ostalimi usklajen le način vrednotenja z odločitvenim drevesom (oznaka ODL), ki je očitno za namene vrednotenja manj primeren. Edina večja izjema so rezultati pri preverjanju povezanosti vrednotenj tipizacije TIPI9 z vidika padavinskega režima, pri katerih so stopnje povezanosti precej nizke, nekatere so tudi statistično neznačilne (pri $p=0,05$); bolj usklajeni so v tem primeru le informacijski prispevek in razmerje informacijskega prispevka ter koeficient η^2 , koeficient F in PUKV.

Pri analizi usklajenosti vrednotenj na podlagi vseh podatkovnih slojev smo ugotovili, da se precej načinov vrednotenja med seboj dobro ujema. Od ostalih načinov vrednotenja odstopata delež enako klasificiranih celic z odločitvenim drevesom, ki je narejen z vsemi podatkovnimi sloji, ter povprečje deležev enako klasificiranih celic z odločitvenimi drevesi, narejenimi s posameznimi podatkovnimi sloji. Te ugotovitve smo potrdili z raziskavami tako pri TIPI9 kot tudi pri TIPI13; pri slednji so bile stopnje povezanosti rahlo manjše. To pomeni, da sta verjetno oba načina vrednotenja z odločitvenim drevesom dejansko manj primerna za vrednotenje izdelanih tipizacij.

Po analizi vrednotenj modeliranih tipizacij, ki so izdelane z metodami nadzorovane klasifikacije, imamo precej argumentov, da potrdimo hipotezo. V večini primerov so se načini vrednotenja izkazali za usklajene, pri tem pa je bilo ugotovljeno, da vrednotenje s pomočjo izdelave odločitvenega drevesa (in nadaljnje ugotavljanje, koliko celic je po tem odločitvenem drevesu enako klasificiranih) najbolj odstopa od ostalih načinov vrednotenja. To se je še najbolj pokazalo pri vrednotenju z več podatkovnimi sloji naenkrat. Nekoliko negotovosti povzroča predvsem vrednotenje modeliranih tipizacij TIPI9 z vidika podatkovnega sloja padavinski režim. Eden izmed razlogov za to je gotovo tudi večmodalna frekvenčna porazdelitev tega podatkovnega sloja (slika 47), ki se ohranja tudi znotraj posameznih tipov, kar otežuje modeliranje in tudi vrednotenje.

Modelirane tipizacije po metodah nadzorovane klasifikacije smo vrednotili tudi v primerjavi z izvirno tipizacijo. Na ta način lahko sicer vrednotimo predvsem izvirno tipizacijo in ugotovljamo, v kolikšni meri jo lahko potrdimo z računalniškim modelom. Primerjava med modelirano in izvirno tipizacijo je bila narejena z izračunom Cramerjevega koeficienta in koeficienta kappa ter ugotavljanjem deleža enako klasificiranih celic. Po analizah s TIPI9 in TIPI13 smo ugotovili, da se vsi trije načini med seboj usklajeni, zato lahko za tovrstno vrednotenje potrdimo hipotezo o obstoju objektivnosti vrednotenja.

Kot smo opazili, smo prišli po vrednotenju na podlagi vključenih podatkovnih slojev nenadzorovanih tipizacij in nadzorovanih tipizacij do različnih zaključkov. Zaradi tega lahko

prvo hipotezo potrdimo delno.

analizo pa lahko sklenemo z ugotovitvijo, da je vrednotenje tipizacij, ki so narejene z metodami nadzorovane klasifikacije, možno, saj se različni načini vrednotenja na podlagi podatkovnih slojev med seboj ujemajo. Vrednotenje tipizacij s pomočjo primerjave (na primer izvirne tipizacije z modelirano tipizacijo) je po naših raziskavah prav tako zanesljivo.

Na podlagi navedenih ugotovitev, ki so povezane s preverjanjem prve hipoteze, **kot aplikativen rezultat naloge predlagamo način objektivnega vrednotenja** pri izdelavi tipizacij pokrajine, ki bi lahko bil uporaben za vse tipizacije ne glede na njihov namen.

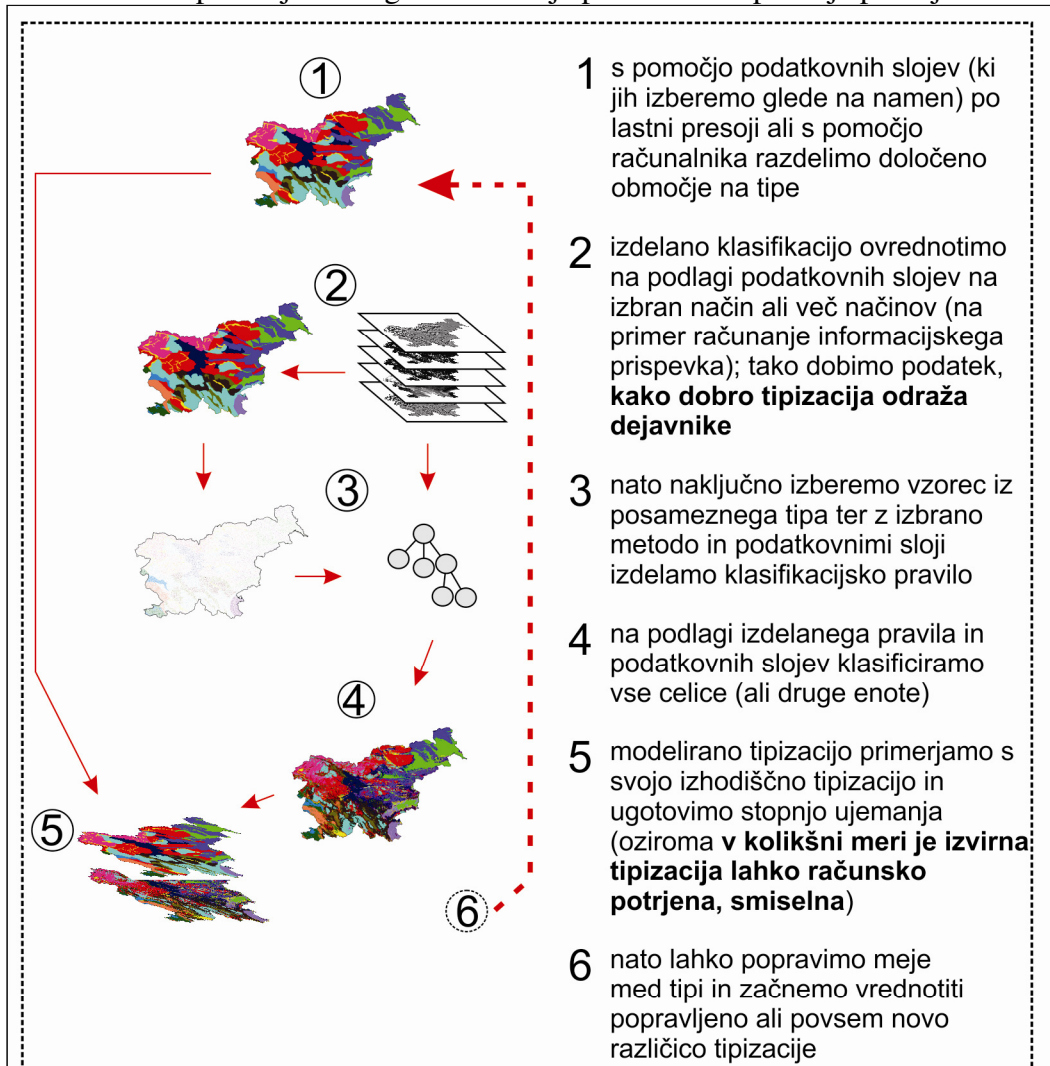
Predlagamo sledeči postopek za vrednotenje tipizacij³⁷ (glej tudi sliko 90):

1. raziskovalec s pomočjo podatkovnih slojev (ki jih izbere glede na namen) po lastni presoji ali s pomočjo računalnika razdeli določeno območje na tipe,
2. izdelano klasifikacijo ovrednoti na podlagi podatkovnih slojev na en izbran način ali pa več načinov (na primer računanje informacijskega prispevka),
3. nato naključno izbere vzorec celic (ali drugih enot, če analiza ne temelji na rastru) iz posameznega tipa ter z izbrano metodo izdelava klasifikacijsko pravilo,
4. na podlagi izdelanega pravila klasificira vse celice,
5. modelirano tipizacijo primerja s svojo izvirno tipizacijo in ugotovi stopnjo ujemanja (oziroma v kolikšni meri je izvirna tipizacija računsko potrjena),
6. raziskovalec lahko nato popravi meje med tipi in izdelava novo različico tipizacije (pri tem si lahko pomaga z dodatnimi metodami; na primer statistično razlikovanje med posameznimi tipi lahko primerjamo z Mann-Whitneyjevim testom),
7. ves postopek od 1 do 6 (izdelava in preverjanje različnih različic tipizacije) lahko ponovi večkrat, kar pomeni, da dobi več različic tipizacije,
8. za vsako narejeno tipizacijo ima raziskovalec podatek (oceno) o vrednotenju z vidika podatkovnih slojev in podatek o ujemanju z modelirano tipizacijo; te podatke za vsako tipizacijo nato vnese v graf, kjer ena os predstavlja vrednotenje z vidika podatkovnih slojev, druga pa ujemanje z modelirano tipizacijo,
9. raziskovalec izbere tisto različico svoje (popravljenе) izvirne tipizacije, ki ima visoko oceno z vidika podatkovnih slojev in se čim boljše ujema z modelirano tipizacijo.

Geoinformacijsko orodje za modeliranje izberemo na podlagi lastnosti podatkovnih slojev in drugih lastnosti, lahko pa pri izdelavi različic uporabimo tudi več različnih nastavitvev in metod. Pri tem postopku je treba še izpostaviti, da spreminjanje števila tipov ni dovoljeno, saj to pomembno vpliva na vrednotenje (glej poglavje 7). Opozoriti je treba še, da vrednotenje s pomočjo podatkovnih slojev temelji na vseh celicah (oziroma morebitnih drugih enotah), vrednotenje s pomočjo modeliranja pa na podlagi vzorca celic.

³⁷ Glede na nekatere podobnosti med izdelavo tipizacij in regionalizacij verjamemo, da je omenjeni predlog vrednotenja izdelane tipizacije primeren tudi pri procesu izdelave regionalizacij.

Slika 90: Postopek objektivnega vrednotenja pri izdelavi tipizacije pokrajine.



Ves postopek od 1 do 6 se nato lahko ponovi večkrat. Za vsako narejeno tipizacijo dobimo podatek o vrednotenju z vidika podatkovnih slojev in podatek o ujemanju z modelirano tipizacijo. Te podatke za vsako klasifikacijo nato vnesemo v grafikon, kjer ena os predstavlja vrednotenje z vidika podatkovnih slojev, druga pa ujemanje z modelirano tipizacijo:

Y os: vrednotenje z vidika podatkovnega/ih sloja/ev (predstavitev dejavnikov)

težimo k temu, da imamo smiselno tipizacijo (ki jo lahko potrdimo računsko), ki dobro ponazarja naravne dejavnike (podatkovne sloje)

X os: ujemanje izvirne z modelirano tipizacijo (smiselnost, računsko potrditev)

Izberemo tisto različico svoje izvirne tipizacije, ki imajo visoke ocene z vidika podatkovnih slojev in se čim boljše ujemajo z modelirano tipizacijo.

9.1.2 Potrjevanje obstoječih naravnih pokrajinskih tipov

Druga hipoteza: »Z geografskimi informacijskimi sistemi je možno ugotoviti, katera so tista območja, ki se ne glede na uporabo različnih geoinformacijskih orodij uvrščajo v enake oziroma podobne tipe, ter katera so tista območja, ki jih geoinformacijska orodja uvrščajo različno.«

Drugo hipotezo smo preverili predvsem z analizo v drugem delu naloge (sklop metod nadzorovanih klasifikacij), s katero smo poskusili obstoječi tipizaciji (TIPI9 in TIPI13) čim boljše opisati z modelom po več različnih metodah ter ugotoviti, kje so območja, ki jih lahko potrdimo z vsemi metodami oziroma geoinformacijskimi orodji. V prvem delu zaradi dejstva, da tipov pri metodah nenadzorovanih klasifikacij vnaprej ni definiranih in je zatorej vsak tip po svoje pravilen, nismo iskali območij, ki se klasificirajo podobno, temveč smo iskali območja, ki niso blizu povprečnih lastnosti nobenega tipa.

Na podlagi vsake izmed naravnopokrajinskih tipizacij, ki smo jih izdelali v prvem delu z metodami nenadzorovane klasifikacije, smo izračunali Evklidovo razdaljo posamezne celice od najbližjega centroida tipa. Nato pa smo na podlagi vseh izračunanih razdalj v posamezni seriji (tipizacije z enakim številom tipov) izračunali povprečno oddaljenost za vsako celico. Ugotovili smo, da so izračunane oddaljenosti med seboj statistično značilno povezane. Najvišje vrednosti Pearsonovega in tudi Spearmanovega koeficienta so bile zabeležene v sklopu tipizacij z 2 tipoma, nekoliko nižje pa pri ostalih tipizacijah z več tipi. Oddaljenosti, izračunane na podlagi tipizacij, ki so izdelane z metodo iterativnega samoorganizirajočega nenadzorovanega klasifikatorja, predvsem pa z metodo segmentacije, se z ostalimi ujemajo precej manj. To se je pokazalo pri vseh številih tipov. Pri metodi segmentacije je glavni razlog ta, da metoda pri izdelavi tipizacije upošteva sosedskost celic.

Pri primerjavi povprečne oddaljenosti celic med različnimi serijami smo ugotovili, da so tudi tukaj oddaljenosti med seboj povezane s statistično značilnostjo $p=0,001$. To na splošno pomeni, da je celica, ki je na robu nekega tipa pri tipizaciji s 5 tipi, prav tako na robu tipa pri tipizaciji z 10 tipi. Tu smo tudi ugotovili, da so oddaljenosti med seboj bolj povezane, če izhajajo iz izračuna tipizacij s podobnim številom skupin, oddaljenosti po tipizaciji z dvema tipoma se ne povezujejo tako močno kot ostale z več tipi. Na ta način smo ugotovili, katere celice so (ne glede na tip) bolj na robu oziroma bolj izstopajo. V smislu iskanja robnih celic, ki jih objektivno težje klasificiramo, lahko to hipotezo potrdimo. Pomanjkljivost tega dela analize je, da nismo preverili, kako se obnašajo drugi načini izračunavanja.

Ugotovili smo, da so bile kot obrobna območja določena visokogorska območja (z nizko povprečno temperaturo), obalno območje (z nizko nadmorsko višino in visoko temperaturo), pobočja z visokim naklonom. Blizu centroidom so določena bolj ravninska območja. Del razloga je gotovo ta, da je glede na frekvenčno porazdelitev naklon blizu 0° najbolj pogost naklon, zelo strmih naklonov pa je precej manj; prav tako je izjemno nizka povprečna temperatura prisotna na vršnem delu Alp. Vsa ta območja so bila zato označena kot robna.

V drugem delu naloge, torej v primeru že določenih tipov izvernih tipizacij TIPI9 (Perko, 1998a, Perko, 1998b, Perko, 2007b) in TIPI13 (Špes s sod., 2002), smo po izdelavi vseh modeliranih tipizacij seštevali, kolikokrat je posamezna celica klasificirana v posamezen tip. Tak seštevek trdnih modeliranih tipizacij lahko vzamemo kot splošno mehko tipizacijo, ki je narejena na podlagi več različnih metod in bi morala biti zato precej objektivna.

To objektivnost smo ugotavljali tako, da smo po posameznih tipih izračunali povezanost seštevka trdnih modeliranih tipizacij z vrednostmi mehkih modeliranih tipizacij (naredili smo ločeni analizi za modelirane tipizacije po naključnem in ekspertnem vzorcu). Ugotovili smo, da seštevek trdnih modeliranih tipizacij po različnih geoinformacijskih orodjih še najbolj objektivno prikazuje, kako močno se posamezna celica uvršča v različne tipe. Seštevek trdnih modeliranih tipizacij se namreč relativno dobro povezuje z vsemi mehкими modeliranimi tipizacijami (glej poglavji 8.6 in 8.7). To smo potrdili tako po modeliranih tipizacijah TIPI9

kot tudi po TIPI13. Posamezni koeficienti povezanosti med posameznimi mehкими klasifikacijami so sicer različno visoki: ponekod so zelo visoki, ponekod pa zelo nizki. Znotraj te analize smo ugotovili, da ima vzorčenje tudi na tem področju precejšen vpliv. Ugotovili smo namreč, da so sicer seštevki klasifikacij v posamezen tip, ki smo jih določili po izdelavi tipizacij z naključnim vzorcem, in seštevki klasifikacij v posamezen tip, ki smo jih določili po izdelavi tipizacij z ekspertnim vzorcem, statistično značilno povezani. Stopnje povezanosti pa so različne, nekatere so precej nizke. Po primerjavi za tipizacijo TIPI9 smo na splošno dobili nekoliko večja ujemanja kot pri tipizaciji TIPI13. Slednja ima več tipov (13 tipov) kot prva (9 tipov), zato je pričakovano večje razhajanje modeliranih tipizacij in manjše ujemanje med posameznimi seštevki. Pri tipu širše rečne doline v visokogorju, hribovju in na krasu pri tipizaciji TIPI13 je po enem izmed izračunov povezanost med obema seštevkom klasifikacij v posamezen tip celo negativna (preglednica 99), kar je edini primer in kaže na to, da je način vzorčenja pri modeliranju obstoječih tipizacij očitno precej pomemben. Seštevanje klasifikacij v posamezen tip oziroma prekrivanje modeliranih naravnopokrajinskih tipizacij smo aplikativno uporabili, ko smo ugotavljali:

- katere celice so po vseh modeliranih tipizacijah enako klasificirane kot v izvorni tipizaciji,
- katere celice se po nobeni modelirani tipizaciji ne ujemajo z izvorno tipizacijo,
- katere celice so po vseh modeliranih tipizacijah enako klasificirane, a niso enako klasificirane kot v izvorni tipizaciji.

Po prekrivanju modeliranih tipizacij z izvorno tipizacijo smo ugotovili, kje so območja, ki niso toliko podobna prvotno določenemu tipu (po izvorni tipizaciji), in kje so območja, ki jih lahko z vsemi modeli (ali pa večino le-teh) potrdimo kot pravi tip. Bolj opazen primer so recimo odstopanja raznih dolin znotraj gorovij. To je še dodaten argument, da lahko geoinformacijska orodja pripomorejo k odkrivanju manj ustrezno klasificiranih območij.

Delež celic, ki se po vseh modeliranih tipizacijah ujemajo z izvorno tipizacijo TIPI9, je pri naključnem naboru 36,6 %, pri ekspertnem pa 28,1 %. Tu gre predvsem za območja obeh sredozemskih in panonskih tipov ter višjih delov dinarskih planot, alpskega sredogorja in gorovja. Alpske ravnine so bile potrjene v večjem delu med Ljubljanskim poljem in Deželo. Večinoma so nepotrjene posamezne vzpetine znotraj ravnine (npr. Rašica) in doline znotraj pretežno goratih/hribovitih/gričevnatih območij (na primer doline Save, Soče, Drave, Ščavnice). Opazna je odsotnost ujemanja med modeliranimi in izvornimi tipi na območju Celjske kotline, srednje Soške doline, območja med Vrhniko in Idrijo, Pivške kotline, Ljubljanskega barja, Dolenjskega podolja, Suhe krajine, Bizeljskega, večjega dela Krške kotline, Gorjancev, večjega dela Bele krajine.

Delež celic, ki se po nobeni modelirani tipizaciji ne ujemajo z izvorno tipizacijo TIPI9, je pri naključnem naboru 11,8 %, pri ekspertnem pa 19,4 %. Med temi območji najdemo predvsem obrobja posameznih tipov (na primer obrobje sredozemskih gričevij na Brkinih) in nekatere doline in druge depresije znotraj bolj vzpete in razgibane pokrajine (na primer alpske doline znotraj alpskih gorovij). Nekaj območij je tudi bolj obširnih (na primer Banjšice, Kolovrat, Kočevskoreški ravniki). Večinoma gre za območja, ki so bila manj ustrezno klasificirana pri ročnem izrisu meje predvsem zaradi manjšega merila in omejene natančnosti.

Delež celic, ki so po vseh modeliranih tipizacijah usklajene glede tipov, a se razlikujejo od izvorne tipizacije, je pri TIPI9 po naključnem naboru 4,2 %, po ekspertnem pa 5,5 %. V grobem lahko rečemo, da gre za obrobna območja tipov in nekatera območja, ki bi najverjetneje morala biti v osnovi klasificirana drugače, a zaradi osnovnega merila niso bila (na primer Iški vršaj bi moral spadati bolj k alpskim ravninam kot pa dinarskim podoljem in ravnikom).

Delež celic, ki se po vseh modeliranih tipizacijah ujemajo z izvorno tipizacijo TIPI13, je pri naključnem naboru 30,1 %, pri ekspertnem pa 22,0 %. V grobem lahko rečemo, da je največje

ujemanje (pri obeh sklopih modeliranih tipizacij) pri tipih visokogorski svet (višji deli), ravnine in širše doline v gričevju notranjega dela Slovenije (brez vmesnih vzpetin), Kras in Podgorski kras ter gričevje v primorskem delu Slovenije. Dobro se ujemajo tudi gričevja v notranjem delu Slovenije, višji deli visokih kraških palnot in hribovij v karbonatnih kamninah ter nizki kras Bele krajine (slednji samo po naključnem vzorcu). Najmanj ujemanja je na območju sredogorij v osrednji Sloveniji, kar je verjetno tudi najbolj prehodno območje glede podnebja, poleg tega pa ima veliko razgibanost v reliefu.

Delež celic, ki se po nobeni modelirani tipizaciji ne ujema z izvirno tipizacijo TIPI13, je pri naključnem naboru 16,2 %, pri ekspertnem pa 24,1 %. Opazno je, da so to predvsem vznožja vzpetin, pri modeliranih tipizacijah po ekspertnem vzorčenju pa tudi večje površine na Banjšicah, Brkinih, Kočevskem in v Posavskem hribovju. V primerjavi s TIPI9 tu ni celotnih dolin, saj je bila tipizacija TIPI13 narejena podrobneje in je doline (na primer v visokogorju) ustrezno določila kot samostojen tip.

Delež celic, ki so po vseh modeliranih tipizacijah usklajene glede tipov, a se razlikujejo od izvirne tipizacije, je pri TIPI13 po naključnem naboru 4,4 %, po ekspertnem pa 5,6 %. Ta območja so robna območja, neizdvojene doline (na primer Krma). Večja območja so se pokazala po analizi modeliranih tipizacij po ekspertnem naboru učnih celic, na primer Vipavska brda, ki so jih modeli soglasno uvrstili v tip gričevje v primorskem delu Slovenije (prvotno hribovje v pretežno nekarbonatnih kamninah).

Glede deleža ujemanja po posameznih modeliranih tipizacijah in posameznih tipih smo pri tipizaciji TIPI9 ugotovili, da se posamezne modelirane tipizacije po ekspertnem naboru učnih celic z izvirno tipizacijo TIPI9 ujemajo med 51 in 61 %, pri naključnem naboru pa med 51 in 75 %. Modelirani tipizaciji po metodi največje verjetnosti in najmanjše razdalje se z izvirno tipizacijo povečini najmanj ujemata. Izmed tipov je med modeliranimi in izvirmimi tipizacijami največje ujemanje pri panonskih ravninah, panonskih gričevjih, alpskih ravninah, sredozemskih gričevjih in sredozemskih planotah. To so tipi, ki jih je lažje opredeliti zaradi velikih ravnin in/ali zaradi njihove lege na skrajnem jugozahodnem oziroma vzhodnem delu Slovenije, kjer je v primerjavi z osrednjimi deli manj izrazita prehodnost v smislu podnebnih značilnosti. Zaradi načina vzorčenja (enak delež ne glede na velikost tipa) in tudi zaradi večje raznolikosti so bile za večje tipe ugotovljena manjša ujemanja med modelirano in izvirno tipizacijo.

Pri tipizaciji TIPI13 smo ugotovili, da se modelirane tipizacije po ekspertnem naboru učnih celic z izvirno tipizacijo TIPI13 ujemajo med 43 in 53 %, po naključnem naboru pa med 47 in 69 %. Tudi tu v negativnem smislu odstopata modelirani tipizaciji po metodi najmanjše razdalje in največje verjetnosti. Ob prostorskem pregledu ujemanja celic je opazno, da gre za gričevnate ali ravninske tipe, ki so na vzhodu države (gričevja v notranjem delu Slovenije, ravnine in širše doline v gričevju notranjega dela Slovenije, nizki kras Bele krajine) ter za nekatere tipe na skrajnem jugozahodu države (Kras in Podgorski kras, gričevje v primorskem delu Slovenije). Vzroke za njihovo visoko ujemanje gre iskati predvsem v legi v podnebno manj prehodnem območju, velikem deležu ravnin (kar je lažje opisati z matematičnimi pravili) ter visokem deležu učnih celic v primerjavi s celotno površino tipa. Opazno je tudi visoko ujemanje celic tipa visokogorski svet; večja stopnja ujemanja je med drugim tudi posledica tega, da so avtorji izločili alpske planote in večje alpske doline.

Po vseh naštetih ugotovitvah lahko

drugo hipotezo potrdimo,

saj nam uporaba različnih geoinformacijskih orodij dejansko omogoča relevantno določitev, katera območja posameznih tipov so večkrat potrjena kot pravilna in katera ne. Poleg tega lahko na podlagi povezanosti mehkih klasifikacij in seštevka različnih modeliranih tipizacij ugotovimo, da lahko seštevke prav tako predstavlja objektivno mehko tipizacijo. Ugotovljamo torej, da se lahko mehke tipizacije naredijo tudi na podlagi različnih trdnih modeliranih

tipizacij tako, kot smo to storili v nalogi (slika 85). Pri ugotavljanju splošne oddaljenosti posamezne celice od povprečnih značilnosti tipov (na podlagi rezultatov modeliranih tipizacij, ki so izdelane z metodami nenadzorovane klasifikacije) lahko hipotezo tudi dodatno podpremo (sicer le z enim geoinformacijskim orodjem – računanjem Evklidove razdalje), saj smo s primerjavo različnih oddaljenosti (pri 2, 5, 10, 15 tipih) modeliranih tipizacij ugotovili, da se le-te večinoma (izjema so denimo tipizacije po segmentaciji) dobro ujemajo med seboj in da omogočajo vpogled v to, kje so celice bolj oddaljene od najbližjih centroidov.

9.2 Spoznanja o uporabnosti geoinformacijskih orodij

V tem delu smo kritično opisali geoinformacijska orodja z vidika uporabnosti pri izdelavi naravnopokrajinske tipizacije, z vidika vrednotenja tipizacij in z vidika ugotavljanja ujemanja tipizacij. Pri tem smo se ozrli na dobljene rezultate v nalogi ter tudi teoretična dejstva. Za posamezna geoinformacijska orodja (metode), ki smo jih uporabili, smo izpostavili nekatere prednosti, slabosti in področja uporabnosti³⁸.

9.2.1 Pregled uporabnosti uporabljenih geoinformacijskih orodij

9.2.1.1 Geoinformacijska orodja za nenadzorovano klasifikacijo

Metoda voditeljev (v programih SPSS, Statistica in Idrisi; preglednice 103–105) je pogosto uporabljena metoda (glej poglavje 3.4). Klasificiranje je preprosto in temelji na razdalji med celicami v večrazsežnostnem prostoru. Glavni pomanjkljivosti sta, da rešitve niso dokončne in so zelo odvisne od izbora začetnih centroidov ter da je možno uporabljati le številske podatkovne sloje. V nalogi smo uporabili različna geoinformacijska orodja, ki imajo implementirano metodo voditeljev. Ta orodja uporabniku ponujajo različne načine izbora začetnih centroidov in tako pomembno vplivajo na rezultat. Pri majhnem številu skupin (tipov) je ta vpliv manjši, a z večanjem števila skupin tudi usklajenost rezultatov pada. To se je pokazalo tudi v praktičnem primeru izdelave tipizacij Slovenije, pri katerem smo ugotovili, da se rezultati pri iskanju dveh tipov precej bolje ujemajo kot rezultati pri iskanju petih, desetih oziroma petnajstih tipov.

Rezultati metode so v primerjavi z ostalimi metodami ocenjeni podobno ali nekoliko bolje, ujemanje pa je zelo nizko predvsem z rezultati po metodi segmentacije.

Metoda je primerna za iskanje naravnih tipov. Zaradi vpliva začetnih centroidov sta nujni večkratna uporaba metode in vizualna primerjava rezultatov.

Preglednica 103: Metoda voditeljev v programu SPSS.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	določi se število skupin; med njimi ni hierarhične povezave
nadzor uporabnika (število nastavitvev ³⁹)	3
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	precejšnje
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	primerljivi z ostalimi

³⁸ Analize, v katerih so raziskovalci preverjali različne metode klasifikacij in njihove rezultate, niso redke. Duro, Franklin in Dubé (2012, 259 in 260) so navedli primere raziskav različnih avtorjev, ki so primerjali na primer odločitvena drevesa, nevralna omrežja in druge. Zanimivo je, da so opozorili tudi na različne rezultate, saj so nekateri označili določeno metodo kot uspešnejšo od druge, medtem ko so drugi prišli do drugačnih spoznanj.

³⁹ Določanje števila skupin ni všteto.

⁴⁰ Lastnost je subjektivno ocenjena po pregledu preglednic povezanosti v poglavju 7.4.

⁴¹ Lastnost je subjektivno ocenjena po pregledu grafikonov v poglavju 7.3.

Preglednica 104: Metoda voditeljev v programu Statistica.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	določi se število skupin; med njimi ni hierarhične povezave
nadzor uporabnika (število nastavitvev ³⁹)	2
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	precejšnje
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	primerljivi z ostalimi

Preglednica 105: Metoda voditeljev v programu Idrisi.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	določi se število skupin; med njimi ni hierarhične povezave
nadzor uporabnika (število nastavitvev ³⁹)	4
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	precejšnje
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	primerljivi z ostalimi

Analiza vrhov v histogramu (preglednica 106) je zanimiva zaradi svojega delovanja, saj izhaja iz frekvenčne porazdelitve v večrazsežnostnem prostoru (če uporabljamo vsaj tri podatkovne sloje). Pomanjkljivost je ta, da je možno uporabljati le številske podatkovne sloje. Metoda je po rezultatih in ujemanju kar primerljiva z rezultati metode voditeljev. V nekaterih primerih je na podlagi podatkovnih slojev nekoliko slabše ocenjena. Pri izdelavi tipizacij smo opazili, da so, še posebej pri petnajstih tipih, tipi zelo razdrobljeni. Metoda je uporabna za iskanje naravnih skupin glede na pogostnost pojava.

Preglednica 106: Analiza vrhov v histogramu.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	določi se število skupin; med njimi ni hierarhične povezave
nadzor uporabnika (število nastavitvev ³⁹)	4
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	dobro
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	primerljivi z ostalimi (z nekaj negativnimi izjemami)

Metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja s kratico ISOCLUST (preglednica 107) je sestavljena iz različnih modulov programa Idrisi, ki naj bi povečali objektivnost. Uporabnik zato tudi nima toliko možnosti vplivati na rezultat. Pomanjkljivost je, tako kot pri ostalih opisanih, da je možno uporabljati le številske podatkovne sloje.

Metoda je po rezultatih primerljiva z metodami, ki smo jih opisali do sedaj. Ponekod so opažene nekoliko slabše ocene v okviru vrednotenja glede na podatkovne sloje.

Metoda je primerna za iskanje naravnih skupin.

Preglednica 107: Metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni nadzor uporabnika (število nastavitev ³⁹)	določi se število skupin; med njimi ni hierarhične povezave 2
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	dobro, ponekod šibko
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	primerljivi z ostalimi (ponekod negativna odstopanja)

Segmentacija (preglednica 108) omogoča določanje meja oziroma prehod iz rastrske v vektorsko obliko zapisa. Pri tem se lahko količina podatkov precej zmanjša (nimamo več celic, ampak segmente/poligone). Treba pa je vedeti, da so segmenti homogeni po tistem podatkovnem sloju (ali po tistih podatkovnih slojih), na podlagi katerega segmentiramo. Ko imamo izdelane segmente, lahko pridobimo nove podatke, na primer najnižjo nadmorsko višino segmenta, najvišjo nadmorsko višino segmenta, višinsko razliko segmenta ... Segmentom lahko pripišemo rastrske podatke različnih ločljivosti, kar pa je treba ustrezno navesti v spremnem besedilu. Pomanjkljivost je, da lahko uporabimo le številske podatke, zaradi nastavitve petih parametrov pa lahko izdelamo veliko različic rezultata. Metoda ni uporabna za izdelavo tipizacije. Zaradi povsem drugačnega računskega ozadja daje segmentacija namreč precej drugačne tipizacije Slovenije kot pa ostala geoinformacijska orodja, ki smo jih uporabili za izdelavo tipizacije. Segmentacija deluje pri čedalje manjšem številu segmentov vse bolj »požrešno« in večja območja, ne glede na to, kako smiselno je to. Tipi, ki smo jih dobili s segmentacijo, so najmanj podobni vsem ostalim rezultatom nenadzorovane klasifikacije in niso razdrobljeni. Pri dveh tipih smo dobili nazorno razdelitev na visokogorski svet in ostalo Slovenijo, pri ostalih pa so se oblikovale (prave) regije, ki pa imajo razne pomanjkljivosti zaradi »nasilnega« združevanja sosednjih enot. Pri petih tipih sta tako v istem tipu celo jugozahodna ter severovzhodna Slovenija. To je tudi razlog za slabše ocene z vidika podatkovnih slojev. Segmentacija je eno izmed redkih orodij, ki dejansko izdeluje regionalizacijo, saj v isto enoto klasificira le območja, ki so si sosednja, zato je lahko v tem primeru govorimo o poskusih regionalizacije Slovenije. Segmentacija je uporabna za določitev (po površini manjših) homogenih območij v večjem merilu oziroma za izdelavo segmentov, ki jih lahko nadalje klasificiramo z drugimi metodami. Pri tem zmanjšamo število podatkov. Segmentom pa lahko določimo dodatne spremenljivke (za seznam glej na primer Duro, Franklin, Dubé, 2012, 263).

Preglednica 108: Segmentacija.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je v rastrski in vektorski obliki
možnost posploševanja; določanje različnih ravni nadzor uporabnika (število nastavitev ³⁹)	možnost posploševanja le v isti seriji z različnimi tolerančnimi pragovi (segmenti so hierarhični) 5
rezultati naloge	
lastnost	opis
ujemanje z ostalimi modeliranimi tipizacijami ⁴⁰	šibko
rezultati vrednotenja na podlagi podatkovnih slojev ⁴¹	precejšnja negativna odstopanja

9.2.1.2 Geoinformacijska orodja za nadzorovano klasifikacijo

Metoda **odločitvenega drevesa, različica CT**, (preglednica 109) v programu SPSS nima nobenih predpostavk glede podatkov, zato lahko uporablja nominalne in številske podatke hkrati⁴². Z obrezovanjem drevesa lahko tudi posplošimo rezultate. Slabost metode je ta, da gre za serijo odločitev, vsakokrat na podlagi enega podatkovnega sloja. Prednost pa je v preglednosti in nazornosti (izris odločitvenega drevesa).

Modelirane tipizacije Slovenije te metode v primerjavi z rezultati ostalih metod niso ravno najboljše glede na vrednotenje z vidika podatkovnih slojev, po drugi strani pa se modelirane tipizacije po odločitvenem drevesu bolje ujemajo z izvirno tipizacijo kot pa večina ostalih modeliranih tipizacij. Pri popačenih izvornih tipizacijah se drevesa ne obnesejo (priloga 14), kar je v bistvu dobro, saj ne podpirajo naključnih ali pa slabo določenih ročnih klasifikacij (in njihovih učnih celic). Glede na vrednotenje je torej očitno, da se modeli po tej metodi bolj prilagajajo izvirnikom in ne sledijo toliko (svoji) novi strukturi.

Metoda je zelo primerna za obdelavo nominalnih podatkov, saj jih ni treba preoblikovati v številske.

Preglednica 109: Odločitveno drevo (različica CT).

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	ni omejitev
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	posploševanje je možno z obrezovanjem (pruning) ali drugačnimi nastavitvami
nadzor uporabnika (število nastavitvev ³⁹)	5 (in validacija)
rezultati naloge	
lastnost	opis
ujemanje z izvirno tipizacijo	nadpovprečno ujemanje glede na ostale rezultate
rezultati vrednotenja na podlagi podatkovnih slojev ⁴³	pogosto ovrednoteno slabše od ostalih
modeliranje popačene izvorne tipizacije ⁴⁴	ni mogoče

Metoda najmanjše razdalje (preglednica 110) je (tako kot vse ostale v nadaljevanju) omejena na številske podatkovne sloje, plega tega pa rezultata ne moremo posploševati. Metoda daje glede na podatkovne sloje zelo dobre rezultate (boljše od ostalih), z izvirnikom pa se slabo ujema. Pri modeliranih naravnopokrajinskih tipizacijah Slovenije je opazno, da po tej metodi dobimo pri modelih nekoliko bolj razpršene tipe v osrednji Sloveniji kot pri ostalih metodah. Slabo ujemanje z izvirnikom nakazuje, da metoda precej upošteva lastnosti podatkovnih slojev in vsiljuje svojo strukturo. To smo potrdili tudi s tem, da smo modelirali popačeno izvirno tipizacijo – rezultat se z izvirnikom ni ujemal, vrednotenje na podlagi podatkovnih slojev pa je bilo nekajkrat primerljivo ali celo zelo dobro (priloga 14).

Preglednica 110: Metoda najmanjše razdalje.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	ne
nadzor uporabnika (število nastavitvev ³⁹)	2
rezultati naloge	

⁴² Pri uporabi programske opreme je treba biti previden, saj nekatera geoinformacijska orodja (na primer CTA v Idrisiju) uporabljajo metodo odločitvenih dreves, a le s številskiimi podatki.

⁴³ Lastnost je subjektivna ocena po pregledu lestvic vrednotenja glede na podatkovne sloje v poglavju 8.3. Pri oceni smo dali večjo težo tistim načinom vrednotenja, ki so usklajeni z večino ostalih načinov.

⁴⁴ Ocena je podana na podlagi modeliranja popačenih naravnopokrajinskih tipizacij (priloga 14).

lastnost	opis
ujemanje z izvorno tipizacijo	ponavadi najmanjše med vsemi
rezultati vrednotenja na podlagi podatkovnih slojev ⁴³	pogosto ovrednoteno boljše od ostalih
modeliranje popačene izvorne tipizacije ⁴⁴	slabo ujemanje s popačeno izvorno tipizacijo; vsili svojo strukturo, zato ima v nekaterih primerih ocenjevanja na podlagi podatkovnih slojev dokaj dobre rezultate (priloga 14); ponekod ne določi vseh tipov

Metoda največje verjetnosti (preglednica 111) je uporabna le za številske podatke, posplošitve pa niso možne. Metoda daje rezultate, ki se slabo do povprečno dobro ujemajo z izvornikom. Pri modeliranih naravnopokrajinskih tipizacijah Slovenije je opazno, da po tej metodi dobimo pri modelih nekoliko bolj razpršene tipe v osrednji Sloveniji kot pri ostalih metodah. Pri vrednotenju na podlagi podatkovnih slojev so v primerjavi z ostalimi vključenimi metodami pogosto zelo dobro ocenjene. Podobno kot pri metodi najmanjše razdalje je tudi tukaj mogoče zaznati, da metoda vsiljuje svojo strukturo, saj se modelirane popačene tipizacije s popačeno klasifikacijo ne ujemajo, kljub temu pa so nekajkrat kar dobro ocenjene z vidika podatkovnih slojev (priloga 14).

Preglednica 111: Metoda največje verjetnosti.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	ne
nadzor uporabnika (število nastavitev ³⁹)	najmanj 2
rezultati naloge	
lastnost	opis
ujemanje z izvorno tipizacijo	pri ekspertnem načinu slabše ujemanje; povprečno pri naključnem načinu
rezultati vrednotenja na podlagi podatkovnih slojev ⁴³	pogosto ovrednoteno boljše od ostalih
modeliranje popačene izvorne tipizacije ⁴⁴	slabo ujemanje s popačeno izvorno tipizacijo vsili svojo strukturo, zato je v redkih primerih celo dobro ovrednotena z vidika podatkovnih slojev (glej priloga 14)

Metoda najbližjih sosedov (preglednica 112) lahko upošteva le številske podatke, posploševanja niso možna. Z metodo smo izdelali takšne naravnopokrajinske modelirane tipizacije Slovenije, ki so glede na vse druge v nalogi najbolj podobne izvorni tipizaciji, hkrati pa so ti rezultati z vidika podatkovnih slojev ovrednoteni zelo različno, nikoli pa niso ocenjeni kot najboljši. Kljub veliki podobnosti z izvornikom so vidna nekatera velika odstopanja, na primer določitev osamelcev na Ljubljanskem polju k drugemu tipu. To pomeni, da bi lahko modele po tej metodi uporabili za iskanje največjih neskladij v izvornih tipizacijah. Dobra stran metode je, da ne vsili svoje strukture, saj se dobro prilagaja izvorniku. Tudi pri analizi s popačeno tipizacijo metoda ni vsilila svoje strukture (priloga 14).

Preglednica 112: Metoda najbližjih sosedov.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	ne
nadzor uporabnika (število nastavitev ³⁹)	2
rezultati naloge	

lastnost	opis
ujemanje z izvirno tipizacijo	večinoma največje ujemanje
rezultati vrednotenja na podlagi podatkovnih slojev ⁴³	različno ovrednoteno, a nikoli kot najboljše
modeliranje popačene izvirne tipizacije ⁴⁴	slabo ujemanje s popačeno izvirno tipizacijo; slabo ovrednotena z vidika podatkovnih slojev (ne vsili svoje strukture)

Metoda odločitvenega drevesa, različice CTR, CTE, CTG, (preglednica 113) lahko obdela le številske podatke, kar je velika slabost, prednost pa predstavlja možnost posploševanja, ki je izvedljiva z obrezovanjem izdelanega drevesa. Število nastavitvev je dokaj skromno – le en parameter je treba nastaviti pred začetkom. V nalogi smo uporabili to orodje trikrat, in sicer s tremi načini izračunavanja »čistosti« (razmerje informacijskega prispevka, Ginijev koeficient, informacijski prispevek).

Metoda daje rezultate, ki v primerjavi z ostalimi rezultati v nalogi niso ravno najboljše ovrednoteni z vidika podatkovnih slojev, nekoliko bolje se izkažejo pri ujemanju z izvirnikom. Modeliranje popačene izvirne tipizacije ni možno, kar pomeni, da metoda naključnih ali slabih podatkov ne more modelirati in vsiliti svoje strukture (priloga 14).

Preglednica 113: Odločitveno drevo različic CTR, CTE, CTG (mere razmerje informacijskega prispevka, Ginijev koeficient, informacijski prispevek).

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski (intervalni ali razmernostni) podatki
izris meja; vizualna preglednost	rezultat je rastrski prikaz celic
možnost posploševanja; določanje različnih ravni	posploševanje je možno z obrezovanjem (pruning)
nadzor uporabnika (število nastavitvev ³⁹)	1
rezultati naloge	
lastnost	opis
ujemanje z izvirno tipizacijo	rahlo nadpovprečno ujemanje glede na ostale rezultate
rezultati vrednotenja na podlagi podatkovnih slojev ⁴³	pogosto ovrednoteno slabše od ostalih
modeliranje popačene izvirne tipizacije ⁴⁴	ni mogoče

9.2.1.3 Geoinformacijska orodja za vrednotenje tipizacij z več podatkovnimi sloji hkrati

Po pregledu uporabljenih geoinformacijskih orodij za vrednotenje tipizacij z več podatkovnimi sloji hkrati (preglednice 114–116) smo ugotovili, da računanje deleža enako klasificiranih celic po modelu diskriminancijske analize in oddaljenost od najbližjega centroida dajeta podobne rezultate, računanje deleža enako klasificiranih po modelu odločitvenega drevesa pa nekoliko drugačne. Prednost slednje je ta, da lahko ocenjujejo tipizacije z nominalnimi in številiškimi podatki. Prvi dve sta omejeni le na številske podatkovne sloje.

Preglednica 114: Delež enako klasificiranih po modelu odločitvenega drevesa (vsi podatkovni sloji hkrati).

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	ni omejitve
vpliv uporabnika na rezultat ocene	da (določanje velikosti drevesa in drugih lastnosti)
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	slabo

⁴⁵ To lastnost smo ocenili predvsem na podlagi ugotovitev v delu naloge, ki obravnava vrednotenje tipizacij, ki so narejene na podlagi metod nadzorovane klasifikacije.

Preglednica 115: Računanje oddaljenosti od najbližjega centroida.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski podatki
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

Preglednica 116: Delež enako klasificiranih po modelu diskriminančne analize.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski podatki
vpliv uporabnika na rezultat ocene	da
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

9.2.1.4 Geoinformacijska orodja za vrednotenje s posameznimi podatkovnimi sloji

Po pregledu uporabljenih geoinformacijskih orodij za vrednotenje tipizacij s pomočjo posameznega podatkovnega sloja (preglednice 117–122) smo ugotovili, da se različni načini vrednotenja dobro povezujejo med seboj. Nekoliko odstopa vrednotenje z deležem enako klasificiranih po modelu odločitvenega drevesa, ki pa ima prednost, da lahko upošteva vse vrste podatkovnih slojev. Informacijski prispevek in razmerje informacijskega prispevka lahko prav tako uporabljata vse vrste podatkovnih slojev, ostali načini pa le številske.

Preglednica 117: Delež enako klasificiranih po modelu odločitvenega drevesa (po en podatkovni sloj).

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	ni omejitev
vpliv uporabnika na rezultat ocene	da (določanje velikosti drevesa in drugih lastnosti)
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	manjša

Preglednica 118: Koeficient F.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski podatki
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

Preglednica 119: Koeficient eta².

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski podatki
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

Preglednica 120: Povprečni umerjeni koeficient variacije.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	številski podatki
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

Preglednica 121: Informacijski prispevek.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	ni omejitev
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

Preglednica 122: Razmerje informacijskega prispevka.

osnovne možnosti geoinformacijskega orodja	
lastnost	opis
možnost uporabe podatkov	ni omejitev
vpliv uporabnika na rezultat ocene	ne
rezultati naloge	
lastnost	opis
ujemanje z ostalimi načini vrednotenja ⁴⁵	dobro

9.2.1.5 Geoinformacijska orodja za vrednotenje ujemanja klasifikacij

Geoinformacijska orodja oziroma načini vrednotenja (koeficient kappa, Cramerjev koeficient, delež enako klasificiranih celic), ki smo jih uporabili v nalogi, so dali podobne rezultate. Vse metode sprejmejo nominalne podatke, vpliv uporabnika pa ni možen.

9.2.2 Druge pomembne ugotovitve

Podobnost rezultatov analiz TIPI9 in TIPI13

Ugotovili smo, da sta si lestvici vrednotenja s pomočjo podatkovnih slojev in tudi lestvici vrednotenja s pomočjo izvorne tipizacije po obeh analizah v nalogi (TIPI9 in TIPI13) na splošno zelo podobni. To pomeni, da smo v dveh poskusih (TIPI9 in TIPI13) z vsakim vrednotenjem podobno rangirali uspešnost geoinformacijskih orodij oziroma modeliranih tipizacij. Če je torej neko geoinformacijsko orodje z vidika izbranega načina vrednotenja (na primer povprečne oddaljenosti od najbližjega centroida) v primerjavi z ostalimi orodji izdelalo dobro modelirano tipizacijo po izvorni tipizaciji TIPI9, je enako dobro izdelalo modelirano tipizacijo tudi po izvorni tipizaciji TIPI13 (poglavje 8.9).

Vpliv števila tipov na vrednotenje in usklajenost med modeliranimi tipizacijami

V analizi usklajenosti vrednotenja tipizacij po metodah nenadzorovane klasifikacije glede na število različnih tipov smo ugotovili, da je zelo pogosto vidna povezava med višino ocene in številom tipov (trend ni jasno viden le pri vrednotenju s koeficientom F). Tipizacije z večjim številom tipov so bile namreč večinoma ovrednotene kot boljše, le po vrednotenju z odločitvenim drevesom kot slabše (poglavje 7.3). Usklajenost tipizacij (medsebojna podobnost) pa se z večanjem števila različnih tipov manjša, saj je z večanjem števila tipov pri prekrivanju možnih tudi več različnih kombinacij (poglavje 7.5).

Povprečni umerjeni koeficient variacije (PUKV) kot pomoč pri iskanju primernih podatkovnih slojev glede na merilo tipizacije oziroma velikost obravnavanega območja

Glede na to, da je bilo v geografiji precej napisanega o dejavnikih na različnih ravneh (merilih) proučevanja pokrajine (na primer Klijn 1994 in Bailey 1996) ter da obstaja že nekaj statističnih analiz podatkovnih slojev z različnimi osnovnimi enotami (Krevs 1998) in rastrskega podatkovnega sloja z različnimi ločljivostmi (na primer Drăguț, Eisank in Strasser 2011), smo uvideli, da lahko tovrstna spoznanja povežemo. To smo poskusili z izračunom povprečnega umerjenega koeficienta variacije (poglavje 6, podrobne opis v prilogi 4). Z njim smo lahko ločili podatkovne sloje po tem, kako se v povprečju obnaša njihova spremenljivost na različno velikih območjih. Tako smo lahko za območje Slovenije ocenili, kateri podatkovni sloji so pomembni pri klasifikaciji v manjšem merilu (za večje območje) in kateri pri klasifikaciji v večjem merilu (za manjše območje). Po tej analizi lahko na primer v Sloveniji podatke o padavinskem režimu uporabimo predvsem pri določanju tipov v majhnem merilu, podatke o nadmorski višini in temperaturi lahko uporabimo tako pri majhnem kot tudi pri velikem merilu, podatke o reliefni razgibanosti (višinska, naklonska razgibanost, ekspozicija ...) pa predvsem v velikem merilu, torej za manjša območja.

Na področju klasifikacije pokrajin do sedaj ni bilo pogosto uporabljenega objektivnega določanja tega, kateri dejavniki so primerni za določeno območje. Verjamemo, da je PUKV metoda, ki lahko zmanjša subjektivnost pri izboru podatkovnih slojev s tega vidika.

Za izdelavo različno velikih območij, s katerimi lahko izračunamo PUKV-je različnih ravni, lahko izberemo različne sistematične načine; nekateri predlogi so: mreža kvadratov, razdelitev na skupine s pomočjo metode voditeljev z vrednostmi X in Y osi ter razdelitev s pomočjo kroga (slika 91).

Slika 91: Različni načini določanja območij za izračunavanje PUKV-jev. Primer za raven s petimi enotami.



Vpliv izbire vzorčenja in geoinformacijskih orodij na rezultat

Potrdili smo ugotovitve iz literature (Campbell 1996; Lillesand, Kiefer in Chipman 2008), da način vzorčenja pomembno vpliva na rezultate. Pri primerjavi modeliranih tipizacij smo zasledili naslednje (poglavje 8):

- pri računanju stopnje povezanosti (ujemanja) med modeliranimi tipizacijami smo ugotovili, da sta modelirani tipizaciji, ki sta narejeni z enako metodo, a drugačnim načinom vzorčenja, lahko tako različni med seboj kot modelirani tipizaciji, ki sta izdelani z različnima metodama (poglavje 8.4),
- pri vrednotenju na podlagi podatkovnega sloja je lahko način vzorčenja eden izmed vzrokov za razlike v oceni (poglavje 8.3),

- seštevki trdnih modeliranih tipizacij po posameznih tipih po obeh načinih vzorčenja se povezujejo statistično značilno ($p=0,01$), vendar so koeficienti pri posameznih tipih izredno nizki, v enem primeru je povezanost celo negativna (poglavje 8.6).

Posebej velja izpostaviti ugotovitve po primerjavi ujemanja modeliranih tipizacij z izvirno tipizacijo (poglavje 8.3.3). Če primerjamo samo učne celice, je ujemanje večje, če uporabimo ekspertni način vzorčenja; če primerjamo vse celice, je ujemanje večje, če uporabimo naključni način vzorčenja. To preprosto pomeni, da lahko z ekspertnim vzorčenjem izdelamo bolj preproste, »čiste« modele, ki pa so tudi močnejše prilagojeni lastnostim učnih celic. Če modeliramo tipe, ki so zelo natančno narejeni (ni risarskih napak), je ekspertni način lahko bolj primeren. V primeru da gre za zelo posplošeno tipizacijo, je za modeliranje boljši naključni izbor učnih celic.

Pri metodah nenadzorovane klasifikacije in metodah nadzorovane klasifikacije smo ugotovili, da izbira geoinformacijskega orodja vsekakor vpliva na rezultat (modelirano tipizacijo). S prekrivanjem različnih rezultatov lahko pridemo do spoznanja o tem, kje se rezultati ujemajo oziroma kje so posamezni tipi bolj dokazljivi.

Naključnost za ugotavljanje vsiljevanja strukture klasifikacije

Do zanimivih ugotovitev smo prišli z analizo (priloga 14), s katero smo popačili izvirni naravnopokrajinski tipizaciji TIPI9 in TIPI13 ter nato za obe skušali narediti modelirane tipizacije. Ugotovili smo, da nekatera geoinformacijska orodja (na primer odločitveno drevo) ne morejo modelirati slabo zasnovanih tipizacij (ki so podobne naključnemu klasificiranju) in izdelati modela. Nekatera geoinformacijska orodja pa, nasprotno, lahko kljub nesmiselni zasnovi izvirne tipizacije izdelajo modele, ki so lahko (vsaj pri nekaterih načinih vrednotenja s pomočjo podatkovnih slojev) dobro ocenjeni, a z izvirno popačeno tipizacijo nimajo kaj dosti skupnega, kar pomeni, da je orodje vsililo svojo strukturo (na primer metoda najkrajše razdalje). Za preučevanje lastnosti geoinformacijskih orodij oziroma spoznavanje njihovega delovanja je preverjanje modeliranja popačenih klasifikacij lahko v pomoč, saj uporabnik dobi informacijo o tem, katera metoda klasifikacije bolj vsiljuje svojo strukturo in katera metoda se bolj prilagodi učnim podatkom (čeprav slabim oziroma popačenim). Tako lahko uporabnik, ki meni, da ima reprezentativno podatkovno bazo, uporabi metode, ki se bolj prilagodijo učnim podatkom, v nasprotnem primeru pa mora preizkusiti različne metode in primerjati rezultate.

Predlog uporabe geoinformacijskih orodij za naravnopokrajinsko tipizacijo Slovenije

Glede na vse ugotovitve predlagamo, da se za izdelavo naravnopokrajinske tipizacije Slovenije lahko uporabi naslednji sklop geoinformacijskih orodij:

a) kjer so število in osnovne lastnosti tipov že znani:

- uporaba segmentacije za združitev najbolj homogenih območij na podlagi najbolj natančnih podatkovnih slojev (na primer nadmorske višine in naklona),
- izbira učnih poligonov (z ogledom na terenu),
- uporaba odločitvenega drevesa kot klasifikacijskega modela ter klasifikacija celotne države (izdelava več različic tipizacije),
- ob izdelavi več različic vključimo v postopek še ocenjevanje vseh različic s pomočjo geoinformacijskih orodij za vrednotenje na podlagi podatkovnih slojev in uspešnosti modeliranja (slika 90) ter nato izberemo različico, ki je ovrednotena kot najboljša,
- vnos morebitnih popravkov mej.

b) kjer število in osnovne lastnosti tipov niso znani:

- uporaba segmentacije za združitev najbolj homogenih območij na podlagi najbolj natančnih podatkovnih slojev (na primer nadmorske višine in naklona),

- (ob dovolj velikem zmanjšanju količine podatkov zaradi segmentacije) uporaba metode hierarhičnega razvrščanja⁴⁶ za oceno števila skupin,
- preizkušanje različnih metod nenadzorovane klasifikacije in izdelava več različic,
- ocenjevanje različic iz prejšnjega koraka s pomočjo geoinformacijskih orodij za vrednotenje na podlagi podatkovnih slojev ter uspešnosti modeliranja,
- izbor najboljše tipizacije,
- vnos morebitnih popravkov.

⁴⁶ V disertaciji te metode zaradi prevelike količine podatkov (več kot 500.000 celic) nismo uporabili.

10. Sklep

Kljub temu da znanstveniki niso enotnega mnenja glede obstoja raznih bolj ali manj homogenih območij v naravi, ki jih lahko označimo kot (naravne) tipe, lahko v t. i. virtualnem svetu takšne enote zagotovo najdemo. Če predpostavimo, da so podatkovni sloji (digitalni model višin, interpolirana karta temperatur, razmerje med višino padavin pozimi in višino padavin poleti ...) približki naravnih dejavnikov (nadmorska višina, temperatura, padavinski režim ...), lahko na povsem objektivni način opravimo klasifikacijo oziroma razdelitev določenega območja na tipe, ki so zato približki splošnih naravnih značilnosti. V virtualnem svetu, kjer je resnično okolje predstavljeno s številskimi ali opisnimi vrednostmi za posamezno prostorsko enoto (na primer celico), lahko lažje govorimo o obstoju tipov z mejami. Potek meja v virtualnem svetu je sicer odvisen od namena razmejevanja, uporabljenih metod in tudi interpretacije rezultatov. Zaradi različnih metodologij obstajajo različni rezultati – bolj pogoste (torej tisti, ki so enaki kljub različnim metodološkim pristopom) lahko razumemo kot bolj objektivne.

Veliko število podatkovnih slojev, geoinformacijskih orodij in drugih postopkov (na primer vzorčenja) dopuščajo več različnih rezultatov – klasifikacij. Ko raziskovalec določa parametre, jih lahko določa tudi subjektivno, zato je celotna klasifikacija tudi manj objektivna. A tu je treba pripomniti, da gre še vedno za precejšnjo mero objektivnosti, saj nastavitve parametrov veljajo enako za vse celice in s tega vidika ni pristranskosti glede klasifikacije ali pa risanja mej (vse celice so obravnavane enako). Po eni strani raznovrstne možnosti omogočajo poskušanje raznih metod tako dolgo, dokler ne pridemo dovolj blizu zelenemu rezultatu (kar lahko tudi zlorabimo), po drugi strani pa lahko s primerjavo več različnih rezultatov tudi objektivneje sklepamo. V nalogi smo ugotovili, da lahko nekatere metode nadzorovane klasifikacije bolj vsilijo svojo strukturo (na primer metoda najmanjše razdalje) kot pa nekatere druge (na primer metoda najbližjega sosedu). Posledično je zaradi tega ujemanje med izvirno in modelirano klasifikacijo manjše. Na uspešnost modeliranja poleg izbire metode oziroma geoinformacijskega orodja vpliva tudi način vzorčenja. V nalogi smo preizkusili dva, naključno in ekspertno, ter ugotovili, da smo dobili različne rezultate. Geografski informacijski sistemi so vsekakor omogočili velik korak k objektivnosti določanja/prepoznavanja (odvisno od tega, kateri skupini znanstvenikov pripadamo) pokrajinskih enot. Uporabimo jih lahko pri:

- pridobivanju in pripravi podatkovnih slojev,
- analizi oziroma vrednotenju podatkov,
- izdelavi klasifikacij (tipizacij),
- preverjanju ustreznosti klasifikacij oziroma njihovem vrednotenju,
- kartografskem prikazu,
- arhiviranju in dopolnjevanju izdelanih klasifikacij.

Hipotezi

V nalogi smo se osredotočili predvsem na **vrednotenje tipizacij**, poleg tega pa smo dobršen del posvetili tudi vrednotenju podatkovnih slojev. Glavni temi sta bili vseskozi nepristranska izbira najboljše kombinacije vhodnih podatkovnih slojev (*input*) ter izbira najustreznjega izhodnega rezultata (*output*). Tipizacije smo poskusili čim bolj objektivno vrednotiti s pomočjo informacijskega prispevka, razmerja informacijskega prispevka, odločitvenega drevesa, diskriminancijske analize, povprečnega umerjenega koeficienta variacije, koeficienta F , koeficienta η^2 in povprečne oddaljenosti celic od centroida, s katerimi smo ugotavljali, kako dobro je tipizacija narejena glede na podatkovne sloje. S pomočjo koeficienta κ , Cramerjevega koeficienta in deleža enako klasificiranih celic pa smo ugotavljali, kako močno se modelirane tipizacije ujemajo med seboj ter (v sklopu z metodami nadzorovane klasifikacije) tudi kako močno z izvirnimi tipizacijami.

Pri analizi tipizacij po metodah nenadzorovane klasifikacije je bila ugotovljena manjša usklajenost omenjenih načinov vrednotenja kot pa pri analizi tipizacij po metodah nadzorovane klasifikacije, kjer smo ugotovili, da se različni načini vrednotenja tipizacij dobro ujemajo in zato lahko objektivno ocenimo, katera tipizacija je bolj ustrezna glede na izbrane podatkovne sloje. Nasploh kot manj primeren in od ostalih odstopajoč način vrednotenja se je izkazal način z izračunom deleža enako klasificiranih po modelu odločitvenega drevesa. Izsledki raziskav v nalogi so zato bolj uporabni za tisto skupino raziskovalcev, ki v pokrajini že pozna določene tipe oziroma primere tipov. Ti lahko uporabijo v nalogi predlagan postopek vrednotenja, ki bi lahko bil uporaben za vse klasifikacije pokrajine, za različne namene; edini pogoj je ustrezna podatkovna baza. To pomeni, da so tipizacija in podatkovni sloji v enakem koordinatnem sistemu enake ločljivosti in obsega (število vrstic in kolon se mora prav tako ujemati). Pri morebitnih primerjavah različic klasifikacij z različnim številom kategorij (tipov) pa se je treba zavedati, da je večina mer, ki smo jih preizkusili, podvržena vplivu števila tipov.

Območja, ki se kljub raznolikim metodam klasificirajo enako, smo z uporabo različnih metod nadzorovane klasifikacije prepoznali tako, da smo najprej izdelali modelirane tipizacije, nato pa smo seštevali, kolikokrat je posamezna celica klasificirana v posamezen tip. Tak seštevek trdnih modeliranih tipizacij lahko upoštevamo tudi kot neko splošno mehko tipizacijo, saj smo ugotovili, da se seštevek povezuje z različnimi metodami mehke nadzorovane klasifikacije, ki nam jih nudijo obstoječi programski paketi, in zato daje relevanten vpogled v to, kje so jedra tipov in kje obrobja.

V nalogi smo na ta način tudi ugotovili, kje so območja, ki so po vseh modeliranih tipizacijah enako klasificirana (imajo pri seštevku trdnih klasifikacij najvišjo možno vrednost); kje so območja, ki so enaka po vseh modelih in hkrati enaka tudi izvorni tipizaciji; kje so območja, ki glede na izvorno tipizacijo niso nikoli enako klasificirana; ter kje so območja, ki se ujemajo po vseh modelih, a se ne ujemajo z izvorno tipizacijo. Na ta način smo prišli do praktičnih ugotovitev o tem, kje v Sloveniji bi lahko izboljšali izvorni tipizaciji TIPI9 in TIPI13, kje so najbolj očitna območja posameznih tipov in kje najtežje računsko opisljiva območja. Pri tipizaciji **TIPI9** smo z vsemi modeli v posameznem sklopu (po ekspertnem in naključnem načinu vzorčenja) potrdili tipe na približno eni tretjini Slovenije; gre za večja območja sredozemskih in panonskih tipov ter višjih območij dinarskih planot, alpskega sredogorja in gorovja. Alpske ravnine so bile potrjene v večjem delu med Ljubljanskim poljem in Deželo. Izmed vseh devetih tipov je bilo glede na posamezne modele največje ujemanje ugotovljeno pri panonskih ravninah, panonskih gričevjih, alpskih ravninah, sredozemskih gričevjih in sredozemskih planotah. Omenjene tipe je verjetno lažje opredeliti zaradi obsežnih ravnin in pa zaradi njihove lege na skrajnem jugozahodnem oziroma vzhodnem delu države, kjer je v primerjavi z osrednjimi deli prehodnost v smislu podnebnih značilnosti manj izrazita. Zaradi načina vzorčenja (enak delež ne glede na velikost tipa) in nasploh zaradi večje pokrajinske raznolikosti se modeli slabše obnesejo pri površinsko večjih tipih. Nikoli pa niso bile potrjene predvsem nekatere vzpetine znotraj ravnin (npr. Rašica v Ljubljanski kotlini) in doline znotraj pretežno vzpetih območij (na primer doline Save, Soče, Drave, Ščavnice). Opazna je odsotnost močnega ujemanja med modeliranimi in izvirnimi tipi na območju Celjske kotline, srednje Soške doline, območja med Vrhniko in Idrijo, Pivške kotline, Ljubljanskega barja, Dolenjskega podolja, Suhe krajine, Bizeljskega, dela Krške kotline, Gorjancev, Bele krajine. Po vsakem sklopu vzorčenja v nekaterih primerih nismo niti z enim modelom uspeli potrditi dela ozemlja (sicer obakrat manj kot eno petino). Med temi območji so predvsem obrobja posameznih tipov (na primer obrobje sredozemskih gričevij na Brkinih) in nekatere doline in druge depresije znotraj bolj vzpete in razgibane pokrajine (na primer alpske doline znotraj alpskih gorovij). Nekaj območij je tudi bolj obširnih (na primer Banjšice, Kolovrat,

Kočevskoreški ravniki). Neskladja so se pojavila med drugim tudi preprosto zaradi manjšega merila in omejene natančnosti pri ročnem izrisu meje izvornih tipov. Pri tipizaciji **TIP13** smo z vsemi modeli v posameznem sklopu (po ekspertnem in naključnem načinu vzorčenja) potrdili predvsem celice na območju višjega dela tipa visokogorski svet, tipa ravnine in širše doline v gričevju notranjega dela Slovenije (brez vmesnih vzpetin), tipa Kras in Podgorski kras ter tipa gričevje v primorskem delu Slovenije. Dobro se ujemajo tudi gričevja v notranjem delu Slovenije, višji deli visokih kraških planot in hribovij v karbonatnih kamninah ter nizki kras Bele krajine (slednji samo v sklopu z naključnim vzorcem). Tako močnega ujemanja ni na območju sredogorij v osrednji Sloveniji. To je z vidika podnebja verjetno tudi najbolj prehodno območje, poleg tega pa je tu relief razgiban (menjavanje dolin, vzpetin ...), kar je težje opisljivo z matematičnimi pravili. Izmed vseh 13 tipov smo glede na posamezne modele ugotovili največje ujemanje pri gričevnatih ali ravninskih tipih, ki so na vzhodu države (gričevja v notranjem delu Slovenije, ravnine in širše doline v gričevju notranjega dela Slovenije, nizki kras Bele krajine) ter pri nekaterih tipih na skrajnem jugozahodu države (Kras in Podgorski kras, gričevje v primorskem delu Slovenije). Tip visokogorski svet ima tudi večjo stopnjo ujemanja, saj so avtorji izločili alpske planote in večje alpske doline. Območja, ki jih nismo potrdili niti z enim modelom v posameznem sklopu, so predvsem vznožja vzpetin, pri modeliranih tipizacijah po ekspertnem vzorčenju pa tudi večje površine na Banjšicah, Brkinih, Kočevskem in v Posavskem hribovju. Na podlagi analize modeliranih tipizacij, ki so bile izdelane z metodami nenadzorovane klasifikacije, smo s primerjavo povprečnih oddaljenosti celic od najbližjih centroidov tipov posameznih modeliranih tipizacij ugotovili, da se le-te med seboj večinoma dobro povezujejo.

Prvo hipotezo o vrednotenju tipizacij, ki se glasi: »*Z ustrezno kombinacijo geoinformacijskih orodij tipizacij in vrednotenjem rezultatov tipizacij je mogoče objektivno oceniti kakovost tipizacij*«, smo **potrdili le deloma**. V celoti je nismo mogli potrditi predvsem zaradi rezultatov analize vrednotenja tipizacij po metodah nenadzorovane klasifikacije, pri katerih se je pokazalo, da različni načini vrednotenja med seboj niso dovolj usklajeni. Naše ugotovitve na področju vrednotenja tipizacij po metodah nadzorovane klasifikacije pa hipotezi pritrjujejo (torej, da so različni načini vrednotenja dovolj usklajeni in da je objektivno vrednotenje možno) in so podprte z rezultati dveh ločenih analiz (analiza tipizacije TIP19 in tipizacije TIP13), ki sta si zelo podobni; to dejstvo predstavlja močan argument za to, da lahko rezultatom disertacije zaupamo. Poleg tega pa je treba izpostaviti še, da smo ugotovili, da sta obstoječi geografski klasifikaciji (TIP19 in TIP13) vsekakor smiselni tudi v matematičnem pogledu, saj smo lahko na njunem temelju izdelali modele z vsemi uporabljenimi geoinformacijskimi orodji ter opravili različne matematične analize v nadaljevanju. Kljub temu da smo lahko klasifikaciji potrdili »le« 50–75 %, je to namreč še vedno precej več, kot bi bilo v primeru modeliranja naključne oziroma slabe tipizacije (priloga 14). Če bi našo nalogo izdelali na podlagi slabih tipizacij, ne bi mogli niti izpeljati vseh računskih postopkov, klasifikacij in vrednotenja.

Smiselnost vrednotenja rezultata se je torej dobro pokazala predvsem pri vrednotenju tipizacij, ki smo jih izdelali z metodami nadzorovane klasifikacije. Ob tem spoznanju smo sklenili, da lahko predlagamo na tem področju v prihodnosti vrednotenje v dveh sklopih. Pri prvem vrednotimo, kako dobro neka klasifikacija odraža podatkovne sloje (se z njimi povezuje), pri drugem pa, kako dobro lahko neko klasifikacijo potrdimo matematično na podlagi izbranega vzorca. Oba načina vrednotenja sta si precej podobna, a je med njima razlika, saj pri prvem vrednotimo klasifikacije z vidika podatkovnih slojev na podlagi vseh celic, pri drugem pa s pomočjo vzorca celic skušamo ugotoviti, ali pridemo do podobnega rezultata tudi po računski poti. Gre torej za dvojno ocenjevanje, ki še poveča objektivnost.

Drugo hipotezo o iskanju območij, ki so enako klasificirana ne glede na uporabljeno geoinformacijsko orodje, – »**Z geografskimi informacijskimi sistemi je možno ugotoviti, katera so tista območja, ki se ne glede na uporabo različnih geoinformacijskih orodij uvrščajo v enake oziroma podobne tipe, ter katera so tista območja, ki jih geoinformacijska orodja uvrščajo različno**« – pa **smo potrdili**, saj nam uporaba različnih geoinformacijskih orodij dejansko omogoča ugotoviti, katera območja tipov se kljub različnim metodam enako klasificirajo in katera ne ter kako pogosto se posamezna celica klasificira v vsakega izmed določenih tipov. Slednje smo dosegli s seštevanjem primerov, v katerih je posamezna celica klasificirana v določen tip. Da je tak seštevek posameznih trdnih klasifikacij podoben splošni mehki klasifikaciji in hkrati relevanten podatek, smo dokazali s primerjavo seštevka za posamezne tipe z rezultati različnih metod mehke nadzorovane klasifikacije za posamezne tipe.

Uporabnost geoinformacijskih orodij

Med izdelavo disertacije smo preizkusili različna geoinformacijska orodja, ki smo jih kritično ovrednotili, ter predlagali, kako bi jih lahko uporabili za določanje tipov naravnih pokrajin v Sloveniji. Pri uporabi orodij je treba biti pozoren na to, ali imamo podatke, ki so zanje primerni.

Potencialno zelo uporabna orodja v geografiji so segmentacija in nekatera orodja strojnega učenja (na primer odločitvena drevesa, informacijski prispevek).

Segmentacijo želimo izpostaviti zato, ker pomeni prehod iz klasičnega rastrskega sistema, ki temelji na celicah (*pixel-based*), v objektni (*object-based*) vektorski sistem poligonov.

Prednosti tega prehoda sta med drugim, da:

- poligonom lahko pripišemo različne rastrske vrednosti, izračunamo dodatne spremenljivke, poleg tega pa dobimo s tem možnost analize s pokrajinskimi spremenljivkami (ang. *landscape metrics*; seznam najpogosteje uporabljenih sta navedli Šímová in Gdulová leta 2012),
- zmanjšamo število enot (saj združimo najbolj homogena rastrska območja) in pospešimo celotno analizo.

Metode strojnega učenja prinašajo dodatne možnosti objektivne obdelave nominalnih podatkov. Obdelava teh podatkov je v geografiji pogosta (vrsta kamnine, vrsta gozdne združbe, tip rabe tal ...), zato so te metode zagotovo uporabne.

Med pomembnimi spoznanji in novostmi, ki jih je vredno ob zaključku omeniti, spadata gotovo tudi priprava in opis povprečnega umerjenega koeficienta variacije (PUKV), ki se je izkazal kot uporaben pri preučevanju tega, kako se obnašajo podatkovni sloji na posameznih prostorskih ravneh, ter nam lahko pomaga pri izbiri ustreznih podatkovnih slojev. S pomočjo PUKV smo za Slovenijo ugotovili, kateri podatkovni sloji so primerni za klasifikacijo v večjem merilu in kateri v manjšem merilu.

Vizija

Nedvomno je klasifikacija Zemljinega površja izjemnega pomena, saj prispeva k preglednosti in omogoča boljše prostorsko načrtovanje. Veliko število pokrajinskih klasifikacij Slovenije in tudi raznolika terminologija sta dokaza, da je bilo tovrstno opravilo v slovenski geografiji že od nekdaj živahno. To področje pa mora ostati med primarnimi nalogami geografije tudi v prihodnje. Vzporedno z znanstvenimi raziskavami, ki morajo zajemati vsebinski in tudi metodološki vidik, je treba razvijati tudi uporabnost pridobljenega znanja na področju naravnopokrajinske klasifikacije. Tu imamo v mislih predvsem razvoj geoinformacijskih orodij oziroma celotnih programskih paketov, ki bi bili predvsem namenjeni klasifikaciji pokrajine in bi vsebovali geoinformacijska orodja za vse korake v procesu klasifikacije (od poizvedovanja o vhodnih podatkih do vrednotenja rezultatov). Z ustreznim programom bi

uporabniku na ta način prihranili iskanje primernih metod, uporabo različnih programov, dopolnjevanje le-teh z lastno napisanimi programskimi kodami in podobno. Ob današnji zmogljivosti računalnikov bi lahko bil celoten proces klasifikacije in vrednotenja dobljenih tipov (ali regij) tako povezan, da bi bila omogočena kar največja dinamičnost. S tem imamo v mislih predvsem možnost, da bi po izdelani (začetni) klasifikaciji že ob premiku posamezne meje dobili podatek, ali smo izboljšali naš izdelek ali ne (slika 92). Ob ustrezni strojni opremi (na primer interaktivna miza z zaslonom, ki je občutljiv na dotik) bi program lahko uporabnikom nudil podporo pri odločanju in argumentiranju o klasifikacijah (slika 93). Ob tem moramo nujno izpostaviti, da program ne bi bil namenjen le izdelavi (klasičnih, geografskih) klasifikacij pokrajine, ampak tudi klasifikaciji pokrajine s povsem specifičnega vidika; na primer za izdelavo čim bolj objektivne klasifikacije (potencialnih) kmetijskih površin, pri kateri bi uporabili podatkovne sloje, ki so pomembni z vidika rodovitnosti prsti (na primer nadmorska višina, vlažnost prsti, tip prsti, višina padavin v rastni dobi), za klasifikacijo satelitskih slik pri izdelavi karte pokrovnosti tal in na raznih drugih področjih.

Slika 92: Primer zamišljenega računalniškega programa za izdelavo in vrednotenje naravnopokrajinskih tipizacij.

The screenshot displays the LandscapeModeler 1.0 software interface. The main window is titled 'Zemljevid' (Map) and shows a topographic map with a highlighted area. A callout box points to a boundary line with the text 'popravek/premik meje med dvema enotama' (correction/shift of the boundary between two units). A legend on the right lists several data layers: nadmorska_visina.tif, naklon_s.tif, son_energija.tif, padavine_1960_2000.tif, padavinski_r.tif, and kamnine25.tif.

Below the map is a 'Rezultati vrednotenja' (Evaluation Results) panel showing a graph of 'informacijski prispevek' (informational contribution) on the y-axis (ranging from 0 to 1) and 'delež ujemanja celic' (cell matching percentage) on the x-axis (ranging from 0% to 100%). A callout box indicates 'sprememba ocene po premiku' (change in evaluation after shift). The graph shows two points, 'x' and 'x', representing the state before and after the boundary shift.

On the right side, there are two 'Nastavitve vrednotenja z vidika podatkov' (Evaluation Settings by Data View) panels. The top one is for 'informacijski prispevek' and the bottom one is for 'vidika modeliranja' (modeling view). Both panels allow users to select evaluation methods and weight different data layers. A callout box points to the 'izbira načina vrednotenja' (choice of evaluation method) section.

At the bottom right, a 'Trenutna ocena popravka' (Current Evaluation of Correction) panel shows a table of values for different data layers before and after the correction, along with the 'delež ujemanja celic' (cell matching percentage) before and after the correction. A callout box indicates 'sprememba ocene po premiku' (change in evaluation after shift).

	pred premikom:	po premiku:
nadmorska_visina.tif	0,7654320 b	0,8001255 b
padavinski_r.tif	0,8054326 b	0,8597492 b
kamnine25.tif	0,4483212 b	0,4900838 b
povprečje	0,6730619 b	0,7166528 b

	pred premikom:	po premiku:
delež ujemanja celic	52,021 %	53,545 %

Slika 93: Uporabniki računalniškega programa pri snovanju tipizacije.



11. Viri

- Abonyi, J., Feil, B., 2007. Cluster analysis for data mining and system identification. Basel, Boston, Berlin, Birkhäuser, 303 str.
- Acharya, T., Ray, A. K., 2005. Image processing. Principles and applications. Hoboken, J. Wiley & Sons, 428 str.
- Anderson, M. G., Ferree, C. E., 2010. Conserving the stage: Climate change and the geophysical underpinnings of species diversity. PLoS one, 5, 7, str. e11554 (1–10). DOI: <http://dx.doi.org/10.1371/journal.pone.0011554>
- Armitage, D. W., Ober, H. K., 2010. A comparison of supervised learning techniques in the classification of bat echolocation calls. Ecological Informatics, 5, 6, str. 465–473. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2010.08.001>
- Axelsson, R., Angelstam, P., Törnblom, J., 2010. Development of integrative landscape research towards problem-oriented science. V: Machar, I., Kovár, P. (ur.). Landscape structures, functions and management : response to global ecological change: book of abstracts. Praga, CZ-IALE, str. 135.
- Badgley C., Fox, D. L., 2000. Ecological biogeography of North American mammals: species density and ecological structure in relation to environmental gradients. Journal of Biogeography, 27, 6, str. 1437–1467. DOI: <http://dx.doi.org/10.1046/j.1365-2699.2000.00498.x>
- Bailey, R. G., 1996. Ecosystem geography. New York, Springer, 204 str.
- Bailey, R. G., 2005. Identifying ecoregion boundaries. Environmental Management, 34, S1, str. 14–26. DOI: <http://dx.doi.org/10.1007/s00267-003-0163-6>
- Bastian, O., 2000. Landscape classification in Saxony (Germany) – a tool for holistic regional planning. Landscape and urban planning 50, 1-3, str. 145–155. DOI: [http://dx.doi.org/10.1016/S0169-2046\(00\)2900086-4](http://dx.doi.org/10.1016/S0169-2046(00)2900086-4)
- Bat, M., Dobnikar Tehovnik, M., Mihorko, P., Grbović, J., 2003. Tekoče vode. V: Uhan, J., Bat, M. (ur.). Vodno bogastvo Slovenije. Ljubljana, Ministrstvo za okolje, prostor in energijo, Agencija Republike Slovenije za okolje, str. 27–45.
- Bätzing, W., 2011. Ja za alpsko makroregijo - a zgolj s prostorom enakega obsega. CIPRA info, 95 (Alpe na odru), str. 19.
- Bear, J., 1972. Dynamics of fluids in porous media. New York, Dover publication, 764 str.
- Belbin, L., McDonald, C., 1993. Comparing three classification strategies for use in ecology. Journal of Vegetation Science, 4, 3, str. 341–348. DOI: <http://dx.doi.org/10.2307/3235592>
- Bell, F. G., 2007. Engeneering geology. Second edition. Amsterdam, Boston, Heidelberg, London, New York, Oxford, Pariz, San Diego, San Francisco, Singapur, Sydney, Tokio, Elsevier, 581 str.
- Berk, S., Kete, P., Žagar, T., Pegan Žvokelj, B., Košir, J., 2012. Ocena proizvodne sposobnosti zemljišč iz razpoložljivih prostorskih podatkov. V: Ciglič, R., Perko, D., Zorn, M. (ur.). Geografski informacijski sistemi v Sloveniji 2011–2012. Ljubljana, Založba ZRC, str. 99–108.
- Biogeographical regions, Europe (različica iz leta 2008). European Environmental Agency. URL: <http://dataservice.eea.europa.eu/dataservice/metadetails.asp?id=1054> (Citirano 26. 8. 2009).
- Bocage. Dictionary.com. URL: <http://dictionary.reference.com/browse/bocage> (Citirano 27.8.2009).
- Bohn, U., Neuhäusl, R., Gollub, G., Hettwer, C., Neuhäuslová, Z., Raus, Th., Schlüter, H., Weber, H., 2000/2003. Karte der natürlichen Vegetation Europas / Map of the natural vegetation of Europe. Münster, Bundesamt für Naturschutz, str. 524.
- Brabyn, L., 2009. NZ Landscape Classification Version II (Introduction). URL: <http://www.waikato.ac.nz/wfass/subjects/geography/people/lars/landscape/index.shtml> (Citirano 16. 10. 2009).

- Bratina Jurkovič, N., 2008. Evropska konvencija o krajini, izvajanje v Sloveniji. Ljubljana, Ministrstvo za okolje in prostor, 35 str.
- Breskvar Žaucer, L., Marušič, J., 2006. Analiza krajinskih tipov z uporabo umetnih nevronske mreže. *Geodetski vestnik*, 50, 2, str. 224–237.
- Bryan, B. A., 2006. Synergistic techniques for better understanding and classifying the environmental structure of landscapes. *Environmental Management*, 37, 1, str. 126–140.
- Bunce, R. G. H., 1994. The application of quantitative methods of classification to strategic ecological survey in Britain. V: Klijn, F. (ur.). *Ecosystem classification for environmental management*, Dordrecht, Kluwer, str. 173–182.
- Bunce, R. G. H, Barr, C. J., Clarke, R. T., Howard, D. C., Lane, A. M. J., 1996. Land classification for strategic ecological survey. *Journal of environmental management*, 47, 1, str. 37–60. DOI: <http://dx.doi.org/10.1006/jema.1996.0034>
- Burrough, P. A., Wilson, J. P., van Gaans, P. F. M., Hansen, A. J., 2001. Fuzzy k-means classification of topo-climatic data as an aid to forest mapping in the Greater Yellowstone Area, USA. *Landscape ecology*, 16, 6, str. 523–546.
- Campbell, J. B., 1996. *Introduction to remote sensing*. Second edition. London, Taylor & Francis, 622 str.
- Carteron, A., Jeanmougin, M., Leprieur, F., Spatharis, S., 2012. Assessing the efficiency of clustering algorithms and goodness-of-fit measures using phytoplankton field data. *Ecological informatics*, 9, str. 64–68. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2012.03.008>
- Castillo-Rodríguez, M., López-Blanco, J., Muñoz-Salinas, E., 2010. A geomorphologic GIS-multivariate analysis approach to delineate environmental units, a case study of La Malinche volcano (central México). *Applied Geography*, 30, 4, str. 629–638. DOI: <http://dx.doi.org/10.1016/j.apgeog.2010.01.003>
- Cegnar, T., 1998. Temperatura zraka. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 100–103.
- Ciglič, R., 2009. Slovenija v naravnogeografskih členitvah Evrope. *Geografski vestnik*, 81, 2, str. 29–45.
- Ciglič, R., 2010a. Information values of absolute elevation and elevation difference for illustration of thermal belt. *Acta geographica Slovenica/Geografski zbornik*, 50, 2, str. 177–200. DOI: <http://dx.doi.org/10.3986/AGS50201>
- Ciglič, R., 2010b. Subjektivnost pri metodi segmentacije. V: Perko, D., Zorn, M. (ur.). *Geografski informacijski sistemi v Sloveniji 2009–2010*. Ljubljana, Založba ZRC, 55–63.
- Ciglič, R., 2012. Evaluation of digital data layers for establishing natural landscape types in Slovenia. V: Andrei, M.-T. (ur.). *Landscapes: Perception, knowledge, awareness, and action*. Proceedings of the FG-SHU International Symposium on Geography. New York, Addelton Academic Publishers, str. 39–51.
- Ciglič, R., Perko, D., 2012. Slovenia in geographical typifications and regionalizations of Europe. *Geografski vestnik*, 84, 1, str. 23–38.
- Ciglič, R., Zorn, M., Komac, B., 2011. Primerjava različnih načinov modeliranja plazovitosti. V: Zorn, M., Komac, B., Ciglič, R., Pavšek, M. (ur.). *Neodgovorna odgovornost*. Ljubljana, Založba ZRC, str. 39–50.
- Clark, A. N., 1998. *The Penguin dictionary of geography*. London, Penguin, 454 str.
- Clark, M. L., Aide, T. M., Grau, H. R., Riner, G., 2010. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America. *Remote sensing of environment*, 114, 11, str. 2816–2832. DOI: <http://dx.doi.org/10.1016/j.rse.2010.07.001>
- Čarni, A., Marinček, L., Seliškar, A., Zupančič, M., 2002. *Vegetacijska karta gozdnih združb Slovenije (CD ROM)*. Ljubljana, ZRC SAZU.
- Černe, A., Klemenčič, M. M., Plut, D., 1981. Metodologija opredeljevanja pokrajinskih enot na primeru tržiške občine. V: Brinovec, S. (ur.). *Gorenjska*. Ljubljana, Geografsko društvo Slovenije, str. 130–137.
- Damgaard, C., 2012. Gini coefficient (Wolfram MathWorld). URL: <http://mathworld.wolfram.com/GiniCoefficient.html> (Citirano 29. 11. 2012).

- Demek, J., Quitt, E., Raušer, J., 1972. Zur Problematik der physisch-geographischen Regionalisation. V: Mazúr, E. (ur.). Theoretische Probleme der physisch-geographischen Raumgliederung. Bratislava, Slowakischen Akademie der Wissenschaften, str. 15–26.
- Demeritt, D., Wainwright, J., 2005. Models, modelling and geography. V: Castree, N., Rogers, A., Sherman, D. (ur.). Questioning geography: fundamental Debates. Malden, Blackwell, str. 206–225.
- Digital map of European ecological regions. European environmental agency. URL: <http://dataservice.eea.europa.eu/dataservice/metadetails.asp?id=192> (Citirano 26. 8. 2009).
- Digitalni model višin 25 m (podatkovni sloj). 2010. Ljubljana, Geodetska uprava Republike Slovenije.
- Dimitrovski, I., Kocev, D., Loskovska, S., Džeroski, S. 2012: Hierarchical classification of diatom images using ensembles of predictive clustering trees. *Ecological informatics*, 7, 1, str. 19–29. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2011.09.001>
- Discriminant analysis. URL: <http://www.uk.sagepub.com/burns/website%20material/Chapter%2025%20-%20Discriminant%20Analysis.pdf> (Citirano 20. 5. 2011).
- Discriminant function analysis. URL: www.unt.edu/rss/class/mike/6810/DFA.ppt (citirano 1. 3. 2012).
- Distribution of family income – Gini index. The World Factbook. URL: <https://www.cia.gov/library/publications/the-world-factbook/fields/2172.html> (Citirano 29. 11. 2012).
- Dodge, Y., 2008. The concise encyclopedia of statistics. New York, Springer, 616 str.
- Dolinar, M., 2004. GIS kot orodje pri izdelavi klimatskih kart. V: Podobnikar, T., Perko, D., Hladnik, D., Krevs, M., Čeh, M., Stančič, Z. (ur.). Geografski informacijski sistemi v Sloveniji 2003–2004. Ljubljana, Založba ZRC, str. 195–202.
- Dolinar, M., 2006. Prostorska porazdelitev trajanja sončnega obsevanja. V: Perko, D., Nared, J., Čeh, M., Hladnik, D., Krevs, M., Podobnikar, T., Šumrada, R. (ur.). Geografski informacijski sistemi v Sloveniji 2005–2006. Ljubljana, Založba ZRC, str. 61–71.
- Dominguez-Granda, L., Lock, K., Goethals, P. L. M., 2011. Using multi-target clustering trees as a tool to predict biological water quality indices based on benthic macroinvertebrates and environmental parameters in the Chaguana watershed (Ecuador). *Ecological informatics*, 6, 5, str. 303–308. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2011.05.004>
- Drăguț, L., Eisank, C., 2012. Automated object-based classification of topography from SRTM data. *Geomorphology*, 141-142, str. 21–33. DOI: <http://dx.doi.org/10.1016/j.geomorph.2011.12.001>
- Drăguț, L., Eisank, C., Strasser, T., 2011. Local variance for multi-scale analysis in geomorphometry. *Geomorphology*, 130, 3-4, str. 162–172. DOI: <http://dx.doi.org/10.1016/j.geomorph.2011.03.011>
- Duro, D. C., Fanklin, S. E., Dubé, M. G., 2012. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote sensing of environment*, 118, str. 259–272. DOI: <http://dx.doi.org/10.1016/j.rse.2011.11.020>
- Džeroski, S., 2002. Environmental sciences. V: Klösgen, W., Žytkow, J. M. (ur.). Handbook of data mining and knowledge discovery. Oxford, Oxford University Press, str. 817–830.
- Eastman, J. R., 2009. IDRISI Taiga. Guide to GIS and Image Processing. Worcester, Clark Labs, Clark University, 342 str.
- Ellison, A. M., 2010. Repeatability and transparency in ecological research. *Ecology*, 91, 9, str. 2536–2549. DOI: <http://dx.doi.org/10.1890/09-0032.1>
- Eskelson, B. N. I., Temesgen, H., Hagar, J. C., 2012. A comparison of selected parametric and imputation methods for estimating snag density and snag quality attributes. *Forest ecology and management*, 272, str. 26–34. DOI: <http://dx.doi.org/10.1016/j.foreco.2011.06.041>
- European Landscape Character Areas. Typologies, Cartography and Indicators for the Assessment of Sustainable Landscapes. 2005. Wascher, D. M. (ur.). Wageningen, Landscape Europe, 160 str.

- European Landscape Network. Medmrežje: <http://www.eurolandscape.net/> (Citirano 11. 8. 2011).
- Europe's Environment: the Dobriš Assessment. 1995. Stanners, D., Bourdeau, P. (ur.). Copenhagen, European environment agency, 676 str. URL: <http://www.eea.europa.eu/publications/92-826-5409-5/chap03.zip> (Citirano: 27.8.2009).
- Evans, I. S., 1972. General geomorphometry, derivatives of altitude, and descriptive statistics. V: Chorley, R. J. (ur.). *Spatial Analysis in Geomorphology*. London, Methuen, str. 17–90.
- Fayyad, U. M., Irani, K. B., 1993. Multi-interval discretization of continuous-valued attributes for classification learning. V: Bajcsy, R. (ur.). *Proceedings of the Thirteenth international joint conference on artificial intelligence 2*. San Mateo, Morgan Kaufmann publishers, str. 1022–1027.
- Ferligoj, A., 1989. Razvrščanje v skupine. Teorija in uporaba v družboslovju. Ljubljana, Fakulteta za sociologijo, politične vede in novinarstvo, 182 str.
- Ferligoj, A., 1997. Recent developments in cluster analysis. V: Kalpić, D., Hljuz Dobrić, V. (ur.). *ITI '97: proceedings of the 19th International Conference on Information Technology Interfaces*, Zagreb, University computing centre, str. 253–261.
- Ferligoj, A. Multivariatna analiza. Diskriminantna analiza. URL: <http://vlado.fmf.uni-lj.si/vlado/podstat/Mva.htm> (Citirano 10. 5. 2010).
- Ferreira, A., 2006. Pokrajinskoekološka členitev Zgornje Gorenjske. *Dela*, 26, str. 61–74.
- Firebaugh, G., 1999. Empirics of world income inequality. *American journal of sociology*, 104, 6, str. 1597-1630. DOI: <http://dx.doi.org/10.1086/210218>
- Gabovec, M., 1990. Pomen reliefa za geografsko podobo Polhograjskega hribovja. *Geografski zbornik*, 30, str. 5-68.
- Gabovec, M., 1996. Solar Radiation and the Diverse Relief of Slovenia. Sončno obsevanje v reliefno razgibani Sloveniji. *Geografski zbornik*, 36, str. 47–68. (z digitalni podatkovnim slojem)
- Gabovec, M., Hrvatin, M., 1998. Površje. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 80–83.
- Gaganis, P., 2000. On the quantification of the effect of model error on groundwater model predictions and risk assessments. Doktorska dispozicija. Vancouver, University of British Columbia, 201 str.
- Gams, I., 1978a. Kvantitativna prirodnogeografska regionalizacija Slovenije. Raziskovalna naloga. Ljubljana, Filozofska fakulteta, Oddelek za geografijo. 43 str.
- Gams, I., 1978b. Pokrajinska ekologija soseske Soča. V: Kunaver, J. (ur.). *Zgornje Posočje*. Ljubljana, Geografsko društvo Slovenije, str. 313–334.
- Gams, I., 1979. K pokrajinsko ekološki razčlenitvi mariborske regije. V: Kert, B. (ur.). *Mariborsko Podravje*. Maribor, Geografsko društvo Slovenije, str. 37–51.
- Gams, I., 1981. Pokrajinsko-ekološka sestava Gorenjske. V: Brinovec, S. (ur.). *Gorenjska*. Ljubljana, Geografsko društvo Slovenije, str. 130–137.
- Gams, I., 1983. Geografske značilnosti Slovenije. Ljubljana, Mladinska knjiga, 103 str.
- Gams, I., 1984. Metodologija geografske razčlenitve ozemlja. *Geografski vestnik*, 56, str. 75–82.
- Gams, I., 1986a. Osnove pokrajinske ekologije. Ljubljana, Filozofska fakulteta, 175 str.
- Gams, I., 1986b. Za kvantitativno razmejitev med pojmi gričevje, hribovje in gorovje. *Geografski vestnik*, 58, str. 77–81.
- Gams, I., 1998a. Pokrajinsko ekološka sestava Slovenije. V: Gams, I., Vrišer, I. (ur.). *Geografija Slovenije*. Ljubljana, Slovenska matica, str. 214–243.
- Gams, I., 1998b. Lega Slovenije v Evropi in med njenimi makroregijami. V: Gams, I., Vrišer, I. (ur.). *Geografija Slovenije*. Ljubljana, Slovenska matica, str. 7–23.
- Gams, I. 2000. Stanje v (prirodno)geografski regionalizaciji Slovenije. *Geografski vestnik*, 72, 1, str. 53–60.
- Gams, I., 2003. *Kras v Sloveniji v prostoru in času*. Ljubljana, Založba ZRC, 515 str.

- Gams, I., Kladnik, D., Orožen Adamič, M., 1995. Naravnogeografske regije Slovenije. V: Orožen Adamič, M., Perko, D., Kladnik, D. (ur.). Krajevni leksikon Slovenije, Ljubljana, DZS, str. 24–25.
- Gams, I., Lovrenčak, F., Plut, D. 1978. Soča, Breginj in Kamno v pokrajinsko-ekološki primerjavi. V: Kunaver, J. (ur.). Zgornje Posočje. Ljubljana, Geografsko društvo Slovenije, str. 335–347.
- Gandhi, V., 2008. Vector data. V: Shekhar, S., Xiong, H. (ur.). Encyclopedia of GIS. New York, Springer, str. 1217–1221.
- Geografija. 2001. Tržič, Učila International, 682 str.
- Geografski terminološki slovar. 2005. Kladnik, D., Lovrenčak, F., Orožen Adamič, M. (ur.). Ljubljana, Založba ZRC, 451 str.
- Geološki terminološki slovar. 2006. Pavšič, J. (ur.). Ljubljana. ZRC SAZU, 333 str.
- Godron, M., 1994. The natural hierarchy of ecological systems. V: Kljajn, F. (ur.). Ecosystem classification for environmental management. Dordrecht, Kluwer, str. 69–84.
- Goodchild, M. F., 2011. Scale in GIS: An overview. *Geomorphology*, 130, 1-2, str. 5–9. DOI: <http://dx.doi.org/10.1016/j.geomorph.2010.10.004>
- Groom, G., 2005. Methodological review of existing classifications. V: Wascher, D. M. (ur.). European Landscape Character Areas. Typologies, cartography and indicators for the assessment of sustainable landscapes. Wageningen, Landscape Europe, str. 32–45.
- Haber, W., 1994. System ecological concepts for environmental planning. V: Kljajn, F. (ur.). Ecosystem classification for environmental management. Dordrecht, Kluwer, str. 49–68.
- Haggett, P., 2001. Geography: a global synthesis. Harlow, Prentice Hall an imprint of Pearson Education, 833 str.
- Hargrove, W. W., Hoffman, F. M., 2005. Potential of multivariate quantitative methods for delineation and visualization of ecoregions. *Environmental management*, 34, S1, str. 39–60. DOI: <http://dx.doi.org/10.1007/s00267-003-1084-0>
- Hauser-Davis, R. A., Oliveira, T. F., Silveira, A. M., Silva, T. B., Ziolli, R. L., 2010. Case study: Comparing the use of nonlinear discriminating analysis and artificial neural networks in the classification of three fish species: acaras (*Geophagus brasiliensis*), tilapias (*Tilapia rendalli*) and mullets (*Mugil liza*). *Ecological Informatics*, 5, 6, str. 474–478. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2010.08.002>
- Hazeu, G. W., Metzger, M. J., Múcher, C. A., Perez-Soba, M., Renetzeder, Ch., Andersen, E., 2010. European environmental stratifications and typologies: An overview. *Agriculture, ecosystems and environment*, 142, 1-2, str. 29–39. DOI: <http://dx.doi.org/10.1016/j.agee.2010.01.009>
- Hladnik, D., 2005. Spatial structure of disturbed landscapes in Slovenia. *Ecological engineering*, 24, 1-2, str. 17–27. DOI: <http://dx.doi.org/10.1016/j.ecoleng.2004.12.004>
- Hoek, E., 1999. Putting numbers to geology – an engineer’s viewpoint. *quarterly journal of engineering geology*, 32, 1, str. 1–19. DOI: <http://dx.doi.org/10.1144/GSL.QJEG.1999.032.P1.01>
- Hrvatin, M., Perko, D., 2000. Regionalizacija in tipizacija mestne občine Ljubljana. V: Gabrovec, M., Orožen Adamič, M. (ur.). Ljubljana, geografija mesta, Ljubljana, Ljubljansko geografsko društvo, Založba ZRC, str. 101–116.
- Hrvatin, M., Perko, D., 2010. Določanje enot oblikovanosti površja Slovenije z metodo regionalne zvezne delitve. V: Perko, D., Zorn, M. (ur.). Geografski informacijski sistemi v Sloveniji 2009–2010. Ljubljana, Založba ZRC, str. 21–31.
- Idrisi Taiga Help System (16.05), 2010. URL: <http://www.clarklabs.org/support/IDRISI-Taiga-Service-Update-16-05.cfm> (Citirano: 9.2.2010).
- Ihara, S., 1993. Information theory for continuous systems. Singapur, World scientific publishing, 313 str.
- Ilešič, S., 1956. Slovenske pokrajine. *Geografski obzornik*, 3, str. 25–38.
- Ilešič, S., 1957/1958. Problemi geografske rajonizacije ob primeru Slovenije. *Geografski vestnik*, 29/30, str. 83–140.

- Ilešič, S., 1972. Slovenske pokrajine. *Geografski vestnik*, 44, str. 9–31.
- Iwahashi, J., Pike, R. J., 2007. Automated classifications of topography from DEMs by an unsupervised nested-means algorithm and a three-part geometric signature. *Geomorphology*, 86, 3-4, str. 409–440. DOI: <http://dx.doi.org/10.1016/j.geomorph.2006.09.012>
- Jiang, B., Ding, X., Ma, L., He, Y., Wang, T., Xie, W., 2008. A hybrid feature selection algorithm: combination of symmetrical uncertainty and genetic algorithms. *Optimization and systems biology. The second international symposium, OSB'08. Lijiang, ORSC & APORC*, str. 152–157.
- Jongman, R. H. G., Bunce, R. G. H., Metzger, M. J., Múcher, C. A., Howard, D. C., Mateus, V. L., 2006. Objectives and applications of a statistical environmental stratification of Europe. *Landscape Ecology* 21, 3, str. 409–419. DOI: <http://dx.doi.org/10.1007/s10980-005-6428-0>
- Karta odsekov ZGS s šifrantom (podatkovni sloj). 2008. Ljubljana, Zavod za gozdove Slovenije.
- Kampichler, C., Wieland, R., Calmé, S., Weissenberger, H., Arriaga-Weiss, S., 2010. Classification in conservation biology: A comparison of five machine-learning methods. *Ecological informatics*, 5, 6, str. 441–450. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2010.06.003>
- Kastelec, D., Košmelj, K., 2008. Diskriminantna analiza in klasifikacija: osnove in primer. *Acta agriculturae Slovenica*, 91, 1, str. 167–190.
- Kireyeu, V., Shkaruba, A., 2010. Landscape classifications of Belarus for studies of environmental change. V: Machar, I., Kovár, P. (ur.). *Landscape structures, functions and management : response to global ecological change: book of abstracts*. Praga, CZ-IALE, str. 17.
- Kladnik, D., 1996. Naravnogeografske členitve Slovenije. *Geografski vestnik*, 68, str. 123–159.
- Kladnik, D., Perko, D., 1998. Zgodovina regionalizacij Slovenije. V: Perko, D., Orožen Adamič, M. (ur.). *Slovenija, pokrajine in ljudje*. Ljubljana, Mladinska knjiga, str. 20–25.
- Klemenčič, M. M., 2004. Družbenogeografske regionalizacije Slovenije. V: Drozg, V. (ur.). *Teorija in praksa regionalizacije Slovenije*. Maribor, Pedagoška fakulteta, str. 37–43.
- Klemenčič, M. M., 2005. Regija in regionalna struktura Slovenije, *Dela*, 23, str. 5–58.
- Klijn, F. 1994. Spatially nested ecosystems: guidelines for classification from a hierarchical perspective. V: Klijn, F. (ur.). *Ecosystem classification for environmental management*, Dordrecht, Kluwer, str. 85–116.
- Klijn, F., Udo de Haes, H. A., 1994. A hierarchical approach to ecosystems and its implications for ecological land classification. *Landscape Ecology*, 9, 2, str. 89–104. DOI: <http://dx.doi.org/10.1007/BF00124376>
- Klimatološka povprečja 1971–2000. Agencija RS za okolje. URL: http://meteo.arso.gov.si/met/sl/climate/tables/normals_71_00/ (Citirano 11. 6. 2012).
- Kmetijska shola. Kmetijske in rokodelske novice 6. 9. 1843, letnik 1, številka 10, str. 38. URL: <http://www.dlib.si/v2/StreamFile.aspx?URN=URN:NBN:SI:DOC-1Z0B1M3W&id=f3976b83-e7a7-4283-bd67-02f90172f98d&type=PDF> (Citirano 24. 2. 2011).
- Kolbezen, M., 1998. Kopenske vode. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 94–95.
- Komac, M., 2005. Statistics of the geological map of Slovenia at scale 1 : 250.000. *Geologija*, 38, 1, str. 117–126.
- Kononenko, I., 2005. *Strojno učenje*. Ljubljana, Fakulteta za računalništvo in informatiko, 450 str.
- Košir, Ž., Zorn-Pogorelc, M., Kalan, J., Marinček, L., Smole, I., Čampa, L., Šolar, M., Anko, B., Accetto, M., Robič, D., Toman, V., Žgajnar, L., Torelli, N., Tavčar, I., Kutnar, L., Kralj, A. 2007: *Gozdnovegetacijska karta Slovenije (CD ROM)*. Ljubljana, Gozdarski inštitut Slovenije.
- Košmelj, B., 1983. Uvod v multivariatno analizo. Ljubljana, Ekonomska fakulteta Borisa Kidriča, 272 str.

- Kraft, J., Einax, J. W., Kowalik, C., 2004. Information theory for evaluating environmental classification systems. *Analytical and bioanalytical chemistry*, 380, 3, str. 475–483. DOI: <http://dx.doi.org/10.1007/s00216-004-2769-9>
- Krevs, M., 1992. Iskanje lokalnih reliefnih ekstremov na DMR. *Geografski vestnik*, 64, 205–218.
- Krevs, M., 1998. Vpliv izbora prostorske enote na rezultate geografskih statističnih analiz. *Geografski vestnik*, 70, str. 185–204.
- Krevs, M., 2001a. Statistična povezanost med neštevilkama spremenljivkama. Učno gradivo za predmet Kvantitativne metode 1. Ljubljana, Filozofska fakulteta, Oddelek za geografijo. 40 str.
- Krevs, M., 2001b. Statistična povezanost med številkama in med ordinalnima spremenljivkama. Učno gradivo za predmet Kvantitativne metode 1. Ljubljana, Filozofska fakulteta, Oddelek za geografijo. 46 str.
- Kutnar, L., Kobler, A., Bergant, K., 2009. Vpliv podnebnih sprememb na pričakovano prostorsko prerezporeditev tipov gozdne vegetacije. *Zbornik gozdarstva in lesarstva*, 89, str. 33–42.
- Landsat. National aeronautics and space administration. URL: <http://landsat.gsfc.nasa.gov/> (Citirano 13. 6. 2012).
- Landscape Europe. URL: <http://www.landscape-europe.net/> (Citirano 11. 8. 2011).
- Lang, S., Walz, U., Klug, H., Blaschke, T., Syrbe, R.-U., 2009. Landscape metrics – a toolbox for assessing past, present and future landscape structures. V: Bender, O., Evelpidou, N., Krek, A., Vassilopoulos, A. (ur.). *Geoinformation technologies for geocultural landscapes: European perspectives*. Leiden, CRC Press/Balkema, str. 207–234.
- Leathwick, J. R., Overton, J. McC., McLeod, M., 2003. An environmental domain classification of New Zealand and its use as a tool for biodiversity management. *Conservation biology*, 17, 6, str. 1612–1623. DOI: <http://dx.doi.org/10.1111/j.1523-1739.2003.00469.x>
- Leser, H., 1976. *Landschaftsökologie*. Stuttgart, E. Ulmer, 432 str.
- Lillesand, T. M., Kiefer, R. W., Chipman, J. W., 2008. *Remote sensing and image interpretation*. Hoboken, John Wiley, 756 str.
- Lin, N., Noe, D., He, X., 2006. Tree-based methods and their applications. V: Phoam, H. (ur.). *Springer handbook of engineering statistics*. London, Springer, str. 551–570. DOI: <http://dx.doi.org/10.1007/978-1-84628-288-1>
- Litostratigrafska karta Slovenije (podatkovni sloj). 2007. Ljubljana, Geološki zavod Slovenije (naročnik Agencija RS za okolje).
- Loveland, T. R., Merchant, J. M., 2004. Ecoregions and ecoregionalization: geographical and ecological perspectives. *Environmental Management*, 34, S1, str. 1–13. DOI: <http://dx.doi.org/10.1007/s00267-003-5181-x>
- Lovrenčak, F., 1996. O uporabi pojma pokrajina. *Geografski vestnik*, 68, Ljubljana, str. 265–266.
- Lovrenčak, F., 1998. Prsti. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 114–115.
- Lotufo, R. A., Audigier, R., Saúde, A. V., Machado, R. C., 2008. Morphological image processing. V: Wu, Q., Merchant, F. A., Castleman, K. R. (ur.). *Microscope image processing*, Burlington, San Diego, London, Elsevier, Academic press, str. 114–157.
- Marušič, J., Ogrin, D., Jančič, M., 1998. *Metodološke osnove*. Ljubljana, Ministrstvo za okolje in prostor, Urad RS za prostorsko planiranje, Oddelek za krajinsko arhitekturo, Biotehniška fakulteta, Univerza v Ljubljani, 120 str.
- Matvejev, S. D., 1991. *Naravni tipi predelov Slovenije in njihovo varstvo*. Ljubljana, Zavod RS za varstvo naravne in kulturne dediščine, 48 str.
- McCoy, R. M., 2005. *Field methods in remote sensing*. New York, Guilford press, 160 str.
- McGarigal, K., Cushman, S., Stafford, S., 2000. *Multivariate statistics for wildlife and ecology research*, New York, Springer, 283 str.

- McKillup, S., Dyar, M. D., 2010. Geostatistics explained: an introductory guide for earth scientists. Cambridge, Cambridge, 414 str.
- McMahon, G., Wiken, E. B., Gauthier, D. A., 2004. Toward a scientifically rigorous basis for developing mapped ecological regions. *Environmental Management*, 34, 1, str. 111–214. DOI: <http://dx.doi.org/10.1007/s00267-004-0170-2>
- McRoberts, R. E., 2012. Estimating forest attribute parameters for small areas using nearest neighbors techniques. *Forest ecology and management*, 272, str. 3–12. DOI: <http://dx.doi.org/10.1016/j.foreco.2011.06.039>
- Meeus, J. H. A., 1995. Pan-European landscapes. *Landscape and urban planning* 31, 1-3, str. 57–79. DOI: [http://dx.doi.org/10.1016/0169-2046\(94\)01036-8](http://dx.doi.org/10.1016/0169-2046(94)01036-8)
- Meinel, G., Neubert, M., 2004. A comparison of segmentation programs for high resolution remote sensing data. *ISPRS Archives*, XXXV, Part B, str. 1097–1105.
- Melik, A., 1935. Slovenija: geografski opis. Ljubljana. Slovenska matica, 700 str.
- Melik, A., 1946. Prirodnogospodarska sestava Slovenije, *Geografski vestnik*, 18, str. 3–22.
- Melik, A., 1954. Slovenski alpski svet. Ljubljana, Slovenska matica, 606 str.
- Melik, A., 1957. Štajerska s Prekmurjem in Mežiško dolino. Ljubljana, Slovenska matica, 594 str.
- Melik, A., 1959. Posavska Slovenija. Ljubljana, Slovenska matica, 595 str.
- Melik, A., 1960. Slovensko primorje. Ljubljana, Slovenska matica, 546 str.
- Melo, R., Vieira, G., Caselli, A., Ramos, M., 2012. Susceptibility modeling of hummocky terrain distribution using the information value method (Deception Island, Antarctic Peninsula). *Geomorphology*, 155-156, str. 88–95. DOI: <http://dx.doi.org/10.1016/j.geomorph.2011.12.027>
- Metzger, M. J., Bunce, R. G. H., Jongman, R. H. G., Mücher, C. A., Watkins, J. W., 2005. A climatic stratification of the environment of Europe. *Global Ecology and Biogeography*, 14, 6, str. 549–563. DOI: <http://dx.doi.org/10.1111/j.1466-822X.2005.00190.x>
- Mihevc, A., 1998. Kraško površje. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 90–91.
- Milavec, K., Verbovšek, T., 2012: Večkriterijsko vrednotenje vodonosnika Spodnje Savinjske doline za pridobivanje obnovljive toplotne energije. V: Ciglič, R., Perko, D., Zorn, M. (ur.). *Geografski informacijski sistemi v Sloveniji 2011–2012*. Ljubljana, Založba ZRC, str. 33–43.
- Mitchell, T. M., 1997. Lecture slides for textbook *Machine learning*. URL: <http://www.cs.cmu.edu/afs/cs.cmu.edu/project/theo-20/www/mlbook/ch3.pdf> (Citirano 3. 5. 2010).
- MODIS. National aeronautics and space administration. URL: <http://modis.gsfc.nasa.gov/index.php> (Citirano: 13. 6. 2012).
- Mora, B., Wulder, M. A., White, J. C., 2010. Segment-constrained regression tree estimation of forest stand height from very high spatial resolution panchromatic imagery over a boreal environment. *Remote Sensing of Environment*, 114, 11, str. 2474–2484. DOI: <http://dx.doi.org/10.1016/j.rse.2010.05.022>
- Mücher, C. A., Bunce, R. G. H., Jongman, R. H. G., Klijn, J. A., Koomen, A. J. M., Metzger, M. J., Wascher, D. M., 2003. Identification and Characterisation of Environments and Landscapes in Europe. *Alterra rapport 832*. Wageningen, Alterra, 119 str.
- Mücher, C. A., Wascher, D. M., Klijn, J. A., Koomen, A. J. M., Jongman, R. H. G., 2006. A new European landscape map as an integrative framework for landscape character assessment. V: Bunce, R. G. H., Jongman, R. H. G. (ur.). *Landscape ecology in the Mediterranean, inside and outside approaches*, *Proceedings of the European IALE conference*. Faro, IALE, str. 233–243.
- Mücher, C. A., Klijn, J. A., Wascher, D. M., Schaminée, J. H. J., 2009. A new European landscape classification (LANMAP): a transparent, flexible and user-oriented methodology to distinguish landscapes. *Ecological Indicators*, 10, 1, str. 87–103. DOI: <http://dx.doi.org/10.1016/j.ecolind.2009.03.018>

- Naga Jyothi, B., Babu, G. R., Murali Krishna, I. V., 2008. Object oriented and multi-scale image analysis: strengths, weaknesses, opportunities and threats-a review. *Journal of computer science*, 4, 9, str. 706–712. DOI: <http://dx.doi.org/10.3844/jcssp.2008.706.712>
- Natek, K., 1993. Tipi površja v Sloveniji. *Geografski obzornik*, 40, 4, str. 26–31.
- Natek, K., Žiberna, I., 2004. Naravnogeografske regionalizacije Slovenije V: Drozg, V. (ur.). *Teorija in praksa regionalizacije Slovenije*. Maribor, Pedagoška fakulteta, str. 25–36.
- Noirfalise, A., 1987: *Map of the natural vegetation of the member countries of the European community and of the Council of Europe*. Luksemburg, Office for Official Publications of the European Communities, 80 str.
- Olson, D. M., Dinerstein, E., Wikramanayake, E. D., Burgess, N. D., Powell, G. V. N., Underwood, E. C., D'Amico, J. A., Itoua, I., Strand, H. E., Morrison, J. C., Loucks, C. J., Allnut, T. F., Ricketts, T. H., Kura, Y., Lamoreux, J. F., Wettengel, W. W., Hedao, P., Kassem, K. R., 2001. Terrestrial ecoregions of the World: a new map of life on earth. *BioScience* 51, 11, str. 933–938. (Podatkovni sloj: <http://worldwildlife.org/publications/terrestrial-ecoregions-of-the-world>)
- Ogrin, D., 1996. Podnebni tipi v Sloveniji. *Geografski vestnik*, 68, str. 39–56.
- Ogrin, D., 1998. Podnebje. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 110–111.
- Ogrin, D., 2009. Analiza in funkcijsko vrednotenje fizičnogeografskih sestavin Slovenije. V: Ogrin, D., Plut, D. (avtorja). *Aplikativna fizična geografija Slovenije*. Ljubljana, Znanstvena založba Filozofske fakultete, str. 11–150.
- OpenLandscapes. URL: <http://openlandscapes.zalf.de/default.aspx> (Citirano 11. 8. 2011).
- Oštir, K., 2006. *Daljinsko zaznavajne*. Ljubljana, Založba ZRC, 250 str.
- Owen, S. M., MacKenzie, A. R., Bunce, R. G. H., Stewart, H. E., Donovan, R. G., Stark, G., Hewitt, C. N., 2006. Urban land classification and its uncertainties using principal component and cluster analyses: a case study for the UK West Midlands. *Landscape and urban planning* 78, 4, str. 311–321. DOI: <http://dx.doi.org/10.1016/j.landurbplan.2005.11.002>
- Pan-European biological and landscape diversity. URL: <http://www.pebls.org/index.php?ido=1&lang=eng> (Citirano 11. 8. 2011).
- Pedološka karta (podatkovni sloj). 2007. Ministrstvo za kmetijstvo in okolje. URL: <http://rkg.gov.si/GERK/> (Citirano 13. 6. 2012).
- Pedološka karta v merilu 1 : 25.000. URL: http://stari.bf.uni-lj.si/cpvo/Novo/SF_PodatkiTalSlovenije.htm (Citirano 13. 6. 2012).
- Perko, D., 1989. Vzhodna Krška kotlina s posebnim ozirom na poselitev. Magistrska naloga. Ljubljana, Filozofska fakulteta, Oddelek za geografijo, 176 str.
- Perko, D., 1990. Tipi pokrajin v porečju Kokre. *Geografski obzornik*, 39, 2, str. 25–32.
- Perko, D., 1992. Zveze med reliefom in gibanjem prebivalstva 1880–1981 v Sloveniji. Doktorska disertacija. Ljubljana, Filozofska fakulteta, Oddelek za geografijo. 183 str.
- Perko, D., 1998a. The Regionalization of Slovenia. *Geografski zbornik*, 38, str. 11–57.
- Perko, D., 1998b. Tipizacija in regionalizacija Slovenije. *Geografski obzornik*, 45, 1, str. 12–17.
- Perko, D., 1998c. Nadmorske višine površja. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 84–85.
- Perko, D., 1998d. Geografija, regija in regionalizacija. Slovenija. Pokrajine in Ljudje. Ljubljana, Mladinska knjiga, str. 12–15.
- Perko, D., 2001. Analiza površja Slovenije s stometrskim digitalnim modelom reliefa. Ljubljana, ZRC, 229 str.
- Perko, D., 2007a. Morfometrija površja Slovenije. Ljubljana, Založba ZRC, 92 str.
- Perko, D., 2007b: *Landscapes*. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Pavšek, M., Perko, D., Repolusk, P., Urbanc, M. (ur.). *Slovenija in focus*. Ljubljana, Založba ZRC, str. 33–55.
- Perko, D., Kladnik, D., 1998. Nova regionalizacija Slovenije. Slovenija. Pokrajine in ljudje. Ljubljana, Mladinska knjiga, str. 26–31.

- Plut, D., 1977. Fizičnogeografska regionalizacija Koprskega primorja s pomočjo faktorske analize. *Geografski vestnik*, 49, str. 165–171.
- Plut, D., 1980. Raziskovalne in delovne metode pokrajinske ekologije, *Geografski vestnik*, 52, str. 135-144.
- Plut, D., 1981. Pokrajinska ekologija Bele krajine. V: Pak, M. (ur.). *Raziskovalno delo Inštituta za geografijo univerze Edvarda Kardelja v Ljubljani*. Ljubljana, Inštitut za geografijo universe Edvarda Kardelja, str. 141–166.
- Plut, D., 1991. Entropijska zanka. *Radovljica, Didakta*, 152 str.
- Plut, D., 1995. Brez izhoda? Svetovni okoljski proces. Ljubljana, DZS, 190 str.
- Plut, D., 1999a. Regionalizacija Slovenije po sonaravnih kriterijih. *Geografski vestnik*, 71, str. 9–25.
- Plut, D., 1999b. Zasnova členitve Slovenije na pokrajine s pomočjo trajnostno sonaravnih izhodišč. V: Vrišer, I. (ur.). *Pokrajine v Sloveniji*. Ljubljana, Vlada RS, Služba za lokalno samoupravo, str. 65–72.
- Plut, D., 2005. Teoretična in vsebinska zasnova trajnostno sonaravnega napredka. *Dela* 23, str. 59–114.
- Poehls D. J., Smith, G. J., 2009. *Encyclopedic dictionary of hydrogeology*. Amsterdam, Academic press/Elsevier, str. 175.
- Pratt, W. K., 2007. *Digital image processing*. Los Altos, J. Wiley & Sons, 786 str.
- Pravilnik o določanju in vodenju bonitete zemljišč. *Uradni list Republike Slovenije*, 47/2008. Ljubljana.
- Pravilnik o določitvi vodnih teles podzemnih voda. *Uradni list Republike Slovenije*, 63/2005. Ljubljana.
- Radovan, D., 1995. *Toponimska navodila za Slovenijo*. Ljubljana, Geodetska uprava Republike Slovenije, 29 str.
- Renetzeder, C., van Eupen, M., Mücher, C.A., Wrbka, T., 2008. A spatial regional reference framework for sustainability assessment in Europe. V: Helming, K., Pérez-Soba, M., Tabbush, P. (ur.). *Sustainability impact assessment of land use changes*. Berlin, Heidelberg, Springer, str. 249–268.
- Repe, B., 2006. *Pedogeografska karta in njena uporabnost v geografiji*. Doktorska disertacija. Ljubljana, Filozofska fakulteta, Oddelek za geografijo, 432 str.
- Repe, B., 2010. Značilne kombinacije pedogenetskih dejavnikov v Sloveniji. V: Perko, D., Zorn, M. (ur.). *Geografski informacijski sistemi v Sloveniji 2009–2010*. Ljubljana, Založba ZRC, str. 99–110.
- Richards, J., Jia, X., 2006. *Remote sensing digital image analysis: an introduction*. Berlin, Heidelberg, Springer, 439 str.
- Rivas-Martínez, S., Penas, A., Díaz, T. E., 2009. *Worldwide bioclimatic classification system*. URL: <http://www.globalbioclimatics.org/> (Citirano 26. 8. 2009).
- Rogerson, P. A., 2006. *Statistical methods for geography: a student guide*. London, Thousand Oaks, New Delhi, SAHE Publications, 304 str.
- Romportl, D., Chuman, T., 2007. Proposal method of landscape typology in the Czech Republic. *Journal of landscape ecology*, 0, 0, str. 43–53.
- Romportl, D., 2009. *Landscape typology of the Czech Republic (Typologie krajiny České republiky)*. Doktorska dispozicija. Praga, Přírodovědecká fakulta, Katedra fyzické geografie a geokologie, 18 str.
- Runhaar, H. J., Udo de Haes, H. A. 1994. The use of site factors as classification characteristics for ecotopes. V: Klijn, F. (ur.). *Ecosystem Classification for Environmental Management*. Dordrecht, Kluwer, str. 139–172.
- Sagadin, J., 2003. *Statistične metode za pedagoške*. Maribor, Obzorja, 470 str.
- Saito, H., Nakayama, D., Matsuyama, H., 2009. Comparison of landslide susceptibility based on a decision-tree model and actual landslide occurrence: The Akaishi mountains, Japan. *Geomorphology*, 109, 3-4, 108–121. DOI: <http://dx.doi.org/10.1016/j.geomorph.2009.02.026>

- Schmithüsen, J., 1972. Naturräumliche Gliederung und landschaftsräumliche Gliederung. V: Mazúr, E. (ur.). Theoretische Probleme der physisch-geographischen Raumgliederung. Bratislava, Verlag der Slowakischen Akademie der Wissenschaften, str. 145–150.
- Singhal, B. B. S., Gupta, R. P., 2010. Applied hydrogeology of fractured rocks. Dordrecht, Springer, 408 str.
- Sket, B., 2003. Oblikuje se današnje živalstvo. V: Sket, B., Gogala, M., Kuštor, V. (ur.). Živalstvo Slovenije. Ljubljana, Tehniška založba Slovenije, 664 str.
- Slovar slovenskega knjižnega jezika. 2005. Elektronska izdaja v1.1. Ljubljana, DZS.
- Soto, S., Pintó, J., 2010. Delineation of natural landscape units for Puerto Rico. Applied Geography, 30, 4, str. 720–730. DOI: <http://dx.doi.org/10.1016/j.apgeog.2010.01.010>
- Spitz, K., Moreno, J., 1996. A practical guide to groundwater and solute transport modeling. New York, Wiley, 461 str.
- SPSS Statistics 17.0 Algorithms. 2010. URL: <http://support.spss.com/ProductsExt/SPSS/ESD/17/Download/User%20Manuals/English/SPSS%20Statistics%2017.0%20Algorithms.pdf> (Citirano 6. 12. 2010).
- SPSS Help. Dokumentacija SPSS Statistics 17.0. 2008.
- StatSoft, Inc. 2012: Electronic Statistics Textbook. Tulsa. URL: <http://www.statsoft.com/textbook/>.
- Stumpf, A., Kerle, N., 2011. Object-oriented mapping of landslides using random forests. Remote sensing of environment, 115, 10, str. 2564-2577. DOI: <http://dx.doi.org/10.1016/j.rse.2011.05.013>
- Synoptic presentation of the status of landscape policies pursued by the member states of the Council of Europe 2006-2007. Strasbourg. 2007. URL: http://www.coe.int/t/dg4/cultureheritage/heritage/landscape/TFLOR-2007-7rev-Synoptic_bil.pdf (Citirano 18. 8. 2011).
- Swanwick, C., 2002. Landscape character assessment. Guidance for England and Scotland. Sheffield, University of Sheffield, Department of Landscape, 84 str.
- Šimová, P., Gdulová, K., 2012. Landscape indices behavior: A review of scale effects. Applied geography, 34, str. 385–394. DOI: <http://dx.doi.org/10.1016/j.apgeog.2012.01.003>
- Špes, M., Cigale, D., Lampič, B., Natek, K., Plut, D., Smrekar, A., 2002. Študija ranljivosti okolja. Ljubljana, ZRC, 150 str.
- Tarábek, K., 1972. Die problem der klimageographischen Regionalisation. V: Mazúr, E. (ur.). Theoretische Probleme der physisch-geographischen Raumgliederung. Bratislava, Verlag der Slowakischen Akademie der Wissenschaften, str. 45–50.
- The indicative map of European biogeographical regions: methodology and development. 2006. Pariz, European topic centre on biological diversity, 13 str.
- Theodoridis S., Koutroumbas, K., 2006. Pattern recognition. 3. Izdaja. San Diego, Elsevier/Academic Press, 837 str.
- The European Landscape Convention. URL: <http://www.coe.int/t/dg4/cultureheritage/heritage/landscape/> (Citirano 11. 8. 2011).
- Thiam, A., Eastman, J. R., 2009. Vegetation indices. Idrisi Taiga guide to GIS and image processing. Worcester, Clark Labs, Clark University, str. 212–224.
- Tirelli, T., Pessani, D., 2011. Importance of feature selection in decision-tree and artificial-neural-network ecological applications. *Alburnus alburnus alborella*: A practical example. Ecological Informatics, 6, 5, str. 309–315. DOI: <http://dx.doi.org/10.1016/j.ecoinf.2010.11.001>
- Topole, M., 1992. Tipi pokrajín v porečju Mirne. Geografski obzornik, 39, 4, str. 28–32.
- Udo de Haes, H. A., Klijn, F., 1994. Environmental policy and ecosystem classification. V: Klijn, F. (ur.). Ecosystem classification for environmental management, Dordrecht, Kluwer, str. 1–22.
- Udvardy, M. D. F., 1975. A classification of the biogeographical provinces of the World, IUCN Occasional paper 18. Morges, International union for conservation of nature and natural resources, 50 str.

- Uttakleiv, L. A., 2012. Landscape mapping of Nordland County, Norway. *Geodata magazine* oktober 2012, Oslo, str. 35.
- Van Eetvelde, V., Antrop, M., 2009. A stepwise multi-scale typology and characterisation for trans-regional integration, applied on the federal state of Belgium. *Landscape and urban planning*, 91, 3, str. 160–170. DOI: <http://dx.doi.org/10.1016/j.landurbplan.2008.12.008>
- Veliki angleško slovenski slovar. 2005. Elektronska izdaja v1.2. Ljubljana, DZS.
- Verbič, T., 1998. Kamnine. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). *Geografski atlas Slovenije*. Ljubljana, DZS, str. 74–77.
- Verbovšek, T., 2008. Koeficienti prepustnosti razpok in matriksa v slovenskih karbonatnih vodonosnikih. *Geologija*, 51, 2, str. 245–255.
- Vodna telesa podzemne vode (podatkovni sloj v shape datoteki). 2007. Ljubljana, Ministrstvo za okolje in proctor, Agencija RS za okolje.
- Vodotoki. EIONET. URL: <http://nfp-si.eionet.europa.eu/Dokumenti/GIS/voda/> (Citirano 2. 12. 2006).
- Vrišer, I., 1998. Uvod v geografijo. 6. izdaja. Ljubljana, Filozofska fakulteta, Oddelek za geografijo, 458 str.
- Vrišer, I., 1999. Regionalizacija. V: Vrišer, I. (ur.). *Pokrajinske v Sloveniji*. Ljubljana, Vlada Republike Slovenije, Služba za lokalno samoupravo, str. 126.
- Waltz, J. P., 1969. Ground water. V: Chorley, R. J. (ur.). *Water, earth and man: a synthesis of hydrology, geomorphology, and socio-economic geography*. London, Methuen & Co., str. 259–267.
- Warner, T. A., Campagna, D. J. 2009. Remote sensing with Idrisi® Taiga. A beginner's guide. Hong Kong, Geocarto International Centre, 297 str.
- Wascher, D. M., 2005. Landscape character: linking space and function. V: Wascher, D. M. (ur.). *European Landscape Character Areas. Typologies, cartography and indicators for the assessment of sustainable landscapes*. Wageningen, Landscape Europe, str. 1–4.
- Whittow, J. B., 2000. *Dictionary of physical geography*. London, Penguin books, 590 str.
- Williams, K. J., Belbin, L., Austin, M. P., Stein, J. L., Ferrier, S. 2012. Which environmental variables should I use in my biodiversity model? *International journal of geographical information science*, 26, 11–12, str. 2009–2047. DOI: <http://dx.doi.org/10.1080/13658816.2012.698015>
- Witten, I. H., Frank, E., 2005. *Data mining: practical machine learning tools and techniques*. Amsterdam, Morgan Kaufman, 525 str.
- Wolock, D. M., Winter, T. C., McMahon, G. 2004. Delineation and evaluation of hydrological-landscape regions in the United States using geographic information system tools and multivariate statistical analyses. *Environmental management*, 34, S1, str. 71–88. DOI: <http://dx.doi.org/10.1007/s00267-003-5077-9>
- Woodcock, C. E., Strahler, A. H., 1987. The factor of scale in remote sensing. *Remote sensing of environment*, 21, 3, str. 311–332. DOI: [http://dx.doi.org/10.1016/0034-4257\(87\)90015-0](http://dx.doi.org/10.1016/0034-4257(87)90015-0)
- Wu, Q., Castleman, K. R., 2008. *Image segmentation*. V: Wu, Q., Merchant, F. A., Castleman, K. R. (ur.). *Microscope image processing*, Burlington, San Diego, London, Elsevier, Academic press, str. 159–194.
- Yohannes, Y., Webb, P., 1999. *Classification and regression trees, CART™: A user manual for identifying indicators of vulnerability to famine and chronic food insecurity*. Washington, International food policy research institute, 50 str.
- Zakon o ratifikaciji Evropske konvencije o krajini /MEKK/. 2003. Uradni list RS 19/2003. URL: <http://www.uradni-list.si/1/objava.jsp?urlmpid=200346> (Citirano 1. 3. 2012).
- Zemljevidi povprečnih mesečnih in letnih temperatur in zemljevidi povprečnih mesečnih in letnih padavin 1971–2000 (podatkovni sloj). 2010. Ljubljana, Agencija RS za okolje.
- Zemljevid tipov kamnin (podatkovni sloj, različica 9.12.). 2012. Ljubljana. Geografski inštitut Antona Melika ZRC SAZU.
- Zhou, Y., Narumalani, S, Waltman, W. J., Waltman, S. W., Palecki, M. A., 2003. A GIS-based spatial pattern analysis model for eco-region mapping and characterization.

International journal of geographical information science, 17, 5, str. 445–462. DOI:
<http://dx.doi.org/10.1080/1365881031000086983>

- Zonneveld, I. S., 1994. Basic principles of classification. V: Klijn, F. (ur.). Ecosystem classification for environmental management, Dordrecht, Kluwer, str. 23–48.
- Zupančič, B., 1995. Klimatografija Slovenije. Količina padavin: obdobje 1961–1990. Ljubljana, Hidrometeorološki zavod Slovenije, 366 str.
- Zupančič, B., 1998. Padavine. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). Geografski atlas Slovenije. Ljubljana, DZS, str. 98–99.
- Zupančič, M., 1989. Fitogeografija. V: Javornik, M. (ur.). Enciklopedija Slovenije 3. Ljubljana, Mladinska knjiga, str. 120–121
- Zupančič, M., Seliškar, A., Žagar, V., 1998. Rastlinstvo. V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). Geografski atlas Slovenije. Ljubljana, DZS, str. 116.
- Zupančič, M., Marinček, L., Puncer, I., Seliškar, A. 1998a. Potencialno naravna vegetacija (zemljevid). V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). Geografski atlas Slovenije. Ljubljana, DZS, str. 117 in 119.
- Zupančič, M., Marinček, L., Puncer, I., Žagar, V., Prešeren, M., Seliškar, A., Accetto, M., Tregubov, V. 1998b: Realna vegetacija (zemljevid). V: Fridl, J., Kladnik, D., Orožen Adamič, M., Perko, D. (ur.). Geografski atlas Slovenije. Ljubljana, DZS, str. 117 in 118.
- Žiberna, I., Natek, K., Ogrin, D. 2004: Naravnogeografska regionalizacija Slovenije pri pouku geografije v osnovni šoli. V: Drozg, V. (ur.). Teorija in praksa regionalizacije Slovenije. Maribor, Pedagoška fakulteta, str. 85–90.
- Žlebnik, L., 1966. Hidrogeološke razmere na območju strojnice elektrarne Srednja Drava 1. stopnja. Geologija, 9, 489–503.
- Žlebnik, L., 1981. Hidrogeološki pogoji za gradnjo elektrarne Mavčiče. Geologija 24, 1, str. 151–167.

12. Seznam preglednic, slik in prilog

12.1 Seznam preglednic

Preglednica 1: Hierarhija prostorskih enot in ustrezni dejavniki po Kljnu (1994).....	17
Preglednica 2: Hierarhija prostorskih enot in ustrezni dejavniki po Baileyu (1996).....	18
Preglednica 3: Uporaba naravnih dejavnikov pri klasifikacijah (Groom, 2005, 39 in 40).....	19
Preglednica 4: Poimenovanja prostorskih enot na različnih ravneh (Bailey, 1996, 24).....	20
Preglednica 5: Primeri klasifikacij glede na več naravnih dejavnikov.....	26
Preglednica 6: Primeri klasifikacij glede na en naravni dejavnik.....	26
Preglednica 7: Primeri klasifikacij manjših območij znotraj Slovenije.....	26
Preglednica 8: Seznam klasifikacij območja Evrope.....	28
Preglednica 9: Pregled nekaterih značilnosti klasifikacij Evrope.....	28
Preglednica 10: Pregled izvirnih podatkovnih slojev.....	35
Preglednica 11: Seznam vseh izvirnih in izpeljanih podatkovnih slojev.....	35
Preglednica 12: Vrednotenje podatkovnih slojev glede na izstopajoče vrednosti oziroma glede na razliko med normaliziranimi vrednostma 1. in 99. percentila.....	39
Preglednica 13: Matrika povezanosti podatkovnih slojev, izražena s Pearsonovim koeficientom in tudi s Spearmanovim koeficientom.....	41
Preglednica 14: Pojasnjevalna moč in stopnja povezanosti podatkovnih slojev z obstoječimi klasifikacijami Slovenije. Statistična značilnost posameznih izračunanih koeficientov F in η^2 je manjša od $p=0,001$, kar pomeni, da je statistična značilnost teh lestvic $p=0,041$	46
Preglednica 15: PUKV za razdelitev Slovenije na različne enote.....	51
Preglednica 16: Pregled metod nenadzorovane klasifikacije.....	57
Preglednica 17: Stopnja povezanosti izbranih podatkovnih slojev.....	58
Preglednica 18: Delež pojasnjene variance, ki jo pojasni posamezna glavna komponenta po metodi glavnih komponent s podatkovnimi sloji prepustnost, povprečna letna temperatura in naklon.....	58
Preglednica 19: Povezanost glavnih komponent s posameznimi podatkovnimi sloji.....	58
Preglednica 20: Povprečne vrednosti vseh mer vrednotenja na podlagi posameznih podatkovnih slojev. Statistična značilnost posameznega povprečnega koeficienta η^2 in koeficienta F je $p=0,003$	76
Preglednica 21: Preverjanje usklajenosti vrednotenja na podlagi naklona (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	78
Preglednica 22: Preverjanje usklajenosti vrednotenja na podlagi naklona (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	79
Preglednica 23: Preverjanje usklajenosti vrednotenja na podlagi prepustnosti (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	79
Preglednica 24: Preverjanje usklajenosti vrednotenja na podlagi prepustnosti (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	80
Preglednica 25: Preverjanje usklajenosti vrednotenja na podlagi temperature (Pearsonov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	81
Preglednica 26: Preverjanje usklajenosti vrednotenja na podlagi temperature (Spearmanov koeficient). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	81
Preglednica 27: Usklajenost vrednotenja glede na vse podatkovne sloje (Pearsonov koef.). Odebeljeni koeficienti so statistično značilni pri $p=0,05$	83
Preglednica 28: Usklajenost vrednotenja glede na vse podatkovne sloje (Spearmanov koeficient). Odebeljeni so statistično značilni pri $p=0,05$	84
Preglednica 29: Cramerjev koeficient povezanosti za klasifikacije z 2 skupinama ($p=0,001$).....	87
Preglednica 30: Cramerjev koeficient povezanosti za klasifikacije s 5 skupinami ($p=0,001$).....	88
Preglednica 31: Cramerjev koeficient povezanosti za klasifikacije z 10 skupinami ($p=0,001$).....	88
Preglednica 32: Cramerjev koeficient povezanosti za klasifikacije s 15 skupinami ($p=0,001$).....	88
Preglednica 33: Število kombinacij za posamezno serijo tipizacij.....	89
Preglednica 34: Skupen delež površine območij, ki pokrivajo vsaj 1 % površine Slovenije.....	89
Preglednica 35: Koeficienti povezanosti za serijo tipizacij z 2 tipoma. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.....	92
Preglednica 36: Koeficienti povezanosti za serijo tipizacij s 5 tipi. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.....	93
Preglednica 37: Koeficienti povezanosti za serijo tipizacij z 10 tipi. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.....	94
Preglednica 38: Koeficienti povezanosti za serijo tipizacij s 15 tipi (različica A). Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.....	95
Preglednica 39: Koeficienti povezanosti za serijo tipizacij s 15 tipi (različica B). Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$, razen če je drugače navedeno v oklepaju. Največja povprečna vrednost je odebeljena. Preglednica je podvojena glede na diagonalo.....	96
Preglednica 40: Koeficienti povezanosti povprečnih oddaljenosti celic od najbližjih centroidov med serijami. Prva vrsta je Pearsonov koeficient, druga pa Spearmanov koeficient. Statistična značilnost koeficientov je povsod $p<0,001$	97
Preglednica 41: Imena in oznake posameznih pokrajinskoekoloških tipov.....	99
Preglednica 42: Imena in oznake posameznih pokrajinskih tipov.....	100

Preglednica 43: Izbrana geoinformacijska orodja za izvedbo metod nadzorovane klasifikacije.....	101
Preglednica 44: Povprečne velikosti enot znotraj tipov TIPI9 in teoretično ustrezni dejavniki razmejitev.....	103
Preglednica 45: Povprečne velikosti enot znotraj tipov za tipizacijo TIPI13 in teoretično ustrezni dejavniki razmejitev.....	104
Preglednica 46: Podatkovni sloji, ki ponazarjajo naravne dejavnike, ki jih lahko glede na velikost obstoječih enot posameznih tipov uporabimo za izdelavo tipizacij.....	105
Preglednica 47: Osnovne statistične značilnosti izbranih podatkovnih slojev (N=506.450 celic), izražene v normaliziranih vrednostih (0–100).....	105
Preglednica 48: Pearsonov in Spearmanov koeficient povezanosti ($p < 0,01$).....	105
Preglednica 49: Povprečne vrednosti posameznih podatkovnih slojev po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).....	106
Preglednica 50: Povprečne vrednosti posameznih podatkovnih slojev po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).....	106
Preglednica 51: Usklajenost izbire učnih celic s priporočili iz literature.....	107
Preglednica 52: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI9 po naključnem vzorčenju.....	108
Preglednica 53: Osnovne statistične značilnosti učnih celic (N=18.000 celic), izražene v normaliziranih vrednostih (0–100).....	109
Preglednica 54: Povprečne vrednosti podatkovnih slojev za učne celice po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).....	109
Preglednica 55: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI13 po naključnem vzorčenju.....	110
Preglednica 56: Osnovne statistične značilnosti učnih celic (N=26.000 celic), izražene v normaliziranih vrednostih (0–100).....	111
Preglednica 57: Povprečne vrednosti podatkovnih slojev za učne celice po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).....	111
Preglednica 58: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI9 po ekspertnem vzorčenju.....	112
Preglednica 59: Osnovne statistične značilnosti (N=18.000 celic), izražene v normaliziranih vrednostih (0–100).....	113
Preglednica 60: Povprečje po tipih tipizacije TIPI9, izražene v normaliziranih vrednostih (0–100).....	114
Preglednica 61: Število učnih celic v posameznem tipu in njihov delež glede na vse celice v tipu tipizacije TIPI13 po ekspertnem vzorčenju.....	115
Preglednica 62: Osnovne statistične značilnosti (N=26.000 celic), izražene v normaliziranih vrednostih (0–100).....	116
Preglednica 63: Povprečje po tipih tipizacije TIPI13, izražene v normaliziranih vrednostih (0–100).....	116
Preglednica 64: Povprečna oddaljenost celic od najbližjega centroida.....	125
Preglednica 65: Delež enako klasificiranih celic po modelu diskriminancijske analize.....	125
Preglednica 66: Delež enako klasificiranih celic po modelu odločitvenega drevesa z upoštevanjem vseh uporabljenih podatkovnih slojev hkrati.....	126
Preglednica 67: Delež enako klasificiranih celic po modelih odločitvenih dreves z upoštevanjem posameznih slojev.....	127
Preglednica 68: Informacijski prispevek (v bitih) za posamezni podatkovni sloj ter povprečje.....	127
Preglednica 69: Razmerje informacijskega prispevka za posamezni podatkovni sloj ter povprečje.....	128
Preglednica 70: Koeficient η^2 za posamezni podatkovni sloj ter povprečje. Statistična značilnost posameznega η^2 je 0,001, kar pomeni, da je statistična značilnost posamezne lestvice 0,015, lestvice povprečnih vrednosti pa 0,059.....	129
Preglednica 71: Koeficient F glede na posamezni podatkovni sloj ter povprečje. Statistična značilnost posameznega koeficienta F je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$	129
Preglednica 72: Povprečni umerjeni koeficient variacije za posamezni podatkovni sloj in povprečje.....	130
Preglednica 73: Povprečna oddaljenost celic od najbližjega centroida.....	131
Preglednica 74: Delež pravilno klasificiranih celic po diskriminancijski analizi.....	131
Preglednica 75: Delež enako klasificiranih celic po modelu odločitvenega drevesa z upoštevanjem vseh uporabljenih podatkovnih slojev hkrati.....	132
Preglednica 76: Delež enako klasificiranih celic po modelih odločitvenih dreves z upoštevanjem posameznih slojev.....	133
Preglednica 77: Informacijski prispevek (v bitih) za posamezni podatkovni sloj ter povprečje.....	133
Preglednica 78: Razmerje informacijskega prispevka za posamezen podatkovni sloj ter povprečje.....	134
Preglednica 79: Koeficient η^2 za posamezni podatkovni sloj in povprečje. Statistična značilnost posameznega koeficienta η^2 je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$	134
Preglednica 80: Koeficient F glede na posamezen dejavnik in povprečje. Statistična značilnost posameznega koeficienta F je $p=0,001$, kar pomeni, da je statistična značilnost posamezne lestvice $p=0,015$, lestvice povprečne vrednosti pa $p=0,059$	135
Preglednica 81: Povprečni umerjeni koeficient variacije za posamezen dejavnik in povprečje.....	136
Preglednica 82: Delež pravilno klasificiranih učnih celic za modelirane tipizacije TIPI9.....	149
Preglednica 83: Delež pravilno klasificiranih vseh celic za modelirane tipizacije TIPI9.....	149
Preglednica 84: Cramerjev koeficient povezanosti ter koeficient kappa za primerjavo med izvirno tipizacijo in posamično modelirano tipizacijo. Vsi izračunani koeficienti so statistično značilni pri $p=0,001$	150
Preglednica 85: Delež pravilno klasificiranih učnih celic (ekspertni in naključni nabor) TIPI13.....	151
Preglednica 86: Delež pravilno klasificiranih vseh celic TIPI13.....	152
Preglednica 87: Cramerjev koeficient povezanosti ter koeficient kappa za primerjavo med izvirno tipizacijo in posamezno modelirano tipizacijo. Vsi izračunani koeficienti so statistično značilni pri $p=0,001$	152
Preglednica 88: Cramerjev koeficient povezanosti za pare modeliranih tipizacij TIPI9 ($p=0,001$).....	153
Preglednica 89: Koeficient kappa (%) za pare modeliranih tipizacij TIPI9 ($p=0,001$).....	153
Preglednica 90: Cramerjev koeficient povezanosti za pare modeliranih tipizacij TIPI13 ($p=0,001$).....	153
Preglednica 91: Koeficient kappa (%) povezanosti za pare modeliranih tipizacij TIPI13 ($p=0,001$).....	154
Preglednica 92: Delež celic, ki se po vseh modelih ujemajo z izvirno tipizacijo TIPI9.....	155
Preglednica 93: Delež celic, ki se po nobenem modelu ne ujemajo z izvirno tipizacijo TIPI9.....	159
Preglednica 94: Celice, ki so v vseh modeliranih tipizacijah enako klasificirane, a niso enake izvorni tipizaciji TIPI9.....	162
Preglednica 95: Delež celic, ki se po vseh modelih ujemajo z izvirno tipizacijo TIPI13.....	166

Preglednica 96: Delež celic, ki se po nobenem modelu ne ujemajo z izvirno tipizacijo TIPI13.	170
Preglednica 97: Celice, ki so v vseh modeliranih tipizacijah enako klasificirane, a niso enake izvorni tipizaciji TIP13.	173
Preglednica 98: Pearsonov in Spearmanov koeficient ($p=0,01$) povezanosti za posamezne seštevke trdnih modeliranih tipizacij TIPI9 po posameznih tipih za modelirane tipizacije, narejene z ekspertnim vzorcem, in modelirane tipizacije, narejene z naključnim vzorcem učnih celic.	182
Preglednica 99: Pearsonov in Spearmanov koeficient povezanosti ($p=0,01$) za posamezne seštevke trdnih modeliranih tipizacij TIPI13 po posameznih tipih za modelirane tipizacije, narejene z ekspertnim vzorcem, in modelirane tipizacije, narejene z naključnim vzorcem učnih celic.	189
Preglednica 100: Geoinformacijska orodja za izdelavo mehkih nadzorovanih klasifikacij.	190
Preglednica 101: Pearsonovi in Spearmanovi koeficienti povezanosti med lestvicami vrednotenja po obeh analizah (TIPI9 in TIPI13) za posamezne načine vrednotenja s pomočjo podatkovnih slojev. V vrstici pod koeficienti so navedene tudi statistične značilnosti.	193
Preglednica 102: Pearsonovi in Spearmanovi koeficienti ($p=0,001$) povezanosti med lestvicami vrednotenja po obeh analizah (TIPI9, TIPI13) za posamezne načine vrednotenja s pomočjo izvirne tipizacije.	195
Preglednica 103: Metoda voditeljev v programu SPSS.	203
Preglednica 104: Metoda voditeljev v programu Statistica.	204
Preglednica 105: Metoda voditeljev v programu Idrisi.	204
Preglednica 106: Analiza vrhov v histogramu.	204
Preglednica 107: Metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja.	205
Preglednica 108: Segmentacija.	205
Preglednica 109: Odločitveno drevo (različica CT).	206
Preglednica 110: Metoda najmanjše razdalje.	206
Preglednica 111: Metoda največje verjetnosti.	207
Preglednica 112: Metoda najbližjih sosedov.	207
Preglednica 113: Odločitveno drevo različic CTR, CTE, CTG (mere razmerje informacijskega prispevka, Ginijev koeficient, informacijski prispevek).	208
Preglednica 114: Delež enako klasificiranih po modelu odločitvenega drevesa (vsi podatkovni sloji hkrati).	208
Preglednica 115: Računanje oddaljenosti od najbližjega centroida.	209
Preglednica 116: Delež enako klasificiranih po modelu diskriminancijske analize.	209
Preglednica 117: Delež enako klasificiranih po modelu odločitvenega drevesa (po en podatkovni sloj).	209
Preglednica 118: Koeficient F.	209
Preglednica 119: Koeficient η^2	209
Preglednica 120: Povprečni umerjeni koeficient variacije.	210
Preglednica 121: Informacijski prispevek.	210
Preglednica 122: Razmerje informacijskega prispevka.	210
Preglednica 123: Uvrstitev ozemlja Slovenije po Naravnogeografski regionalizaciji (Bohn s sod., 2002/2003).	253
Preglednica 124: Primeri uporabe geografskih informacijskih sistemov za namen klasifikacije.	257
Preglednica 125: Vrednosti PUKV za posamezne razdelitve.	262
Preglednica 126: Pearsonovi (prva vrstica) in Spearmanovi koeficienti (druga vrstica) stopnje povezanosti različnih padavinskih režimov ($p=0,01$).	287
Preglednica 127: Indeks mediteranskosti za dve obdobji (Zupančič, 1995; Klimatološka povprečja ..., 2012).	287
Preglednica 128: Tipi kamnin (Zemljevid tipov kamnin, 2012).	291
Preglednica 129: Razvrstitev kamnin po prepustnosti*.	292
Preglednica 130: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI4 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).	297
Preglednica 131: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI9 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).	297
Preglednica 132: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI13 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).	298
Preglednica 133: Izračunani Pearsonovi (prva vrstica) in Spearmanovi koeficienti (druga vrstica) za povezanost različnih lestvic povprečnih ocen vrednotenja podatkovnih slojev. Statistična značilnost je za vse koeficiente $p=0,01$	298
Preglednica 134: Delež celic, ki so enako klasificirane z odločitvenim drevesom.	299
Preglednica 135: Razmerje informacijskega prispevka za posamezno klasifikacijo.	299
Preglednica 136: Informacijski prispevek za posamezno klasifikacijo.	300
Preglednica 137: Povprečni umerjeni koeficient variacije za posamezno klasifikacijo.	301
Preglednica 138: Vrednosti F za posamezno klasifikacijo. Razvrščeno po povprečni vrednosti. Statistična značilnost posameznega koeficienta F je $p=0,001$ (če ni drugače navedeno), kar pomeni, da je statistična značilnost lestvice povprečne vrednosti $p=0,125$	302
Preglednica 139: Vrednosti η^2 za posamezno klasifikacijo. Razvrščeno po povprečni vrednosti. Statistična značilnost (če ni drugače navedeno) posameznega η^2 je 0,001, kar pomeni, da je statistična značilnost posamezne lestvice 0,040 (letna temperatura ima 0,049), lestvice povprečne vrednosti pa 0,124.	303
Preglednica 140: Vrednosti deleža enako klasificiranih celic pri gradnji odločitvenega drevesa z vsemi tremi podatkovnimi sloji.	304
Preglednica 141: Povprečna oddaljenost posamezne celice od najbližjega centroida skupine.	305
Preglednica 142: Delež enako klasificiranih celic po modelu diskriminancijske analize.	305
Preglednica 143: Pregled argumentov izbora podatkovnih slojev.	307
Preglednica 144: Primer opisa rezultata nadzorovanih klasifikacij na primeru modeliranih tipizacij TIPI9 po metodi odločitvenega drevesa CT.	309
Preglednica 145: Pearsonovi koeficienti stopnje povezanosti vrednotenja glede na vse podatkovne sloje hkrati. V drugi vrstici so zapisane ustrezne statistične značilnosti koeficientov.	311
Preglednica 146: Spearmanovi koeficienti stopnje povezanosti vrednotenja glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.	311

Preglednica 147: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.	312
Preglednica 148: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.	312
Preglednica 149: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.	313
Preglednica 150: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.	313
Preglednica 151: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.	314
Preglednica 152: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.	314
Preglednica 153: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.	314
Preglednica 154: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.	315
Preglednica 155: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.	315
Preglednica 156: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.	316
Preglednica 157: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.	316
Preglednica 158: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.	317
Preglednica 159: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.	317
Preglednica 160: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.	318
Preglednica 161: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.	318
Preglednica 162: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.	318
Preglednica 163: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.	319
Preglednica 164: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.	319
Preglednica 165: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij za tipizacijo TIPI9.	353
Preglednica 166: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij za tipizacijo TIPI13.	360
Preglednica 167: Delež tipov po posameznih modeliranih popačenih tipizacijah TIPI9 in po popačeni izvorni tipizaciji TIPI9.	375
Preglednica 168: Delež tipov po posameznih modeliranih popačenih tipizacijah in po popačeni izvorni tipizaciji TIPI13.	375
Preglednica 169: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi vseh podatkovnih slojev hkrati.	376
Preglednica 170: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja naklon.	376
Preglednica 171: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja padavinski režim.	376
Preglednica 172: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja prepustnost.	376
Preglednica 173: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja nadmorska višina.	377
Preglednica 174: Koeficient kappa in Cramerjev koeficient za primerjavo posameznih modeliranih popačenih tipizacij s popačeno izvorno tipizacijo TIPI9.	377
Preglednica 175: Ujemanje modeliranih popačenih tipizacij z popačeno izvorno tipizacijo TIPI9.	377
Preglednica 176: Cramerjev koeficient povezanosti med modeliranimi popačenimi tipizacijami TIPI9 ($p=0,001$).	378
Preglednica 177: Koeficient kappa (%) povezanosti med modeliranimi popačenimi tipizacijami TIPI9 ($p=0,001$).	378
Preglednica 178: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi vseh podatkovnih slojev hkrati.	378
Preglednica 179: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja naklon.	378
Preglednica 180: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja padavinski režim.	379
Preglednica 181: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja prepustnost.	379
Preglednica 182: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja nadmorska višina.	379
Preglednica 183: Koeficient kappa in Cramerjev koeficient za primerjavo modeliranih popačenih tipizacij TIPI13.	380
Preglednica 184: Ujemanje modeliranih popačenih tipizacij z izvorno popačeno tipizacijo TIPI13.	380
Preglednica 185: Cramerjev koeficient povezanosti med modeliranimi popačenimi tipizacijami TIPI13 ($p=0,001$).	380
Preglednica 186: Koeficient kappa med modeliranimi popačenimi tipizacijami TIPI13 ($p=0,001$).	380

12.2 Seznam slik

Slika 1: Izsek besedila iz Kmetijskih in rokodelskih novic (Kmetijska shola, 1843).....	1
Slika 2: Shema doktorske disertacije.....	5
Slika 3: Teoretična razporeditev pomena dejavnikov po posameznih ravneh ter medsebojna odvisnost (Klijn, 1994, 88).....	16
Slika 4: Zveza med časovno in prostorsko ravno ter dejavniki (Klijn, 1994, 91).....	17
Slika 5: Ravni in vplivi dejavnikov (Mücher s sod., 2003, 17).....	18
Slika 6: Hierarhija prevladujočih biofizikalnih procesov po Mackeyu (cv: Burrough s sod., 2004).....	19
Slika 7: Shematski prikaz možnosti vrednotenja klasifikacij na podlagi podatkovnega sloja in vrednotenja podatkovnih slojev na podlagi klasifikacije.....	31
Slika 8: Učni območji A in B sta sestavljena iz treh sklopov učnih celic – učnih polj.....	32
Slika 9: Metoda vrednotenja z vidika merske lestvice in izstopajočih vrednosti. Primer podatkovnega sloja višinska razgibanost.	38
Slika 10: Grafikoni povezanosti med načini vrednotenja podatkov glede na TIPI4.....	48
Slika 11: Grafikoni povezanosti med načini vrednotenja podatkov glede na TIPI9.....	49
Slika 12: Grafikoni povezanosti med načini vrednotenja podatkov glede na TIPI13.....	49
Slika 13: Povezanost povprečnih vrednosti pri vrednotenju podatkov z vidika posamezne klasifikacije.....	50
Slika 14: Stopnja spreminjanja PUKV glede na vrednost za Slovenijo (PUKVSI=1).....	53
Slika 15: Z Wardovo metodo smo hierarhično združili podatkovne sloje glede na njihove vrednosti spreminjanja PUKV glede na vrednost za Slovenijo.....	54
Slika 16: Naravnopokrajinske tipizacije z 2 tipoma po metodah nenadzorovane klasifikacije.....	59
Slika 17: Naravnopokrajinske tipizacije s 5 tipi po metodah nenadzorovane klasifikacije.....	60
Slika 18: Naravnopokrajinske tipizacije z 10 tipi po metodah nenadzorovane klasifikacije.....	61
Slika 19: Naravnopokrajinske tipizacije s 15 tipi po metodah nenadzorovane klasifikacije.....	63
Slika 20: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem naklon.....	65
Slika 21: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem prepustnost.....	66
Slika 22: Delež enako klasificiranih celic po modelu odločitvenega drevesa s podatkovnim slojem temperatura.....	66
Slika 23: Razmerje informacijskega prispevka podatkovnega sloja naklon.....	67
Slika 24: Razmerje informacijskega prispevka podatkovnega sloja prepustnost.....	67
Slika 25: Razmerje informacijskega prispevka podatkovnega sloja temperatura.....	68
Slika 26: Informacijski prispevek podatkovnega sloja naklon.....	68
Slika 27: Informacijski prispevek podatkovnega sloja prepustnost.....	69
Slika 28: Informacijski prispevek podatkovnega sloja temperatura.....	69
Slika 29: Povprečni umerjeni koeficient variacije za podatkovni sloj naklon.....	70
Slika 30: Povprečni umerjeni koeficient variacije za podatkovni sloj prepustnost.....	70
Slika 31: Povprečni umerjeni koeficient variacije za podatkovni sloj temperatura.....	71
Slika 32: Koeficient F za podatkovni sloj naklon.....	71
Slika 33: Koeficient F za podatkovni sloj prepustnost.....	72
Slika 34: Koeficient F za podatkovni sloj temperatura.....	72
Slika 35: Eta^2 za podatkovni sloj naklon.....	73
Slika 36: Eta^2 za podatkovni sloj prepustnost.....	73
Slika 37: Eta^2 za podatkovni sloj temperatura.....	74
Slika 38: Delež enako klasificiranih celic po modelu odločitvenega drevesa z vsemi tremi podatkovnimi sloji (pri segmentaciji 15 je prikazana različica A).....	74
Slika 39: Povprečna oddaljenost celic po posameznih številnih tipov.....	75
Slika 40: Delež enako klasificiranih celic po modelu diskriminančne analize.....	75
Slika 41: Prekrivanje tipizacije in ugotavljanje kombinacij.....	89
Slika 42: Povprečna oddaljenost za posamezno serijo naravnopokrajinskih tipizacij.....	91
Slika 43: Shematski prikaz modeliranja izvirne naravnopokrajinske tipizacije.....	98
Slika 44: Pokrajinskoekološki tipi (Špes s sod., 2002).....	100
Slika 45: Pokrajinski tipi (Perko, 1998a; Perko, 1998b; Perko, 2007b).....	101
Slika 46: Delež pravilno klasificiranih celic z drevesom (različica CT) za TIPI9 (modra črta) in TIPI13 (rdeča črta) pri določenem številu ravnih.....	102
Slika 47: Histogrami izbranih podatkovnih slojev (N=506.450).....	106
Slika 48: Učne celice za TIPI9 po naključnem vzorčenju.....	108
Slika 49: Histogrami podatkovnih slojev za učne celice po naključnem vzorčenju za TIPI9 (N=18.000).....	109
Slika 50: Učne celice za TIPI13 po naključnem vzorčenju.....	110
Slika 51: Histogrami podatkovnih slojev za učne celice po naključnem vzorčenju za TIPI13 (N=16.000).....	111
Slika 52: Učne celice za TIPI9 po ekspertnem vzorčenju.....	113
Slika 53: Histogrami podatkovnih slojev po stratificiranem vzorčenju za TIPI9 (N=18.000).....	114
Slika 54: Učne celice za tipizacijo TIPI13 po ekspertnem vzorčenju.....	115
Slika 55: Histogrami podatkovnih slojev po ekspertnem vzorčenju za TIPI13 (N=26.000).....	116
Slika 56: Modelirane tipizacije TIPI9 po metodah nadzorovane klasifikacije z naključnim vzorcem učnih celic.....	119
Slika 57: Modelirane tipizacije TIPI9 po metodah nadzorovane klasifikacije z ekspertnim vzorcem učnih celic.....	120
Slika 58: Modelirane tipizacije TIPI13 po metodah nadzorovane klasifikacije z naključnim vzorcem učnih celic.....	121
Slika 59: Modelirane tipizacije TIPI13 po metodah nadzorovane klasifikacije z ekspertnim vzorcem učnih celic.....	122
Slika 60: Vrednotenje modeliranih tipizacij in izvirne tipizacije s pomočjo uporabljenih podatkovnih slojev.....	124
Slika 61: Usklajenost različnih načinov vrednotenja tipizacij TIPI9.....	137
Slika 62: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj naklon.....	138
Slika 63: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj padavinski režim.....	139
Slika 64: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj prepustnost.....	140
Slika 65: Usklajenost različnih načinov vrednotenja tipizacij TIPI9 glede na podatkovni sloj nadmorska višina.....	141
Slika 66: Usklajenost različnih načinov vrednotenja tipizacij TIPI13.....	143

Slika 67: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj naklon.	144
Slika 68: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj padavinski režim.	145
Slika 69: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj prepustnost.	146
Slika 70: Usklajenost različnih načinov vrednotenja tipizacij TIPI13 glede na podatkovni sloj nadmorska višina.	147
Slika 71: Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvirno tipizacijo TIPI9.	156
Slika 72: Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI9.	158
Slika 73: Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI9.	159
Slika 74: Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI9.	161
Slika 75: Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI9.	162
Slika 76: Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvirno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI9.	164
Slika 77: Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvirno tipizacijo TIPI9. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI9.	165
Slika 78: Območja, ki se po vseh modelih (z naključnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.	167
Slika 79: Območja, ki se po vseh modelih (z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.	168
Slika 80: Območja, ki se po vseh modelih (z naključnim vzorcem in z ekspertnim vzorcem) ujemajo z izvirno tipizacijo TIPI13.	169
Slika 81: Območja, ki se po nobenem modelu (z naključnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI13.	171
Slika 82: Območja, ki se po nobenem modelu (z ekspertnim vzorcem) ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po izvorni tipizaciji TIPI13.	172
Slika 83: Območja, ki se ujemajo po vseh modelih (z naključnim vzorcem), a se ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI13.	174
Slika 84: Območja, ki se ujemajo po vseh modelih (z ekspertnim vzorcem), a se ne ujemajo z izvirno tipizacijo TIPI13. Celice so obarvane tako, da prikazujejo tip po modeliranih tipizacijah TIPI13.	175
Slika 85: Prekrivanje modeliranih tipizacij za ugotavljanje, kolikokrat je posamezna celica klasificirana v posamezen tip.	176
Slika 86: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI9 z ekspertnim vzorcem učnih celic.	176
Slika 87: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI9 z naključnim vzorcem učnih celic.	179
Slika 88: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI13 z ekspertnim vzorcem učnih celic.	182
Slika 89: Seštevek uvrstitev celice v posamezen tip po modeliranih tipizacijah TIPI13 z naključnim vzorcem učnih celic.	186
Slika 90: Postopek objektivnega vrednotenja pri izdelavi tipizacije pokrajine.	199
Slika 91: Različni načini določanja območij za izračunavanje PUKV-jev. Primer za raven s petimi enotami.	211
Slika 92: Primer zamišljenega računalniškega programa za izdelavo in vrednotenje naravnopokrajinskih tipizacij.	218
Slika 93: Uporabniki računalniškega programa pri snovanju tipizacije.	219
Slika 94: Okoljska členitev Evrope (Metzger s sod., 2005; Jongman s sod., 2006).	249
Slika 95: Evropska pokrajinska klasifikacija (Mücher s sod., 2003; Mücher s sod., 2006; Mücher s sod., 2009).	250
Slika 96: Evropske ekološke regije oziroma območja (Digital map ..., 2009).	251
Slika 97: Ozemlje Slovenije se uvršča v tri od 14 biotopov sveta.	252
Slika 98: Biogeografske regije oziroma območja, različica iz leta 2008 (Biogeographical regions ... 2009).	253
Slika 99: Naravnogeografska regionalizacija Evrope v Sloveniji (Bohn s sod., 2002/2003).	253
Slika 100: Izsek zemljevida vseevropskih pokrajinskih tipov (Meeus 1995).	254
Slika 101: Izsek razdelitve kopnega po Baileyu (1996).	255
Slika 102: Biogeografske pokrajine Evrope (Europe's ..., 1995).	255
Slika 103: Izsek biogeografskega zemljevida Evrope (Rivas-Martínez, Penas, Díaz 2009).	256
Slika 104: Izsek bioklimatskega zemljevida Evrope (Rivas-Martínez, Penas, Díaz 2009).	256
Slika 105: Prikaz Slovenije, razdeljene z mrežo 5 krat 5 km, 10 krat 10 km, 50 krat 50 km in 100 krat 100 km.	261
Slika 106: Prikaz Slovenije, razdeljene z mrežo kvadratov 10 krat 10 km.	262
Slika 107: Povprečne vrednosti obteženega umerjenega koeficienta za posamezne razdelitve.	263
Slika 108: Primerjava vrednosti PUKV na posamezni ravni z največjo vrednostjo PUKV.	263
Slika 109: Teoretične vrste spreminjana vrednosti PUKV po posameznih ravneh glede na najvišji PUKV.	264
Slika 110: Primer določanja porečij po principu poplavljanja (Pratt, 2007, 594; Lotufo s sod., 2008, 140).	272
Slika 111: Analiza vrhov v histogramu (Richards, Jia, 2006).	273
Slika 112: Postopek nadzorovane klasifikacije (Warner, Campagna, 2009, 198).	275
Slika 113: Primer odločitvenega drevesa za napovedovanje plazovitosti z označenimi posameznimi elementi (Ciglič, Komac, Zorn, 2011).	277
Slika 114: Primerjava indeksa mediteranskosti za dve obdobji (Zupančič, 1995; Klimatološka povprečja ..., 2012).	288
Slika 115: Mehke modelirane naravnopokrajinske tipizacije za tip 1.1 (alpska gorovja).	320
Slika 116: Mehke modelirane naravnopokrajinske tipizacije za tip 1.2 (alpska hribovja).	321
Slika 117: Mehke modelirane naravnopokrajinske tipizacije za tip 1.3 (alpske ravnine).	323
Slika 118: Mehke modelirane naravnopokrajinske tipizacije za tip 2.1 (panonska gričevja).	324
Slika 119: Mehke modelirane naravnopokrajinske tipizacije za tip 2.2 (panonske ravnine).	326
Slika 120: Mehke modelirane naravnopokrajinske tipizacije za tip 3.1 (dinarske planote).	327
Slika 121: Mehke modelirane naravnopokrajinske tipizacije za tip 3.2 (dinarska podolja in ravniki).	329
Slika 122: Mehke modelirane naravnopokrajinske tipizacije za tip 4.1 (sredozemska gričevja).	330
Slika 123: Mehke modelirane naravnopokrajinske tipizacije za tip 4.2 (sredozemske planote).	332
Slika 124: Mehke modelirane naravnopokrajinske tipizacije za tip 1 (visokogorski svet).	333
Slika 125: Mehke modelirane naravnopokrajinske tipizacije za tip 2 (širše rečne doline v visokogorju, hribovju in na krasu).	335
Slika 126: Mehke modelirane naravnopokrajinske tipizacije za tip 3 (visoke kraške planote in hribovja v karbonatnih kamninah).	336
Slika 127: Mehke modelirane naravnopokrajinske tipizacije za tip 4 (hribovja v pretežno nekarbonatnih kamninah).	338
Slika 128: Mehke modelirane naravnopokrajinske tipizacije za tip 5 (medgorske kotline).	339

Slika 129: Mehke modelirane naravnopokrajinske tipizacije za tip 6 (gričevje v notranjem delu Slovenije).	341
Slika 130: Mehke modelirane naravnopokrajinske tipizacije za tip 7 (ravnine in širše doline v gričevju notranjega dela Slovenije).	342
Slika 131: Mehke modelirane naravnopokrajinske tipizacije za tip 8 (kraška polja in podolja).	344
Slika 132: Mehke modelirane naravnopokrajinske tipizacije za tip 9 (nizki kras Notranjske in Dolenjske).	345
Slika 133: Mehke modelirane naravnopokrajinske tipizacije za tip 10 (nizki kras Bele krajine).	347
Slika 134: Mehke modelirane naravnopokrajinske tipizacije za tip 11 (Kras in Podgorski kras).	348
Slika 135: Mehke modelirane naravnopokrajinske tipizacije za tip 12 (gričevje v primorskem delu Slovenije).	350
Slika 136: Mehke modelirane naravnopokrajinske tipizacije za tip 13 (širše doline in obalne ravnice v primorskem delu Slovenije).	351
Slika 137: Izdelava popačene izvorne tipizacije z naključno prerazporeditvijo celic.	372
Slika 138: Popačena tipizacija TIPI9.	373
Slika 139: Popačena tipizacija TIPI13.	373
Slika 140: Modelirane popačene tipizacije TIPI9 po uspeh metodah nadzorovane klasifikacije.	374
Slika 141: Modelirane popačene tipizacije TIPI13 po uspeh metodah nadzorovane klasifikacije.	374

12.3 Seznam prilog

Priloga 1: Opis klasifikacij celotne Slovenije na podlagi naravnih dejavnikov.	243
Priloga 2: Slovenija v posameznih naravnogeografskih klasifikacijah Evrope.	249
Priloga 3: Primeri klasifikacij z geografskimi informacijskimi sistemi.	257
Priloga 4: Podroben opis uporabljenih metod.	259
Priloga 5: Nasveti za izbiranje učnih celic.	282
Priloga 6: Pregled naravnih dejavnikov in podatkovnih slojev.	284
Priloga 7: Usklajenost mer vrednotenja podatkovnih slojev (izračunani Pearsonovi in Spearmanovi koeficienti).	297
Priloga 8: Vrednotenje modeliranih naravnopokrajinskih tipizacij po metodah nenadzorovane klasifikacije.	299
Priloga 9: Argumentiranje izbora podatkov za izdelavo naravnopokrajinskih tipizacij po metodah nadzorovane klasifikacije.	307
Priloga 10: Primer opisa modelirane naravnopokrajinske tipizacije TIPI9 po metodi odločitvenega drevesa (različica CT).	309
Priloga 11: Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 in TIPI13.	311
Priloga 12: Kartografski prikaz posameznih mehkih klasifikacij.	320
Priloga 13: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij.	353
Priloga 14: Dokaz objektivnosti izvirmih naravnopokrajinskih tipizacij TIPI9 in TIPI13.	372

13. Summary

Classifying Slovenia into various spatial units has a long tradition in Slovenian geography. Numerous landscape classifications can be found for Slovenia. In Slovenia, increasingly more digital spatial data are available for natural geographic factors in addition to an increasing number of geographic information tools (methods). Therefore, various approaches can be tested with regard to classifying Slovenia into natural landscape types and solving one of the problems cited in the literature. It was not expected that this dissertation would provide a complete solution to classifying Slovenia into natural landscape types, but the primary goal was to test the applicability of geographic information systems (GIS) and establish which areas they are the most useful in. The primary focus was on using GIS for evaluating data layers (input evaluation), designing typifications (modeling), and evaluating designed typifications (output evaluation). The research was limited to Slovenia.

Two hypotheses were established. The first is: *“By using an appropriate combination of geographic information tools for typification design and evaluating the typification results, it is possible to objectively assess the quality of typifications.”* Various geographic information tools for classification were used to test this hypothesis and produce several natural landscape typifications. These were then evaluated in various ways and it was also verified whether these various evaluation methods are consistent and can be described as objective. The second hypothesis is: *“With geographic information systems one can determine which areas are classified into the same or similar types regardless of which geographic information tools are used, and which areas geographic information tools classify into different types.”* By overlapping maps of natural landscape typifications produced with different geographic information tools, areas can be determined that are always or frequently classified the same way, and areas that are never classified the same. Natural landscape types that were already defined in the past by geographers can thus be confirmed or rejected and attention can be drawn to any weaknesses.

The study was designed such that it started off by examining which natural landscape classifications of Slovenia already exist, which classifications are used in foreign literature, how GIS have been used so far, which natural factors influence the formation of natural landscapes, and which data layers are used to present them. The collected data layers were then limited to the territory of Slovenia. Given the minimum and maximum of an individual layer, the layer values were linearly transferred to a scale ranging from 0 to 100. This neutralized the effect of various scales. The layers had a spatial resolution of 200 m, which means Slovenia was divided into 506,450 cells.

The main part of the study first evaluated the data layers in terms of outliers, informativeness according to already available divisions of Slovenia, mutual correlations, and spatial levels. The selected data layers were then used to produce several typifications based on unsupervised classification methods, and several typifications based on supervised classification methods.

Based on ten unsupervised classification methods (i.e., seven versions of the k-means, the iterative self-organizing unsupervised classifier, histogram peak technique, and segmentation) the selected data layers (i.e., average annual temperature, slope, and permeability) were used to produce natural landscape typifications featuring 2, 5, 10, and 15 types. The typifications produced were then evaluated in terms of the data layers used; it was established to what extent the data layers are correlated with the typifications created. If a typification takes into account a data layer well, the correlation between them is high. The typifications created were evaluated in various ways (e.g., average distance from the centroid, share of pixels with the same type based on a decision tree, share of pixels with the same type based on a discriminatory analysis, information gain, information ratio, F-coefficient, average calibrated

coefficient of variation, and η^2 -coefficient), and it was determined whether the various evaluation methods provide similar results for individual typifications—in other words, whether the evaluation methods are consistent and therefore trustworthy. This is how the first hypothesis was partially tested. In addition, the distance of cells from the average values (the centroids in a multidimensional space, where one variable represents one dimension) were determined for each series of typifications; this was part of the testing the second hypothesis. In the part studying the opportunities to use GIS in connection with supervised classification methods, two divisions of Slovenia were first selected: landscape-ecological types (Špes et al., 2002) and landscape types (Perko, 1998a; Perko, 1998b; Perko, 2007b). This provided a selection of types that had to be sought and confirmed. One random and one expert sample of training cells were taken from each typification. Based on the training cells, the selected data layers (i.e., elevation, slope, permeability, and precipitation) were used to create modeled natural landscape typifications by applying seven supervised classification methods (i.e., the minimum distance to means technique, the maximum likelihood method, the k-nearest neighbor method, and four versions of the decision tree method). All of the natural landscape typifications created were evaluated in several ways in terms of the data layers used (just like evaluating the typifications following the unsupervised classification methods) and it was determined whether different evaluation methods provide similar results—in other words, whether the evaluation methods are consistent. This is again how the first hypothesis was tested. In addition to this evaluation, this part also compared the modeled typifications to the original typification. The goal of this was to establish the extent to which a specific model approximated and confirmed the original typification. The agreement between the original and modeled typifications was also calculated using several methods (share of cells, Cramer coefficient, and kappa coefficient). Because seven modeled typifications were created for each original typification, the number of times an individual cell was classified into a specific type was able to be determined. Such a sum of hard modeled classifications can be used as a general fuzzy typification that is created based on various methods and should therefore be considerably objective. This was proved by calculating the correlation between the sums of hard modeled typifications (general fuzzy typifications) with the values of specific fuzzy modeled typifications for each type. Namely, the affiliation to an individual type was also complemented by producing various soft typifications for each type. The overlapping of modeled and original typifications was then used to establish which areas of individual original types were confirmed with all models, and which areas were not confirmed by even a single model. This analysis tested the second hypothesis and provided an insight into which Slovenian areas are difficult to classify into a specific type with models, and which are the areas of types that can be confirmed with models easier.

Based on the results, the first hypothesis (on the opportunities to objectively evaluate natural landscape typifications) was only partially confirmed. As part of the analysis of typifications following the unsupervised classification methods, it was established that various methods of evaluating typifications are not sufficiently consistent, which means that it was impossible to objectively assess which typification was better. The reason for poor consistency is also the low number of typifications created (ten for each number of types). In addition, it was established that the typification evaluation is definitely influenced by the number of types. Nonetheless, as part of analyzing the typifications following the supervised classification methods, it was established that the various evaluation methods are very consistent, which means the evaluations (ratings) calculated can be trusted. The only exception was the decision-tree evaluation. It proved to be inappropriate compared to other evaluation methods. The second hypothesis was confirmed. By overlapping various modeled typifications following supervised classification methods, information on how many times a specific cell was included in a specific type was obtained for each cell. The maps showing this by

individual type were also relatively well correlated with specific fuzzy typifications for corresponding types. The overlapping of modeled typifications with the original typification made it possible to establish which Slovenian areas can be confirmed in terms of original typification, and which areas contain types that cannot be confirmed. In addition, the analysis of typifications following the unsupervised classification methods showed that the cell distances from the centroids were very similar (this was notice for typifications with 2, 5, 10 or 15 types). The only exception was the distance in typifications following the segmentation method; unlike other methods, this method takes into account the “neighboring” aspect of cells.

The dissertation goals also included a proposal of the best combination of individual tools for creating a natural landscape classification of Slovenia. Therefore, the dissertation concludes by proposing a procedure for creating and evaluating a suitable typification. The following series of geographic information tools can be used for producing a natural landscape typification of Slovenia: a) Where the number and basic characteristics of types are already known: 1. Using segmentation for merging the most homogenous areas based on the most accurate data layers; 2. Selecting training units; using the decision tree as a classification model and classifying the entire country; 3. (If producing several versions), all of the versions are also evaluated using geographic information tools that enable evaluation based on data layers and the modeling success rate, and the best evaluated variation is then selected; 4. Fine modification of the boundaries; b) Where the number and basic characteristics of types are unknown: 1. Using segmentation for merging the most homogenous areas based on the most accurate data layers; 2. (In the case of sufficient reduction of data due to segmentation) using the hierarchical classification method to assess the number of types; 3. Testing various unsupervised classification methods and producing several versions; 4. Evaluating these versions using geographic information tools that enable evaluation based on data layers and modeling success rate; 5. Selecting the best classification; 6. Adding any modifications. Based on the findings connected with testing the first hypothesis, the use of an objective evaluation method in producing landscape typification is also recommended as an applied outcome of the dissertation. The evaluation method is as follows: 1. The researcher uses the data layers purposefully selected to divide a specific area into types, using his own judgment or the computer method; 2. He assesses the typification produced based on the data layers by using one or several selected methods (e.g., calculating the information gain); 3. He randomly selects a sample of training cells (or any other units if the analysis is not based on a grid) from a each type and uses the selected method to develop a classification rule; 4. Based on the rule developed, he then classifies all of the cells; 5. He compares the modeled typification with his original typification and determines the level of compatibility (or the extent to which the original typification is mathematically confirmed); 6. The researcher can then modify the boundaries between types and produce a new typification version; 7. He can repeat the entire procedure from steps 1 to 6 (producing and testing various versions of the typification) several times, which means he obtains several typification versions; 8. For each typification created, the researcher has the information on the evaluation in terms of data layers and the compatibility with the modeled typification; he enters these data in a graph, in which one axis represents the data-layer evaluation and the other the compatibility with the modeled typification; 9. The researcher selects the version of his (modified) original typification that scores high in terms of data layers and is the most compatible with the modeled typification. The dissertation concludes by critically analyzing the geographic information tools in terms of their applicability in creating a typification. It highlights the advantages and disadvantages of individual tools, and their areas of applicability. Potentially very useful tools in geography, which to date have not been used for creating typifications of Slovenia, include segmentation and some machine learning tools (e.g., decision trees and information gain).

14. Priloge

Priloga 1: Opis klasifikacij celotne Slovenije na podlagi naravnih dejavnikov

Klasifikacije na podlagi več naravnih dejavnikov

Melik (1935) je pripravil prvo klasifikacijo na podlagi geološke zgradbe in tektonike. Klasifikacijo je poimenoval Zgradbene enote na Slovenskem in gre v bistvu za geološko regionalizacijo, v kateri so tudi tipi (večje kotline), saj so enote določene na več ločenih območjih. Določil je štiri glavne enote: Alpsko gorovje, Dinarsko gorovje, Jadransko morje (kot tektonska depresija) s Furlansko nižino ter Panonska kotlina, na priloženem zemljevidu pa je določil še peto enoto – večje kotline. Na zemljevidu je Alpski predel razdelil na: Osrednje Alpe, Dravsko skupino, Dinarsko brazgotino, Južne apniške Alpe, Predalpsko hribovje, Predalpsko hribovje z dinarsko zgradbo; Dinarski predel je razdelil na: Pretežno apniško ozemlje ter Proge eocenskega fliša; Subpanonski predel je razdelil na: Mladotercijarno gričevje, Kalnik in Sljeme, del panonsko-rodopske gmote ter Ravnine. Furlanska nižina ni bila razdeljena na manjše enote. Na zemljevidu so vrisane tudi večje kotline (Melik, 1935, 19).

Melik (1946) je pozneje Slovenijo razdelil tako, da bi se v kar največji meri nakazalo smotrno gospodarstvo. Pri tem je upošteval predvsem naravne dejavnike, med katerimi je kot najpomembnejše izbral relief (izoblikovanost površja), kamninsko sestavo, nadmorsko višino in podnebje. Opozoril je tudi na pomen že obstoječih gospodarskih razmer. Slovenijo je razdelil na naslednje kategorije: visokogorski alpski predel (z alpskimi visokimi planotami, ki so posebej izpostavljene), predel alpskega sredogorja, hribovje, predel goric, ravnine in večje doline, dinarske visoke planote, kraško hribovje z nižjimi planotami in podolji (s posebej izločenima Belo krajino in Krasom) in kraška polja.

Melik je v več izdajah (**1954; 1957; 1959; 1960**) objavil tudi temeljit geografski pregled Slovenije po regijah. Regije je v svojih knjigah določil po različnih kriterijih. Za Slovenski alpski svet je uporabil pokrajinsko-fiziognomični kriterij, za Štajersko s Prekmurjem in Mežiško dolino historično-teritorialni kriterij, za Posavsko Slovenijo pripadnost Savskemu porečju ter za Primorsko Slovenijo kombinacijo naravnogeografskega in historičnogeografskega kriterija (Ilešič, 1972, 9).

Ilešič (1956) je izdelal klasifikacijo na pokrajinske tipe po načelu enotne homogene pokrajinske fiziognomije. Pravi, da gre zgolj za osnutek nadaljnjemu delu, zato besedilo ni opremljeno z zemljevidom. Razdelitev je potekala na podlagi naravnogeografskega videza pokrajine ter tistih vidnih antropogenih dejavnikov, ki so precej odvisni od narave (raba tal, oblika naselij, kmetijstvo). Slovenijo je razdelil na 5 skupin pokrajin (alpske, predalpske, subpanonske, kraške in primorske), ki so razdeljene in opisane na eni ali dveh nižjih ravneh. Ilešičevo (1956) delo smo, kljub temu da ne gre za dokončno razdelitev Slovenije in ni priloženega zemljevida, vseeno navedli v seznamu, saj je bilo delo podlaga za poznejši Ilešičevi klasifikaciji iz let 1957/58 in 1972.

Ilešič (1957/58) je objavil zemljevid pokrajinske rajonizacije Slovenije, ki jo je predhodno opisal v Geografskem obzorniku (Ilešič, 1956). Na najvišji ravni je določil pet pokrajinsko-fiziognomičnih makroregij, ki jih je določal na podlagi fiziognomske homogenosti in splošnega značaja pokrajine. Na nižjih ravneh si sledijo mezoregije, submezoregije in mikroregije. Ker se znotraj makroregij pojavljajo ponekod velike razlike, je avtor določil mikroregije; na primer znotraj makroregije Slovenske alpske pokrajine je izločil doline in jih od ostalega visokogorskega sveta ločil glede na zgornjo mejo poselitve (med 1100 in 1300 m), torej je uporabil družbenogeografski dejavnik. Po nekaterih spremembah glede na objavljeni prispevek leta 1956 so bile makroregije in mezoregije določene tako: Alpske pokrajine (se delijo na zahodne in vzhodne), Predalpske pokrajine (se delijo na zahodne,

vzhodne in severovzhodne), Subpanonske pokrajine (se delijo na prave in prehodne) ter Primorske pokrajine (se delijo na Submediteransko-subalpske, prave in Submediteransko-dinarske).

Ilešič (1972) je nato določil še pokrajinsko-tipološko oziroma ekološko razčlenjenost Slovenije. Določil je glavne pokrajine, ki jih je večinoma razdelil še na dveh ravneh (le pri Kraških pokrajinah manjka druga raven). Po tej je določil:

- Alpske pokrajine, med katere je uvrstil visokogorska območja, v katerih so alpsko kmetovanje, pomembna izraba gozda, velik hidroenergetski potencial in turizem (zahodne slovenske alpske pokrajine; vzhodne slovenske alpske pokrajine);
- Predalpsko hribovje, ki ga deli na zahodne slovenske predalpske pokrajine, vzhodne slovenske predalpske pokrajine (kjer je nekaj subpanonskih potez v podnebju in kmetijstvu) in severovzhodne slovenske predalpske pokrajine (tam, kjer so kristalasto sredogorje ter samotne kmetije);
- Slovenske subpanonske pokrajine, ki jih deli na prave subpanonske pokrajine in subpanonsko subdinarske pokrajine,
- Kraške pokrajine notranje Slovenije,
- Slovenske submediteranske ali primorske pokrajine, ki jih je določil na podlagi podnebja in kamnin ter jih deli na prave submediteranske pokrajine in submediteranske prehodne pokrajine.

Ilešič je leta 1972 izdelal tudi bolj posplošeno klasifikacijo z naslovom Geografske regije, s katero je razdelil Slovenijo na podlagi naravnih dejavnikov, zgodovinskih dejavnikov in gravitacijskih središč na skupine regij Osrednje Slovenije, Savinjsko-zgornjesotelske Slovenije, Severovzhodne Slovenije, Jugovzhodne Slovenije, Zahodne Slovenije. Vsaka skupina regij (makroregija) se deli na mezoregije (Ilešič, 1972).

Gams (1978a) je razdelil Slovenijo na šest makroregij na podlagi reliefa in podnebja (Alpe, Predalpsko hribovje, Dinarsko višavje, Ljubljanska kotlina, Submediteranska Slovenija, Subpanonska Slovenija). Nato je določil 57 mezoregij predvsem na podlagi pokrajinske homogenosti. Upošteval je tudi kamnine, talne tipe, vsote temperatur (nad 0 in 5 °C), količino padavin v obdobju april–september, število dni s padavinami vsaj 0,1 mm, razliko med potencialno evapotranspiracijo in padavinami (indeks aridnosti/humidnosti), nadmorsko višino, višinsko razliko (reliefno amplitudo), rabo tal, delež listavcev in iglavcev. Za vse mezoregije je izračunal podatke ter jih prikazal v obsežni tabeli. Pri razmejevanju je bil pozoren tudi na to, da posamezne enote po površini niso preveč odstopale. Regionalizacija je postala temelj za poznejši Gamsovi delitvi (1986 in 1998), ki pa se razlikujeta predvsem pri poimenovanju enot.

Gams (1983) je razdelil Slovenijo za poučevanje v šoli. Klasifikacijo je poimenoval Slovenske regije. Določil je naslednje regije: Alpe, Predalpska Slovenija, Slovensko Primorje ali Submediteranska Slovenija, Dinarske planote celinske Slovenije ter Subpanonska Slovenija. Regije se nadalje različno delijo ne drugo, ponekod tudi na tretjo in četrto raven. Kot glavno merilo je izbral kulturno pokrajino, saj ta odraža naravne dejavnike. Avtor priznava, da dejavnost ni več toliko navezana na naravne dejavnike, a se je podoba pokrajine v agrarni dobi v osnovnih poteza ohranila do danes. Pri regionalizaciji je upošteval tudi družbenogeografski vidik, predvsem gravitacijo središč. Določil je tudi mezoregije, nekatere med njimi je označil kot prehodne (Gams, 1983).

Gams (1986a) je določil tudi pokrajinsko ekološke regije. Najprej je izdelal karte v merilu 1 : 100.000 za ekološko pomembne elemente: višinska pasovitost, reliefna energija (razlika med najvišjo in najnižjo točko znotraj kvadrata 1 x 1 km), litološka karta za vzpeti svet, pedološka karta za nižinski ravninski svet. Višinske pasove je določil na podlagi ekoloških pogojev kultur in rastja, podnebje pa na podlagi podatkov z vremenskih postaj, ki so čim bolj odražale naravne značilnosti posamezne mezoregije (Gams, 1998a). Izračunal je tudi nekatere podatke

za rabo tal. S prekrivanjem kart je določil osnovne mezoregije, točne meje med njimi pa je določil na podlagi značilnosti vsake meje posebej. Mezoregije je združil v makroregije: Visokogorske Alpe, Predalpsko hribovje, Ljubljanska kotlina, Subpanonska Slovenija, Prehodne regije med Predalpsko in Subpanonsko Slovenijo, Dinarske planote notranje Slovenije, Prehodne regije med subpanonskim in dinarskim svetom, Submediteranska Slovenija, Prehodno ozemlje med dinarskim in submediteranskim svetom. Na podlagi klime sta določeni Subpanonska in Submediteranska Slovenija (vinogradništvo), ostale makroregije pa na podlagi reliefa (Gams, 1986a).

Gams (1998a) je klasifikacijo iz leta 1986 rahlo spremenil in izdelal pokrajinsko ekološko sestavo Slovenije. Za razmejitvev makroregij je kot najpomembnejše izbral relief, litologijo (petrografijo) in podnebje. Uporabil je podatke o litologiji, višinske pasove, reliefno amplitudo, razne klimatske koeficiente, letni odtok, potencialne gozdne združbe, rabo tal in talne tipe. Določil je naslednje makroregije: Submediteranska Slovenija, Dinarske kraške planote celinske Slovenije, Predalpsko hribovje, Ljubljanska kotlina, Visokogorske Alpe, Subpanonska Slovenija. Te se nadalje delijo na regije. Poleg regij je posebej določenih tudi 9 prehodnih regij.

Natek (1994 cv: Kladnik, 1996) je Gamsovo klasifikacijo v okviru Študije ranljivosti okolja izpopolnil. Izbral je naslednje kriterije: relief (višinski sloji), litologija (delež karbonatnih kamnin), podnebje (temperature, padavine). Nadaljnja razdelitev temelji na počasi (relief in litologija) in hitreje spremenljivih pokrajinskih dejavnikih (podnebje, vode, prst, rastje) ter rabi tal. Klasifikacija je tristopenjska (Kladnik, 1996).

Gams, Kladnik in Orožen Adamič (1995) so pripravili klasifikacijo, za katero velja, da je narejena predvsem na podlagi reliefa in podnebja (Kladnik, 1996). Določili so 6 makroregij, 2 submakroregiji, 5 prehodnih regij (Visokogorske Alpe, Predalpsko hribovje, Dno Ljubljanske kotline, Subpanonska slovenija, Dinarski kras celinske Slovenije, Primorje, Prehodni predalpsko-subpanonski svet, Prehodni predalpsko-dinarski svet, Prehodni predalpsko-primorski svet, Prehodni subpanonsko-dinarski svet, Prehodni dinarsko-primorski svet) ter manjše mezoregije, mikroregije in submikroregije (Gams, Kladnik, Orožen Adamič, 1995). Bočko-Maceljsko hribovje se ne drži skupaj z ostalimi enotami iste prehodne regije in je obdan z območjem druge makroregije, kar ni v skladu s pojmom regija, ampak bolj tip. Sodelavci Geografskega inštituta Antona Melika in Inštituta za geografijo (Gabrovec, M., Orožen Adamič, M., Pavšek, M., Perko, D., Topole, M., Kladnik, D.) so leta 1996 izdelali klasifikacijo (**Perko, 1998a**), pri čemer so uporabili tudi GIS-e. Zbrane podatkovne sloje (nadmorska višina, naklon, kamninska podlaga, podnebje, rastje in raba tal) so prekrili in tako določili jedra mezoregij. Meje med njimi so (z nekaterimi dogovori o poteku meje) določili subjektivno. Določenih je bilo 48 mezororegij (dodana je bila tudi mezoregija Tržaški zaliv), ki so jih združili v 9 submakroregij in 4 makroregije. Kriteriji makroregionalne delitve so bili reliefne enote in dve podnebni območji – sredozemsko in celinsko (Kladnik, 1996; Perko, Kladnik, 1998). Uvrstitev posamezne mezoregije v makroregijo so preverili s hierarhičnim združevanjem mezoregij po Wardovi metodi (Perko 1998a). Omeniti velja, da submakroregijam bolj ustreza termin *tip*, saj se ista kategorija pojavlja na več prostorsko oddaljenih mestih. Na podlagi te klasifikacije je **Perko (1998b, 2007b)** hkrati določil tudi pokrajinske tipe Slovenije.

Marušič, Ogrin in Jančič (1998) so na podlagi Ilešičeve (1972) regionalizacije izdelali regionalizacijo na štirih ravneh. Na prvi ravni so upoštevali podnebje ter kamninske razmere, na naslednji ravni pa makrorelief. Na zadnji ravni so se oprli na krajinsko podobo. Na prvi ravni so določili krajine alpske regije, krajine predalpske regije, krajine subpanonske regije, kraške krajine notranje Slovenije in krajine primorske regije. Poleg regionalizacije so pripravili tudi tipološko členitev krajinskih vzorcev, ki na najvišji ravni ustreza regionalizaciji (Marušič, Ogrin, Jančič 1998). Omenjeno klasifikacijo so leta 2007 navedli tudi kot primer

določanja pokrajin (izvirno: krajin) pri predstavitvi trenutnega stanja upoštevanja Evropske konvencije o krajini (Synoptic presentation, 2007), obširneje pa je opisana tudi v zloženki (Bratina Jurkovič, 2008).

Plut (1999a; glej tudi Plut 1999b) je izdelal klasifikacijo na podlagi naravnogeografskih (rečna mreža in razvodnice) ter družbenogeografskih dejavnikov (vplivna območja središčnih naselij), ki bi tudi ustrezali regionalni pripadnosti prebivalcev. Klasifikacijo je zasnoval na upravnih mejah, med katerimi je izbral tiste, ki čim bolj sovpadajo s potekom razvodnic. Vrišerjeva (1990) ekonomsko-funkcijska opredelitev mikroregij je bila uporabljena kot temeljni družbenogeografski kriterij. Kot dodatni kriterij je bilo določeno število prebivalcev, in sicer 25.000. Določenih je bilo 8 makroregij (Pomurje, Podravje, Savinjska Slovenija, Gorenjska, Osrednja Slovenija, Jugovzhodna Slovenija, Severna Primorska in Južna Primorska) ter 25 mezoregij.

Špes in sodelavci (2002) so na temelju Gamsove klasifikacije izdelali pokrajinskoekološko regionalizacijo ter tudi tipizacijo. Kot kriterije so na prvi ravni izbrali relief, litologijo (delež karbonatnih kamnin), temperaturo in padavine, na drugi ravni pa relief (menjavanje dolin in hribov) in litologijo. V ospredju je bila težnja po opredelitvi takih enot, v katerih se pojavljajo značilni mozaiki ekotopov. Klasifikacija je bila narejena v treh stopnjah. Na prvi so določili 5 pokrajinskih sklopov (pokrajinskoekoloških območij oziroma makroenot), na drugi 60 pokrajinskih enot (pokrajinskoekoloških enot oziroma mezoenot), na tretji pa 223 pokrajinskih podenot. Pokrajinskoekološka območja so: Alpska Slovenija, Predalpska Slovenija, Panonska Slovenija, Dinarskokraška Slovenija in Sredozemska Slovenija (Špes s sod. 2002). Omeniti velja, da na primer mikroenota Boč prostorsko ni povezana z ostalo Predalpsko Slovenijo, kar – tako kot pri nekaterih drugih klasifikacijah – daje rahel občutek tipizacije.

Špes in sodelavci (2002) so izdelali tudi **tipizacijo**, in sicer tako, da so z abstrahiranjem pokrajinskih razlik na različnih ravneh klasifikacije prišli do pokrajinskoekoloških tipov. Ti so zelo pomembni predvsem za analizo ranljivosti zaradi bolj ali manj homogenega odzivanja na antropogene vplive. Določili so 14 pokrajinskoekoloških tipov (Špes s sod. 2002):

- visokogorski svet,
- širše rečne doline v visokogorju, hribovju in na krasu,
- visoke kraške planote in hribovja v karbonatnih kamninah,
- hribovja v pretežno nekarbonatnih kamninah,
- medgorske kotline,
- gričevje v notranjem delu Slovenije,
- ravnine in širše doline v gričevju notranjega dela Slovenije,
- kraška polja in podolja,
- nizki kras Notranjske in Dolenjske,
- nizki kras Bele krajine,
- Kras in Podgorski kras,
- gričevje v primorskem delu Slovenije,
- širše doline in obalne ravnice v primorskem delu Slovenije,
- morje v Tržaškem zalivu.

Pri tej klasifikaciji nekatere enote bolj spominjajo na regije, saj se pojavljajo samo enkrat, še posebej zato, ker so nekatere tudi pisane z veliko začetnico (na primer Kras in Podgorski kras). Enkratno pojavljanje tipa je lahko tudi posledica izjemne raznolikosti slovenskega ozemlja, saj ne višjih ravneh ne moremo pričakovati pojavljanja tipov na več območjih.

Žiberna, Natek in Ogrin (2004) so pripravili naravnogeografsko regionalizacijo Slovenije za pouk geografije v osnovnih šolah. Določili so 5 makroregij (Alpske pokrajine, Predalpske pokrajine, Dinarskokraške pokrajine, Obsredozemske pokrajine in Obpanonske pokrajine), ki se delijo na 11 mezoregij, pri katerih pa gre dejansko za naravnogeografske pokrajinske tipe.

Glavna kriterija za klasifikacijo sta bila relief in (za Obsredozemske pokrajine) kamninska sestava. Dodatni kriterij je bilo podnebje. Pri razdelitvi na mezoregije so upoštevali predvsem reliefne tipe (Žiberna, Natek, Ogrin, 2004).

Hladnik (2005) je določil 5 tipov (urbano in intenzivno kmetijstvo, mešana kmetijska raba in pašniki, pogozdena pokrajina (2 tipa), gozdna pokrajina). Kot glavne podatkovne sloje je uporabil katastrske občine, rabo tal (CORINE), današnja gozdna območja ter gozdna območja v preteklosti.

Klasifikacije na podlagi posameznega naravnega dejavnika

Melik (1935) je izdelal geomorfološko karto Slovenije, na kateri je določil naslednje tipe: visoko gorovje, sredogorje z visokogorskimi grebeni, sredogorje, hribovje, nizko hribovje, vzpetine v apniško-skrilavem zemljišču panonsko rodopske cone nad 550 m, vzpetine v apniško-skrilavem zemljišču panonsko rodopske cone pod 550 m, planote v apniškem zemljišču nad 400 m, planote v apniškem zemljišču pod 400 m, hribovje v flišnem zemljišču v Primorju, gričevje v flišnem zemljišču v Primorju, hribovje v starejšem terciarnem zemljišču na panonski strani, hribovje v mlajšem terciarnem zemljišču na panonski strani, gričevje s hribi v kotlinah ter podolja v dinarskem predelu, večje staropleistocenske terase v subpanonskem področju, ravnine, strmi robovi ob planotah.

Natek (1993) je določil tipe površja v Sloveniji. Kot glavne kriterije je uporabil nadmorsko višino (zgornja gozdna meja), reliefno amplitudo, kamninsko podlago, smer slemenitve in razgibanost reliefa. Določil je 8 osnovnih tipov površja: ravnina, gričevje, hribovje, visokogorje, nizki kras, visoki kras, nizki fluviokras ter visoki fluviokras.

Ogrin (1996) je na podlagi Köppenovega podnebne sistema 57 slovenskih meteoroloških postaj razdelil v podnebne razrede, nato pa še natančneje na podlagi povprečne temperature najtoplejšega in najhladnejšega meseca ter primerjave med povprečnimi aprilskimi in oktobrskimi temperaturami. Kot dodatni merili sta bila upoštevana še indeks mediteranskosti padavin in letna količina padavin. Podatki veljajo za obdobje 1961–1990. Na podlagi navedenih meril je Slovenijo razdelil na tri glavne podnebne tipe (submediteransko podnebje, zmernocelinsko podnebje in gorsko podnebje) z devetimi podtipi.

Gabrovec in Hrvatini (1998) sta glede na genezo razdelila območje Slovenije na destrukijsko rečno-denudacijski, akumulacijski rečno-denudacijski, ledeniški, apneniški kraški, dolomitni kraški ter abrazijski relief; pri tem sta opozorila tudi na prepletanje omenjenih tipov. Glede na razčlenjenost površja sta določila šest tipov reliefa: ravnine, gričevja, hribovja, gorovja ter nizke in visoke planote.

Perko (2001) je s pomočjo GIS-ov določil enote razgibanosti površja Slovenije. Najprej je za območje Slovenije z natančnostjo 100 m izračunal umerjeni reliefni koeficient, ki je izračunan iz geometrične sredine umerjenega višinskega koeficienta in umerjenega naklonskega koeficienta. Vrednosti umerjenega reliefnega koeficienta je z uporabo filtra povprečil in dobil razmeroma homogena območja enakih razredov umerjenega reliefnega koeficienta. Na podlagi tega je določil osem razredov: nerazgibana ravnina, razgibana ravnina, nerazgibano gričevje, razgibano gričevje, nerazgibano hribovje, razgibano hribovje, gorovje, velika dolina. Perko (2007a) je kasneje svojo razdelitev utemeljil tudi z izračunom regionalnega koeficienta skupne razgibanosti površja, kjer je hkrati zaobjel prostorsko spremenljivost naklonov in ekspozicij površja.

Gams (2003) je določil tipe krasa v Sloveniji. Določil je alpski kras, predalpski kras, osamljeni kras, visoki dinarski kras (predvsem visoke kraške planote) in nizki dinarski kras (predvsem nizke kraške planote in ravniki).

Zaradi tesne navezanosti raznih biogeografskih klasifikacij na pokrajinskoekološke klasifikacije, pri katerih se mora po nekaterih mnenjih upoštevati predvsem vegetacija, na tem mestu na kratko povzemamo lastnosti nekaterih fitogeografskih razdelitev Slovenije.

Prvo fitogeografsko klasifikacijo Slovenije je opravil **Wraber leta 1969** (cv: Zupančič, 1989). Slovenijo je razdelil na 6 fitogeografskih območij: dinarsko, preddinarsko, alpsko, predalpsko, submediteransko in subpanonsko območje. Razdeljeno je bilo bolj na geografski osnovi in glede na takrat znane rastlinske združbe, predvsem gozdne združbe in njihovo ekologijo. **Košir (1975)** (cv: Zupančič, 1989) je izdelal fitogeografsko razdelitev Slovenije, ki je bila izdelana na osnovi podnebnih dejavnikov in glede na gozdne združbe. **Zupančič, Marinček, Seliškar in Puncer** so leta **1986** (cv: Zupančič, 1989) izdelali nov predlog fitogeografske klasifikacije Slovenije, ki je bil leta 1989 po priredbi Zupančiča in Puncerja prirejen in objavljen tudi v Enciklopediji Slovenije (**Zupančič, 1989**, 120). Ta je vključena v fitogeografske enote na evropski ravni. Klasifikacija je izdelana z upoštevanjem rastja, predvsem glede na potencialno, oziroma glede na oroklimatogene fitocenoze, njihove ekološke razmere, posebnosti flore, predvsem endemitov. Ta fitogeografska klasifikacija ima tri regije, na nižjih ravneh pa province in sektorje. Alpsko-visokonordijska regija ima le alpsko provinco, evrosibirsko-severnoameriška regija se deli na srednjeevropsko provinco in ilirsko provinco, mediteranska regija pa ima le eno provinco – jadransko (Zupančič, 1989, 120 in 121).

Matvejev (1991) je določil sedem biomov. To so ekosistemi, ki so si podobni po pretoku energije in zakonitostih kroženja snovi. Določil je naslednje biome: mediteranski zimzeleni gozdovi in makija, submediteranski gozdovi, listnati gozdovi, iglasti gozdovi borealnega tipa, visokogorska melišča, pašniki in ledeniki, elementi gozdnih step in oromediteranski elementi. Biome je določil s pomočjo sestave in videza rastja ter preučevanja habitatov za živalstvo po ekološki podobnosti. Opozoril je, da zarisane meje v naravi dejansko ne obstajajo, saj je med biomi veliko prehodnih območij.

Sket (2003) je biogeografsko delitev zasnoval na več načinov. Slovenijo je razdelil na podlagi razširjenosti ozemeljsko vezanih živali, torej tistih, ki so na določenem območju nastale in se tam prilagajale spremembam v okolju, na podlagi razširjenosti ozemeljsko nevezanih živalih, torej tistih, ki so se ob ekoloških spremembah lahko preselile drugam, ter na podlagi rečnega živalstva, ki je pretežno hidrografsko pogojeno. Biogeografska členitev Slovenije po ozemeljsko vezanih vrstah ima tri območja: južnoalpsko območje, dinarsko območje ter predalpsko-subpanonsko območje. Biogeografska členitev Slovenije po ozemeljskih nevezanih vrstah ima pet območij: visokoalpsko območje, alpsko-dinarsko območje, predalpsko-preddinarsko območje, subpanonsko območje in submediteransko območje. Glede na biogeografski vzorec rečnega živalstva je Slovenija razdeljena na podonavsko območje (povodje), jadransko območje (povodje) in pa zaprto kraško vodovje.

Ogrin (2009) je na podlagi biomske, fitogeografskih in zoogeografskih klasifikacij določil štiri enote, katerih glavni namen je prikaz osnovnih prostorskih značilnosti živega sveta v Sloveniji. Avtor opozarja na izrazito prehodnost enot. Slovenijo je razdelil na naslednja življenjska okolja: obsredozemsko življenjsko okolje, življenjsko okolje alpsko-dinarske pregrade, predalpsko-preddinarsko življenjsko okolje in obpanonsko življenjsko okolje.

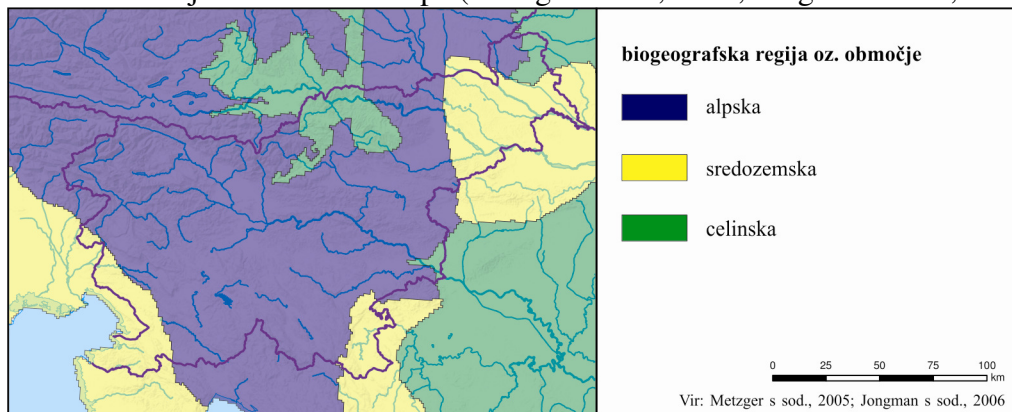
Priloga 2: Slovenija v posameznih naravnogeografskih klasifikacijah Evrope

Okoljska členitev Evrope (*Environmental stratification of Europe*)

Skupina znanstvenikov je izdelala klasifikacijo Evrope za določitev vzorčnih območij v Evropi in za določitev enot, uporabnih za razne modele in poročila o okolju (Metzger s sod., 2005; Múcher s sod., 2003). Uporabili so metodo glavnih komponent, pri kateri so več podatkovnih slojev (višina, naklon, oddaljenost oceana, geografska širina in več podnebnih spremenljivk za mesece januar, april, julij in oktober) nadomestili le s tremi glavnimi komponentami in z njimi celice klasificirali v skupine. Določili so 84 okoljskih razredov (*environmental class*), jih združili v 13 okoljskih con (*environmental zone*) in te v 6 biogeografskih regij oziroma območij (*biogeographic region*). Če upoštevamo še otočja v Atlantskem oceanu, je con 14 in regij oziroma območij 7. Celotna členitev ima prostorsko ločljivost 1 km² (Metzger s sod., 2005; Jongman s sod., 2006; Múcher s sod., 2003). Klasifikacija pokriva ozemlje med 11° zahodne zemljepisne dolžine in 32° vzhodne zemljepisne dolžine ter med 34° in 72° severne zemljepisne širine (Metzger s sod., 2005, 558). Celotno območje je bilo zaradi velikih razlik obdelano v dveh delih (*division*): severnem in južnem (Metzger s sod., 2005, 554 in 558). Čeprav se enote na najvišji ravni imenujejo regije oziroma območja, gre bolj za tipizacijo kot regionalizacijo, zato so njihova imena zapisana z malo začetnico.

Ozemlje Slovenije leži v 3 od 6 biogeografskih regij oziroma območij (slika 94) ter 5 od 13 okoljskih con. Na ozemlju Slovenije so naslednje okoljske cone: južnoalpska cona, cona sredozemskih gorovij, severnosredozemska cona, panonska cona in celinska cona. Na najnižji ravni je v Sloveniji 12 od 84 razredov (Metzger s sod., 2005, 558). Čez ozemlje Slovenije poteka tudi meja med obema glavnima deloma, saj se cona sredozemskih gorovij in severnosredozemska cona uvrščata v južni del, preostale cone pa v severni del.

Slika 94: Okoljska členitev Evrope (Metzger s sod., 2005, Jongman s sod., 2006).



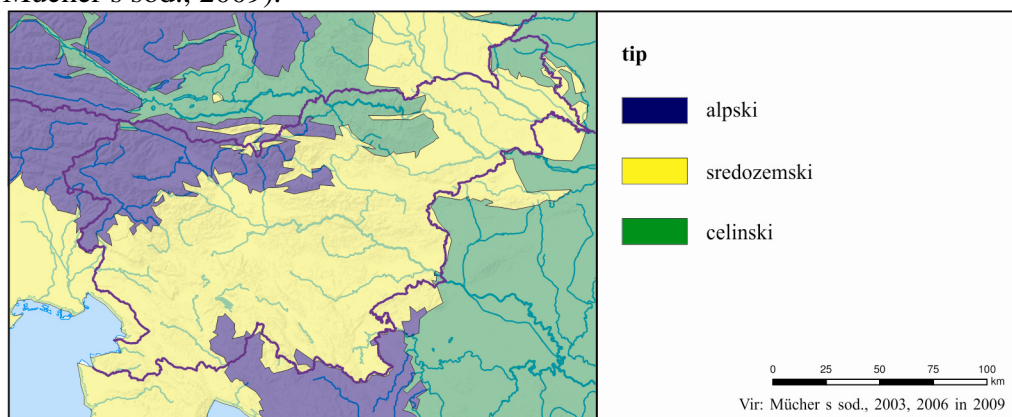
Evropska pokrajinska klasifikacija (*European landscape classification*)

Sodelavci inštituta Alterra so pripravili pokrajinsko klasifikacijo, ki poleg naravnogeografskih vključuje tudi družbenogeografske dejavnike ter uporablja metodo segmentacije in klasifikacijo dobljenih segmentov v skupine. Namen klasifikacije je bil izdelati tipizacijo pokrajin za območje cele Evrope, ki bi jo bilo mogoče povezati tudi s klasifikacijami na ravni posameznih držav ter uporabiti v raznih projektih (Múcher s sod., 2003, 53). Uporabili so podatke o podnebnju, nadmorski višini, prsteh in rabi tal (Múcher s sod., 2006, 5). Posebej so določili tudi večja urbana območja, vodne površine in območja plimovanja (Múcher s sod., 2006). Najprej so Evropo razdelili na manjše homogene enote (segmente) na podlagi podatkov za nadmorsko višino, prst in rabo tal, nato pa so za klasifikacijo teh enot v posamezne tipe poleg teh treh podatkov upoštevali še podnebne podatke (Múcher s sod.,

2009, 4). Pri razvrstitvi homogenih enot na prvi ravni, ki ima 8 tipov (*type*, arktični, borealni, atlantski, alpski, sredozemski, celinski, anatolski in stepski tip), so upoštevali podnebje, pri razvrstitvi na drugi ravni, ki ima 31 tipov (*type*), so upoštevali še nadmorsko višino, pri tretji ravni so dodali še prst, zato ima 76 tipov (*type*), pri najnižji, četrti ravni, pa so upoštevali še posebna območja rabe tal, zato ima 350 pokrajinskih tipov (*landscape type*) in več kot 14.000 poligonov (Mücher s sod., 2006, 9). Razen alpskega tipa se na najvišji ravni le redki tipi pojavljajo na različnih, prostorsko ločenih območjih.

Rastrska obdelava je sprva potekala s celicami velikosti 1 km², dobljene poligone oziroma enote, manjše od 11 km², pa so nato združili s sosednjimi. Končni zemljevid je narejen v merilu 1 : 2.000.000 in pokriva celotno Evropo do Urala na vzhodu ter Azerbajdžana na jugovzhodu in Nove dežele na severovzhodu; Ciper ni vključen (Mücher s sod., 2006). Prva različica zemljevida (Mücher s sod., 2003) je pokrivala le del območja Evropske unije. Na ozemlju Slovenije so na prvi ravni trije tipi: sredozemski, celinski in alpski tip (slika 95). Skoraj vsa Slovenija leži v sredozemskem tipu, Goriška brda pa so del alpskega tipa. Na drugi ravni je v Sloveniji 8 tipov, dodatno sta posebej določeni tudi urbani območji Ljubljane in Maribora. Na tretji ravni je na ozemlju Slovenije 12 od 76 tipov; na zadnji, četrti, ravni pa je v Sloveniji prisotnih 19 od 350 tipov.

Slika 95: Evropska pokrajinska klasifikacija (Mücher s sod., 2003, Mücher s sod., 2006, Mücher s sod., 2009).



Digitalni zemljevid evropskih ekoloških regij oziroma območij – DMEER (*Digital map of European ecological regions – DMEER*) in Kopenske ekološke regije oziroma območja sveta (*Terrestrial ecoregions of the world*)

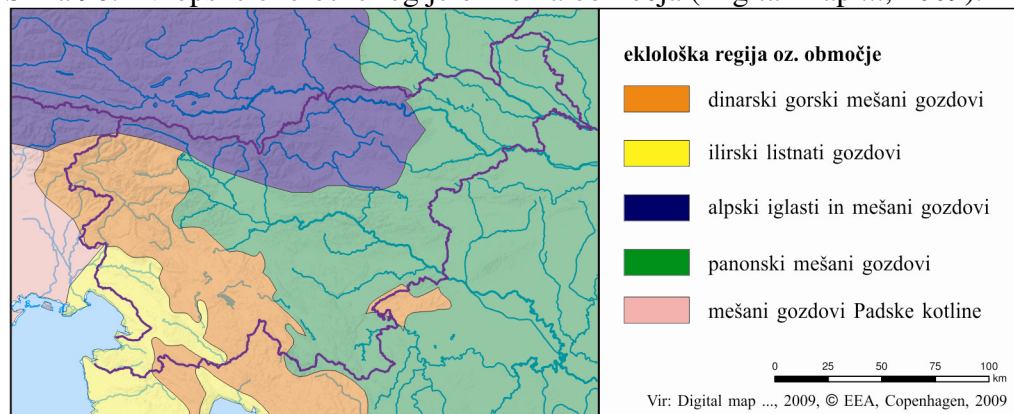
DMEER je biogeografski zemljevid, ki prikazuje porazdelitev evropskih ekoloških regij (*European ecological regions*) oziroma območij na podlagi podnebnih, topografskih in geobotaničnih podatkov. Izdelali so jo znanstveniki z več evropskih inštitutov ter Svetovnega fonda divje narave (*World wildlife fund – WWF*) s hierarhičnim razvrščanjem podatkov, pridobljenih z zemljevida naravnega rastijskega Urada za varstvo narave (*Bundesamt für Naturschutz*) in zemljevida Evropske pokrajinske klasifikacije britanskega Inštituta za zemeljsko ekologijo (*Institute of terrestrial ecology*) v ločljivosti 0,5° krat 0,5°. Poligone, ki so jih določili na podlagi obeh podatkovnih slojev, so s poskušanjem večkrat razvrstili v skupine, nato pa za posamezne dele Evrope določili, katera razvrstitev je najbolj primerna. Izločili so vse poligone, manjše od 2000 km². Končni zemljevid v merilu 1 : 2.500.000 so uskladili z zemljevidom ekoloških regij oziroma območij WWF (*WWF ecoregions*). S klasifikacijo so želeli spodbuditi bolj učinkovito ravnanje v pokrajinah ter prikazati območja s homogenimi ekološkimi razmerami. Pokriva območje celotne Evrope v velikosti 10,5 milijona km² prek Turčije vse do obal Bližnjega vzhoda in Sinaja (Mücher s sod., 2003, 114 in 116; Digital map ..., 2009). Končna klasifikacija temelji na rastju in ima lastnosti tipizacije,

saj so enote enake kategorije prostorsko ločene. Ekološke regije oziroma območja so poimenovani večinoma po tipu rastja, zato so v legendi zemljevida njihova imena zapisana z malo začetnico. Klasifikacija ima 68 evropskih ekoloških regij oziroma območij (*ecological region*) (Digital map ..., 2009).

Ozemlje Slovenije se na zemljevidu uvršča med štiri različne enote in meji na eno (slika 96):

- dinarski gorski mešani gozdovi,
- ilirski listnati gozdovi,
- alpski iglasti in mešani gozdovi,
- panonski mešani gozdovi,
- mešani gozdovi Padske kotline.

Slika 96: Evropske ekološke regije oziroma območja (Digital map ..., 2009).



Zemljevid kopenskih ekoloških regij oziroma območij (*terrestrial ecoregions*) je namenjen izboljššanju okoljevarstvenega načrtovanja. Pri izdelavi so se oprli na biogeografsko znanje. Zemljevid pokriva celoten svet in ima relativno visoko natančnost, saj prikazuje širok razpon različne favne in flore (Olson s sod., 2001, 933).

Ekološke regije oziroma območja (*ecoregions*) avtorji označujejo kot relativno obsežne enote, ki imajo posebno kombinacijo naravnih združb in vrst. Meje teh enot ustrezajo naravnemu stanju pred večjimi spremembami rabe tal (Olson s sod., 2001, 933).

Kopni del sveta je po tej členitvi razdeljen na 8 geografskih domen⁴⁷ (*geographic realms*) in 14 biomov⁴⁸ (*biomes*). Znotraj teh je določenih 867 ekoloških regij oziroma območij (*ecoregions*). Posamezne enote so določili na podlagi različnih virov (glej Olson s sod., 2001, 934), za zahodno *Palearktično območje*, v katero spada tudi Evropa, so uporabili zemljevid DMEER. Posamezna območja so uskladili (približno enako merilo, usklajena sosednja območja) in jih ponekod popravili. Na območjih, za katera niso našli biogeografskih delitev, so se oprli na reliefne oblike in nato na vegetacijo. Povprečna velikost ekoloških območij je približno 150.000 km², mediana pa 56.300 km² (Olson s sod., 2001, 934).

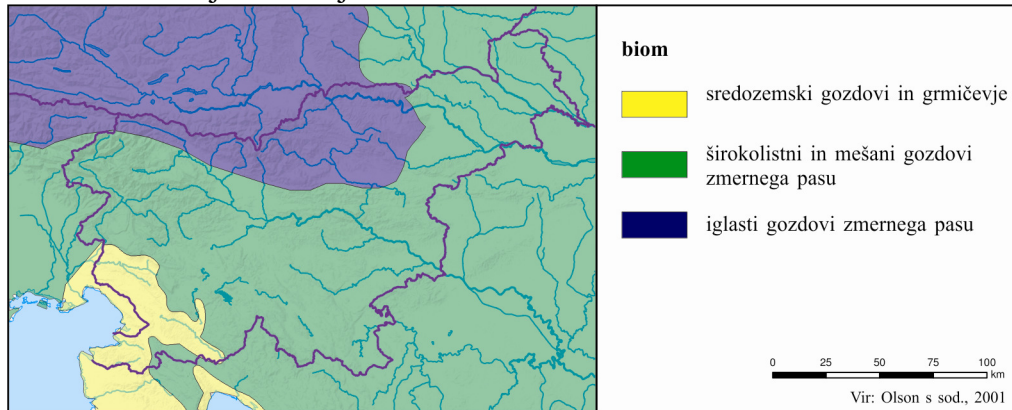
Izmed 14 biomov (*biomes*) so v Sloveniji prisotni kar trije: sredozemski gozdovi, dobrave in grmovja; širokolistni in mešani gozdovi zmernih geografskih širin; iglasti gozdovi zmernih

⁴⁷ Geografske domene so: *Oceania* (obsega Tihi ocean), *Nearctic* (obsega Severno Ameriko), *Neotropic* (obsega Srednjo in Južno Ameriko), *Afrotropic* (obsega Podсахarsko Afriko), *Paleartic* (obsega Evropo in večji del Azije), *Indo-Malay* (obsega Južno ter Jugovzhodno Azijo), *Australasia* (obsega Avstralijo in del otočja med Azijo in Avstralijo) (Olson s sod., 2001).

⁴⁸ Biomi so: tropski in subtropski vlažni širokolistnati gozdovi; tropski in subtropski sušni širokolistnati gozdovi; tropski in subtropski iglasti gozdovi; širokolistni in mešani gozdovi zmernih geografskih širin; iglasti gozdovi zmernih geografskih širin; borealni gozdovi/tajga; tropski in subtropski travniki, savana in grmičevja; travniki, savana in grmičevja zmernih geografskih širin; poplavni travniki in savane; gorski travniki in grmičevja; tundra; sredozemski gozdovi, dobrave in grmovja; puščave in suho grmičevje; mangrove. Jezera oziroma večje vodne površine, skalovja in ledeniki so izločeni posebej (Olson s sod., 2001).

geografskih širin. Ekološke regije oziroma območja (*ecoregions*), ki so na ozemlju Slovenije, so identični tistim pri klasifikaciji DMEER. To je zanimivo, saj so tako začrtane meje in kategorije, ki so bile določene za DMEER, ostale pomembne tudi na svetovni ravni, ne samo na evropski (slika 97).

Slika 97: Ozemlje Slovenije se uvršča v tri od 14 biomov sveta.



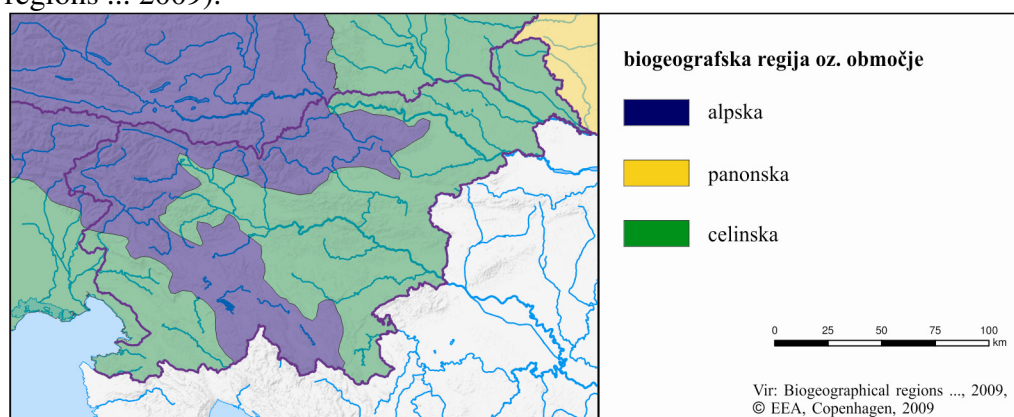
Biogeografske regije oziroma območja (*Biogeographical regions*)

Zemljevid biogeografskih regij (*Biogeographical regions*) oziroma območij so izdelali za omrežje NATURA2000. To je bilo prvič, da so v uradnem dokumentu Evropske unije sprejeli meje, ki niso administrativne (Mücher s sod., 2003, 113). V zadnjo različico iz leta 2008 so vključili države znotraj Evropske unije, vključno s Kanarskimi otoki in Azori (*Biogeographical regions ...*, 2009). Prve različice so slonele na združevanju naravnega rastja članic Evropske skupnosti in Sveta Evrope (Noirfalies, 1987), gozdne združbe so združevali v biogeografske regije oziroma območja (mednje so vključili tudi aconalne enote) ter zemljevid posplošili; pri kasnejših različicah pa so uporabili tudi Zemljevid potencialne vegetacije, ki ga je pripravil nemški Zvezni urad za varstvo okolja (*The indicative map ...*, 2006). Klasifikacija iz leta 2008, ki zajema območje znotraj Evropske unije, ima 9 biogeografskih regij (*biogeographical regions*) oziroma območij: alpsko, atlantsko, črnomoško, borealno, celinsko, makaronezijsko, sredozemsko, panonsko in stepsko. Klasifikacija iz leta 2005 na zemljevidu Evrope prikazuje vse evropske države do Urala in Kavkaza ter Turčijo. Ima enajst kategorij – ob prej omenjenih še arktično in anatolsko regijo oziroma območje.

Klasifikacija se sicer opira na naravno rastje, vendar nekatere meje potekajo po administrativnih državnih mejah, kar jo odmika od povsem naravne delitve. Nekatere biogeografske regije oziroma območja se pojavljajo na več prostorsko ločenih krajih (alpska regija oziroma območje v Skandinaviji). Ker gre spet bolj za tipizacijo kot regionalizacijo, smo enote poimenovali z malimi začetnicami.

Ozemlje Slovenije se glede na klasifikaciji iz leta 2005 in 2008 (slika 98) uvršča med celinsko in alpsko regijo oziroma območje, na severovzhodu pa se dotika panonske regije oziroma območja (meja poteka po državni meji). Presenetljiva je uvrstitev jugozahodnega dela Slovenije k celinski regiji oziroma območju. Na zemljevidu iz leta 2005, na katerem so prikazane vse države, se Slovenija na jugozahodu dotika tudi sredozemske regije oziroma območja.

Slika 98: Biogeografske regije oziroma območja, različica iz leta 2008 (Biogeographical regions ... 2009).



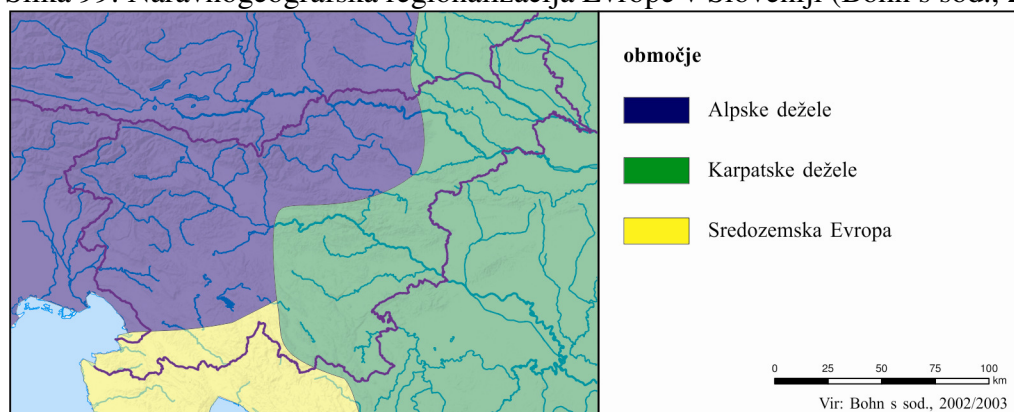
Naravnogeografska razdelitev Evrope (*Physisch-geographische Gliederung Europas*)

Nemški Zvezni urad za varstvo narave je izdelal zemljevid naravnega rastja Evrope v merilu 1 : 2.500.000. Glavni namen je bila izdelava zemljevida naravnega rastja po enotni metodi za celotno Evropo. Kot podlaga tej razdelitvi je bila pripravljena naravnogeografska klasifikacija Evrope (nem. *Physisch-geographische Gliederung Europas*), pri kateri so upoštevali značilnosti podnebja, kamnin in prsti. Evropo so razdelili na 4 podceline (*Subkontinent*; Severna Evropa, Zahodna in Srednja Evropa, Južna Evropa, Vzhodna Evropa), 9 območij (*Großraum*) ter 47 fizičnogeografskih regij (*physisch-geographische Region*), ki se delijo še naprej na podenote oziroma podregije (Bohn s sod., 2002/2003, 68 in 69). Naravnogeografska klasifikacija je na vseh ravneh bolj regionalizacija kot tipizacija, zato smo enote tudi pri spornih imenih zapisali z veliko začetnico. Enote zajemajo v celoti le eno sklenjeno območje. Ozemlje Slovenije se uvršča v 2 podcelini, 3 območja in 4 regije (slika 99, preglednica 123).

Preglednica 123: Uvrstitev ozemlja Slovenije po Naravnogeografski regionalizaciji (Bohn s sod., 2002/2003).

podcelina	območje	fizičnogeografske regije
Zahodna in Srednja Evropa	Alpske dežele	Alpe, Severnoitalijansko nižavje
	Karpatske dežele	Panonska kotlina
Južna Evropa	Sredozemska Evropa	Balkanski polotok

Slika 99: Naravnogeografska regionalizacija Evrope v Sloveniji (Bohn s sod., 2002/2003).



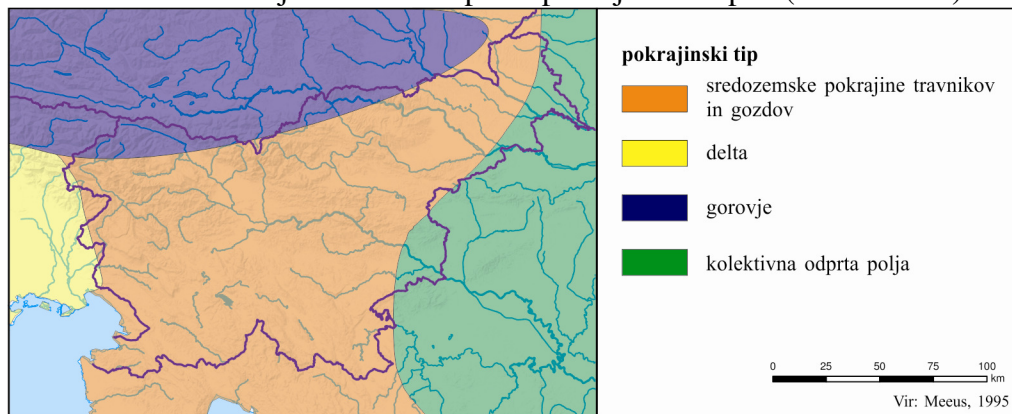
Vseevropski pokrajinski tipi (*Pan-European landscape types*)

Zemljevid vseevropskih pokrajinskih tipov v merilu 1 : 25.000.000, ki ga je izdelal Meeus (1995), je zaobjel območje Evrope do Urala in Kavkaza. Na severu je vključena tudi Nova

dežela (Meeus, 1995, 57). Kriteriji so bili: reliefne oblike (kot posledica kamninske podlage in podnebja), ekonomski potencial rabe tal, sonaravnost človekovega delovanja, ohranjenost narave, poselitveni vzorec, poljska razdelitev, vizualni vtis in kakovost razgleda (Meeus, 1995, 61 in 62). Namen tipizacije je bil ustvariti temelje za sonaravni razvoj Evrope (Meeus, 1995, 57 in 58). Meeus (1995) je določil 30 pokrajinskih tipov (*landscape types*). Te je združil v 9 skupin: tundre, tajge, višavja in visokogorja, pokrajina travnikov in gozdov, odprta polja, regionalne pokrajine (*regional landscapes*), stepe, sušne pokrajine, terasirane pokrajine. Regionalne pokrajine so tisti tipi, ki se zaradi svojih izjemnih naravnih ali kulturnih značilnosti pojavljajo le na enem mestu ali na nekaj mestih (Meeus, 1995, 65).

Ozemlje Slovenije (slika 100) se skoraj v celoti uvršča le v en pokrajinski tip, in sicer med sredozemske pokrajine travnikov in gozdov (*mediterranean semi bocage*⁴⁹), ki spada v skupino pokrajin travnikov in gozdov. Gre za območje v padavinski senci gora, ki so kljub sušnemu podnebju obdelana. Podnebje je sredozemsko, raba tal raznolika, prevladujejo podeželska naselja (Meeus, 1995, 69). V neposredni bližini Slovenije (zaradi slabe resolucije je natančna interpretacija otežena) so še nekateri tipi: na vzhodu tip kolektivna odprta polja, na zahodu tip delta, na severu pa tip gorovje (Meeus, 1995, 63).

Slika 100: Izsek zemljevida vseevropskih pokrajinskih tipov (Meeus 1995).



Ekološke regije oziroma območja kontinentov (*Ecoregions of the Continents*)

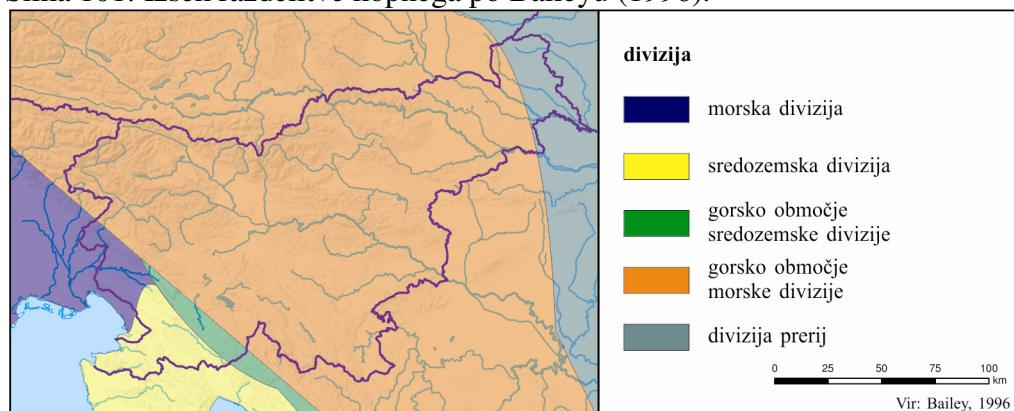
Na podlagi klimatske klasifikacije po Köppnu, klasifikacije prsti (FAO/UNESCO World soil map) in rastja je Bailey (1996) določil klasifikacijo ekoloških regij oziroma območij na kopnem. Bailey (1996) je kopno razdelil na štiri domene (*domain*): polarna (*polar domain*), vlažna domena zmernih geografskih širin (*humid temperate domain*), sušna domena (*dry domain*) in vlažna tropska domena (*humid tropical domain*). Domene je razdelil na 15 divizij (*division*), za vsako od teh pa je posebej izločil gorsko območje. Avtor je določil tudi province (*province*), a jih kartografsko ni prikazal. Posamezne kategorije se pojavljajo na več prostorsko ločenih območjih, poimenovana pa so izrazito po podnebnih značilnostih, zato gre pri tej razdelitvi površja vsekakor za tipizacijo. Za izris zemljevida ekoloških regij oziroma območij (*ecoregion*) na kopnem si je pomagal tudi s knjigo *Fiziko-geograficheskii atlas mira* (Gerasimov, 1964 cv: Baliey, 1996, 81).

Območje Slovenije je v celoti uvrščeno v vlažno domeno zmernih geografskih širin. Na območju Slovenije oziroma v njeni bližini so naslednje divizije: morska divizija (*Marine division*), gorsko območje morske divizije (*Marine regime mountains*), sredozemska divizija (*Mediterranean division*), gorsko območje sredozemske divizije (*Mediterranean regime mountains*), divizija prerij (*Prairie division*). To pomeni, da ima Slovenija 5 izmed vseh 30

⁴⁹ Angleška beseda *bocage* označuje pokrajino s prepletanjem travnikov in gozdov (Bocage, 2009).

tipov (slika 101). Če ne bi izločili gorskih območij kot posebnih tipov, pa lahko zaključimo, da so v Sloveniji 3 izmed 15 tipov.

Slika 101: Izsek razdelitve kopnega po Baileyu (1996).

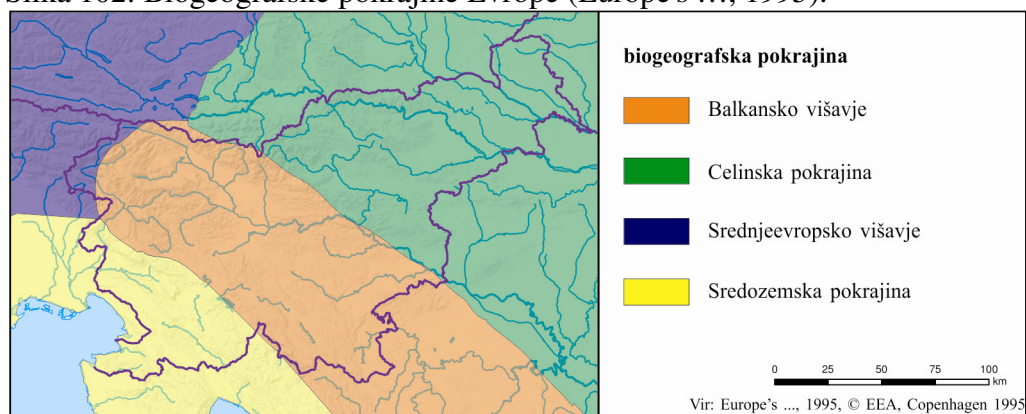


Biogeografske pokrajine Evrope (*Biogeographical provinces of Europe*) in biogeografske pokrajine sveta (*Biogeographical provinces of the World*)

Biogeografske pokrajine Evrope, uporabljene v Poročilu o stanju okolja v Evropi (*Europe's Environment*) leta 1995, so povzete po določenih biogeografskih pokrajinah sveta, ki jih je pripravil Udvardy (1975), zato jih predstavljamo skupaj. Zanje nismo našli bolj podrobnega metodološkega opisa.

Skoraj vse enote so poimenovane po zemljepisnih imenih in se pojavljajo le enkrat, zato bi klasifikacijo lahko uvrstili med regionalizacije, vendar zaradi nedoslednosti pri poimenovanju enot in ker se klasifikacija ne nadaljuje na manjše enote tega ne moremo zagotovo trditi. Ozemlje Slovenije se uvršča v 4 od 19 pokrajin (*province*): Balkansko višavje, Celinska pokrajina, Sredozemska pokrajina in Srednjeevropsko višavje (slika 102). Ob biogeografskih pokrajinah Evrope so za območje tedanje Evropske unije v poročilu prikazali tudi 4 biogeografske cone Evropske unije. Razlog za manjše število in delež kategorij na ozemlju Slovenije je tudi dejstvo, da so v klasifikacijo zajeti še severna Afrika, Turčija, vzhodno Sredozemlje ter območje vzhodno od Kaspijskega morja.

Slika 102: Biogeografske pokrajine Evrope (Europe's ..., 1995).



Biogeografski zemljevid Evrope (*Biogeographic map of Europe*) z bioklimatskim zemljevidom Evrope (*Bioclimatic map of Europe*)

Znanstveniki Univerze v Leonu so pripravili biogeografski zemljevid Evrope, ki prikazuje ozemlje do severnega Arabskega polotoka in Kaspijskega morja, vključuje pa tudi Kanarske otoke, Spitsberge, Novo deželo in Deželo Franca Jožefa. Zemljevid v merilu 1 : 16.000.000

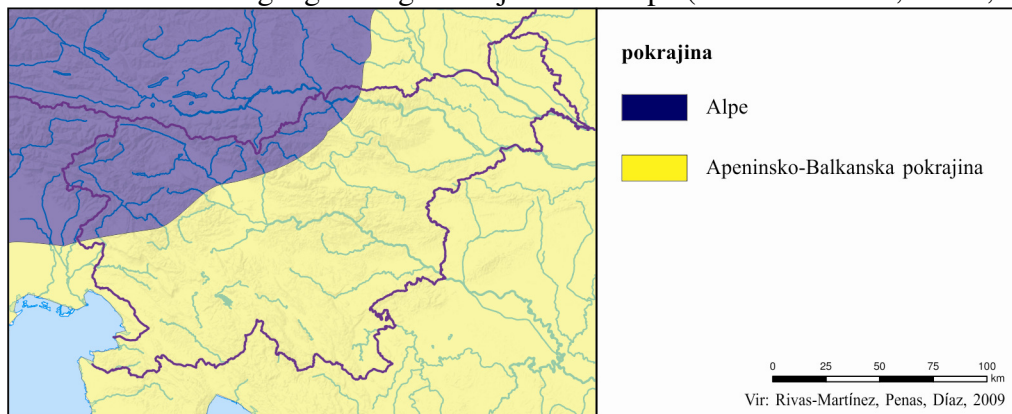
ima 5 enot (*region*): obarktično, evrosibirsko, sredozemsko, iransko-turansko in saharsko-arabsko. Prvi dve enoti imata še po 3 podenote (*subregion*). Tretjo raven predstavlja 30 pokrajin (*province*), zadnjo pa območja (*sector*), ki jih je skupaj 71 (Rivas-Martínez, Penas, Díaz, 2009). Na višjih ravneh gre bolj za tipizacijo, zato so imena enot zapisana z malo začetnico, na nižjih ravneh pa bolj za regionalizacijo, zato so imena enot zapisana z veliko začetnico. Bolj podrobnega metodološkega opisa nismo našli.

Ozemlje Slovenije se v celoti uvršča v evrosibirsko enoto in alpsko-kavkaško podenoto, naprej pa deli na Alpe in Apeninsko-Balkansko pokrajino. Na najnižji ravni se uvršča v območje Vzhodnih Alp, Ilirsko območje in Padsko območje (slika 103).

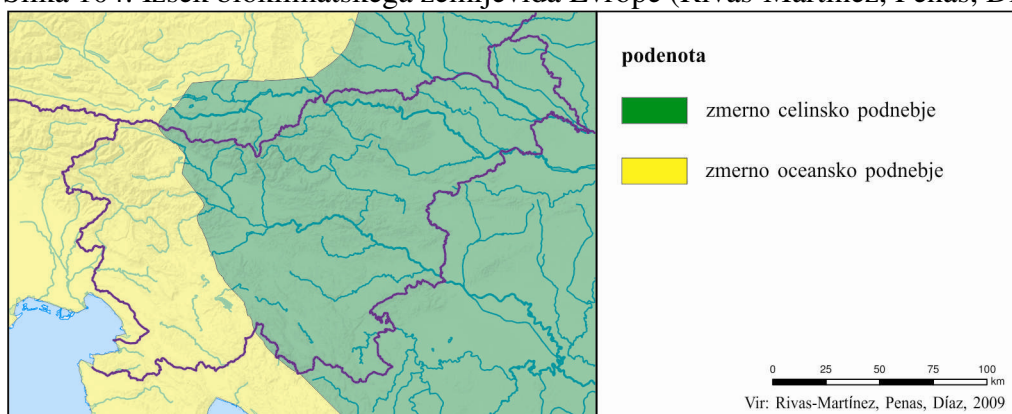
Poleg biogeografskega zemljevida Evrope so pripravili tudi bioklimatsko delitev Evrope v merilu 1 : 16.000.000, in sicer na treh ravneh. Gre za prikaz podnebnih območij oziroma tipov. Ozemlje Evrope so razdelili na 4 makrobioklimatske enote (*macrobioclimate*): polarno, borealno, zmerno in sredozemsko enoto, te pa na 16 podenot (*bioclimate*) z nekaj različicami (*variants*), a le pri nekaterih (Rivas-Martínez, Penas, Díaz, 2009).

Zahodni del Slovenije se uvršča v podenoto zmernega oceanskega podnebja, vzhodni del pa v podenoto zmernega celinskega podnebja. Meja med obema poteka po dolini Save, zahodno od Ljubljane in nato v dinarski smeri proti jugovzhodu (slika 104). S primerjavo obeh zemljevidov dobimo boljšo predstavo o naravnih razmerah v Sloveniji.

Slika 103: Izsek biogeografskega zemljevida Evrope (Rivas-Martínez, Penas, Díaz 2009).



Slika 104: Izsek bioklimatskega zemljevida Evrope (Rivas-Martínez, Penas, Díaz 2009).



Priloga 3: Primeri klasifikacij z geografskimi informacijskimi sistemi

Preglednica 124: Primeri uporabe geografskih informacijskih sistemov za namen klasifikacije.

klasifikacija in vir	uporabljene metode	uporabljeni podatkovni sloji
pokrajinska klasifikacija Belgije (Van Eetvelde, Antrio, 2009)	metoda glavnih komponent, metoda voditeljev (k-means), hierarhično razvrščanje	nadmorska višina, pokrovnost tal, pedološka karta, satelitski posnetki Landsat
pokrajinska tipizacija Češke (Romportl, 2009)	metoda glavnih komponent, segmentacija, metoda najbližjih sosedov, nadzorovana klasifikacija z algoritmi Leica image analyst in ISODATA	povprečna letna temperatura, nadmorska višina, naklon, kamnine, pokrovnost tal, dodatno še karta prsti, potencialne vegetacije in pokrajinske strukture
okoljska členitev Evrope (Metzger s sod., 2005)	metoda glavnih komponent, klasifikacija z algoritmom ISODATA, računanje stopnje povezanosti	nadmorska višina, naklon, »oceanskost«, geografska širina, mesečni podatki za minimalno in maksimalno temperaturo, količino padavin in delež sončnega vremena
klasifikacija urbanih površin West Midlanda (Owen s sod., 2006)	metoda glavnih komponent, hierarhično razvrščanje z Wardovo metodo, računanje oddaljenosti vrednosti celice od povprečja kategorije, različni izračuni negotovosti	delež posameznih kategorij rabe tal, naklon
testne klasifikacije (Belbin, McDonald, 1993)	klasifikacija po metodi ALOC, klasifikacija z algoritmom Flexible-UPGMA, delitev enot po algoritmu TWINSpan	simulirani podatkovni sloji
ekološka pokrajinska členitev dela Avstralije (Bryan, 2000)	metoda glavnih komponent, klasifikacija z Bayesovim klasifikatorjem (<i>AutoClass-C</i>), nevronska omrežje (algoritem <i>Kohonen SOM</i>), metoda voditeljev	povprečna letna temperatura, maksimalna temperatura najtoplejšega obdobja, minimalna temperatura najhladnejšega obdobja, povprečna temperatura sušne dobe, povprečna temperatura vlažne dobe, dnevni temperaturni razpon, letni temperaturni razpon, minimalna topografska temperatura, maksimalna topografska temperatura, povprečne letne padavine, padavine v suhi dobi, padavine v vlažni dobi, sezonskost padavin, letni vlažnostni indeks, vlažnostni indeks prsti, relativna intenziteta kratkovalovnega valovanja, rodovitnost prsti, pH prsti, vsebnost soli v prsti, kamnitost prsti, prepustnost prsti
določanje topoklimatskih kategorij v parku Yellowstone, ZDA (Burrough s sod., 2001)	mehka (<i>fuzzy</i>) metoda voditeljev, izračun χ^2 za primerjavo rezultatov, entropija klasifikacije, koeficient delitve F	nadmorska višina, naklon, vodoravna in navpična ukrivljenost, oddaljenost od grebenov, letna količina sončnega sevanja, topografski indeks vlažnosti
evropska pokrajinska klasifikacija (Mücher s sod., 2003; 2006; 2009)	segmentacija, ugotavljanje kombinacij s prekrivanjem slojev, posploševanje rezultatov	klimatski tipi, nadmorska višina, tip prsti, raba tal
klasifikacija Portorika (Soto, Pintó, 2010)	nelinearna metoda glavnih komponent, metoda voditeljev, diskriminančna analiza	nadmorska višina, naklon, življenjska območja (<i>life zones</i>), kamninska podlaga
klasifikacija ekoloških regij oziroma območij v ZDA (Hargrove, Hoffman, 2005)	metoda glavnih komponent, metoda voditeljev	nadmorska višina, količina rastlinam dostopne vode, organska snov v prsti, vsebnost dušika v prsti, globina visokega

		nivoja podtalnice, povprečne padavine v rastni dobi, povprečno sončno sevanje v rastni dobi, topli dnevi v rastni dobi, hladni dnevi izven rastne dobe
klasifikacija pokrajine vulkana La Maliche (Mehika) (Castillo-Rodríguez, López-Blanco, Muñoz-Salinas, 2010)	metoda glavnih komponent, hierarhično razvrščanje	letalski posnetki, delež posamezne rabe tal, vegetacije, tipa prsti, nadmorska višina, naklon, oblika, ekspozicija, temperatura
klasifikacija ZDA (Wolock, Winter, McMahon, 2004)	razmejitev na porečja, metoda glavnih komponent, metoda najbližjih sosedov, analiza variance	višinska razlika, delež ravnin, delež ravnin nad srednjo vrednostjo višine, delež ravnin pod srednjo vrednostjo višine, prepustnost prsti (delež peska v prsti), prepustnost kamnin (razred kamninskih skupin), razlika med povprečno letno količino padavin in potencialno evapotranspiracijo
ekološke regije v Nebraski (Zhou s sod., 2003)	segmentacija po algoritmu <i>region-growing</i>	časovni niz satelitskih posnetkov senzorja AVHRR, debelina prsti, delež organskega materiala, vodna kapaciteta, povprečna vodna bilanca in seštevek temperatur v rastni dobi, naklon, ekspozicija, nadmorska višina, usmerjenost proti vzhodu, poligoni STATSGO (kot osnovne prostorske enote)
klasifikacija Nove Zelandije (Leathwick s sod., 2003)	nehierarhično razvrščanje (mera Gower), hierarhično razvrščanje (mera Gower)	povprečna letna temperatura, povprečna julijska minimalna temperatura, povprečna letna količina sončnega obsevanja, povprečni letni padavinski primanjkljaj, povprečno mesečno razmerje padavin in potencialne evapotranspiracije, povprečni oktobrski, naklon in razni podatki o fizikalnih in kemijskih lastnostih
kraške krajine notranje Slovenije (Breskvar Žaucer, Marušič, 2006)	nadzorovana klasifikacija z nevronskimi mrežami	nadmorska višina, strmina pobočij, izpostavljenost stranem neba, pojavnost gozdov, kmetijskih zemljišč, poselitve, pasovi oddaljenosti od poselitve, matična kamnina, pasovi oddaljenosti od največjih strmin pobočij (nad 60 %), povprečna letna temperatura, povprečna letna količina padavin in pasovi oddaljenosti od površinskih voda
klasifikacija Evrope (Renetzedder s sod., 2008)	metoda voditeljev, strokovna presoja; analiza variance (koeficient F) za oceno pomembnosti atributov	podnebje, relief, kamninska sestava, gostota poselitve, sprememba gostote poselitve, ocena aktivnosti, BDP, delež nezaposlenih, funkcionalne urbane površine, pokrovnost tal in drugo

Priloga 4: Podroben opis uporabljenih metod

Seznam:

1. Metode za vrednotenje podatkovnih slojev in klasifikacij
2. Metode za ugotavljanje usklajenosti klasifikacij
- 3.1 Metode nenadzorovane klasifikacije
- 3.2 Metode nadzorovane klasifikacije
- 3.3 Metode mehke nadzorovane klasifikacije

1. Metode za vrednotenje podatkovnih slojev in klasifikacij

1.1 Koeficient F

Primerjava variance znotraj in med skupinami je ena izmed možnosti za oceno rezultata klasifikacije. Nizke variance znotraj skupine kažejo na homogenost. Če je varianca med skupinami precej večja kot varianca znotraj skupin, je verjetno, da sta vsaj dve skupini v klasifikaciji med seboj različni z vidika testiranega podatkovnega sloja (Zhou s sod., 2003). Z analizo variance (ANOVA) primerjamo varianco med skupinami in varianco znotraj skupin. Razmerje med varianco znotraj skupin in med skupinami je F; višje vrednosti pomenijo večji pomen neodvisne spremenljivke⁵⁰. Koeficient F izračunamo, da ugotovimo, ali se povprečne vrednosti spremenljivke razlikujejo po posameznih skupinah – v našem primeru tipih (SPSS Help, 2008; Sagadin, 2003; Foster, 2006). Višja vrednost koeficienta F odraža večje razlike med skupinami (Kastelec, Košmelj, 2008, 169).

Za analizo variance potrebujemo vsaj eno neodvisno kategorično spremenljivko in številsko odvisno spremenljivko, obstaja pa kar nekaj domnev (SPSS Help, 2008; Rogerson, 2006, 132):

- vsaka skupina je neodvisen in naključen vzorec iz normalno porazdeljene populacije,
- skupine morajo imeti enake variance,
- odvisna spremenljivka mora biti intervalna ali razmernostna,
- enote v vsaki skupini so normalno porazdeljene.

Kljub temu naj bi bila analiza variance robustna metoda; če je statistična značilnost p precej manjša od 0,01, je rezultat tudi sprejemljiv (Rogerson, 2006, 139). Koeficient F se izračuna po sledečih formulah (Sagadin, 2003, 356–358):

$$F = \frac{s_m^2}{s_v^2}$$
$$s_m^2 = \frac{K_m}{k - 1}$$
$$s_v^2 = \frac{K_v}{N - k}$$
$$K_v = \sum_{j=1}^k \sum_{i=1}^{n_j} (y_{ij} - \bar{y}_{.j})^2$$
$$K_m = \sum_{j=1}^k n_j (y_{.j} - \bar{y}_{..})^2$$

Pri tem je K_m vsota kvadratov med skupinami, K_v je vsota kvadratov v skupinah, N je število enot, k je število skupin. Simbola s_v in s_m sta srednja kvadrata ali oceni variance, n_j je število enot v j -ti skupini, y_{ij} je i -ta enota v j -ti skupini, $\bar{y}_{.j}$ je povprečje v j -ti skupini, $\bar{y}_{..}$ je povprečje

⁵⁰ V podrobnem opisu metod ponekod uporabljamo izraz spremenljivka, ki je enak izrazu podatkovni sloj.

vseh enot v vseh skupinah. Statistično značilnost preverimo v tabeli F vrednosti za prostostni stopnji $g_1=k-1$ in $g_2=N-k$.

1.2 Koeficient variacije in povprečni umerjeni koeficient variacije

Koeficient variacije (KV) je relativna mera variacije in omogoča primerjavo variabilnosti različnih spremenljivk. Višja vrednost pomeni večjo spremenljivost. Koeficient variacije dobimo tako, da standardni odklon (σ) izrazimo v odstotkih aritmetične sredine (M) (Sagadin, 2003, 92):

$$KV = \frac{100\sigma}{M}$$

KV je osnova za izračun povprečnega umerjenega koeficienta (PUKV), ki smo ga uporabili v nalogi in je podrobneje opisan v nadaljevanju, saj v literaturi nismo zasledili uporabe KV na takšen način.

Na začetku opisa PUKV navajamo izsledke raziskave, ki jo je leta 1998 objavil Krevs. Krevs je med drugim preučeval, kako se spreminja izračunani koeficient variacije za Slovenijo, če spreminjamo osnovne prostorske enote (podatke zbrane za krajevne skupnosti zamenjamo s podatki za občine itd.), na podlagi katerih izračunamo koeficient variacije. Ugotovil je, da se s povečevanjem osnovnih prostorskih enot mere spremenljivosti zmanjšujejo; to pa zaradi vse večje notranje heterogenosti enot in vse manjših razlik med njimi (Krevs, 1998, 191). Krevs (1998, 190) pravi, da je uporabna tudi »*informacija, ki jo dobimo s primerjavo spremenljivosti spremenljivk med seboj, za iste prostorske enote. Večji koeficient variacije za določeno spremenljivko pomeni, da njene prostorske razlike bolje prikažemo po izbranih območjih kot za spremenljivke z nižjim koeficientom variacije (po istih območjih)*«. Krevs (1998, 193) je na izbranih spremenljivkah ugotovil, da se pri večini koeficient variacije z večanjem izbrane prostorske enote bolj ali manj enakomerno znižuje. Hkrati pa Krevs (1998, 201) opozarja, da ugotovitve ne veljajo nujno za druge spremenljivke, ki v njegovi raziskavi niso bile zajete. Krevsova ter nekatere druge raziskave na področju ločljivosti in informativnosti rastrskih podatkov in segmentacij (Evans, 1972; Woodcock, Strahler, 1987; Drăguț, Eisank, Strasser, 2011; Ciglič, 2010b; Drăguț, Eisank, 2012) so bile povod za raziskavo in izdelavo povprečnega umerjenega koeficienta variacije (PUKV), ki smo ga uporabili predvsem za ugotavljanje pomena podatkovnih slojev z vidika spreminjanja prostorske ravni.

V naši analizi je osnovna prostorska enota, ki nosi posamezen podatek, ves čas enaka, t. j. rastrska celica (piksel), območje, za katerega se izračuna variabilnost, pa se spreminja. Predpostavljamo, da prihaja pri izračunu povprečnega umerjenega koeficienta variacije za različno velika območja do različnega obnašanja med spremenljivkami (to smo potrdili v praktičnem delu raziskave).

V okviru naloge smo torej izračunali povprečni umerjeni koeficient variacije (PUKV).

Računski del je sestavljen iz računanja umerjenega KV za posamezno prostorsko enoto i (območje posamezne občine, območje enega tipa, poljuben kvadratni izsek nekega območja ...) ter nato računanja povprečja umerjenih KV-jev vseh prostorskih enot (vse občine ali tipi v državi, vsi kvadratni izseki ...). Za boljšo primerljivost med KV-ji smo pri izračunu KV-ja posamezne prostorske enote i povprečno vrednost enote zamenjali s povprečjem za celo Slovenijo M_{vsi} (tak način je na primer uporabil Perko (2001) pri izračunu koeficienta razgibanosti površja), zato govorimo o umerjenem koeficientu variacije.

Umerjeni koeficient variacije (UKV) za posamezno prostorsko enoto je:

$$UKV_i = \frac{100\sigma_i}{M_{vsi}}$$

Kjer je σ_i standardni odklon spremenljivke v posameznem tipu i ter je M_{vsi} povprečje spremenljivke na celotnem območju Slovenije.

Ker se lahko pri razdelitvi pojavijo prostorske enote, ki so po površini zelo majhne, bi te utegnile premočno zmanjšati povprečje UKV-jev vseh prostorskih enot (torej gre v primeru tipizacije za povprečje vseh tipov). Zato pri računanju najprej posamezni UKV pomnožimo s številom celic v prostorski enoti C_i , seštevek vseh tako obteženih UKV-jev pa delimo s številom vseh celic C_{vsi} .

Povprečni UKV prostorskih enot (oziroma v primeru, da je prostorska enota tip, celotne tipizacije) je označen kot PUKV in se izračuna:

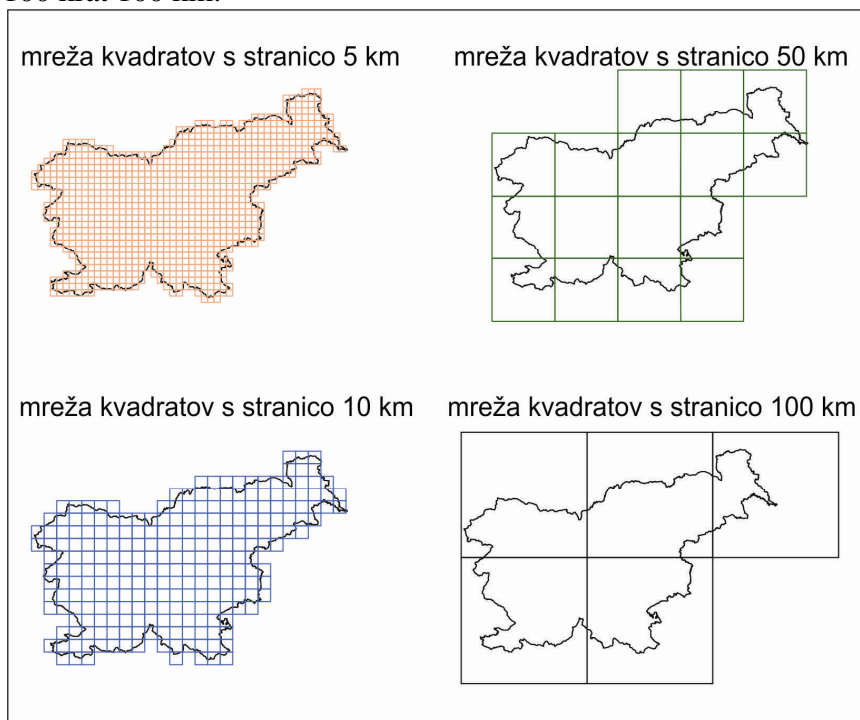
$$PUKV = \frac{\sum C_i \times UKV_i}{C_{vsi}}$$

Pri tem je C_i – število celic v posameznem tipu i , UKV_i – umerjeni koeficient variacije posameznega tipa i , C_{vsi} – število celic na celotnem območju.

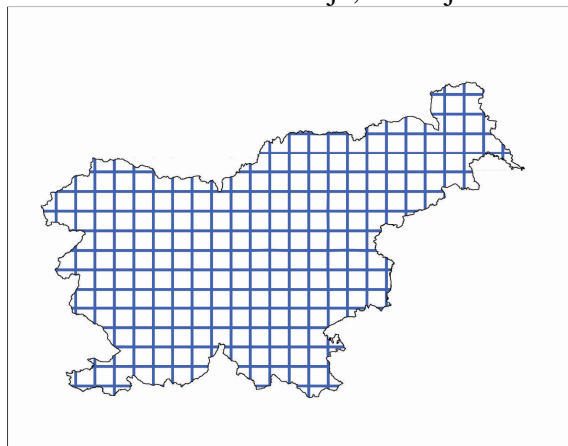
Praktičen primer izračuna PUKV

Želeli smo preveriti, kolikšne so vrednosti treh spremenljivk (podatkovnih slojev) za različne arbitrarne razdelitve Slovenije na manjše enote. Slovenijo smo razdelili z različnimi mrežami (sliki 105 in 106). Območja ob meji niso popolni kvadrati. Vsak kvadrat je samostojna enota.

Slika 105: Prikaz Slovenije, razdeljene z mrežo 5 krat 5 km, 10 krat 10 km, 50 krat 50 km in 100 krat 100 km.



Slika 106: Prikaz Slovenije, razdeljene z mrežo kvadratov 10 krat 10 km.



Za vsako razdelitev (za mrežo 100 krat 100 km, mrežo 50 krat 50 km ...) smo izračunali PUKV za podatkovne sloje nadmorska višina, padavinski režim (razmerje med vsoto poletnih padavin in vsoto zimskih padavin) in ekspozicija. Podatki so rastrski (ločljivost 1 km krat 1 km) in umerjeni na lestvico 0–100, kjer je 0 najnižja vrednost in 100 najvišja vrednost izvirnega podatkovnega sloja.


Po izračunanih povprečnih umerjenih koeficientov variacije (preglednica 125, slika 107) se je izkazalo, da je nadmorska višina večinoma najbolj variabilna. Padavinski režim je občutno manj variabilen kot pa nadmorska višina. In tem bolj ko se oža območje (manjši je kvadrat mreže), manj raznovrstnih vrednosti ima padavinski režim in tudi manj je uporaben za morebitno klasifikacijo manjšega območja. Ekspozicija ima variabilnost pri vseh razdelitvah približno enako, kar pomeni, da izbrane razdelitve očitno ne vplivajo na variabilnost podatka in da bi lahko šlo tudi za šum (torej podatek, ki ni primeren za klasifikacijo).

Preglednica 125: Vrednosti PUKV za posamezne razdelitve.

podatkovni sloj	vrednost PUKV za mreže z različnimi razmiki (%)				vrednost PUKV za Slovenijo ⁵¹ (%)
	5 km	10 km	50 km	100 km	
nadmorska višina	18,6	26,3	46,0	50,6	63,4
padavinski režim	4,2	7,3	18,2	24,3	46,9
ekspozicija	24,3	27,1	29,1	29,3	29,6


⁵¹ Vrednost PUKV za Slovenijo (1 enota) je enak koeficientu variacije.

Slika 107: Povprečne vrednosti obteženega umerjena koeficienta za posamezne razdelitve.



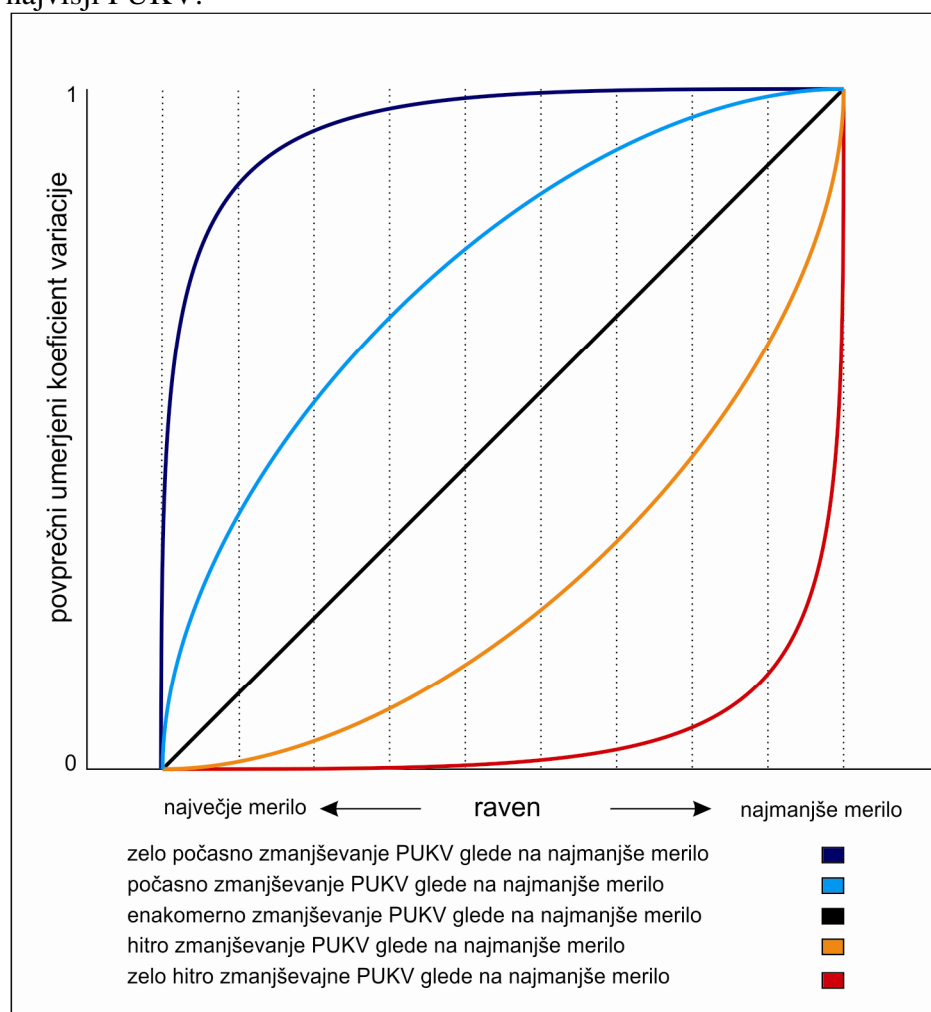
Pregled PUKV-jev dopolnimo tako, da za posamezen podatkovni sloj primerjamo PUKV vseh nižjih ravni s tistim za najvišjo (v našem primeru za Slovenijo). Na ta način je primerljivost med ravnmi še boljša (slika 108; glej tudi sliko 14 v poglavju 6).

Slika 108: Primerjava vrednosti PUKV na posamezni ravni z največjo vrednostjo PUKV.



Teoretično je na največjih območjih PUKV največji, če pa območja (na primer kvadrate) zmanjšamo do te mere, da je v vsakem le ena celica, je vrednost PUKV teoretično enaka 0 (nič). Če bi na primer za naše testne podatkovne sloje (slika 107) izračunali PUKV na gosti mreži majhnih kvadratov, bi dobili za vsakega vrednost zelo blizu nič. Zmanjševanje vrednosti od največje vrednosti posameznega podatkovnega sloja (indeks = 1) do teoretično najnižje vrednosti (indeks = 0) poteka za vsak podatkovni sloj drugače (slika 109). Pri nekaterih se vrednosti hitro znižujejo, kar pomeni, da so podatkovni sloji uporabni v manjših merilih, pri nekaterih počasneje, kar pomeni, da so uporabni (tudi) v velikem merilu. Podatkovni sloji, pri katerih se vrednost znižuje izjemno počasi in se na večini ravneh skoraj ne znižuje, lahko predstavljajo šum.

Slika 109: Teoretične vrste spreminjana vrednosti PUKV po posameznih ravneh glede na najvišji PUKV.



1.3 Korelacijski koeficient eta (η) in korelacijsko razmerje eta² (η^2)

Korelacijski koeficient eta (η) in korelacijsko razmerje eta² (η^2) se uporabljata kot meri korelacije med odvisno spremenljivko y in neodvisno spremenljivko x . Neodvisna spremenljivka je lahko nominalna, ordinalna ali pa grupirana številka, odvisna pa intervalna ali razmernostna (Sagadin, 2003, 163–166). Eta² izračunamo po formuli:

$$\eta_{y,x}^2 = \frac{\sigma_M^2}{\sigma_y^2} = \frac{\frac{1}{N} \sum_{j=1}^k N_j (M_{yj} - M_y)^2}{\sigma_y^2}$$

Pri tem je:

σ_M^2 – del variance spremenljivke y , ki je pojasnjen s spremenljivko x , z njenim vplivom na spremenljivko y ,

σ_y^2 – celotna varianca spremenljivke y ,

$\eta_{y,x}^2$ – delež variance odvisne spremenljivke y , ki je pojasnjen z neodvisno spremenljivko x ,

$\eta_{y,x}$ – razmerje med standardnima odklonoma; $\eta_{y,x} = \sqrt{\eta_{y,x}^2}$,

N – število enot,

N_j – število enot v skupini j ,

k – število skupin,

M_{yj} – povprečje spremenljivke y v skupini j ,

M_y – povprečje spremenljivke y .

Korelacijski koeficient eta je smiselno računati za večje število enot, minimalno število skupin pa je 3.

Za statistično značilnost eta² uporabljamo F-preizkus (Sagadin, 2003):

$$F = \frac{\eta^2(n - k)}{(1 - \eta^2)(k - 1)}$$

Izračunano vrednost primerjamo s kritično vrednostjo F-porazdelitve za $g_1=k-1$ in $g_2=N-k$.

Zaradi načina izračunavanja daje vrednotenje s koeficientom F zelo podobne rezultate kot s koeficientom eta² (opazna je očitna nelinearna kvadratna povezanost; glej grafikone usklajenosti vrednotenj v poglavjih 7 in 8). Zaradi nekaterih razlik (na primer vpliv števila tipov na vrednotenje) smo v disertaciji vseeno uporabili oba načina vrednotenja (koeficienta F in eta²).

1.4 Informacijski prispevek in razmerje informacijskega prispevka

V tem poglavju sta opisana informacijski prispevek in razmerje informacijskega prispevka⁵². V razlagi uporabljamo za vrednost nominalne spremenljivke (podatkovnega sloja), ki ga napovedujemo, izraz razred. Razred je torej lahko pokrajinski tip, vrsta rastline, kategorija plazovitosti ...

Informacijski prispevek spremenljivke (*InfoGain(A)*) je definiran kot prispevna informacija spremenljivke. Izračuna se tako, da od entropije razredov (H_R) odštejemo pogojno entropijo razreda pri dani vrednosti spremenljivke ($H_{R|A}$) (Kononenko, 2005)⁵³:

$$InfoGain(A) = H_R - H_{R|A}$$

Razmerje informacijskega prispevka (*GainR(A)*) odpravlja pomanjkljivost informacijskega prispevka, saj pri slednjem kakovost spremenljivke s številom različnih vrednosti raste. Precenjevanje večvrednostnih spremenljivk se zato odpravi z normalizacijo informacijskega prispevka z entropijo vrednosti spremenljivke (H_A) (Kononenko, 2005):

$$GainR(A) = \frac{InfoGain(A)}{H_A}$$

A *GainR(A)* lahko precenjuje spremenljivko z nižjo informacijsko vrednostjo, zato se moramo pri končni oceni ozirati na rezultate obeh mer (Witten, Frank, 2005).

V nadaljevanju so navedene enačbe, ki jih potrebujemo za *InfoGain(A)* in *GainR(A)*, ki so povzete po Kononenku (2005).

Entropija⁵⁴ razredov (H_R):

⁵² Za bolj podroben opis sta na voljo obrazložitvi po Kononenku (2005) ter Wittenu in Franku (2005), pri katerih je tudi primer izračuna. Na konkretnem geografskem primeru sta obe metodi izračuna predstavljeni tudi v prispevku Cigliča (2010).

⁵³ Ob tem velja, da je informacijski prispevek atributa *Gain(A)* večji ali enak 0 in da je maksimalna vrednost informacijskega prispevka atributa *InfoGain(A)* enaka entropiji razredov (H_R).

⁵⁴ *Entropija* je večpomenski izraz, ki ga zasledimo v različnih vedah (Plut, 1991), pogosto pa ima zelo podoben pomen. V nalogi se izraz *entropija* nanaša na tistega iz informacijske teorije, pri katerem je *entropija* definirana kot merilo negotovosti oziroma naključnosti nekega dogodka (Ihara, 1993, 2). Sicer pa se beseda *entropija* uporablja tudi v drugih vedah (fiziki, medicini, ekonomiji, humanistiki, ekologiji in drugod). Zelo znan je drugi zakon termodinamike oziroma entropijski zakon (Gershmel s sod., 1986 cv: Plut, 1991, 13). »Skupna količina energije v določenem procesu je zmeraj ista, ob pretvorbi energije iz ene oblike v drugo pa se zmanjša skupna količina izkoristljive energije, ki bi lahko v bodočnosti opravila delo« (Plut, 1991, 16). Zelo dobro primerjavo med informacijskim in energetskim (fizikalnim) pomenom izraza *entropija* je prikazal Coffey (1981 cv: Plut, 1991, 15–17), ki pravi, »da vsak sistem teži proti popolni homogenosti v razporeditvi energije, v kateri ni mogoče opravljati dela.« To avtor imenuje maksimalna entropija. To je stanje sistema, »kjer nima noben del sistema več energije kot drugi del sistema« (Gersmehl s sod., 1980 cv: Plut, 1991, 15). Številčna ponazoritev nivoja entropije, ki jo lahko povežemo tudi z informacijskim razumevanjem entropije, je prikazana v publikaciji Entropijska zanka (Plut, 1991) na strani 17.

$$H_R = - \sum_k p_k \cdot \log p_k.$$

Entropija vrednosti dane spremenljivke (entropija vrednosti pojasnjevalne spremenljivke) (H_A):

$$H_A = - \sum_j p_j \log p_j$$

Entropija produkta dogodkov razred-vrednost spremenljivke (H_{RA}):

$$H_{RA} = - \sum_k \sum_j p_{kj} \log p_{kj}$$

Pogojna entropija razreda pri dani vrednosti spremenljivke ($H_{R|A}$):

$$H_{R|A} = H_{RA} - H_A = - \sum_j p_j \sum_k \frac{p_{kj}}{p_j} \log \frac{p_{kj}}{p_j}$$

$$H_{R|A} = - \sum_j p_j \sum_k p_{k|j} \log p_{k|j}$$

Ob tem velja, da je $H_{RA} \geq H_{R|A}$.

Pri tem je:

$$p_{kj} = n_{kj} / n$$

$$p_k = n_k / n$$

$$p_j = n_j / n$$

$$p_{k|j} = p_{kj} / p_j = n_{kj} / n_j$$

n – število učnih primerov (število vseh celic)

n_k – število učnih primerov iz razreda k (število celic v razredu k napovedane spremenljivke)

n_j – število učnih primerov z j -to vrednostjo dane spremenljivke A_i (število celic z vrednostjo j pojasnjevalne spremenljivke A_i),

n_{kj} – število učnih primerov iz razreda k in z j -to vrednostjo dane pojasnjevalne spremenljivke A_i (število celic v razredu k napovedanega atributa z j -to vrednostjo pojasnjevalne spremenljivke A_i)

Nekateri računski postopki za klasifikacije v skupine lahko obravnavajo le nominalne spremenljivke. Zato je treba v takih primerih številke spremenljivke diskretizirati oziroma razdeliti na več intervalov (Witten, Frank, 2005). Diskretizacija številskih spremenljivk je nujna tudi pri računanju informacijskega prispevka. Metod za to je več (Witten, Frank, 2005), tista, ki je uporabljena pri ocenjevanju pomembnosti številkega atributa v programu Weka 3.5.8. (Hall s sod., 2009), ki smo ga uporabili v naših analizah, temelji na entropiji ter upošteva načelo najkrajšega opisa (MDL – *minimum description length*)⁵⁵. Ko delimo enote

⁵⁵ Pri tem postopku se najprej ugotovi, katera delitev številskih vrednosti v dve skupini glede na izbrano spremenljivko zagotavlja največji informacijski prispevek. Ko je meja, na podlagi katere se enote razvrstijo, določena, se postopek ponovi za vrednosti nad in pod izbrano mejo – torej proces se nadaljuje v obeh smereh. Brez določenega kriterija se lahko ta proces nadaljuje, dokler ne razdeli čisto vseh enot tako, da so skupine enot čiste. Ker to ni smiselno, saj bi se ugotovitve preveč prilagajale učnemu vzorcu in bi bilo rezultat teže splošiti, so vpeljana določila za ustavitev procesa diskretizacije. Zato se pri vsaki delitvi preveri, ali je informacijski prispevek (te delitve) dovolj velik glede na število enot, število razredov, entropije enot, entropije enot v vsakem podintervalu (po delitvi) in števila razredov v vsakem podintervalu (po delitvi) (za enačbo glej: Fayyad, Irani, 1993; Witten, Frank, 2005).

na intervale, iščemo takšno razdelitev, ki naredi skupine glede na vsebnost razredov čim bolj »čiste« (Witten, Frank, 2005).

1.5 Ginijev koeficient

Ginijev koeficient⁵⁶ se lahko uporablja kot mera nečistoče in je definiran z enačbo (Lin, Noe, He, 2006, 556; tudi Yohannes, Webb, 1999, 15):

$$i(m) = 1 - \sum_{k=1}^K \left[p_m(k) \right]^2$$

Pri tem je $i(m)$ mera čistoče v vozlišču m , K je število razredov napovedane spremenljivke, k je k -ti razred napovedane spremenljivke, $p_m(k)$ pa je delež enot z vrednostjo k v vozlišču.

1.6 Model diskriminančne analize za preverjanje klasifikacij

Z diskriminančno analizo lahko izdelamo model napovedovanja pripadnosti posamezni skupini. Model je zgrajen iz diskriminančnih funkcij, ki so narejene kot linearne kombinacije pojasnjevalnih oziroma neodvisnih spremenljivk. Te funkcije so z utežmi določene tako, da kar najbolj ločujejo med skupinami (SPSS Help, 2008). Omenjene linearne enačbe diskriminančnih spremenljivk napovejo, v katero skupino nominalne spremenljivke spada posamezna enota (Kastelec, Košmelj, 2008; Discriminant Analysis, 2011). Pri diskriminančni analizi določimo koeficiente (uteži) diskriminančne funkcije tako, da je razmerje med vsoto kvadratov med skupinami in vsoto kvadratov znotraj skupin največje (Košmelj, 1983). V analizi se določi ena diskriminančna funkcija manj, kot je število skupin oziroma kolikor je neodvisnih pojasnjevalnih spremenljivk, če je število le-teh manjše od števila skupin. Model diskriminančne analize lahko zapišemo takole (SPSS Help, 2008):

$$d_{ik} = b_{0k} + b_{1k}x_{i1} + \dots + b_{pk}x_{ip}$$

Pri tem je d_{ik} diskriminančna funkcija k za enoto i , p število pojasnjevalnih (neodvisnih) spremenljivk, b_{jk} utež koeficienta j diskriminančne funkcije k , x_{ij} pa je vrednost enote i za pojasnjevalno spremenljivko j .

Pri uporabi diskriminančne analize moramo zadostiti nekaterim domnevam, kot so (Discriminant analysis, 2011; SPSS Help, 2008; Ferligoj, 2010):

- število skupin mora biti najmanj 2,
- v vsaki skupini morata biti najmanj 2 enoti,
- število spremenljivk mora biti vsaj za 2 manjše od števila enot,
- nobena spremenljivka ne sme biti linearna kombinacija preostalih spremenljivk,
- naključnost vzorca,
- normalna porazdelitev neodvisnih spremenljivk,
- vsaka enota pripada le eni skupini nominalne (napovedane) spremenljivke,
- dobra in smiselna razdelitev v skupine,
- neodvisne spremenljivke ne smejo biti močno povezane,
- variančno-kovariančne matrice morajo biti enake po skupinah,
- povezanost dveh neodvisnih spremenljivk je konstantna glede na skupine,
- povprečja in variance ne smejo biti povezani (če se primerja po skupinah).

⁵⁶ Ginijev koeficient temelji na Lorenzovi krivulji in je mera neenakosti v populaciji (Damgaard, 2012). Splošna enačba koeficientov neenakosti (I), med katere spada tudi Ginijev koeficient, je $I = \sum_j p_j f(r_j)$. Pri tem je $r_j = X_j/X$ (razmerje med povprečjem v skupini j in povprečjem celotne populacije), $p_j = n_j/N$ (delež populacije j od celotne populacije N), f je funkcija za merjenje neenakosti (Firebaugh, 1999). Ginijev koeficient se pogosto uporablja v družboslovju; verjetno je najbolj znan primer računanja neenakosti porazdelitve dohodka prebivalcev v posamezni državi. Nižji Ginijev koeficient pomeni bolj enakomerno porazdelitev dohodka, višji pa bolj neenakomerno porazdelitev dohodka (Distribution of ..., 2012).

Za preizkus domnev imamo nekatere metode. Boxov M test na primer preverja enakost kovariančnih matrik po skupinah, a je treba dodati, da je ta test včasih nezanesljiv (Kastelec, Košmelj, 2008). Rezultati diskriminančne analize so lahko napačni, če korelacija med osnovnimi spremenljivkami ni linearna ali pa če v podatkih obstaja veliko osamelcev (Kastelec, Košmelj, 2008).

Ko je model diskriminančnih funkcij narejen, se lahko napove, v katero skupino spada posamezna enota. Nadaljevanje izdelave diskriminančnih funkcij so torej klasifikacijske funkcije. Enačba linearne klasifikacijske funkcije je (Kastelec, Košmelj, 2008; StatSoft, 2012):

$$d_i(x_0) = c_{i0} + c_{i1}x_{01} + c_{i2}x_{02} + \dots + c_{ip}x_{0p}$$

Pri tem je i skupina, p je število spremenljivk, c_{i0} je konstanta, c_{ij} so koeficienti linearne kombinacije, x_{0j} so vrednosti osnovne spremenljivke j (neodvisne, pojasnjevalne spremenljivke). Za enoto x_0 v postopku klasifikacije izračunamo vrednosti k linearnih klasifikacijskih funkcij $d_i(x_0)$ in jo klasificiramo v tisto skupino, za katero je vrednost klasifikacijske funkcije največja.

2. Metode za ugotavljanje usklajenosti klasifikacij

2.1 Koeficient kappa (κ)

Koeficient kappa prikazuje, kako se oceni dveh različnih ocenjevalcev med seboj ujemata. Meri ujemanje med dvema klasifikacijama tako, da upošteva tudi ujemanje po naključju. Pri izračunu koeficienta kappa (κ) je nujno, da je število kategorij enako ter da so identifikatorji za posamezne tipe/skupine/ocene enaki. Vrednost 1 pomeni popolno ujemanje, vrednost 0 pa le ujemanje, ki bi ga dosegli zgolj po naključju. Prednost koeficienta je tudi, da se lahko primerja z izračunanimi koeficienti kappa za druge (večje in manjše) preglednice (SPSS Help, 2008; Campbell, 1996, 388–392; Lillesand, Kiefer, Chipman, 2008, 590–591). Zaradi tega se zdi ta mera uporabna predvsem pri primerjavi izvirnih tipizacij z modeliranimi tipizacijami. Koeficient kappa je za testiranje podobnosti uporabil tudi Metzger s sodelavci (2005). Enačba za izračun je:

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Pri tem je r število vrstic v matriki/preglednici, x_{ii} je število enot v vrstici i in koloni i (število enot v diagonali; pravilno uvrščene enote), x_{i+} je število enot v vrstici i , x_{+i} je število enot v koloni i , N pa je število vseh enot.

2.2 Cramerjev koeficient povezanosti

Z izračunom Cramerjevega koeficienta povezanosti V (Krevs, 2001a; Perko, 2001) med seboj primerjamo nominalne spremenljivke (na primer klasifikacije). Cramerjev koeficient V ima vrednosti od 0 do 1 in ni odvisen od velikosti tabele, kar pomeni, da lahko koeficient primerjamo za različno velike tabele (Sagadin 2003, 316–317).

$$V = \sqrt{\frac{\chi^2}{n(m-1)}}$$

Pri tem je m manjše število izmed števila stolpcev in vrstic, hi^2 (χ^2) pa pomeni:

$$\chi^2 = \sum \frac{(f - f_t)^2}{f_t}$$

Pri tem je f dejanska frekvenca posamezne celice v matriki stolpcev in vrstic, f_t pa teoretična frekvenca posamezne celice v matriki stolpcev in vrstic.

3. Metode za izdelavo klasifikacij

3.1 Metode nenadzorovane klasifikacije

Z metodami nenadzorovane klasifikacije oziroma razvrščanjem v skupine stremimo k temu, da podatke uredimo v skupine na tak način, da bosta dosežena interna homogenost in eksterna izolacija (Ferligoj, 1989). Razvrščanje v skupine ima cilj, da podobne enote združi v skupine. Glavni cilj je minimizirati varianco znotraj skupine ter maksimizirati varianco med skupinami (Rogerson, 2006, 263, 264). Pomanjkljivosti metod so na primer (McGarigal, 2000, 123 in 124):

- občutljivost na vrednosti z velikim odstopanjem, ki jih metode pogosto klasificirajo v ločen razred,
- vsaka metoda vsiljuje svojo obliko, zato je treba primerjati rezultate več različnih metod,
- težavno določanje števila skupin (nujna določena stopnja subjektivnosti).

Osnovni koraki pri reševanju problemov metod nenadzorovane klasifikacije so (Ferligoj, 1989, 19; podoben razpored navajata tudi Theodoridis, Koutroumbas, 2006):

1. izbira objektov,
2. določitev spremenljivk,
3. računanje podobnosti med enotami,
4. uporaba ustrezne metode razvrščanja v skupine,
5. ocena dobljene rešitve.

Theodoridis in Koutroumbas (2006, 485) menita, da lahko končno oceno poda le poznavalec z ustreznega področja.

3.1.1 Metoda voditeljev

Metoda voditeljev (imenovana tudi *k-means*) je nehierarhična metoda (McGarigal, 2000) in spada med optimizacijske metode (Košmelj, 2006, 305 in 306). Pri tej metodi moramo določiti število skupin, v katerih so določeni tudi voditelji (imenovani tudi centriodi oziroma težišča) – enote, okrog katerih se potem zbirajo ostale enote (na primer celice). Nato se izračuna in določi nove voditelje teh novih skupin. Postopek se konča, ko se nova množica voditeljev ne razlikuje od množice voditeljev, dobljene korak pred njo (Ferligoj, 1989, 93; Richards, Jia, 2006, 252). Mere podobnosti (ali različnosti) med enotami se pri metodi voditeljev računajo postopoma med samim procesom razvrščanja (Ferligoj, 1989). Ponavadi se uporablja Evklidova razdalja (Richards, Jia, 2006, 250). V vsakem koraku postopka metode voditeljev nas ponavadi zanima, kako dobra je razvrstitev. To merimo z izbrano kriterijsko funkcijo. Kriterijska funkcija za posamezno skupino je ponavadi določena s pomočjo merjenih razlik med enotami, na primer (Ferligoj, 1989, 53):

$$p(C) = \sum_{X,Y \in C} d(X,Y)$$

Centroide lahko izberemo na različne načine. Najpreprosteje je, da so določeni slučajno, pogosto pa se voditelje maksimalno razprši med proučevanimi enotami (Ferligoj, 1989). Primerno število skupin lahko razberemo s pregledom ravni združevanja pri hierarhičnem razvrščanju v skupine. Število skupin pa lahko določamo tudi s pregledom vrednosti kriterijskih funkcij dobljenih optimalnih razvrstitev pri različnem številu skupin: najprimernejše je tisto število skupin, pri katerem je največji padec vrednosti upoštevane kriterijske funkcije (Ferligoj, 1989; McGarigal, 2000). To pomeni, da lahko seštejemo oddaljenost enot od centroida – pri homogenih skupinah bodo vrednosti nizke. Je pa res, da se s tem ne meri razlika med skupinami.

Za uporabo metode voditeljev morajo biti spremenljivke številske, vsaj intervalne ali razmernostne. Če so merjene na različnih merskih lestvicah, je priporočena določena

standardizacija podatkov (SPSS Help, 2008). Med bolj perečimi problemi so izbor kazalcev strukture, začetnih voditeljev (ali skupin) ter določitev števila skupin (Ferligoj, 1997, 259 in 260). Množica vseh možnih razvrstitev je končna, zato postopek slej kot prej najde lokalno optimalno rešitev. To je tudi slabost te metode, ki pa jo lahko omilimo z večkratnim ponavljanjem postopka – vsakič izberemo druge začetne voditelje (Ferligoj, 1989).

Metoda voditeljev v programu SPSS

V programu SPSS lahko metodo voditeljev izvedemo v modulu *K-Means Cluster Analysis*. Program omogoča, da določimo največje število prestavljanj (do 999) ter kriterij konvergence (*convergence criterion*). Slednji določa, za koliko odstotkov se mora premakniti vsaj eden izmed voditeljev (centroidov) po enem prestavljanju, da se razvrščanje nadaljuje. Dodatna možnost (*Use running means*) v SPSS omogoča, da se voditelji izračunajo po prestavljanju prav vsake posamezne enote (v našem primeru rastrske celice). Uporabnik mora določiti število skupin in največje možno število prestavljanj. Razdalje med enotami so Evklidove razdalje (SPSS Help, 2008).

Metoda voditeljev v programu Statistica

V programu Statistica lahko metodo voditeljev opravimo v modulu *Cluster Analysis: K-Means Clustering* (StatSoft, 2012). Postopek omogoča določitev števila prestavljanj ter tri načine izbire začetnih voditeljev: izbor začetnih skupin, ki imajo maksimalne razdalje med seboj; izbor voditeljev na podlagi intervala na lestivici razdalj; samostojni izbor voditeljev. Uporabnik mora določiti še število skupin in največje možno število prestavljanj. Razdalja za metodo voditeljev v programu Statistica je kvadrirana Evklidova razdalja. Razdalja $D(i, k)$ med enoto i iz skupine k za M spremenljivk X_j se na primer izračuna z enačbo:

$$D(i, k) = \sqrt{\frac{1}{M} \sum_{j=1}^M (X_{ij} - \bar{X}_j^{(k)})^2}$$

Pri tem je $\bar{X}_j^{(k)}$ povprečje za spremenljivko j in skupino k .

Metoda voditeljev v programu Idrisi Taiga

V programu Idrisi Taiga lahko metodo voditeljev izvedemo na različne načine v modulu *KMEANS*. Tudi ta omogoča različno določanje začetnih centroidov (Idrisi Taiga, 2010):

- naključna razdelitev (*random partition*), pri kateri se celice naključno razdelijo v k skupin, nato pa se izračunajo voditelji posameznih skupin,
- naključna izbira (*random seed*), pri kateri program naključno določi k točk kot začetne voditelje, nato pa ostale celice po najmanjši razdalji klasificira v eno izmed k skupin,
- voditelji so določeni v n razsežnostnem prostoru (*diagonal axis*) tako, da so izbrani sistematično z določenim intervalom od najmanjše do največje vrednosti vektorja vseh podatkovnih slojev.

Pri tem mora uporabnik poleg izbire začetnih voditeljev določiti maksimalno število skupin, določiti kriterija za ustavitev procesa (delež prestavljenih enot pri eni iteraciji ter število iteracij). Poleg tega se lahko izbere še možnost, da se (pre)majhne skupine pridružijo večjim (Idrisi Taiga, 2010).

3.1.2 Segmentacija

Segmentacija je postopek klasifikacije rastrske slike oziroma postopek združevanja sosednjih celic (pikslov) na podlagi določenih kriterijev v večje homogene prostorske enote – segmente. V teh segmentih morajo imeti celice čim bolj podobne lastnosti (Meinel, Neuber, 2004, 1097; Acharya, Ray, 2005, 131). Te lastnosti so lahko predstavljene s sivinami, kontrastom,

spektralno vrednostjo ali teksturo (Acharya, Ray, 2005, 131). Notranjost posameznih homogenih območij mora biti brez manjših »lukenj«, meje med enotami pa morajo biti sklenjene ter čim bolj natančne (Pratt, 2007, 579). Segmentacija je tudi začetni del zelo pogosto uporabljene objektne analize slik oziroma objektne klasifikacije (*object based image analysis*), v kateri se upošteva tudi njihovo prostorsko razmerje (Naga Jyothi, Babu, Murali Krishna, 2008, 706 in 707). Razvoj različnih algoritmov segmentacije je čedalje večji (Acharya, Ray 2005, 131), a zaenkrat še ni poenotene metode za segmentacijo digitalnih podatkovnih slojev (Pratt, 2007, 579). Metode segmentacije se v glavnem delijo glede na upoštevanje nezveznosti (*discontinuity*) oziroma podobnosti (*similarity*) med celicami. Pri prvih se razdelitev izvaja glede na nenadne spremembe vrednosti celic (iskanje robov), v drugem primeru pa se sosednje celice, ki so med seboj podobne, združujejo v zaključeno prostorsko enoto (Acharya, Ray, 2005, 132). Pregled in razdelitev različnih metod je naredilo že več avtorjev (na primer Achary, Ray, 2005; Wu, Castleman, 2008), a pogledi avtorjev niso enotni. Pratt (2007) je na primer metode segmentacije razdelili takole:


- segmentacije na podlagi frekvenčne porazdelitve (histograma),
- segmentacije z razvrščanjem,
- segmentacije območij,
- segmentacije meja,
- segmentacije na podlagi teksture.

V praktičnem delu naloge smo uporabili program Idrisi Taiga, ki za segmentacijo uporablja način, ki ustreza metodi delitve površja na porečja (*watershed segmentation*) ter postopkom rasti regij oziroma območij (*region growing*). Zaradi tega ju v nadaljevanju na kratko opisujemo. Po Prattovi (2007) delitvi obe spadata v skupino segmentacij območij oziroma regij (*region segmentation*).

Segmentacija z metodo porečij

Postopek je zasnovan na podlagi preučevanja površja in hidrologije. Posamezne vrednosti celic rastrskega sloja so razumljene kot vrednosti višine površja (torej lahko za segmentacijo uporabimo kateri koli podatkovni sloj, na primer gostoto rečne mreže, pa ga program dejansko obravnava kot model višin). Visoke vrednosti ustrezajo »vrhovom« in »grebenom«, nizke vrednosti pa »dolinam« in »nižinam«. Če si zamislimo kapljo vode, ta seveda teče iz višjih vrednosti proti nižjim. Akumulacija kapljic vode okrog lokalnega minimuma se imenuje zbirna kotlina (*catchment basin*) in vse celice, s katerih se voda steka v isto kotlino, so del istega porečja (*watershed*). Obstajata dva osnovna pristopa k določanju porečij: metoda dežja in metoda poplavljanja (Pratt, 2007; Lotufo s sod., 2008). Pri prvem se določijo lokalni minimumi, ki se jim dodeli oznako. Nato se s pomočjo namišljene kapljice vsem neoznačenim celicam dodeli tista vrednost, ki jo ima lokalni minimum, v katerega steče kapljica (Pratt, 2007, 593 in 594). V drugem primeru se v celicah, ki predstavljajo lokalne minimume, začne nabirati voda. Ta se dviga in poplavlja površje. Če pri poplavljanju kakšno kotlino preplavi, se ustvari navidezna pregrada, ki je visoka toliko, kot je visok najvišji greben (Pratt, 2007, 594; Lotufo s sod., 2008, 139; slika 110). Prevelika razčlenjenost je lahko ena izmed pomanjkljivosti omenjene metode (Pratt, 2007, 593-595; Acharya, Ray, 2005, 151; Lotufo s sod., 2008, 140), saj se za segmentacijo na porečja pogosto uporablja podatkovni sloj spremenljivosti (Lotufo s sod., 2008, 140).

Slika 110: Primer določanja porečij po principu poplavljanja (Pratt, 2007, 594; Lotufo s sod., 2008, 140).



Segmentacija z metodo rasti regij oziroma območij

Rast regij oziroma območij (*region growing*) je postopek segmentacije, ki združuje posamezne sosednje celice ali manjšo skupino celic v vedno večje prostorske enote (Pratt, 2007, 590; Wu, Castleman, 2008, 173; Acharya, Ray, 2005, 148). Glavni kriterij pri tem procesu je homogenost območij. Na začetku je nekako treba razdeliti podatkovni sloj na majhne zaključene prostorske enote; te lahko dobimo tudi kot porečja, opisana v prejšnjem poglavju. Na podlagi vrednosti posameznih celic se izračunajo izbrani kazalci posameznih prostorskih enot (območij/regij), ki služijo za medsebojno primerjavo in združevanje v večje prostorske enote. Na podlagi teh izračunov se nato izračuna razlika med sosednjimi regijami in preveri moč meje med njimi. Če sta si regiji med seboj različni, se meja ohrani, če pa sta si podobni, je meja označena kot šibka in v takem primeru se ti sosednji prostorski enoti združita v večjo enoto. Postopek preverjanja meja se ponavlja in prostorske enote se združujejo, dokler so nekatere meje še označene kot šibke (Wu, Castleman, 2008, 173 in 174; Acharya, Ray, 2005, 148). Obstaja veliko različic metode rasti območja (glej Pratt, 2007, 590–592; Acharya, Ray, 2005, 48). Pri izvedbi segmentacije je treba za doseg dobrih rezultatov določiti nekatere parametre pri združevanju (Pratt, 2007, 590), še posebej so pomembni naslednji (Acharya, Ray 2005, 148):

- določitev začetnih točk oziroma območij/regij ter ustrezne lastnosti, na podlagi katerih se bo proces izvajal,
- določitev povezanosti oziroma sosedskosti območij/regij,
- izračun mere podobnosti med sosednjimi območji/regijami in določitev ravni, do katere se le-ta še združujejo,
- določitev pragu minimalne površine območij/regij.

Segmentacija v programu Idrisi Taiga

Modul *SEGMENTATION* v programu Idrisi Taiga računalniško razčlenjuje površje po načelu določanja porečij ter rasti regij/območij. Najprej določi porečja, ki predstavljajo začetne homogene prostorske enote, nato pa jih združuje na podlagi podobnosti. Meje se torej zarisujejo v prvem koraku, nato pa se meje brišejo tam, kjer so šibke oziroma ločujejo preveč podobni sosednji regiji/območji. Proces segmentacije dejansko obsega tri računske sklope (Idrisi Taiga, 2010):

- izdelava površja iz izbranega podatkovnega sloja (Z matričnim oknom poljubne velikosti se izračuna lokalna varianca za posamezno celico. Če uporabljamo več podatkovnih slojev, se vsi z utežmi združijo v en sloj.)
- določitev porečij (Podatkovni sloj iz prejšnje alineje, ki prikazuje varianco, se v tem delu obravnava kot sloj digitalnega modela višin – celice z visoko varianco so grebeni,

celice z nizko pa doline. Celice se uvrstijo v pripadajoča porečja, ki predstavljajo osnovne segmente.)


- združevanje sosednjih porečij (Podobni segmenti se v tem koraku združijo, če zadostijo tolerančnemu pragu, ki ga določi uporabnik. Pri tem se za par dveh segmentov preveri, ali sta si medsebojno najbolj podobna soseda ter ali je njuna združitev v skladu z določenim tolerančnim pragom. Vrednosti za primerjavo se izračunajo na podlagi razlik med standardnimi odkloni in povprečji za posamezne segmente pred in po združitvi.)

V programu Idrisi Taiga je treba pri tem postopku zato določiti: število podatkovnih slojev z utežmi; velikost okna, s katerim računamo varianco; razmerje pomena povprečja in standardnega odklona segmentov pri računanju podobnosti (dva parametra); tolerančni prag podobnosti za združitev sosednjih segmentov (Idrisi Taiga, 2010).

3.1.3 Analiza vrhov v histogramu

Pri metodi analize vrhov v histogramu gre za klasifikacijo s pomočjo večrazsežnostnega histograma (Richards, Jia, 2006). Analiza poteka tako, kot bi pregledovali vrhove v enodimenzionalnem histogramu, kjer vrh (*peak*) predstavlja vrednost z najvišjo frekvenco. Ko odkrijemo take vrhove, se vse celice pridružijo najbližjemu vrhu in formirajo skupino, območja med vrhovi, torej doline, pa postanejo meje med skupinami (Eastman, 2009). Za boljšo in hitrejšo izvedbo histogrami niso narejeni iz posameznih celic, ampak iz košev (*bin*) s celicami. Če imamo torej tri podatkovne sloje z razponom vrednosti 1–100, potem imamo 100^3 možnih kombinacij, kar pomeni kar 1.000.000 kombinacij. Če imamo območje veliko 100 x 100 celic, pomeni, da je celic 10.000. To pomeni, da je teoretično možno, da se vsaka celica uvrsti v kombinacijo (eno zmed 1.000.000), kjer je sama. Zato lahko vsaka tvori vrh. Da se to ne zgodi, se razpon vrednosti podatkovnih slojev razdeli v razrede (*bins*) – recimo v našem primeru vsak podatkovni sloj razdelimo v 10 razredov. To pomeni, da imamo sedaj 10^3 oziroma 1000 različnih kombinacij; kar pomeni dejansko 1000 prostorčkov v tridimenzionalnem histogramu, kamor razvrstimo 10.000 celic. V vsakem takem razredu (*binu*) je tako v povprečju lahko 10 enot, kar že omogoča nastanek pravih vrhov (Richards, Jia, 2006; slika 111).

Slika 111: Analiza vrhov v histogramu (Richards, Jia, 2006).



Metoda analize vrhov v histogramu v programu Idrisi Taiga

V programu Idrisi Taiga lahko uporabimo metodo analize vrhov v histogramu, ki je na voljo v modulu CLUSTER. Uporablja se lahko eno- do sedemdimenzionalni histogram. Uporabnik v programu Idrisi lahko izbere med grobo in fino klasifikacijo. Pri prvi mora vrh imeti vse nedagonalne sosedje z nižjo frekvenco, pri drugi pa ima lahko en nedagonalni sosed višjo frekvenco. Modul CLUSTER ne uporablja originalnih vrednosti za določanje vrhov. Tako kot je bilo predstavljeno pri splošnem opisu te metode, tudi Idrisi razdeli vrednosti v izbrano število košev oziroma nivojev (*GreyLevel*), ki jih uporabi za izdelavo histograma (Idrisi Taiga, 2010; Eastman, 2009).

Najprej program linearno raztegne vsak podatkovni sloj na vrednosti 0–255, nato pa pregleda histogram za vsak podatkovni sloj ter določi mejne (*CutOff*) točke, ki jih določi uporabnik (na primer 5 % najmanjših in največjih vrednosti). Nato se vrednosti v vsakem podatkovnem sloju preračunajo v nivoje (*GreyLevel*). Za to se uporabljajo naslednja pravila:

za $DN_{original} \leq Cutoff_{left}$ je vrednost $Val_{new} = 0$

za $DN_{original} \geq Cutoff_{right}$ je vrednost $Val_{new} = GreyLevel - 1$

za $DN_{original}$ velja $Val_{new} = (DN_{original} - Cutoff_{left}) / (Cutoff_{right} - Cutoff_{left}) * (GreyLevel - 1)$

Pri tem je $DN_{original}$ izvorna vrednost posamezne celice, Val_{new} nova vrednost posamezne celice, $Cutoff_{left}$ in $Cutoff_{right}$ mejni vrednosti, *GreyLevel* število nivojev (sivin).

Ti podatkovni sloji so nato uporabljeni za izdelavo histogramov, s katerimi se išče vrhove (Idrisi Taiga, 2010).

Parametri, ki jih mora uporabnik določiti, so: število podatkovnih slojev; število nivojev; določiti mejne (*CutOff*) točke; izbrati grobo ali fino metodo določanja vrhov; določiti pravilo izbire končnega števila skupin (izločiti manj pomembne skupine, izbrati največje skupine, ohraniti vse skupine) (Idrisi Taiga, 2010).

3.1.4 Metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja

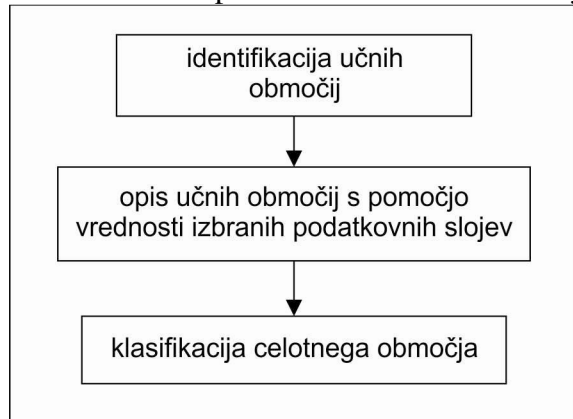
Metoda iterativnega samoorganizirajočega nenadzorovanega klasifikatorja (*iterative self-organizing unsupervised classifier*) je znana tudi po kratici ISOCLUST⁵⁷ in je na voljo v programu Idrisi v istoimenskem modulu. Metoda izvede klasifikacijo tako, da najprej s pomočjo modula CLUSTER (opisan v prejšnjem poglavju) določi začetno klasifikacijo, nato pa s pomočjo modulov MAKESIG in MAXLIKE (opisana v poglavju 4 in prilogi 4) določi učna območja ter nadzorovano klasificira celice v skupine. Postopek se nekajkrat ponovi tako, da se po klasifikaciji zopet izberejo učne celice iz posameznih skupin, računalnik pa znova klasificira vse celice. V postopku najprej izberemo podatkovne sloje, nato pa določimo število iteracij, maksimalno število skupin in minimalno število celic, ki služijo kot učne celice za posamezno skupino (Idrisi Taiga, 2010).

3.2 Metode nadzorovane klasifikacije

Pri metodi nadzorovane klasifikacije (na primer pri določanju pokrovnosti tal iz satelitskih posnetkov) izbiramo območja, za katere poznamo dejansko kategorijo oziroma tip (na primer gozdove, vodne površine). Ta se imenujejo trening območja (*training sites*) ali učna območja; v disertaciji najpogosteje uporabljamo izraz učne celice. Vrednosti učnih celic naj bi predstavljale tipične (v primeru satelitskih posnetkov spektralne) značilnosti podatkovnih slojev. Na koncu so vse ostale celice izven učnih območij uvrščene v posamezno kategorijo oziroma tip (Warner, Campagna, 2009, 198; slika 112).

⁵⁷ Metodo so zasnovali razvijalci programa Idrisi. Zaradi dolgega imena v disertaciji pogosto uporabljamo krajši izraz: ISOCLUST.

Slika 112: Postopek nadzorovane klasifikacije (Warner, Campagna, 2009, 198).



Klasifikacija je iterativni proces. Po prvih rezultatih pogosto popravljamo izbor učnih celic ali nastavitev, da bi dosegli čim bolj optimalne rezultate (Warner, Campagna, 2009). Prednosti nadzorovanih klasifikacij so (Campbell, 1996, 328):

- poznavalec ima nadzor nad kategorijami,
- zaradi enakih kategorij je možna (boljša) primerjava med različnimi klasifikacijami (po obdobjih ali po različnih območjih),
- ni treba povezovati spektralnih in informacijskih razredov,
- uspešnost klasifikacije se lahko preveri tako, da preverimo, kako pravilno so se uvrstile učne celice (pri tem pa pravilno klasificirane učne celice še ne pomenijo dobre klasifikacije!).

Slabosti nadzorovanih klasifikacij so (Campbell, 1996, 328 in 329):

- poznavalec določi kategorije (kar pomeni, da niso tako »naravne« kot pri metodah nenadzorovane klasifikacije),
- učne celice so določene na podlagi informacijskih kategorij in ne na podlagi spektralnih kategorij (torej številskih lastnosti podatkovnih slojev),
- učne celice lahko slabo ponazarjajo lastnosti celotnega območja (tudi kategorije, ki niso določene z učnimi celicami, ne moremo prepoznati).

Pri vseh nadzorovanih klasifikacijah je treba določiti učne celice, na podlagi katerih izdelamo pravila ali določimo spektralni podpis (tipične vrednosti) kategorije. Postopek določanja učnih celic (poglavje 4 in priloga 5) je obvezen prvi korak za vse metode nadzorovane klasifikacije v disertaciji.

3.2.1 Metoda najmanjše razdalje

Metoda najmanjše razdalje je preprosta, saj celice klasificira v tisto skupino, katere voditelj oziroma centroid je celici v večrazsežnostnem prostoru najbližji (razsežnosti je toliko, kot je številskih spremenljivk oziroma podatkovnih slojev). V programu Idrisi je metoda v modulu MINDIST (Idrisi Taiga, 2010). Metoda ne predvideva naključnosti celic (McCoy, 2005, 10). Metoda v programu Idrisi omogoča dve bolj podrobni nastavitvi: izbira med uporabo »surovih« vrednosti ali pa Z-vrednosti ter določitev največje razdalje od centroida, na kateri se lahko še izvede klasifikacija posamezne celice (Idrisi Taiga, 2010). Tako kot pri vseh ostalih metodah nadzorovane klasifikacije, moramo tudi tukaj najprej določiti učne celice, s pomočjo katerih izračunamo centroide – torej povprečja podatkovnih slojev po posameznih kategorijah klasifikacije.

3.2.2 Odločitveno drevo

Odločitvena drevesa spadajo med metode strojnega učenja. Pri gradnji odločitvenega drevesa izbiramo pojasnjevalne spremenljivke oziroma podatkovne sloje glede na oceno njihove informativnosti ter tako ustvarimo ustrezne podmnožice, iz katerih glede na njihove pripisane vrednosti sestavljamo odločitveno drevo oziroma povezano sosledje pravil. Z metodo lahko pojasnimo obstoječe podatke ter napovedujemo nove vrednosti (Kononenko, 2005, 2–3; Witten, Frank, 2005). Poglavitni namen odločitvenih dreves je, da na razumljiv način opišemo odnos med napovedano spremenljivko (tisto spremenljivko, katere vrednosti modeliramo, *objective variable*) in eno ali več pojasnjevalnimi spremenljivkami (*explanatory variable*). Odločitvena drevesa si vizualno dobro predstavljamo, pravila pa so jasno izražena, zato je rezultat lažje interpretirati kot na primer delovanje nevronske mreže, pri katerem je način delovanja skrit znotraj mreže in govorimo o »črni skrinjici« (Breskvar Žaucer, Marušič, 2006, 236; Saito, Nakayama, Matsuyama, 2009, 113). Odločitveno drevo (slika 113) je sestavljeno iz notranjih vozlišč, ki ustrezajo pojasnjevalnim spremenljivkam, vej, ki ustrezajo podmnožicam z vrednostmi pojasnjevalnih spremenljivk, in listov oziroma končnih vozlišč, ki ustrezajo vrednostim napovedane spremenljivke (Mitchell, 1997, 49; Kononenko, 2005, 129). Iz odločitvenega drevesa lahko razberemo pravilo za klasifikacijo enote preprosto tako, da potujemo od vrha drevesa do končnega vozlišča, vmes pa se ravnamo po izdelanih pravilih (Witten, Frank, 2005).

Gradnja drevesa je proces, pri katerem se dejansko uporabljajo univariatne razdelitve. Drevo se v splošnem gradi od začetka vse do konca po naslednjem principu (SPSS Statistics, 2010, 762):

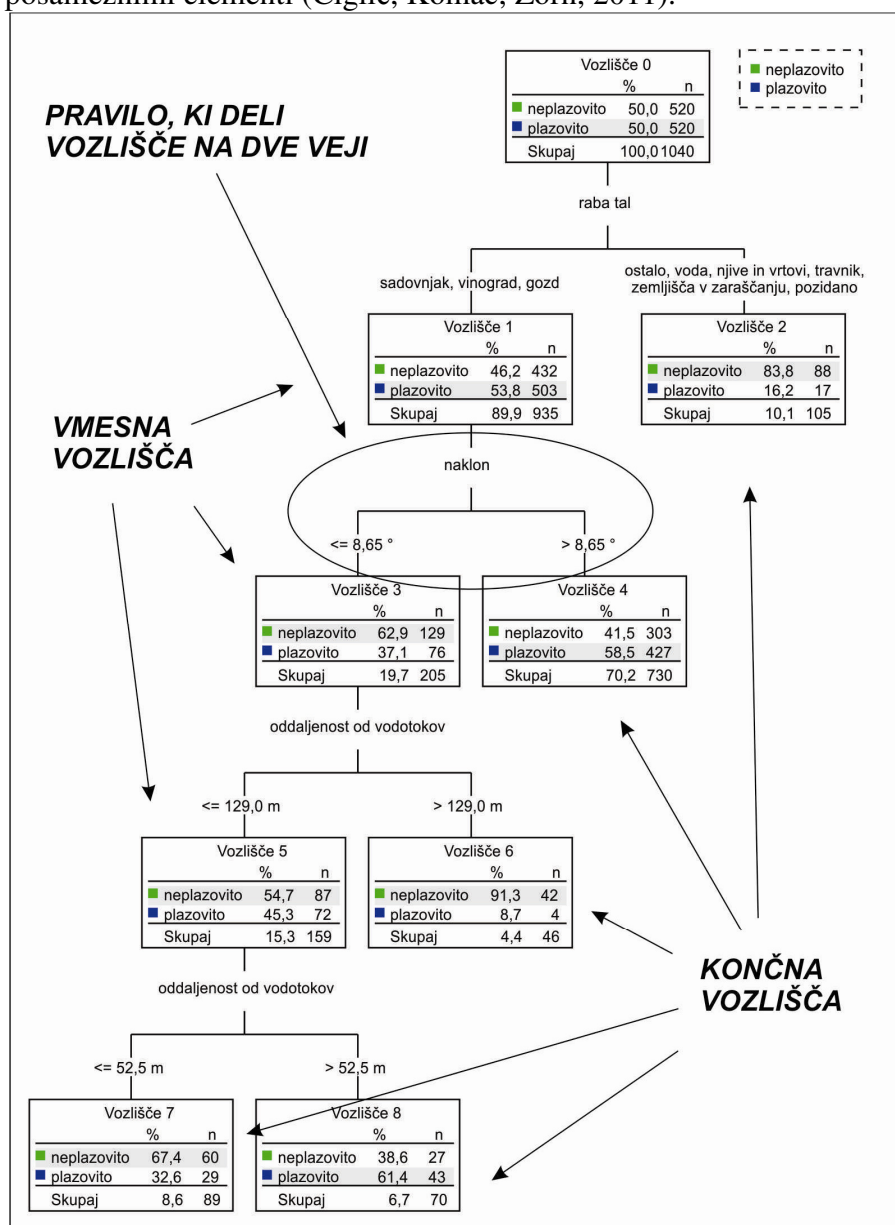
- za dano vozlišče poiskati najboljšo razdelitev za vsako od napovedovalnih spremenljivk,
- izmed vseh potencialnih delitev s prejšnje alineje izbrati najboljšo,
- razdeliti vozlišče.

Ta proces se med gradnjo drevesa nenehno ponavlja, dokler drevo ni zgrajeno. Na koncu se drevo lahko obreže (*pruning*).

Prednost odločitvenih dreves je, da niso vezana na predhodno verjetnostno porazdelitev odvisne in neodvisne spremenljivke, lahko vključujejo diskretne in zvezne spremenljivke, nanje ne vplivajo odvečne spremenljivke in šum, vključimo lahko tudi podatke z manjkajočimi vrednostmi. Računsko niso zahtevne, rezultate pa dokaj lahko interpretiramo. Visoka natančnost je lahko dosežena s kombinacijo različnih dreves (Breiman, 1996 cv: Dimitrovski s sod., 2012).

V nalogi smo uporabili različne načine izdelave odločitvenih dreves. Uporabili smo programa SPSS in Idrisi Taiga. V programu SPSS smo izdelali odločitveno drevo (različica CT), pri katerem se uporablja algoritem *Classification and Regression Trees* (CRT) in mera Ginijev koeficient. S programom Idrisi Taiga pa smo izdelali odločitvena drevesa (različica CTE, različica CTG, različica CTR), kjer algoritem *Classification Tree Analysis* (CTA) uporablja mere: informacijski prispevek (*Entropy*), Ginijev koeficient (*Gini*) in razmerje informacijskega prispevka (*Ratio*).

Slika 113: Primer odločitvenega drevesa za napovedovanje plazovitosti z označenimi posameznimi elementi (Ciglič, Komac, Zorn, 2011).



3.2.2.1 Odločitveno drevo (različica CT)

Zelo razširjen algoritem za gradnjo odločitvenih dreves je *Classification And Regression Tree*. Postopek poteka tako, da se najprej zgradi veliko in kompleksno drevo, ki se močno prilagaja učnim enotam (celicam), nato pa se z obrezovanjem drevo posploši (Lin, Noe, He, 2006, 556). Pri tem v vozliščih deli enote binarno, torej vsakič samo v dve skupini. Proces se ponavlja, dokler niso končna vozlišča dovolj »čista« oziroma določeni pogoji izpolnjeni – na primer ko dosežemo določeno število ravni ali pa dobimo minimalno število enot v listu (Lin, Noe, He, 2006, 556). Tudi tu moramo torej izbrati najbolj informativno spremenljivko in določiti mejo, na podlagi katere delimo enote, ter nato drevo obrezati. Za razdelitev se pogosto uporabljata dva možna pristopa: gradnja s pomočjo Ginijevega koeficienta (ta način smo uporabili v disertaciji) in gradnja s pravilom Twoing.

Ena izmed slabosti metode je ta, da pri gradnji drevesa raje izbira spremenljivke, ki omogočajo veliko število razdelilnih točk (*splitting points*). Zaradi tega so večkrat uporabljene številske spremenljivke kot pa nominalne.

Podroben opis metode odločitvenega drevesa (različica CT)

a) Gradnja drevesa

Za vsako pojasnjevalno spremenljivko x_j algoritem najde vrednost razdelitve, pri kateri je zabeležen največji upad mere nečistoče, na primer Ginijevega koeficienta⁵⁸ (Lin, Noe, He, 2006, 557; Yohannes, Webb 1999, 15):

$$\Delta i_j(t, m) = i(m) - [q_L i(m_L) + q_R i(m_R)],$$

Pri tem so:

$\Delta i_j(t, m)$ – razlika v meri nečistoče za delitev pri vrednosti t pojasnjevalne spremenljivke j in številu enot m ,

q_L in $i(m_L)$ – delež enot in mera nečistoče v levi veji,

q_R in $i(m_R)$ – delež enot in mera nečistoče v desni veji.

Algoritem pregleda vse pojasnjevalne spremenljivke z namenom, da najde najboljšo spremenljivko in najboljšo delitev te spremenljivke, torej kombinacijo j, t (Lin, Noe, He, 2006, 557). Mera nečistoče ima svoj minimum $i(m)=0$ takrat, ko so vse enote v vozlišču iz iste kategorije.

b) Določanje razreda vozlišča

Končno vozlišče oziroma list je klasificirano v tisti razred napovedane spremenljivke, ki predstavlja največji delež med vsemi kategorijami. Matematični zapis je:

$$k(m) = \arg \max_k [p_m(k)].$$

Lahko sicer klasificiramo tudi tako, da določimo vozlišče m v kategorijo k tako, da izberemo najmanjšo pričakovano ceno napačne klasifikacije (*misclassification cost*) za kategorijo k (Lin, Noe, He 2006, 556). Podroben opis tega lahko najdemo tudi v prispevku Yohannesa in Webba iz leta 1999 (str. 15) in v opisu algoritmov v programu SPSS (SPSS Statistics, 2010, 780). Po tem postopku moramo torej določiti, kakšna je »kazen« za napačno klasifikacijo posamezne kategorije. V nalogi tega načina nismo izbrali.

c) Obrezovanje drevesa (*pruning*)

Obrezovanje dreves je treba opraviti, ker so velika drevesa težja za interpretacijo, se preveč prilegajo učnim enotam in jih je zato težko prenesti na drug vzorec (Yohannes, Webb, 1999, 18). Obrezovanje je postopno; tako se naredi nabor dreves od najbolj kompleksnega (z največ vozlišči in listi) do tistega, ki ima vse enote v enem listu (Lin, Noe, He, 2006). Postopek iskanja dreves lahko poteka po načelu najšibkejšega člana (*weakest-link*) (Yohannes, Webb, 1999; Lin, Noe, He, 2006, 557 in 558). To pomeni, da se postopoma reže tam, kjer je razmerje med spremembo »cene« napačne klasifikacije (*misclassification cost*) zaradi *pruninga* in kompleksnostjo drevesa najmanjše (torej manjša je sprememba in večja je kompleksnost, bolj šibek je člen drevesa in hitreje ga program odreže) (Lin, Noe, He, 2006, 558). To se ponavlja, dokler ni drevo obrezano na osnovni list.

Izmed vseh obrezanih dreves se izbere tisto, ki ima najmanjšo napako klasifikacije (*classification error*; pravilo 0-SE). Alternativa je tudi, da se izbere najmanjše drevo po pravilu 1-SE, torej najmanjše drevo znotraj ene standardne napake najbolj natančnega in hkrati najbolj kompleksnega drevesa (*one standard error of the minimum error rate*) (Yohannes, Webb, 1999, 19; Lin, Noe, He, 2006, 558). Napaka klasifikacije (*classification error*) za posamezno drevo se lahko oceni na podlagi testnega vzorca ali pa s prečnim preverjanjem (*V-fold cross-validation*), ocenimo lahko tudi na podlagi enot, s katerimi smo

⁵⁸ Ko iščemo spremenljivko in vrednost te spremenljivke, na podlagi katere razdelimo enote (na primer celice) v dve skupini (vozlišči), iščemo taki skupini, ki bosta čim bolj »čisti«, oziroma želimo čim bolj znižati vrednost Ginijevega koeficienta (Lin, Noe, He, 2006, 556). Mera nečistoče Ginijev koeficient favorizira spremenljivke z več vrednostmi (Kononenko, 2005).

izdelali drevo (Lin, Noe, He, 2006, 558; SPSS Statistics, 2010, 796). Slednji način je primeren predvsem, če nimamo velike podatkovne baze (Yohannes, Webb 1999, 13).

Odločitveno drevo (različica CT) v programu SPSS

V programu SPSS algoritem deluje v splošnem tako, kot je opisano v prejšnjih odstavkih. V SPSS-u lahko določamo najmanjše število enot v vozliščih (vmesnih in končnih), število ravni, način izračuna mere nečistoče (v našem primeru Ginijev koeficient) in najmanjšo zahtevano razliko v informacijski vrednosti. Imamo tudi možnost vključiti ali izključiti obrezovanje drevesa. Pri obrezovanju imamo možnost določiti, v kakšnem razmaku (izraženo v standardni napaki) od drevesa z minimalno klasifikacijsko napako lahko iščemo najmanjše drevo. Odločimo se lahko tudi, ali bomo uporabili oceno natančnosti ter kakšno (brez ločenega testnega vzorca, prečno preverjanje ali z ločenim testnim vzorcem).

3.2.2.2 Odločitvena drevesa (različice CTE, CTG in CTR)

Algoritem je na voljo v programu Idrisi Taiga (modul CTA). Metoda v programu je zasnovana tako, da lahko uporablja samo številske spremenljivke oziroma podatkovne sloje, čeprav bi lahko nevedni uporabniki dejansko vključili tudi nominalne podatkovne sloje s številske oznakami. Pri tej metodi se na podlagi učnih celic izdelava odločitveno drevo s pomočjo binarnih delitev. Kot mera čistoče se lahko uporabijo informacijski prispevek (različica CTE), razmerje informacijskega prispevka (različica CTR) in Ginijev koeficient (različica CTG). Razdeljevanje vozlišč se nadaljuje, dokler niso ta »čista«. Pri obrezovanju drevesa se izločijo končna vozlišča, ki imajo delež razreda manjši od določenega praga, torej se končna vozlišča, ki niso dovolj »čista«, obrežejo (Idrisi Taiga, 2010). Ob tem naj opozorimo, da je kljub uporabi enake mere nečistoče (Ginijev koeficient) rezultat zaradi drugačnega načina obrezovanja in drugih lastnosti v programu Idrisi Taiga drugačen kot pa pri gradnji odločitvenega drevesa v SPSS.

3.2.3 Metoda največje verjetnosti

Metoda največje verjetnosti (*maximum likelihood classification*) je ena izmed najpogosteje uporabljenih metod klasifikacije satelitskih posnetkov (Richards, Jia, 2006, 194) in temelji na Bayesovem teoremu (*Bayesian Probability Theory*). Osnovna teorija je izražena s formulo (Eastman 2009, 162):

$$p(h|e) = \frac{p(e|h) * p(h)}{\sum_i p(e|h_i) * p(h_i)}$$

Pri tem je:

$p(h|e)$ – posteriorna verjetnost; verjetnost dogodka h (hipoteze), če se zgodi dogodek e ,
 $p(e|h)$ – verjetnost, da se je zgodil dogodek e , če je dogodek h resničen (pogojna verjetnost),
 $p(h)$ – verjetnost dogodka h ne glede na dogodek e (apriorna verjetnost).

Podroben opis postopka klasifikacije po metodi največje verjetnosti

Postopek največje verjetnosti je opisan po Richardsu in Jiau (2006, 194–201). Pri klasifikaciji celice \mathbf{x} nas zanima sledeča verjetnost (pogojna verjetnost):

$$p(\omega_i|\mathbf{x}), i = 1, \dots, M$$

Pri čemer je ω_i razred (spektralni razred v primeru obdelave satelitskih slik) in \mathbf{x} vektor celice. Verjetnost $p(\omega_i|\mathbf{x})$ daje verjetnost, da je pravi razred ω_i za celico na poziciji \mathbf{x} . Klasifikacija je izvedena:

$$\mathbf{x} \in \omega_i, \text{ če } p(\omega_i|\mathbf{x}) > p(\omega_j|\mathbf{x}) \text{ za vse } j \neq i.$$

S trening celicami lahko določimo $p(\mathbf{x}|\omega_i)$ ali verjetnost, da je na vrednosti oziroma poziciji \mathbf{x} razred ω_i .

Za vrednost \mathbf{x} se lahko tako izračuna set verjetnosti posameznih razredov s pomočjo Bayesovega teorema:

$$p(\omega_i|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_i) * p(\omega_i)}{\sum_{i=1}^M p(\mathbf{x}|\omega_i) * p(\omega_i)}$$

Spodnji del zgoraj navedene enačbe ni pomemben (za podrobneje glej Richards, Jia, 2006, 195). Iz preostalega dela pa je izračunana diskriminančna funkcija $g_i(\mathbf{x}) = \ln p(\mathbf{x}|\omega_i) + \ln p(\omega_i)$.

Klasifikacija po metodi največje verjetnosti uporablja sledečo enačbo, ki ji pravimo diskriminančna funkcija g :

- če poznamo apriorno verjetnost:

$$g_i(\mathbf{x}) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\mathbf{x} - \mathbf{m}_i)^t \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i)$$

- če apriorne verjetnosti ne poznamo:

$$g_i(\mathbf{x}) = -\ln |\Sigma_i| - (\mathbf{x} - \mathbf{m}_i)^t \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i)$$

Kjer je \mathbf{m}_i povprečje vektorja (*mean vector*) in Σ_i kovariančna matrika.

Nato pa sledi primerjava:

$$\mathbf{x} \in \omega_i \text{ if } g_i(\mathbf{x}) > g_j(\mathbf{x}) \text{ za vse } j \neq i.$$

Postopek v programu Idrisi Taiga

Pred samim postopkom klasifikacije moramo najprej določiti učne celice, s katerimi izdelamo spektralne podpise. Podpisi imajo statistično informacijo vsakega območja za vsak sloj.

V programu Idrisi je metoda največje verjetnosti na voljo v modulu MAXLIKE. Ta modul na podlagi povprečja in kovariančne matrike spektralnih podpisov (narejenih z učnimi celicami) za vsako posamezno celico izračuna verjetnost pripadnosti posamezni kategoriji. MAXLIKE v svojih izračunih upošteva morebitno povezanost med sloji (Eastman, 2009). Poleg tega lahko vključimo tudi apriorno (ali prvotno) verjetnost. Ta pove, kolikšna je možnost, da se določena kategorija pojavi v rezultatu klasifikacije, še preden zaženemo klasifikacijo. V modulu MAXLIKE jo lahko vključimo na različne načine (Idrisi Taiga, 2010), a v nalogi te možnosti nismo uporabili. Navadno lahko to določimo na podlagi predpostavk o deležu površine, ki ga pokrivajo posamezne kategorije. Na koncu določimo minimalno število celic v razredu. Pri metodi največje verjetnosti je treba še opozoriti, da je že majhna verjetnost dovolj, da je celica klasificirana v neko kategorijo, saj metoda ne predpostavlja, da obstajajo tudi kategorije, ki niso v spektralnih podpisih. V modulu imamo zato dodano možnost, da lahko takšne celice pustimo neklasificirane.

3.2.4 Metoda najbližjih sosedov

Metoda najbližjih sosedov (*k-nearest neighbors*) je dokaj preprosta. Ko napovedujemo razred novi celici, poiščemo k na podlagi vrednosti spremenljivk najbližjih učnih celic in določimo večinsko kategorijo, torej kategorijo, ki mu pripada največ k najbližjih sosedov (Kononenko, 2005, 292). Če so v učnih primerih napake, je dobro, da povečamo število najbližjih sosedov in tako zmanjšamo možnost zajema »napačnega« sosedu. Hkrati pa lahko s prevelikim številom najbližjih sosedov pri klasifikaciji upoštevamo tiste sosednje celice, ki niso v bližini in niso podobne celici, ki jo klasificiramo. Število najbližjih sosedov k se določa eksperimentalno. Za razdaljo se pogosto uporablja Evklidova (Kononenko, 2005, 292–293). Kot primer uporabe metode lahko navedemo McRobertsovo (2012) raziskavo.

Metoda najbližjih sosedov v programu Idrisi Taiga

V programu Idrisi Taiga je metoda najbližjih sosedov v modulu KNN. Ta za določitev kategorije celice uporabi k najbližjih sosednjih celic iz nabora učnih celic. Celica, ki jo

klasificiramo, se klasificira v tisto kategorijo, ki je ob pregledu k najbližjih učnih celic prevladujoča (Idrisi Taiga, 2010). Pri metodi KNN je treba paziti, da so učni vzorci približno enako veliki za vse kategorije! Tudi število najbližjih sosedov vpliva na rezultat. Pri modulu KNN izberemo datoteko s podpisi (lastnosti učnih celic) ter število najbližjih sosednjih celic, na podlagi katerih vsaki celici določimo kategorijo. Nastaviti moramo tudi največje dovoljeno število učnih celic na kategorijo.

3.3 Metode mehke nadzorovane klasifikacije

V nalogi smo uporabili tudi mehke različice metod najbližjih sosedov, odločitvenih dreves (različic CTE, CTG, CTR), največje verjetnosti in metode najmanjše razdalje. Vse z izjemo zadnje metode mehke klasifikacije so bile izpeljane v programu Idrisi Taiga.

3.3.1 Mehka različica metode najmanjše razdalje

V programu SPSS smo za učne celice izračunali povprečja vseh podatkovnih slojev za vse kategorije. Tako smo dobili centroide kategorij za učne celice. Nato smo izračunali oddaljenost vsake celice od centroida vsake kategorije. Tako smo za vsako celico dobili podatek, za koliko je oddaljena od povprečne vrednosti posamezne kategorije; za vsako kategorijo smo dobili zemljevid, ki je prikazal oddaljenost celic od povprečja (centroida) kategorije (tipa) v večrazsežnostnem prostoru spremenljivk.

3.3.2 Mehka različica metode odločitvenih dreves različic CTE, CTG in CTR

Trdna metoda je opisana v enem izmed prejšnjih poglavij te priloge. Pri mehki različici dobimo za vsako kategorijo po en zemljevid, na katerem je prikazana stopnja pripadnosti celice posamezni kategoriji. Stopnja pripadnosti dejansko pomeni delež kategorije v končnem vozlišču, v katerega je bila klasificirana celica (Idrisi Taiga 2010).

3.3.3 Mehka različica metode največje verjetnosti

Trdna metoda največje verjetnosti je opisana v enem izmed prejšnjih poglavij te priloge. Njena mehka različica je v Idrisiju na voljo v modulu BAYCLASS. Pri tej metodi se za vsako celico izračuna verjetnost pripadnosti posamezni kategoriji. Po uporabi tega modula računalnik izdela zemljevide pripadnosti za vsako kategorijo. Če bi vse te zemljevide analizirali in bi naredili zemljevid, na katerem bi celici pripisali kategorijo, ki imajo izmed vseh kategorij največjo verjetnost, bi dobili rezultat modula MAXLIKE. BAYCLASS predpostavlja, da so kategorije, ki so v spektralnem podpisu, edine možne (Idrisi Taiga, 2010; Eastman, 2009).

3.3.4 Mehka različica metode najbližjih sosedov

Delovanje trdne različice te metoda je opisano v enem izmed prejšnjih poglavij te priloge. Pri mehki klasifikaciji po tej metodi dobimo toliko zemljevidov, kot je kategorij. Posamezni celici se na posamičnem zemljevidu pripiše delež najbližjih sosedov, ki pripadajo posamezni izmed vseh možnih kategorij (Idrisi Taiga, 2010).

Priloga 5: Nasveti za izbiranje učnih celic

V literaturi je kar nekaj priporočil za zajemanje učnih območij oziroma celic, ki jih lahko izberemo na več različnih lokacijah – učnih poljih (Warner, Campagna, 2009; Idrisi Taiga, 2010; Campbell, 1996, 329–333; Lillesand, Kiefer, Chipman, 2008, 557–560; McCoy, 2005, 12–24; Eastman, 2009; Richards in Jia, 2006, 199; Loveland, Merchant, 2004, 4):

- pri izbiri učnih polj moramo izbrati takšna, ki so v osredju že znanih enot, saj je v osrednjih delih enot (regij ali tipov) homogenost največja in najbolj očitna; obrobje je namreč tisti del, kjer se lahko pojavijo nejasnosti,
- dobro je imeti čim večje število celic, v vzorcu pa morajo biti zajete vse kategorije,
- izbrati tipična učna območja; učna območja morajo biti čim bolj homogena (po možnosti z unimodalno porazdelitvijo), hkrati pa naj obsegajo tudi razpon tipičnih vrednosti za izbrano kategorijo,
- učna območja morajo biti reprezentativna,
- učna območja posameznih kategorij morajo obsegati dovolj celic; učnih celic mora biti teoretično vsaj $n + 1$ (n je število podatkovnih slojev), dobro pa je, da jih je za posamezno kategorijo vsaj 10-krat ali 100-krat toliko kot podatkovnih slojev,
- učna območja naj bi obsegala vsaj 100 celic na kategorijo,
- učna območja morajo biti dovolj velika, hkrati pa posamezno učno polje ne sme biti preveliko,
- posamezna učna polja za eno kategorijo naj imajo 10–40 celic,
- velikost učnih polj je odvisna tudi od heterogenosti pokrajine, zato enotnega pravila ni,
- pri določanju velikosti učnih polj si lahko pomagamo z enačbo (Justice, Townshed, 1981 cv: McCoy, 2005, 23): $A=P(1 + 2L)$; A je velikost učnega polja, P je velikost celice, L je lokacijska natančnost, izražena v številu celic,
- oblika učnih območij ni pomembna, čeprav bi lahko učna območja, ki so določena v zaokroženih poljih, podcenila variabilnost znotraj kategorije in precenila razlike med kategorijami,
- izkušnje kažejo, da je bolje določiti več manjših učnih polj za posamezno kategorijo kot pa le nekaj velikih,
- učna polja naj imajo vsaj 3 krat 3 celice,
- če so učna območja določena naključno (in ne kot večji poligoni) znotraj razredov, je efekt podobnosti minimiziran in se klasifikacija izboljša,
- če je znotraj informacijskega razreda več spektralnih razredov, morajo biti slednji vsi dovolj dobro zastopani z učnimi celicami⁵⁹,
- učna območja se lahko določajo tudi s poskušanjem,
- izogibati se je treba izbiranju učnih celic blizu meje kategorij, zato lahko učna polja oziroma območja celic, ki so na robu oziroma sežejo čez robove, zavrremo, četudi je zato naključnost nekoliko zmanjšana; celice lahko zavrremo tudi zaradi nedostopnosti (pri terenskem delu), a to je že večji vpliv na naključnost.

Za izboljšanje nabora učnih celic lahko uporabimo več postopkov (Lillesand, Kiefer, Chipman, 2008, 560–567):

- uporaba histograma, s katerim lahko ugotovimo, ali je v katerem vzorcu učnih celic več spektralnih razredov za posamezen podatkovni sloj (večmodalna porazdelitev!),
- uporaba grafikonov (*coincident spectral plot*), s katerimi vidimo, kje se vrednosti posameznih kategorij za posamezni podatkovni sloj prekrivajo,
- uporaba razsevnega grafikona,

⁵⁹ Več spektralnih razredov je lahko znotraj enega informacijskega razreda in en spektralni razred lahko vsebuje več informacijskih razredov (McCoy, 2005, 14).

- predhodna klasifikacija samih učnih celic in pregled matrike napak (*error matrix*),
- predhodna klasifikacija dela območja.

V nekaterih primerih lahko vzorčimo s pomočjo letalskih posnetkov, če ni druge izbire, lahko uporabimo tudi digitalne zemljevide na računalniškem zaslonu (McCoy, 2005, 13). Lahko se opremo tudi na rezultate nenadzorovanih klasifikacij, v katerih poiščemo homogena območja (Repe, 2006, 160). »Podatkov o lokacijah vzorcev, pridobljenih z ekspertnim načrtom, v glavnem primerov, ne moremo uporabiti za nadaljnje statistične analize, ker večina le teh zahteva naključno izbrane lokacije« (Lillesand, Kiefer, 1994 cv: Repe, 2006, 162; McCoy, 2005 cv: Repe, 2006, 162). Pri ekspertnem določanju učnih območij poznavalec sam izbere območja, ki imajo jasno identiteto (znano kategorijo). Tudi takšna območja morajo imeti tipične spektralne značilnosti kategorije, ki jo predstavljajo, in morajo biti homogena (Campbell, 1996, 328).

Priloga 6: Pregled naravnih dejavnikov in podatkovnih slojev

Pri opisu smo za vsak dejavnik izpostavili, kakšno vlogo ima pri klasifikaciji pokrajin, nato smo preučili njegove značilnosti v Sloveniji, na koncu pa smo dodali informacijo o tem, kateri podatkovni sloji so na voljo za območje Slovenije. Opisali smo naslednje dejavnike ter pripadajoče podatkovne sloje:

1. podnebje,
2. relief,
3. kamninska sestava,
4. prst,
5. vodovje,
6. rastje,
7. živalstvo,
8. antropogeni dejavniki.

1 Podnebje

Podnebje je osnovni naravni dejavnik za določanje razlik v okolju na kontinentalni ravni (Klijn, Udo de Haes, 1994). Podnebni pas je največja enota v klimatogeografskem smislu. Kot posledica oceanskih, celinskih in orografskih vplivov se podnebni pasovi ločijo na podnebna območja (Tarábek, 1972; Bailey, 1996). Podnebje je bistveno za ekologijo (Mücher s sod., 2003, 19) ter kot vir energije in vode igra glavno vlogo za razporeditev ekosistemov. Prst in živi svet sta funkciji podnebja in izoblikovanosti površja. Zaradi tega se podnebje ponuja kot glavni kriterij, takoj za njim pa izoblikovanost površja (Bailey, 1996, 39). Podnebje vpliva tudi na reliefne oblike in erozijo, življenjske (letne) cikle ter produktivnost rastlin. Dejavniki, ki vplivajo na podnebje, se na različnih ravneh spreminjajo (Bailey, 1996, 157). Na primer na temperaturo zraka vplivajo zemljepisna širina, oddaljenost od morja, nadmorska višina, izoblikovanost, naklon in ekspozicija površja, rastje, stopnja urbaniziranosti ter značilnosti tal, kot so albedo, toplotna kapaciteta in podobno (Cegnar, 1998, 100).

Poleg temperature, količine padavin in raznih drugih klimatskih podatkov lahko za prikaz podnebnih značilnosti uporabimo tudi nekatere izpeljane podatke. Bližino oceana lahko na primer prikažemo tudi s t.i. oceanskostjo, ki jo je uporabil Metzger s sodelavci (2005, 553), in sicer tako, da je od julijske temperature odštel januarsko ter delili s sinusom geografske širine. Za območje Slovenije popravka zaradi geografske širine ne bi potrebovali⁶⁰. Izpeljani podatek, kot je podnebni režim, je zelo uporaben tudi zaradi gorskih območij. Gorska območja namreč nimajo enakega podnebja kot sosednja nižinska, vendar imajo enak podnebni režim (Bailey, 1996, 69 in 70).

S tega vidika bi bilo za podnebje dobro uporabiti podatke o:

- padavinskem režimu (na primer indeks mediteranskosti padavin po Ogrinu (1996)),
- letni količini padavin,
- povprečni temperaturi najhladnejšega meseca,
- povprečni temperaturi najtoplejšega meseca,
- razmerju med oktobrskimi in aprilskimi temperaturami ter
- razliko med julijskimi in januarskimi temperaturami (letna temperaturna razlika).

Indeks mediteranskosti padavin omogoča razmejitev glede padavinskega režima (Ogrin, 1996). Po Ilešiču (1970 cv: Ogrin, 1996) bi lahko uporabili tudi razmerje med količino padavin v hladni (od oktobra do marca) in topli polovici leta (od aprila do septembra). Padavinski režim lahko računamo tudi iz razmerja med poletnimi in jesenskimi padavinami (Zupančič, 1998) ali pa razmerja med poletnimi in zimskimi padavinami (Ogrin, 1998).

⁶⁰ Izračunana vrednost sinusa geografske širine za skrajno severno točko ($46^{\circ}53'$) se od vrednosti sinusa za skrajno južno točko ($45^{\circ}25'$) razlikuje le za 0,02.

Razmere v Sloveniji

Vreme in podnebje v Sloveniji sta prostorsko in časovno zelo spremenljiva. Vzrok za to je lega v zmernih geografskih širinah sorazmerno blizu Atlantskega oceana in vpliva zahodne zračne cirkulacije. Pomembna sta tudi relief ter lega na prehodu med Sredozemljem in Evrazijsko celino (Ogrin, 2009, 73). Te lastnosti lahko podpremo tudi z dejstvom, da so Metzger in sodelavci (2005) pri izdelavi svoje evropske klasifikacije Evropo najprej razdelili na dva dela na podlagi podnebja; meja med njima je potekala tudi prek Slovenije! To pomeni, da je za klasifikacijo Slovenije treba upoštevati tudi podnebni režim, ki je sicer bolj uporaben za klasifikacijo večjih območij.

V Sloveniji so trije osnovni podnebni tipi: submediteransko podnebje, zmernocelinsko podnebje in gorsko podnebje. Osnovni podnebni tipi se delijo na devet podtipov na podlagi padavinskega režima, povprečne temperature najhladnejšega meseca, povprečne temperature najtoplejšega meseca ter razmerja med oktobrskimi in aprilskimi temperaturami (Ogrin, 1996). Najbolj sredozemske padavinske razmere so v Snežniškem pogorju, Karavankah in v zahodni Sloveniji, torej kjer je vpliv zahodne cirkulacije največji, najbolj kontinentalne padavinske razmere pa ima severna in severovzhodna Slovenija. Na podlagi indeksa mediteranskosti padavin (obdobje 1961–1990) poteka meja kontinentalnosti padavin po liniji vzhodne Kamniško-Savinjske Alpe–Ljubljana–Suha krajina–severna Bela krajina (Ogrin, 1996), a je treba dodati, da je *»razmejitev Slovenije glede padavinskega režima zahtevna naloga, ker je v bistvu vsa Slovenija prehodno območje, brez izrazite ločnice, med omiljenim sredozemskim in omiljenim celinskim režimom. Celinskost padavin narašča v smeri od juga in zahoda proti vzhodu in severovzhodu«* (Ogrin, 1996, 41). Sicer pa dobijo kraji v bližini morja največ padavin jeseni, kraji v severovzhodni Sloveniji s celinskim podnebnem pa poleti. Največ padavin (več kot 2500 mm) pade v višjem delu na zahodu in jugozahodu države, letna količina padavin pa se zmanjšuje z oddaljenostjo od morja; ob meji z Madžarsko je manj kot 900 mm padavin (Zupančič, 1998, 98). Povprečna letna temperatura je v nižjih delih celinske Slovenije med 8 in 10 °C, v nižjih Obpanonskih pokrajinah ter v zalednih Obsredozemskih pa med 10 in 12 °C. V hribovitem svetu se giblje med 4 in 8 °C (Ogrin, 2009, 78). Največje razlike med maksimalnimi in minimalnimi temperaturami so v severovzhodni Sloveniji, kjer je celinski vpliv najmočnejši. Temperaturne razmere v visokogorju so podobne razmeram v prostem ozračju z manjšimi letnimi in dnevnimi razponi kot v nižinah (Cegnar, 1998, 100). Najvišji deli Slovenije imajo najnižjo temperaturo v letu februarja in ne januarja kot ostalo ozemlje (Ogrin, 2009). Na temperaturo zraka v Sloveniji vplivajo predvsem relief, morje in raba tal. Pri tem je nadmorska višina pomembnejša od oddaljenosti od morja; za povprečno letno temperaturo velja, da se na splošno znižuje za -0,53 °C na 100 m. Poleg višine je za temperature pomembna tudi konkavnost, saj imajo depresije nižje minimalne temperature zaradi pojava temperaturnega obrata (Ogrin, 2009, 77). Takšno »anomalijo« v poteku temperatur z višino je mogoče odpraviti z izračuni že omenjenih temperaturnih režimov. Trajanje sončnega obsevanja je poleti najdaljše ob obali, najkrajše pa v gorah; pozimi pa je največ sončnih ur v višjem delu Slovenije, najmanj pa v kotlinah. Jeseni imajo kotline prav tako najmanj ur, v tem času jih imajo največ ob obali. Tam je poleg severovzhodne Slovenije največ ur tudi spomladi (Dolinar, 2006). Po količini prejete energije kvaziglobalnega sončnega obsevanja je na prvem mestu Slovenija s submediteranskim podnebjem z več kot 4300 MJ/m², na zadnjem mestu pa je del Slovenije z gorskim podnebjem, ki v povprečju prejme nekaj več kot 3700 MJ/m². Razlike so večje glede na ekspozicijo (severna manj kot 3500 MJ/m², južna več kot 4400 MJ/m²) (Gabrovec, 1996).

Podatkovni sloji

Problem pri podnebjem kot kriteriju za klasifikacijo pokrajine je predvsem, da zanj obstajajo večinoma le točkovni podatki (Mücher s sod., 2003, 19). Na Agenciji Republike Slovenije za

okolje so pripravili podatkovne sloje z ločljivostjo 1 km za podatke o povprečni mesečni in letni temperaturi ter povprečni mesečni in letni količini padavin (Dolinar, 2004; Agencija RS za okolje, 2010). To omogoča tudi uporabo podnebnih podatkov (osnovnih in izpeljanih) za namen klasifikacije pokrajine. Tu je treba izpostaviti, da se podnebje spreminja. Zato je pri vsaki izdelani klasifikaciji treba navesti, v katerem obdobju so bili podnebni podatki izmerjeni. Da so padavinski režimi bolj variabilni kot temperaturni, je opozoril tudi Ogrin (1996, 43). Glede na to da je v literaturi omenjenih več načinov ugotavljanja padavinskih režimov, smo za vsakega izdelali rastrski podatkovni sloj in jih primerjali. Izračunali smo:

- indeks mediteranskosti padavin⁶¹ (oznaka PADRAZM) (Ogrin (1996),
- razmerje med količino padavin v jesenskih mesecih in količino padavin v poletnih mesecih⁶² (oznaka PADRAZPJ) (Zupančič, 1998),
- razmerje med količino padavin v zimskih mesecih in količino padavin v poletnih mesecih (oznaka PADRAZPZ) (Ogrin, 1998),
- razmerje med količino padavin od oktobra do marca in količino padavin od aprila do septembra (oznaka PADRAZOM_AS) (Ilešič, 1970 cv: Ogrin, 1996, 42),
- razmerje med količino padavin v oktobru in novembru ter količino padavin v maju in juniju (oznaka PADRAZON_MJ).

Med različnimi padavinskimi režimi je bila ugotovljena visoka stopnja povezanosti (preglednica 126), zato lahko uporabimo praktično katerega koli. Glede na veliko stopnjo povezanosti za analize v nalogi zadostuje en padavinski režim.

Preverili smo tudi povezanost z letno temperaturno amplitudo in razliko v temperaturi med oktobrom ter aprilom (preglednica 13 v poglavju 6). Vsi izračunani Pearsonovi in Spearmanovi koeficienti so bili okoli 0,7 (statistično značilno pri $p=0,01$).

Poleg tega smo primerjali tudi izračune indeksa mediteranskosti za obdobje 1961–1990 in obdobje 1971–2000 za 31 padavinskih postaj po Sloveniji (preglednica 127). Ugotovili smo, da so med obdobjema opazne razlike (indeksi mediteranskosti so za obdobje 1971–2000 z eno izjemo povsod višji), izračunana stopnja povezanosti med obema obdobjema pa je vseeno zelo visoka (slika 114). To pomeni, da se podnebne značilnosti sicer spreminjajo, razmerja med območji pa med večino postaj ostajajo približno enaka.

⁶¹ Indeks mediteranskosti padavin se izračuna tako, da od količine padavin v oktobru in novembru odštejemo količino padavin v maju in juniju, razliko pa nato delimo z letno količino padavin in pomnožimo s 100 (Koppany, Unger, 1992 cv: Ogrin, 1996, 42).

⁶² Seštevek poletnih padavin delimo s seštevkom jesenskih padavin.


Preglednica 126: Pearsonovi (prva vrstica) in Spermanovi koeficienti (druga vrstica) stopnje povezanosti različnih padavinskih režimov ($p=0,01$).

	razmerje med padavinami v jesenskih mesecih in padavinami v poletnih mesecih	razmerje med padavinami v zimskih mesecih in padavinami v poletnih mesecih	indeks mediteranskosti padavin	razmerje med padavinami od oktobra do marca in padavinami od aprila do septembra	razmerje oktoberr in november : maj in junij
razmerje med padavinami v jesenskih mesecih in padavinami v poletnih mesecih	1	0,960	-0,962	-0,962	-0,953
	1	0,960	-0,966	-0,982	-0,967
razmerje med padavinami v zimskih mesecih in padavinami v poletnih mesecih		1	-0,888	-0,968	-0,882
		1	-0,896	-0,981	-0,898
indeks mediteranskosti padavin			1	0,937	0,996
			1	0,957	1,000
razmerje med padavinami od oktobra do marca in padavinami od aprila do septembra				1	0,943
				1	0,958

Preglednica 127: Indeks mediteranskosti za dve obdobji (Zupančič, 1995; Klimatološka povprečja ..., 2012).

padavinska postaja	indeks mediteranskosti		razlika med indeksoma
	1971–2000	1961–1990	
Postojna	4,0	2,3	1,8
Bilje	3,3	3,1	0,2
Nova vas	2,7	1,0	1,7
Ljubljana	1,2	-1,9	3,2
Brnik	1,9	0,3	1,6
Kočevje	3,7	2,5	1,2
Stara Fužina	6,9	6,6	0,3
Ratece	2,1	1,2	1,0
Planina pod Golico	1,8	1,5	0,4
Kredarica	1,4	0,2	1,2
Lesce	3,8	3,1	0,7
Vojsko	7,2	7,0	0,2
Slap	4,2	2,6	1,7
Nanos-Ravnik	3,2	1,1	2,1
Godnje	3,6	2,7	0,8
Portorož	6,1	2,5	3,6
Ilirska Bistrica	5,2	5,3	-0,1
Črnomelj	3,5	1,5	2,0
Novo mesto	0,3	-1,3	1,6
Sevno	-0,6	-3,0	2,4
Bizeljsko	-0,7	-2,1	1,4
Celje	-0,4	-3,2	2,8
Slovenske Konjice	-1,2	-3,4	2,2
Velenje	-1,4	-3,4	2,0
Šmartno pri Slovenj Gradcu	-2,2	-3,4	1,2
Maribor	-1,8	-3,2	1,3
Polički Vrh	-3,1	-4,0	0,9
Jeruzalem	-2,2	-2,9	0,7
Podgradje	-1,5	-2,7	1,2
Murska Sobota	-4,3	-4,9	0,6
Veliki Dolenci	-6,0	-6,3	0,3

Slika 114: Primerjava indeksa mediteranskosti za dve obdobji (Zupančič, 1995; Klimatološka povprečja ..., 2012).



2 Relief

Izoblikovanost površja je pomemben kriterij za določanje manjših enot znotraj makroekosistemov, saj spreminja podnebne režime znotraj makroklimatskih con (Bailey, 1996, 157). Relief, zlasti višina, vpliva na rastje tako na majhnem območju kot tudi v svetovnem merilu (Bailey, 1996). Repe (2010, 108) je opozoril na velik pomen reliefa, saj se le-ta uporablja pri izračunu količine vode v prsteh ter tudi pri interpolaciji podnebnih spremenljivk. Izoblikovanost površja je povezana z ostalimi sestavinami pokrajine; pomembno vpliva na rastje, ki je najbolj viden pokazatelj naravnih razmer v pokrajini, ter na prebivalstvo. Na drugi strani pa na relief vplivajo kamnine.

Površje lahko opisujemo na različne načine. Perko (2007a) je navedel tri temeljne geometrične lastnosti: oddaljenost, nagnjenost in ukrivljenost. Z analizo digitalnega modela višin (DMV) lahko ugotovimo:

- oddaljenost glede na vodoravno ravnino oziroma nadmorsko višino,
- oddaljenost glede na navpično ravnino,
- nagnjenost glede na vodoravno ravnino oziroma naklon,
- nagnjenost glede na navpično ravnino oziroma ekspozicijo,
- ukrivljenost glede na vodoravno ravnino,
- ukrivljenost glede na navpično ravnino.

Z analizo DMV-ja lahko ugotovimo tudi prostorsko spremenljivost navedenih podatkov površja, najbolj pa so uporabni⁶³ (Perko, 2007a, 47):

- lokalni in regionalni koeficient višinske razgibanosti površja,
- lokalni in regionalni koeficient naklonske razgibanosti površja,
- lokalni in regionalni koeficient ekspozicijske razgibanosti površja in
- lokalni in regionalni koeficient skupne razgibanosti površja⁶⁴.

Poleg navedenih se pogosto uporabljajo tudi drugi kazalci (Iwahashi, Pike, 2007), recimo tekstura površja. Ta se izračuna tako, da se s pomočjo matrike 3 krat 3 celice izračuna mediano za vsako osrednjo celico v matriki. Ta sloj se nato odšteje od izvirnega

⁶³ Manj uporabni so lokalni in regionalni koeficient vodoravne razgibanosti površja glede na oddaljenost površja ter lokalni in regionalni koeficient vodoravne in navpične razgibanosti površja glede na ukrivljenost (Perko, 2007a, 47).

⁶⁴ Koeficient skupne razgibanosti površja je geometrična sredina koeficienta naklonske in ekspozicijske razgibanosti površja (Perko, 2007a, 77).

podatkovnega sloja višin; tako se dobi sloj, v katerem izstopajo slemena in dna dolin. Vsem celicam z izbrano vrednostjo, na primer nad 0,5 m in pod -0,5 m, se pripiše vrednost 1, ostalim vrednost 0. Nato s pomičnim krogom z izbranim polmerom izračunamo pogostost pojavljanja teh celic (z vrednostjo 1). Na koncu izračunamo delež pojavljanja razčlenjenega površja tako, da vrednost celice (seštevek vseh vrednosti 1 znotraj kroga) delimo s številom vseh celic v krogu. Vrednosti so podane v odstotkih (Iwahashi, Pike, 2007).

Višina, višinska razgibanost, naklon, naklonska razgibanost, ekspozicija in ekspozicijska razgibanost površja vplivajo na naravne dejavnike v Sloveniji (Perko, 2007a, 85). Perko (2001, 88–91) je dokazal povezanost nadmorske višine, naklona in ekspozicij z različnimi naravnimi dejavniki za območje Slovenije: razgibanostjo, kamninami in rastjem. Vse povezave so se sicer izkazale za statistično značilne, a niso bile v vseh primerih tudi visoke. Tudi razne druge analize so nakazale, da ima relief, predvsem nadmorska višina, velik pomen za razlikovanje pokrajinskih enot (na primer Thompson s sod., 2005).

Vpliv reliefa je tako velik, da je veliko raziskav osnovno prostorsko enoto določilo na podlagi reliefa. Castillo-Rodríguez, López-Blanco, Muñoz-Sa (2010) argumentirajo, da so rastlinske združbe navezane na klimatske dejavnike, te pa v veliki meri določa relief; poleg tega so prsti navezane na naklon površja, z reliefom pa je povezana tudi hidrologija. Razgiban relief lahko na manjšem območju povzroči večje kontraste kot pa nerazgiban relief na večjem območju. Relief vpliva tudi na človekovo delovanje, kar je vidno v rabi tal (Castillo-Rodríguez, López-Blanco, Muñoz-Salinas, 2010, 630–635). Pri tem je treba opozoriti, da lahko določanje ene vrednosti za celotno reliefno obliko (enoto) povzroči napake, predvsem kadar so enote večje ali pa znotraj zelo raznolike (Castillo-Rodríguez, López-Blanco, Muñoz-Salinas, 2010, 636 in 637).

Razmere v Sloveniji

Povprečna nadmorska višina v Sloveniji je 557 m. Najnižja točka je obala Tržaškega zaliva z 0 m, najvišja pa Triglav z 2864 m. Nižja območja so na jugozahodu (ob obali) ter na območju panonskih ravnin na vzhodu; najvišja območja so na severozahodu, kjer so Julijske Alpe, Karavanke in Kamniško-Savinjske Alpe (Perko, 2001, 82–83). Alpsko-dinarska pregrada ima velik pomen za druge pokrajinske prvine, največjega za podnebne razmere, saj na jugozahodni strani omejuje submediteransko podnebje oziroma vegetacijo, na vzhodni strani pa omejuje celinske vplive. Območje predstavlja tudi mejo med jadranskim in črnomořkim porečjem (Ogrin, 2009, 38–39). Povprečni naklon Slovenije je 13,1°. Najmanjši naklon imajo panonske ravnine in alpske kotline, največjega pa visokogorske Julijske Alpe, Karavanke in Kamniško-Savinjske Alpe (Perko, 2001, 108). 3,4 % Slovenije je ravnega in zato nima ekspozicije. Izmed ostalih (neravnih površin z naklonom vsaj 0,5°) površin pa je v Sloveniji največ površja z južno lego (29,1 %), sledijo pa površja s severno (24,1 %), vzhodno (23,9 %) in zahodno lego (22,9 %) (Perko, 2001, 133). V povezavi z nadmorsko višino naj omenimo snežno mejo in zgornjo gozdno mejo. Prva je v Sloveniji na približno 2700 m, druga pa ima zelo različne meje; v Julijskih Alpah med 1600 in 1700 m, Kamniško-Savinjskih Alpah med 1700 in 1800 m in Karavankah med 1800 in 1900 m, na Snežniku pa komaj nekaj nad 1500 m. Višinska meja poseljenosti v povprečju poteka približno 500 m pod gozdno mejo (Perko, 1998c, 84).

Ker je v reliefno razgibani Sloveniji relief ali oblikovanost površja pogosto najpomembnejši dejavnik razlikovanja med pokrajinami in pomembna prvina pri geografskih klasifikacijah, tipizacijah in regionalizacijah, so slovenski geografi izdelali že več delitev ozemlja glede na relief (poglavje 3). Izmed novejših lahko navedemo delitev Natka (1993), Gabrovca in Hrvatina (1998) ter Perka (2001).

Podatkovni sloji

Podatki, ki se nanašajo na značilnost površja oziroma topografije, so večinoma najbolj dostopni (Mücher s sod., 2003, 20 in 21). To velja tudi za Slovenijo. Glede na velik pomen reliefa bi morali vključiti v analizo predvsem:

- nadmorsko višino,
- naklon,
- ekspozicijo,
- regionalne koeficiente razgibanosti (regionalne predvsem zato, ker obravnavamo celotno območje Slovenije).

Geodetska uprava Republike Slovenije je izdelala več digitalnih modelov višin z različno ločljivostjo, med njimi se zelo pogosto uporablja DMV z resolucijo 25 m (Digitalni model ..., 2010). DMV vsebuje podatke o nadmorski višini in omogoča izpeljavo ostalih reliefnih podatkov (naklon, ekspozicija, koeficienti razgibanosti ...).

3 Kamninska sestava

Geološka zgradba vpliva na reliefno podobo, razvoj prsti, vodne razmere ter tudi na živi svet in človeka (Ogrin, 2009, 28). Kamninska podlaga vpliva na fizikalne (vsebnost vode, podzemni vodni tokovi) in kemične lastnosti okolja (vsebnost mineralov). Bolj kot starost in razvoj so pri kamninah pomembni njihova sestava, debelina in podobno (Mücher s sod., 2003, 20). Vpliv podlage na prsti in rastje je najbolj opazen v suhih in hladnih podnebjih (Bailey 1996, 115). Pogosto se pri raziskavah tipi kamnin glede na namen raziskave razvrstijo v bolj pregledne in smiselne skupine. Tako sta na primer Anderson in Ferree (2010) za svojo raziskavo na podlagi geneze, kemijskih značilnosti, značilnosti preperevanja in teksture prsti združila več kot 200 tipov kamnin v 9 litogeokemičnih razredov.

Razmere v Sloveniji

Sedimentne kamnine v Sloveniji pokrivajo 93 % površja, magmatske in metamorfne pa prekrivajo 3 oziroma 4 % površja. Magmaških kamnin, kot so tonalit, granodiorit, andezit, dacit, diabaz in porfiroidne predornine, je največ na Pohorju in vzhodnih Karavankah. Metamorfne kamnine, kot so kvarcit, skrilavec, filit, blestnik, gnajs, serpentinit, amfibolit, eklogit, granulit, se nahajajo predvsem na Pohorju, Kozjaku, Strojni in v vzhodnih Karavankah. Sedimentne kamnine se delijo na piroklastične, klastične, biokemične in kemične. Piroklastične kamnine (vulkanske breče, tufi) so na primer na Smrekovcu, Goričkem ter na več mestih na Gorenjskem in Idrijskem. Klastične nevezane kamnine (glina, pesek, grušč, prod, til) so ob večjih slovenskih rekah ter na kraških poljih, klastične vezane (glinovec, peščenjak, breča, konglomerat, tilit) pa gradijo obsežnejša hribovita in gričevnata območja na severovzhodu Slovenije, hribovja predalpske Slovenije in gričevnata območja v submediteranski Sloveniji. Med biokemičnimi usedlinami prevladujejo apnenci in dolomiti, ki so predvsem na obsežnem območju dinarskega in alpskega sveta, pogosti pa so tudi v predalpski Sloveniji, kjer gradijo višje hribovje, ter v submediteranski Sloveniji (Kras, Podgorski kras ...). Zadnja skupina (kemične usedline) je prisotna le lokalno – na primer sadra v Karavankah, sol v Sečoveljskih solinah (Verbič, 1998, 74–77).

Komac (2005) uvršča kamnine Slovenije med klastične kamnine (ki pokrivajo 49,25 %), karbonatne kamnine (39,31 %), klastično-karbonatne kamnine (4,27 %), piroklastične kamnine (1,78 %), metamorfne kamnine (3,90 %) in magmatske kamnine (1,49 %).

Na Geografskem inštitutu Antona Melika ZRC SAZU so izdelali digitalni Zemljevid tipov kamnin (2012), v katerem so kamnine združene v 25 kategorij (preglednica 128). Zemljevid tipov kamnin je bil pripravljen na podlagi vektorskega sloja Litološka karta 1 : 250.000, ki je bila izdelana na podlagi vektorske *Litostratigrafske karte Slovenije* (Litostratigrafska karta ...,

2007), ki jo je izdelal Geološki zavod Slovenije po naročilu Agencije Republike Slovenije za okolje predvsem na podlagi vektoriziranih geoloških kart Slovenije.

Preglednica 128: Tipi kamnin (Zemljevid tipov kamnin, 2012).

tip kamnin	šifra kamnine
kvartarna glina, melj in pesek	1
kvartarni silikatni prod	2
kvartarni karbonatni prod	3
kvartarni konglomerat	4
kvartarni grušč	5
kvartarni til in tilit	6
terciarne gline	7
terciarni peski	8
terciarni peščenjaki in konglomerati	9
terciarni laporovec	10
neogenski (litotamnijski) apnenci	11
mezozojski in terciarni fliš	12
mezozojski masiven apnenec	13
mezozojski plastovit apnenec	14
mezozojski ploščast apnenec	15
mezozojski apnenec in dolomit	16
mezozojski dolomit	17
mezozojske karbonatno-klastične kamnine	18
paleozojski glinovci in meljevci	19
paleozojski peščenjaki in konglomerati	20
vulkanoklastiti (tufi in tufiti)	21
predornine	22
globočnine	23
slabo odporne metamorfne kamnine (skrilavec, filit)	24
odporne metamorfne kamnine (gnajs, blestnik, amfibolit, serpentinit, eklogit)	25

Med kamninami je treba izpostaviti apnenec in dolomite, pri katerih se je razvil poseben tip površja – kras. Poznamo apneniški kras, dolomitni kras ter kras na konglomeratu in breči (Ogrin, 2009). Delitev krasa na različne tipe je pripravil Mihevc (1998), ki je določil alpski kras, predalpski kras, visoki dinarski kras in nizki dinarski kras.

Kamnine imajo vpliv na površinske in podzemne vodne razmere. Na 33 % ozemlja so dobro prepustne sedimentne kamnine s kraško razpoklinsko poroznostjo (apnenec, dolomit), na 20 % ozemlja so prodno-peščeni nanosi z medzrnsko poroznostjo, na 14 % so glinavci, laporovci, meljevci in tudi dolomiti z razpoklinsko poroznostjo. Na ostalem območju Slovenije (približno 33 %) so plasti z medzrnsko ali razpoklinsko poroznostjo manjše izdatnosti in pa kamnine s slabšo poroznostjo z zelo malo podzemne vode, na primer glina, melj, peščenjak, fliš, magmatske in metamorfne kamnine (Prestor s sod., 2002 cv: Ogrin, 2009, 113).

Podatkovni sloji

Glede na nespremenljivost kamnine ter njihov vpliv na druge dejavnike (vode, rastje, relief) je vključitev podatka o kamninski sestavi nujna. Zato smo uporabili Zemljevid tipov kamnin (2012) in, ker je ta podatkovni sloj nominalen, smo ga za klasifikacije z metodami, ki

zahtevajo številske vrednosti, oštevilčili z vidika koeficienta prepustnosti⁶⁵. Na podlagi različnih domačih in tujih virov (Sanders, 1998 cv: Poehls, 2009; Singhal, Gupta, 2010; Bear, 1972; Bell, 2007; Pravilnik o določitvi ..., 2005; Vodna telesa ..., 2007; Žlebnik, 1966; Žlebnik, 1981; Verbovšek, 2008; Spitz, Moreno, 1996; Waltz, 1969; Gaganis, 2000) smo določili ocene prepustnosti (preglednica 129). Pri tem se zavedamo, da smo s tem uspeli doseči le približno kvantitativno oceno oziroma kvantifikacijo nominalnega podatka. Zaradi medsebojnega učinkovanja različnih dejavnikov je namreč težko številsko opredeliti lastnosti kamnin. Lastnosti kamnin so drugačne kot lastnosti umetnih materialov. Te lastnosti se spreminjajo že na majhnem območju. Podrobne vrednosti niso primerne, prav tako pa so malo uporabne vrednosti, ki so navedene kot široki razponi (Hoek, 1999). Gams (1978a, 11) je opozoril na problem opredeljevanja značilnosti kamnine, saj so le-te zelo različne; kot primer je navedel različne debeline ilovic in mineraloško raznolikost apnencev in dolomitov ter menjavanje bazičnih in silikatnih kamnin na manjšem območju. Kljub temu so v literaturi pogoste tovrstne preobrazbe nominalnih podatkov o kamninah v številske približke (na primer Romportl, Chuman, 2007; Múcher s sod., 2003; 2006; 2009; Wolock, Winter, McMahon, 2004). Milavec in Verbovšek (2012) sta v svoji raziskavi uporabila na primer logaritmirano vrednost koeficienta prepustnosti, saj so vrednosti porazdeljene lognormalno. S tovrstnim ukrepom smo si pomagali tudi pri kvantifikaciji kamnin v tej nalogi.

Preglednica 129: Razvrstitev kamnin po prepustnosti*.

približen koeficient prepustnosti (cm/s)	logaritmirana vrednost	ocena prepustnosti	šifra kamnine
0,1	-1	10	2, 3, 5
		9,5	1
0,01	-2	9	4, 14, 16
		8,5	13
0,001	-3	8	8, 15
		7,5	11
0,0001	-4	7	17
0,00001	-5	6	9
		5,5	12, 21
0,000001	-6	5	6, 10, 18, 20
0,0000001	-7	4	7
0,00000001	-8	3	19
0,000000001	-9	2	22, 24, 25
0,0000000001	-10	1	23

*Razvrstitev je bila narejena na podlagi naslednjih virov: Sanders, 1998 cv: Poehls, 2009; Singhal, Gupta, 2010; Bear, 1972; Bell, 2007; Pravilnik o določitvi ..., 2005; Vodna telesa ..., 2007; Žlebnik, 1966; Žlebnik, 1981; Verbovšek, 2008; Spitz, Moreno, 1996; Waltz, 1969; Gaganis, 2000.

4 Prst

Prst predstavlja pomembno kombinacijo fizikalnih in kemičnih pogojev za rastje in živalstvo. Zemljevidi prsti lahko služijo kot približek za površinsko kamninsko sestavo (Múcher s sod., 2003, 21 in 22). Slabost zemljevidov prsti je ta, da so velikokrat narejene z vzorčenjem in nato povezovanjem z ostalimi naravnimi dejavniki (rastje, reliefna oblika), poleg tega pa ni nujno, da prsti odražajo trenutno podnebje, saj so prsti lahko fosilne (Bailey, 1996, 34).

⁶⁵ Prepustnost je sposobnost porozne kamnine, sedimenta ali preperine, da prevaja tekočino ali plin tako, da se pri tem ne poruši njihova struktura (Geološki terminološki ..., 2006, 226); koeficient prepustnosti je parameter, značilen za stopnjo prepustnosti kamnine (Geološki terminološki ..., 2006, 134).

Razmere v Sloveniji

Zaradi kamninske in reliefne raznolikosti so prsti v Sloveniji raznolike. Evtrične rjave prsti so nastale v flišnih in lapornatih gričevjih ter hribovjih iz karbonatnih kamnin. Poleg tega jih najdemo tudi v ravninah na ledeniških in rečnih nanosih karbonatnega gradiva, kjer so prisotne tudi rendzine. Slednje so pogoste predvsem v višjih legah hribovij iz karbonatnih kamnin. Rankerji, distrične rjave prsti in izprane prsti so nastali na nekarbonatnih nanosih; distrične rjave prsti so prisotne tudi v hribovitem in gorskem svetu iz nekarbonatnih kamnin. Na kraških ravninah in podoljih se prisotne rendzine in rjave pokarbonatne prsti. Ob vodotokih so nastale obrečne prsti, pa tudi oglejane prsti. Šotne in šotno-mineralne prsti so omejene na barja, litosoli pa na vršaje in melišča. V Beli krajini so akrične (steljniške) prsti, na Krasu pa rdečerja prst, imenovana tudi kremenica (Lovrenčak, 1998; Repe, 2010).

Podatkovni sloji

Za območje celotne Slovenije je dostopna Pedološka karta Slovenije (Pedološka karta, 2007). Pedološka karta v merilu 1 : 25.000 vsebuje osnovne podatke o prsteh kot naravnem viru. Namenjena je evidenci talnega fonda na nivoju države, regij, občin ali večjih območij (Pedološka karta v ..., 2012). Pomanjkljivost pedološke karte v primerjavi z litološko karto je ta, da je slednja narejena za celotno Slovenijo, pedološka karta pa le za območja izven urbanih območij. Poleg tega so prisotne tudi kategorije, na primer urbano, rigolana tla ipd., ki ne odražajo naravnega stanja.

Vodovje

Prva delitev na Zemlji je delitev na kopno in morje (Godron, 1994, 71). Značilnosti vodovja pri klasifikacijah pokrajin se pogosto uporabljajo v povezavi z določanjem porečij. Problem se pojavi na območjih, na katerih ni površinske rečne mreže; poleg tega lahko razvodnica glede podzemne vode ne sovпада s površinsko razvodnico. Vodni tokovi lahko tečejo čez klimatsko in reliefno različna območja (Bailey, 1996, 35 in 36). Hidrološke razmere se lahko kažejo tudi pri drugih dejavnikih – na primer gostota rečne mreže se kaže pri geomorfologiji kot gostota rečnih dolin in intenziteti razčlenjenosti (Demek, Quitt, Raušer, 1972). Prevlada površinskega odtoka vode nakazuje na vododržne kamnine ter rečno-denudacijski relief (Ogrin, 2009, 43).

Razmere v Sloveniji

V Sloveniji je veliko kraškega površja in zato je določanje meja po porečjih težje. V povodje Črnega morja spadajo porečja Mure, Drave, Save in Kolpe, v istrsko porečje Jadranskega morja pa porečje Soče in porečja manjših jadranskih rek (Kolbezen, 1998, 94–95). Frantar in Hrvatin (2005) sta določila pet pretočnih režimov: alpski snežno-dežni režim, alpski dežno-snežni režim, dinarski dežno-snežni režim, panonski dežno-snežni režim in sredozemski dežni režim.

Dolžina vseh vodotokov v Sloveniji je približno 28.000 km, od tega pa je vsaj 16.000 km takih, ki so občasno brez vode. Gostota rečne mreže se razlikuje med posameznimi območji v Sloveniji, kar je bolj posledica hidrogeoloških in ne toliko podnebnih razmer. Redko rečno mrežo imajo dinarska in alpska (kraška) Slovenija ter osrednji deli prodnih polj. Na manj prepustnih kamninah je rečna mreža povsod po Sloveniji gosta (Bat s sod., 2003, 27). Porečje Drave ima največjo gostoto rečne mreže $1,88 \text{ km/km}^2$, sledijo porečje Mure ($1,48 \text{ km/km}^2$), Save ($1,23 \text{ km/km}^2$), Soče ($1,16 \text{ km/km}^2$), istrsko porečje $0,96 \text{ km/km}^2$ ter porečje Kolpe ($0,52 \text{ km/km}^2$) (Kolbezen, 1998, 94). Glede na te podatke je smiselno vključiti gostoto rečne mreže ali pa oddaljenost od najbližjega vodotoka v postopek klasifikacije pokrajine.

Podatkovni sloji

Na medmrežju (Vodotoki, 2006) je bila objavljena površinska rečna mreža, ki je bila narejena na podlagi državnih topografskih kart. Podatek omogoča izračun gostote rečne mreže, ki pokaže predvsem na razlike med kraškim in nekraškim površjem.

Rastje

Rastje je pomembno zato, ker lahko kaže na biotski odziv na različne abiotske dejavnike (Haggett, 2001, 166). Razporeditev rastja je odvisna od mnogih dejavnikov, na primer podnebja, prsti, nadmorske višine in ekspozicije, ter se stalno spreminja. Zato rastje odraža številne naravnogeografske dejavnike in biološke značilnosti območja ter ga lahko pri naravovarstvenem delu uporabimo kot ponazoritev ekosistema oziroma ekoloških območij in njihovega stanja, manj primeren pa je za razmejevanje (Bailey, 1996; Digital map ..., 2009). Pri tem se predpostavlja, da so vrste v ravnotežju z ostalimi naravnimi dejavniki. Če so se dejavniki pred kratkim spremenili, potem sestava vrst ni več primerna za dokaz ekološkega tipa (Runhaar, Udo de Haes, 1994, 151). Podatki o dejanski in potencialni vegetaciji so zato pomembni (Mücher s sod., 2003, 22). Razvoj klasifikacije glede na ekološke skupine rastja je zato iterativen proces. Vedno znova se preverja, kakšna je razlika med pričakovanimi vrednostmi na testnih območjih (Runhaar, Udo de Haes, 1994).

Pri razmejevanju glede biogeografskih značilnosti je zelo pomembno poznavanje fitogeografije, ki proučuje geografsko razporeditev rastlinstva na zemeljski površini in prikazuje ter razlaga areale rastlinskih vrst in združb. Območja razmejuje s pomočjo endemičnih vrst, ki predstavljajo pomemben kriterij za delitev v prostoru (Zupančič, 1989, 120 in 121).

Razmere v Sloveniji

Slovenija je bila pred delovanjem človeka in živali pokrita z gozdovi, le v visokogorskem alpskem svetu so bili travniki ter neporasle površine (Zupančič, Seliškar, Žagar, 1998, 116). Območje Slovenije je pod vplivom 3 florističnih regij. Najmočnejši vpliv ima evrosibirsko-severnoameriška regija (pri nas se deli v 2 provinci – srednjeevropsko in ilirsko), v manjši meri pa vplivata še alpsko-visokonordijska in mediteranska regija (Zupančič, 1989, 120 in 121).

Opis najbolj razširjenih gozdnih združb povzemamo po Zupančiču, Seliškarju in Žagarju (1998). Danes so v Sloveniji najbolj razširjeni bukovi gozdovi. Ti so na območju panonskih nižin, predalpskega, alpskega, preddinarskega in dinarskega sveta ter hladnejših submediteranskih rastiščih. Pojavljajo se tako na kisli kot tudi na bazični podlagi. Po razširjenosti sledijo dolinski gozdovi belega gabra na karbonatni matični podlagi. V dolinskem svetu se pojavljajo še občasno poplavljeni gozdovi belega gabra, gozd doba, gozd brestov in črne jelše. Ob bregovih vodotokov so gozdovi vrb. Na jugozahodu, kjer je močan mediteranski vpliv, je hrast puhavec na apnencu in flišu. Hladnejša rastišča na flišu in jerovici poraščata združbi hrasta gradna. Čisti jelovi gozdovi so v predalpskem svetu ter mestoma v dinarskem svetu. Prvotnih smrekovih gozdov je pri nas površinsko malo, drugotnih pa je več. Najvišji gozdni pas je porasel z ruševjem. Skalovita, toploljubna rastišča višjega predalpskega območja poraščajo gabrovci, po vsej Sloveniji pa so razširjeni gabrovci in hrasti. Na karbonatni podlagi je razširjen tudi gozd rdečega in črnega bora (Zupančič, Seliškar, Žagar 1998, 116).

Rastje je biotska komponenta, na kateri se poznajo vplivi človeka (Runhaar s sod., 1994, 141). Človek močno vpliva na vrstno sestavo vegetacije in jo spreminja s homogenimi pogoji v manjše in bolj raznolike parcele in torej ustvarja umetno pokrajino (Godron, 1994, 80). Tudi v Sloveniji je veliko gozdnih površin spremenjenih. Nekateri kisloljubni podgorski bukovi

gozdovi so spremenjeni v drugotne gradnove gozdove. Dolinski gozdovi belega gabra na karbonatni matični podlagi so ponekod spremenjeni v drugotne zakisane gozdove belega gabra. Najnižje ležeči podgorski bukovi gozdovi so ponekod spremenjeni v drugotne gozdove belega gabra. Gozd hrasta puhavca na apnencu in flišu je na apnencu pogosto spremenjen v drugotno grmišče gabrovca. Nekatera bukova rastišča so spremenjena v drugotna smrekovja (Zupančič, Seliškar, Žagar, 1998, 116).

Kutnar, Kobler in Bergant (2009) so za raziskavo vpliva podnebnih sprememb na tipe gozdne vegetacije določili 13 skupin oziroma vegetacijskih tipov, v katerih so združili potencialne gozdne združbe, opredeljene v bazi Zavoda za gozdove Slovenije. Določili so naslednje skupine: acidofilna bukovja; acidofilna rdečeborovja; predgorska bukovja; gorska bukovja; (visoko)gorska bukovja v (pred)alpskem območju; (visoko)gorska bukovja v (pred)dinarskem območju; termofilna bukovja; kolinska hrastova-belogabrovja; nižinska vrbovja, jelševja in dobovja; termofilna črnogabrovja, hrastovja, rdečeborovja in črnoborovja; jelovja; smrekovja; ruševja.

Podatkovni sloji

Dostopni so podatkovni sloji o dejanski vegetaciji, na primer: Gozdnovegetacijska karta Slovenije (Košir s sod., 2007), Vegetacijska karta gozdnih združb v merilu 1 : 400.000 (Čarni s sod., 2002), posplošena karta Realna vegetacija, ki je bila v merilu 1 : 750.000 objavljena v Geografskem atlasu Slovenije (Zupančič s sod., 1998b) ter podrobna digitalna podatkovna baza Zavoda za gozdove Slovenije o gozdnih sestojih in gozdnih odsekih (Karta odsekov ..., 2008). Poleg tega je dostopen tudi zemljevid Potencialna naravna vegetacija (Zupančič s sod., 1998a).

Spremenjenost gozdov ter dejstvo, da gozd porašča nekaj več kot polovico ozemlja Slovenije, sta dva glavna razloga za to, da podatka o dejanski vegetaciji nismo vključili v naše analize. Pri biogeografski klasifikaciji se pojavi tudi problem zaradi zaraščanja in sekundarnih združb. Navadno je ekološki razpon vrst zelo velik, zato prisotnost neke vrste po mnenju Plesníka (1972, 71) ne pove veliko o lokalnih razmerah. Poleg tega pa Bailey predlaga, da morajo ekološke meje temeljiti na dejavnikih, ki oblikujejo oziroma kontrolirajo ekosisteme in ne na trenutni bioti (Bailey, 1996, 33).

Živalstvo

Favna je relativno odvisna komponenta, ki pa je pomembna pri preučevanju in upravljanju biodiverzitete. Podatki o živalstvu navadno niso vključeni v proces določanja tipov pokrajin (Mücher s sod., 2003, 23). Med razlogi je tudi ta, da imajo živalske vrste lahko večja življenjska območja z različnimi naravnimi značilnostmi. Zaradi tega je za opis najboljše uporabiti živalske vrste, ki imajo nizko mobilnost (Runhaar, Udo de Haes, 1994, 162; Haber, 1994, 54).

Razmere v Sloveniji

Kljub temu, da Sloveniji pripada manj kot 0,004 % površja Zemlje, živi na njenem območju več kot 1 % znanih živečih vrst, kar pomeni 24.000 vrst živih bitij, ocene pa se gibljejo med 50.000 in 120.000 (Mršič, 1997 cv: Ogrin, 2009, 127).

Podatkovni sloji

Za uporabo primernih digitalnih podatkovnih slojev o razširjenosti živalskih vrst nismo našli.

Antropogeni dejavniki

Človeška dejavnost vpliva na različne ekosisteme različno močno zaradi različne ranljivosti (Udo de Haes, Klijn, 1994). Zaradi vpliva človeka na okolje nekateri navajajo kategorizacije

naravne ohranjenosti pokrajin. Haber (1994, 60) deli ekosistem oziroma rabo tal glede na zmanjšano naravnost na:

- bioekosisteme,
- naravni ekosisteme,
- ekosisteme, ki so blizu naravnim,
- polovično naravne ekosisteme,
- antropogene ekosisteme,
- tehnološke ekosisteme.

Milanova in Kushlin (1993 cv: Bailey, 141) sta na globalni ravni določila štiri kategorije:

- najbolj pogoste (bistveno nespremenjene) pokrajine,
- sekundarne pokrajine,
- antropogeno spremenjene pokrajine (kmetijske, gozdarske, rekreacijske pokrajine),
- tehnogene pokrajine (tehnogeni pokrajinski kompleksi).

Za klasifikacijo pokrajine lahko upoštevamo tudi antropogene dejavnike. Lahko vključimo na primer pokrovnost tal, rabo tal ali pokrajinski vzorec, sestavo. Za razlikovanje pokrajin lahko uporabimo podatke o sestavi (na primer velikost posameznih enot rabe tal – *patch*) in konfiguraciji, obliki, velikosti in položaju elementov vzorca (McMahon, Wiken, Gauthier, 2004, 116; Zonneveld, 1994, 30). Vzorci v pokrajini namreč odražajo bio-fizikalne pogoje ter tudi vpliv človeka (rabe tal) (Mücher s sod., 2003, 24).

Podatkovni sloji

Za območje Slovenije so na voljo digitalni podatki o rabi tal. Gre dejansko za podigitalizirane letalske posnetke, s katerih je mogoče razbrati pokrovnost, ne pa dejanske rabe tal.

Pokrajinski vzorec oziroma razne kvantitativne podatke lahko sami izračunamo. Pogosto izračuni temeljijo na vektorskih podatkovnih slojih in veljajo za določeno območje (recimo število tipov pokrovnosti na območju izbrane občine). Danes obstajajo različni izračuni t.i. »pokrajinskih mer« (ang. *landscape metrics*). Obširen pregled teh mer so pripravili Šimová in Gdulová (2012) ter Lang s sodelavci (2009).

Omeniti velja tudi čedalje večjo ponudbo satelitskih in letalskih posnetkov, ki so narejeni z različnimi senzorji. Prosto dostopne so denimo zbirke satelitskih posnetkov Landsat (Landsat, 2012), MODIS (MODIS, 2012) in drugih. Prostorska ločljivost takih posnetkov je od nekaj 10 m (na primer 30 m ali več za Landsatove posnetke pri večini spektralnih kanalov) pa več 100 m (na primer 250 m ali več pri senzorjih MODIS). Posnetki so narejeni v več spektralnih kanalih, kar pomeni, da lahko odbojnost površja prikažemo z vidika različnih valovnih dolžin. S kombiniranjem posnetkov v različnih spektrih lahko dobimo dodatne informacije, na primer indekse. Z nekaterimi indeksi lahko tudi odstranimo neželene vplive različnih dejavnikov; nekateri so namenjeni le specifičnim analizam oziroma uporabi določenih senzorjev (Campbell, 1996; Oštir, 2006; Lillesand, Kieffer, Chipman, 2008; Thiam, Eastman, 2009).

Priloga 7: Usklajenost mer vrednotenja podatkovnih slojev (izračunani Pearsonovi in Spearmanovi koeficienti)

Preglednica 130: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI4 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).

	koeficient F	delež enako klasificiranih z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2
koeficient F	1,000	0,552	0,675	0,471	0,972
	1,000	0,528	0,631	0,503	1,000
delež enako klasificiranih z odločitvenim drevesom (CT)		1,000	0,887	0,783	0,684
		1,000	0,778	0,695	0,529
informacijski prispevek			1,000	0,823	0,785
			1,000	0,829	0,630
razmerje informacijskega prispevka				1,000	0,551
				1,000	0,506
koeficient η^2					1,000
					1,000

Preglednica 131: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI9 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).

	koeficient F	delež enako klasificiranih z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2
koeficient F	1,000	0,749	0,836	0,444	0,956
	1,000	0,535	0,603	0,468	1,000
delež enako klasificiranih z odločitvenim drevesom (CT)		1,000	0,932	0,749	0,841
		1,000	0,802	0,760	0,539
informacijski prispevek			1,000	0,677	0,911
			1,000	0,743	0,606
razmerje informacijskega prispevka				1,000	0,540
				1,000	0,471
koeficient η^2					1,000
					1,000

Preglednica 132: Povezanost med različnimi načini vrednotenja podatkovnih slojev glede na klasifikacijo TIPI13 (Pearsonov koeficient je zapisan v prvi vrsti, Spearmanov koeficient pa v drugi vrsti; vsi izračuni so statistično značilni pri $p=0,01$).

	koeficient F	delež enako klasificiranih z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2
koeficient F	1,000	0,784	0,851	0,477	0,960
	1,000	0,736	0,804	0,660	1,000
delež enako klasificiranih z odločitvenim drevesom (CT)		1,000	0,899	0,811	0,834
		1,000	0,863	0,878	0,736
informacijski prispevek			1,000	0,636	0,918
			1,000	0,651	0,805
razmerje informacijskega prispevka pet				1,000	0,565
				1,000	0,661
koeficient η^2					1,000
					1,000

Preglednica 133: Izračunani Pearsonovi (prva vrstica) in Spearmanovi koeficienti (druga vrstica) za povezanost različnih lestvic povprečnih ocen vrednotenja podatkovnih slojev. Statistična značilnost je za vse koeficiente $p=0,01$.

	povprečje ocen glede na klasifikacijo TIPI4	povprečje ocen glede na klasifikacijo TIPI9	povprečje ocen glede na klasifikacijo TIPI13	povprečje vseh ocen
povprečje ocen gledena klasifikacijo TIPI4	1,000	0,926	0,793	0,948
	1,000	0,818	0,512	0,885
povprečje ocen glede na klasifikacijo TIPI9		1,000	0,945	0,994
		1,000	0,787	0,965
povprečje ocen glede na klasifikacijo TIPI13			1,000	0,943
			1,000	0,783
povprečje vseh ocen				1,000
				1,000

Priloga 8: Vrednotenje modeliranih naravnopokrajinskih tipizacij po metodah nenadzorovane klasifikacije

Različni načini vrednotenja glede na posamezni podatkovni sloj

Preglednica 134: Delež celic, ki so enako klasificirane z odločitvenim drevesom.

oznaka klasifikacije	število skupin	delež enako klasificiranih celic z odločitvenim drevesom (CT) z uporabo podatkovnega sloja (%)			povprečje (%)
		naklon	prepustnost	povp. letna temperatura	
10SEG	2	87,2	83	86,1	85,4
09ISO	2	89,1	73,2	73,9	78,7
08CL	2	68,3	95,9	60,6	74,9
04SPSS2	2	71,4	94,5	58,8	74,9
01SPSS	2	71,3	94,4	58,7	74,8
02STAT1	2	71,3	94,4	58,7	74,8
03STAT2	2	71,3	94,4	58,7	74,8
05KM1	2	71,3	94,4	58,7	74,8
06KM2	2	71,3	94,4	58,7	74,8
07KM3	2	71,3	94,4	58,7	74,8
03STAT2	5	57,2	79,3	47,1	61,2
01SPSS	5	56,2	76,1	50,2	60,8
06KM2	5	56,2	76,1	50,2	60,8
07KM3	5	56,2	76,1	50,2	60,8
08CL	5	55,4	84,5	41,1	60,3
04SPSS2	5	55,8	77	46,9	59,9
02STAT1	5	54,6	77	48,1	59,9
05KM1	5	54,5	77	48,1	59,9
09ISO	5	58,5	68,8	40,6	56,0
10SEG	5	50,7	47,3	49,7	49,2
01SPSS	10	46,4	62,3	35,4	48,0
02STAT1	10	46,4	62,3	35,4	48,0
06KM2	10	44,6	60	38,2	47,6
07KM3	10	44	62,3	36,1	47,5
03STAT2	10	43,4	61,9	36,2	47,2
05KM1	10	42,5	62,5	35,5	46,8
04SPSS2	10	43,1	58,1	35,3	45,5
08CL	10	51,3	53	31	45,1
09ISO	10	50	52,5	30	44,2
03STAT2	15	39,3	55,7	33	42,7
07KM3	15	39	54,5	33,8	42,4
06KM2	15	39,6	54,2	33,4	42,4
02STAT1	15	40,1	52,6	34,5	42,4
05KM1	15	38,8	55,3	32,8	42,3
09ISO	15	42,5	52,6	27,7	40,9
08CL	15	43,5	48,8	29,4	40,6
01SPSS	15	38,9	49,2	33,4	40,5
04SPSS2	15	38,5	46,4	33	39,3
10SEG	10	30	32,5	36,2	32,9
10SEG	15B	23,9	31,6	26,2	27,2
10SEG	15A	23,6	31,6	26,2	27,1

Preglednica 135: Razmerje informacijskega prispevka za posamezno klasifikacijo.

oznaka klasifikacije	število skupin	razmerje informacijskega prispevka, izračunanega na podlagi podatkovnega sloja			povprečje razmerja informacijskega prispevka
		naklon	prepustnost	povp. letna temperatura	
05KM1	15	0,24	0,61	0,14	0,33

08CL	15	0,31	0,54	0,14	0,33
07KM3	15	0,23	0,6	0,14	0,32
03STAT2	15	0,23	0,59	0,14	0,32
09ISO	15	0,26	0,59	0,11	0,32
04SPSS2	15	0,24	0,57	0,14	0,32
01SPSS	15	0,23	0,58	0,13	0,31
02STAT1	15	0,23	0,58	0,13	0,31
06KM2	15	0,22	0,59	0,13	0,31
08CL	10	0,3	0,52	0,09	0,30
05KM1	10	0,2	0,57	0,11	0,29
08CL	5	0,16	0,69	0,03	0,29
03STAT2	10	0,2	0,56	0,11	0,29
04SPSS2	10	0,21	0,55	0,1	0,29
07KM3	10	0,2	0,56	0,1	0,29
01SPSS	10	0,2	0,55	0,1	0,28
02STAT1	10	0,2	0,55	0,1	0,28
06KM2	10	0,19	0,54	0,1	0,28
09ISO	10	0,24	0,51	0,08	0,28
03STAT2	5	0,13	0,47	0,06	0,22
02STAT1	5	0,13	0,44	0,07	0,21
04SPSS2	5	0,13	0,44	0,07	0,21
05KM1	5	0,13	0,44	0,06	0,21
09ISO	5	0,17	0,4	0,05	0,21
01SPSS	5	0,12	0,42	0,07	0,20
06KM2	5	0,13	0,42	0,06	0,20
07KM3	5	0,13	0,42	0,06	0,20
10SEG	15A	0,13	0,29	0,13	0,18
08CL	2	0,03	0,5	0,01	0,18
10SEG	15B	0,12	0,28	0,13	0,18
10SEG	10	0,11	0,24	0,11	0,15
01SPSS	2	0,04	0,39	0,01	0,15
02STAT1	2	0,04	0,39	0,01	0,15
03STAT2	2	0,04	0,39	0,01	0,15
05KM1	2	0,04	0,39	0,01	0,15
06KM2	2	0,04	0,39	0,01	0,15
07KM3	2	0,04	0,39	0,01	0,15
04SPSS2	2	0,04	0,38	0,01	0,14
09ISO	2	0,18	0,07	0,05	0,10
10SEG	5	0,09	0,12	0,07	0,09
10SEG	2	0,05	0,02	0,03	0,03

Preglednica 136: Informacijski prispevek za posamezno klasifikacijo.

oznaka klasifikacije	število skupin	informacijski prispevek (bit), izračunan na podlagi podatkovnega sloja			povprečje informacijskega prispevka (bit)
		naklon	prepustnost	povp. letna temperatura	
06KM2	15	1,97	1,97	1,08	1,67
05KM1	15	1,34	2	1,15	1,5
08CL	15	1,56	1,79	1,12	1,49
04SPSS2	15	1,44	1,9	1,09	1,48
07KM3	15	1,31	1,96	1,16	1,48
03STAT2	15	1,33	1,94	1,12	1,46
01SPSS	15	1,37	1,91	1,06	1,45
02STAT1	15	1,32	1,93	1,08	1,44
09ISO	15	1,52	1,95	0,85	1,44
08CL	10	1,51	1,74	0,7	1,32
05KM1	10	1,14	1,87	0,88	1,3

04SPSS2	10	1,23	1,8	0,85	1,29
03STAT2	10	1,15	1,82	0,86	1,28
07KM3	10	1,18	1,83	0,82	1,28
01SPSS	10	1,2	1,82	0,8	1,27
02STAT1	10	1,2	1,82	0,8	1,27
09ISO	10	1,39	1,71	0,66	1,25
06KM2	10	1,11	1,79	0,8	1,23
08CL	5	0,79	1,69	0,26	0,91
02STAT1	5	0,73	1,44	0,52	0,9
04SPSS2	5	0,75	1,44	0,52	0,9
05KM1	5	0,73	1,44	0,52	0,9
10SEG	15A	0,62	0,96	1,09	0,89
03STAT2	5	0,69	1,45	0,5	0,88
09ISO	5	0,93	1,32	0,39	0,88
10SEG	15B	0,61	0,94	1,1	0,88
01SPSS	5	0,68	1,38	0,52	0,86
06KM2	5	0,68	1,38	0,52	0,86
07KM3	5	0,68	1,38	0,52	0,86
10SEG	10	0,54	0,8	0,97	0,77
10SEG	5	0,46	0,58	0,56	0,53
09ISO	2	0,62	0,23	0,29	0,38
01SPSS	2	0,19	0,86	0,05	0,37
02STAT1	2	0,19	0,86	0,05	0,37
03STAT2	2	0,19	0,86	0,05	0,37
04SPSS2	2	0,2	0,86	0,05	0,37
05KM1	2	0,19	0,86	0,05	0,37
06KM2	2	0,19	0,86	0,05	0,37
07KM3	2	0,19	0,86	0,05	0,37
08CL	2	0,16	0,85	0,05	0,35
10SEG	2	0,25	0,07	0,21	0,18

Preglednica 137: Povprečni umerjeni koeficient variacije za posamezne klasifikacije.

oznaka klasifikacije	število skupin	povprečni umerjeni koeficient variacije (%), izračunan na podlagi podatkovnega sloja			povprečje PUKV-ja (%)
		naklon	prepustnost	povp. letna temperatura	
04SPSS2	15	26,86	7,08	10,18	14,71
05KM1	15	29,18	6,37	9,22	14,92
01SPSS	15	28,27	6,53	10,11	14,97
07KM3	15	29,61	6,47	9,15	15,08
03STAT2	15	29,18	6,53	9,52	15,08
02STAT1	15	29,02	6,52	9,86	15,13
09ISO	15	26,85	7,54	11,91	15,43
06KM2	15	30,33	6,55	9,76	15,55
08CL	15	28,71	9,82	9,84	16,12
01SPSS	10	31,51	7,24	11,76	16,84
02STAT1	10	31,51	7,24	11,76	16,84
04SPSS2	10	31,64	7,49	11,52	16,88
07KM3	10	32,01	7,14	11,69	16,95
03STAT2	10	32,82	7,29	11,19	17,10
05KM1	10	33,07	7,17	11,35	17,20
06KM2	10	33,79	7,4	11,58	17,59
09ISO	10	29,23	10,53	13,63	17,80
08CL	10	30,64	10,04	13,52	18,07
02STAT1	5	43,65	10,28	13,81	22,58
05KM1	5	43,68	10,29	13,8	22,59

04SPSS2	5	44,03	10,19	13,94	22,72
06KM2	5	45,04	10,42	13,75	23,07
07KM3	5	45,04	10,42	13,75	23,07
01SPSS	5	45,06	10,42	13,75	23,08
03STAT2	5	45,32	11,89	14,08	23,76
09ISO	5	39,84	15,47	16,05	23,79
08CL	5	50,27	10,74	17,58	26,20
10SEG	15B	48,45	25,55	11,54	28,51
10SEG	15A	48,47	25,45	11,85	28,59
10SEG	10	50,24	27,37	12,17	29,93
09ISO	2	49,3	29,43	16,73	31,82
10SEG	5	52,73	30,43	15,22	32,79
04SPSS2	2	67,61	16,2	19,97	34,59
01SPSS	2	67,68	16,18	19,97	34,61
02STAT1	2	67,68	16,18	19,97	34,61
03STAT2	2	67,68	16,18	19,97	34,61
05KM1	2	67,68	16,18	19,97	34,61
06KM2	2	67,68	16,18	19,97	34,61
07KM3	2	67,68	16,18	19,97	34,61
08CL	2	68,63	16,33	19,98	34,98
10SEG	2	59,87	32,79	16,83	36,50

Preglednica 138: Vrednosti F za posamezno klasifikacijo. Razvrščeno po povprečni vrednosti. Statistična značilnost posameznega koeficienta F je $p=0,001$ (če ni drugače navedeno), kar pomeni, da je statistična značilnost lestvice povprečne vrednosti $p=0,125$.

oznaka klasifikacije	število skupin	koeficient F, izračunan na podlagi podatkovnega sloja			povprečne koeficienta F
		naklon ⁶⁶	prepustnost ⁶⁷	povp. letna temperatura ⁶⁸	
08CL	2	67276,75	1449302	6,37 ⁶⁹	758289,3
06KM2	2	81716,09	1428333	230,39	503426,4
05KM1	2	81727,82	1428280	230,87	503413
07KM3	2	81727,82	1428280	230,87	503413
01SPSS	2	81740,62	1428225	230,96	503398,8
02STAT1	2	81740,62	1428225	230,96	503398,8
03STAT2	2	81740,62	1428225	230,96	503398,8
04SPSS2	2	83493	1419698	348,24	501179,8
01SPSS	5	187397,3	1100406	130162,1	472655,1
06KM2	5	187543,7	1100364	130039,7	472649,3
07KM3	5	187564,6	1100176	130048,7	472596,6
04SPSS2	5	182727,5	1096252	118541,5	465840,3
02STAT1	5	203762,2	1030783	125418,7	453321,2
05KM1	5	203383,9	1030616	125731,3	453243,9
07KM3	10	212588,1	1035527	101781,1	449965,2
02STAT1	10	215114,7	1015871	100384	443789,9
01SPSS	10	215103,4	1015839	100391,1	443777,8
05KM1	10	194699,4	982077,1	108549,3	428442
03STAT2	10	196845	971062,2	117216	428374,4
06KM2	10	185785,6	947360,4	106442,4	413196,1
04SPSS2	10	204962,9	894787,7	103881,4	401210,7
05KM1	15	162212,6	817155,9	117015,1	365461,2
01SPSS	15	185953,9	809046,1	99499,74	364833,2

⁶⁶ Statistična značilnost lestvice je $p=0,040$.

⁶⁷ Statistična značilnost lestvice je $p=0,040$.

⁶⁸ Statistična značilnost lestvice je $p=0,050$.

⁶⁹ Statistično značilno pri 0,012.

07KM3	15	162508,4	806681,1	124839,3	364676,3
02STAT1	15	173659,4	810710,4	105218,4	363196,1
03STAT2	15	165937,7	792908	108485,1	355776,9
06KM2	15	152997,8	743858,1	104630,6	333828,8
03STAT2	5	177955,1	674428,8	110576	320986,6
04SPSS2	15	200496,3	618012,8	93171,79	303893,6
08CL	5	106039,1	733511,8	27950,64	289167,2
09ISO	2	491501,8	111617,9	115239,1	239452,9
08CL	10	202801,1	453285,6	55219,18	237102
09ISO	15	194618,3	450233,6	55087,65	233313,2
09ISO	10	257453,8	307110,5	50114,07	204892,8
08CL	15	164410,5	292382,9	103745,7	186846,4
09ISO	5	258092,8	237680	51930,31	182567,7
10SEG	2	247151,2	5020,83	183122,2	145098,1
10SEG	5	107621,8	19295,5	58889,23	61935,5
10SEG	10	58624,18	23847,24	67513,59	49995
10SEG	15B	41553,19	20967,79	49891,14	37470,71
10SEG	15A	41420,35	21411,94	45156,55	35996,28

*Vse variance (če ni drugače navedeno v oklepaju) so statistično značilne pri $p < 0,001$.

Preglednica 139: Vrednosti η^2 za posamezno klasifikacijo. Razvrščeno po povprečni vrednosti. Statistična značilnost (če ni drugače navedeno) posameznega η^2 je 0,001, kar pomeni, da je statistična značilnost posamezne lestvice 0,040 (letna temperatura ima 0,049), lestvice povprečne vrednosti pa 0,124.

oznaka klasifikacije	število skupin	koeficient η^2 , izračunan na podlagi podatkovnega sloja			povprežje koeficienta η^2
		naklon	prepustnost	povp. letna temperatura	
07KM3	15	0,82	0,96	0,78	0,85
05KM1	15	0,82	0,96	0,76	0,85
02STAT1	15	0,83	0,96	0,74	0,84
03STAT2	15	0,82	0,96	0,75	0,84
01SPSS	15	0,84	0,96	0,73	0,84
04SPSS2	15	0,85	0,94	0,72	0,84
06KM2	15	0,81	0,95	0,74	0,84
03STAT2	10	0,78	0,94	0,68	0,80
07KM3	10	0,79	0,95	0,64	0,79
05KM1	10	0,78	0,95	0,66	0,79
01SPSS	10	0,79	0,95	0,64	0,79
02STAT1	10	0,79	0,95	0,64	0,79
04SPSS2	10	0,78	0,94	0,65	0,79
09ISO	15	0,84	0,93	0,60	0,79
06KM2	10	0,77	0,94	0,65	0,79
08CL	15	0,82	0,89	0,65	0,79
08CL	10	0,78	0,89	0,50	0,72
09ISO	10	0,82	0,84	0,47	0,71
02STAT1	5	0,62	0,89	0,50	0,67
05KM1	5	0,62	0,89	0,50	0,67
01SPSS	5	0,60	0,90	0,51	0,67
06KM2	5	0,60	0,90	0,51	0,67
07KM3	5	0,60	0,90	0,51	0,67
04SPSS2	5	0,59	0,90	0,48	0,66
03STAT2	5	0,58	0,84	0,47	0,63
09ISO	5	0,67	0,65	0,29	0,54
08CL	5	0,46	0,85	0,18	0,50
10SEG	15B	0,53	0,37	0,58	0,49
10SEG	15A	0,53	0,37	0,56	0,49

10SEG	10	0,51	0,30	0,55	0,45
10SEG	5	0,46	0,13	0,32	0,30
04SPSS2	2	0,14	0,74	0,00	0,29
01SPSS	2	0,14	0,74	0,00	0,29
02STAT1	2	0,14	0,74	0,00	0,29
03STAT2	2	0,14	0,74	0,00	0,29
05KM1	2	0,14	0,74	0,00	0,29
06KM2	2	0,14	0,74	0,00	0,29
07KM3	2	0,14	0,74	0,00	0,29
09ISO	2	0,49	0,18	0,19	0,29
08CL	2	0,12	0,74	0,00 ⁷⁰	0,29
10SEG	2	0,33	0,01	0,27	0,20

Različni načini vrednotenja glede na vse podatkovne sloje hkrati

Preglednica 140: Vrednosti deleža enako klasificiranih celic pri gradnji odločitvenega drevesa z vsemi tremi podatkovnimi sloji.

oznaka klasifikacije	število skupin	delež enako klasificiranih celic z odločitvenim drevesom ct (%)
08CL	2	100,0
08CL	5	100,0
01SPSS	2	99,9
02STAT1	2	99,9
03STAT2	2	99,9
05KM1	2	99,9
06KM2	2	99,9
07KM3	2	99,9
04SPSS2	2	99,8
08CL	10	97,6
09ISO	2	97,2
09ISO	5	96,2
01SPSS	5	94,3
05KM1	5	94,3
06KM2	5	94,3
07KM3	5	94,3
02STAT1	5	94,2
03STAT2	5	94,1
04SPSS2	5	93,8
06KM2	10	92,0
03STAT2	10	91,6
07KM3	10	90,9
09ISO	10	90,5
10SEG	2	89,8
01SPSS	10	89,5
02STAT1	10	89,5
04SPSS2	10	88,5
08CL	15	88,1
05KM1	10	87,1
01SPSS	15	87,0
07KM3	15	87,0
02STAT1	15	86,4
09ISO	15	86,4
06KM2	15	82,6
03STAT2	15	81,8
04SPSS2	15	80,2

⁷⁰ Statistično značilno pri 0,01.

05KM1	15	72,8
10SEG	5	59,8
10SEG	10	47,7
10SEG	15B	37,1
10SEG	15A	35,9

Preglednica 141: Povprečna oddaljenost posamezne celice od najbližjega centroida skupine.

oznaka klasifikacije	število skupin	povprečna oddaljenost
07KM3	15	8,8859
05KM1	15	8,9243
03STAT2	15	8,9682
02STAT1	15	9,0204
01SPSS	15	9,0534
04SPSS2	15	9,2055
06KM2	15	9,2530
07KM3	10	10,1863
02STAT1	10	10,1926
01SPSS	10	10,1927
03STAT2	10	10,2056
05KM1	10	10,2304
08CL	15	10,2323
09ISO	15	10,2419
04SPSS2	10	10,2653
06KM2	10	10,5389
08CL	10	11,7217
09ISO	10	12,4183
04SPSS2	5	13,4637
02STAT1	5	13,5042
05KM1	5	13,5060
01SPSS	5	13,6884
06KM2	5	13,6885
07KM3	5	13,6886
03STAT2	5	14,3748
08CL	5	15,8132
09ISO	5	15,9818
04SPSS2	2	19,6206
01SPSS	2	19,6291
02STAT1	2	19,6291
03STAT2	2	19,6291
05KM1	2	19,6292
07KM3	2	19,6292
06KM2	2	19,6293
08CL	2	19,8117
10SEG	15B	20,2223
10SEG	15A	20,2492
10SEG	10	21,5381
09ISO	2	23,4417
10SEG	5	23,9179
10SEG	2	26,3183

Preglednica 142: Delež enako klasificiranih celic po modelu diskriminancijske analize.

oznaka klasifikacije	število skupin	delež pravilno klasificiranih (%)
01SPSS	2	97,7
02STAT1	2	97,7
03STAT2	2	97,7
05KM1	2	97,7
06KM2	2	97,7

07KM3	2	97,7
04SPSS2	2	97,6
07KM3	15	97,3
02STAT1	5	97,1
03STAT2	10	97,1
05KM1	5	97,1
08CL	2	97,0 ⁷¹
06KM2	10	96,9
02STAT1	15	96,7
07KM3	10	96,6
05KM1	15	96,5
01SPSS	10	96,4
02STAT1	10	96,4
05KM1	10	96,3
06KM2	15	96,3
03STAT2	15	96,2
04SPSS2	5	96,2
01SPSS	5	96,1
06KM2	5	96,1
07KM3	5	96,1
01SPSS	15	96,0
03STAT2	5	95,3
04SPSS2	10	94,8
04SPSS2	15	93,7
09ISO	2	85,3
10SEG	2	84,5
08CL	5	83,3
09ISO	5	81,6
09ISO	15	81,3
09ISO	10	81,2
08CL	15	80,4
08CL	10	79,9
10SEG	5	50,7
10SEG	10	39,7
10SEG	15B	29,9
10SEG	15A	29,2

Pri vseh je koeficient F statistično značilen 0,001 (oziroma manj), razen če je drugače označeno. Boxov M test, ki preverja enakost variančno-kovariančnih matrik, je bil v vseh primerih statistično značilen. Ker je ta rezultat manj zanesljiv (Kastelec in Košmelj 2008), smo rezultate vseeno vključili v analizo. Klasifikacije, pri katerih je bila ugotovljena singularna matrika, so zapisane poševno.

⁷¹ Statistična značilnost koeficienta je $p=0,012$.

Priloga 9: Argumentiranje izbora podatkov za izdelavo naravnopokrajinskih tipizacij po metodah nadzorovane klasifikacije.

Preglednica 143: Pregled argumentov izbora podatkovnih slojev.

podakovni sloj (oznaka)	izbran	povezanost	raven	pojasnjevalna moč	razpon vrednosti	drugo
razlika v aprilski in oktobrski temperaturi (APRMOKT)	ne	povezanost z VISINA; opazna povezanost z PADRAZ (VISINA pa precej manj)		nadpovprečna		slabša ločljivost v izvornem podatku
ekspozicija (EKSP0)	ne	šibka povezanost	deluje kot šum	podpovprečna		
gostota rečne mreže (GRM500)	ne	šibka povezanost		podpovprečna	močno odstopajoče skrajne vrednosti	
naklon (NAKLON)	DA	Opazna povezanost s TEMLET in VISINA izjemno visoka povezanost (>0,6) le z merami RAZGIBN in V;		nadpovprečna		
sončno obsevanje (OSONC)	ne	povezana le z ekspozicijo		podpovprečna	odstopajoče skrajne vrednosti	
povprečna višina padavin v aprilu (P_APR)	ne	povezanost s PADLET				
povprečna višina padavin v avgustu (P_AVG)	ne	povezanost s PADLET				
povprečna višina padavin v decembru (P_DEC)	ne	povezanost s PADLET				
povprečna višina padavin v februarju (P_FEB)	ne	povezanost s PADLET				
povprečna višina padavin v januarju (P_JAN)	ne	povezanost s PADLET				
povprečna višina padavin v juliju (P_JUL)	ne	povezanost s PADLET				
povprečna višina padavin v juniju (P_JUN)	ne	povezanost s PADLET				
povprečna višina padavin v maju (P_MAJ)	ne	povezanost s PADLET				
povprečna višina padavin v marcu (P_MAR)	ne	povezanost s PADLET				
povprečna višina padavin v novembru (P_NOV)	ne	povezanost s PADLET				
povprečna višina padavin v oktobru (P_OKT)	ne	povezanost s PADLET				
povprečna višina padavin v septembru (P_SEP)	ne	povezanost s PADLET				
povprečna letna višina padavin (PADLET)	ne	dobro povezana z VIŠINO		nadpovprečna		
padavinski režim: poletje : jesen (PADRAZPJ)	DA	ni povezana z VISINO		nadpovprečna		
padavinski režim: poletje : zima (PADRAZPZ)	ne	povezana s PADRAZPJ (ki pojasnjuje rahlo bolje)		nadpovprečna		
indeks mediteranskosti padavin (PADRAZM)	ne	povezana s PADRAZPJ (ki pojasnjuje rahlo bolje)		nadpovprečna		

prepustnost (PREP)	DA	slaba povezanost z ostalimi		nadpovprečna		
ekspozicijska razgibanost (RAZGIB_E)	ne	šibka povezanost	deluje kot šum	nizka		
naklonska razgibanost (RAZGIB_N)	ne	povezanost z NAKLON		podpovprečna	odstopajoče skrajne vrednosti	
skupna razgibanost (RAZGIB_S)	ne		na višjih ravneh deluje kot šum	podpovprečna		
višinska razgibanost (RAZGIB_V)	ne	povezanost z NAKLON;		nadpovprečna	močno odstopajoče skrajne vrednosti	
povprečna mesečna temperatura v aprilu (T_APR)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v avgustu (T_AVG)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v decembru (T_DEC)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v februarju (T_FEB)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v januarju (T_JAN)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v juliju (T_JUL)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v juniju (T_JUN)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v maju (T_MAJ)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v marcu (T_MAR)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v novembru (T_NOV)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v oktobru (T_OKT)	ne	povezanost s TEMLET				
povprečna mesečna temperatura v septembru (T_SEP)	ne	povezanost s TEMLET				
tekstura (TEKS)	ne	nizka povezanost z ostalimi	na višjih ravneh deluje kot šum	podpovprečna		
povprečna letna temperatura (TEMLET)	ne	povezana z VISINO in tudi 0,6 z PADLET		nadpovprečna		slabša ločljivost v izvornem podatku
letna temperaturna razlika (TEMRAZ)	ne	povezanost z APRMOKT, VISINA, opazna povezanost z PADRAZ (VISINA PA MANJ!)		nadpovprečna		slabša ločljivost v izvornem podatku
nadmorska višina (VISINA)	DA	močno povezana z vsemi, ki so medseboj močno ali dobro povezani: APRMOKT, TEMRAZ in TEMLET; ni povezana s PADRAZ		nadpovprečna		dobra ločljivost v izvornem podatku

Priloga 10: Primer opisa modelirane naravnopokrajnske tipizacije TIPI9 po metodi odločitvenega drevesa (različica CT)

Preglednica 144: Primer opisa rezultata nadzorovanih klasifikacij na primeru modeliranih tipizacij TIPI9 po metodi odločitvenega drevesa CT.

tip (oznaka)	opis lokacij ⁷² tipa		primerjava lokacij modeliranega tipa z izvirnim tipom TIPI9
	naravnopokrajnska tipizacija TIPI9 po metodi CT z ekspertnem naborom učnih celic	naravnopokrajnska tipizacija TIPI9 po metodi CT z naključnim naborom učnih celic	
alpska gorovja (1.1)	Klasificirani najvišji deli Julijskih Alp, Karavank, Kamniško-Savinjskih Alp, Pohorja, Menine planine, Zasavja, Gorjancev, Roga, Snežnika, Vitanjskih Karavank, Boča ter pobočja z visokim naklonom na obrobju Trnovskega gozda, Nanosa, Kolpske doline, Pokljuke, Jelovice. Presenetljivo klasificiran vzhodni del Brkinov.	Klasificirani višji deli Julijskih Alp, Pokljuke, Jelovice, Karavank, Kamniško-Savinjskih Alp, Pohorja, Menine planine, Zasavja (Kum, Bohor), Gorjancev, Roga, Snežnika, Vitanjskih Karavank, Cerkljanskega hribovja ter pobočja z visokim naklonom na obrobju Trnovskega gozda, Nanosa, Kolpske doline, Stojne.	V primerjavi z izvirno klasifikacijo imajo modelirane klasifikacije izločene večje doline (Dolina, Bohinj, doline Save, Savinje, Soče, Kamniške bistrice). Modelirane klasifikacije imajo vključene najvišje dele alpskega hribovja, dinarskih planot ter tudi panonskega gričevja (npr. Boč, Donačka gora) in sredozemskega gričevja (npr. obrobja Nanosa).
alpska hribovja (1.2)	Klasificirani Polhograjsko in Škofjeloško hribovje, Pohorje, razdrobljeni delci Zasavskega hribovja ter Vitanjskih Karavank, Stojne, Krimskega hribovja in Idrijskega hribovja. Deli pobočij znotraj Julijskih in Kamniško-Savinjskih Alp ter Karavank, severni del Goriških Brd.	Klasificirani Škofjeloško, Polhograjsko in Zasavsko hribovje, Vitanjske Karavanke, Pohorje, Strojna, Paški Kozjak ter Boč in Donačka gora, deli Krškega gričevja.	V primerjavi z izvirno klasifikacijo imajo modelirane klasifikacije izločene večje doline (Sora, Sava, Drava, Savinja ter JV del Kozjanskega (z izjemo Orlice). Predvsem ekspertni model vključuje raztresena območja znotraj dinarskih planot ter alpskega gorovja, naključni model pa strnjena višja območja Boča, Maclja ter okolice Mozirja.
alpske ravnine (1.3)	Klasificirani Ljubljansko polje, Celjska kotlina, severni del Dravske ravni, večje doline (Sava, Sora, Savinja, Drava, Mislinja), deli Ribniško-Kočevskega podolja, doline znotraj panonskih gričevij ter nekateri vršaji (npr. Iški vršaj).	Klasificirani Ljubljansko polje, Celjska kotlina, večje doline (Sava, Sora, Savinja okrog Ljubnega ob Savinji), deli Ribniško-Kočevskega podolja, deli dinarskih planot (Dobrepolje), Kozjanskega ter nekateri vršaji (npr. Iški vršaj).	V primerjavi z izvirno klasifikacijo imajo modelirane klasifikacije izločeno predvsem bolj razgibano območje Ljubljanskega polja, ki je sestavljeno iz konglomerata ter raznih karbonatov. Ekspertna klasifikacija vključuje tudi severni del Dravske ravni, večje doline (Sava, Sora, Savinja, Drava, Mislinja), doline znotraj panonskih gričevij. Oba modela vključujeta tudi dele Ribniško-Kočevskega podolja, ter nekatere vršaje.
panonska gričevja (2.1)	Klasificirani Goričko, precejšen del Lendavskih, Dravinjskih in Slovenskih goric, Haloze, severno Kozjansko, Ložniško gričevje, obrobje Celjske kotline, obrobje Pohorja, pobočja dolin Save, Savinje, Drave, osrednji del Krškega gričevja, dei Posavskega hribovja.	Klasificirani Goričko, Lendavske gorice, Slovenske gorice, Dravinjske gorice, Haloze, severno Kozjansko, Ložniško gričevje, obrobje Celjske kotline, obrobje Pohorja, Dravska dolina, pobočja dolin Save in Savinje, Krško gričevje, dei Posavskega hribovja, del Gorjancev.	Izločeni so Boč, Maclja, Donačka gora, Orlica, Bizeljsko in južno Kozjansko ter večje rečne doline (na primer dolina Ščavnice, Ledave). Vključene so pobočja ali dna dolin večjih rek v alpskem hribovju (Drava, Sava, Savinja), obrobje Celjske kotline, Ložniško gričevje, deli Posavskega hribovja.
panonske ravnine (2.2)	Klasificirani Pomurska ravnina, dolina Ščavnice, Dravinje in manjših pritokov Drave in Mure, južno Dravsko-Ptujsko polje, dolina Sotle, Save (od Litije naprej), Krška kotlina (z okolico Novega mesta), dolina Krke od Zagradca, okolica Metlike.	Klasificirani Pomurska ravnina, Dravska ravan, Celjska, Velenjska in Krška kotlina, doline Ledave, Save (od Dolskega) in Savinja (od Celja).	Izločen je severni del Dravske ravni (pri ekspertni klasifikaciji). Vključene so doline večjih in manjših vodotokov v panonskem gričevju in alpskem hribovju. Pri ekspertni klasifikaciji je vključena tudi okolica Novega mesta z dolino Krke ter okolica Metlike.
dinarske planote (3.1)	Klasificirani so Kočevski Rog, Goteniška gora, Stojna, Ribniška Mala in Velika gora, Krmsko	Klasificirani so Kočevski Rog, Goteniška gora, Stojna, Ribniška Mala in Velika gora, Krmsko	Pri obeh so izločena območja: Kambreško, Banjšice, Čepovanski dol, velik del Idrijskega hribovja,

⁷² Zemeljepisna imena so uporabljena tako, da poskušajo kar najbolj opisati območje, in niso poenotena oziroma niso vzeta samo iz enega sistema poimenovanj.

	hribovje, Bloke, Javorniki, Trnovski gozd, Nanos, Snežnik, Slavnik, Vremščica, Pokljuka, Jelovica, Mežakla, deli Polhograjskega, Posavskega hribovja, Gorjancev, Orlice, Bohorja, pobočja ob zgornji Savinji, Matajurja.	hribovje, Menišija, Bloke, Javorniki, Trnovski gozd, Nanos, Snežniško hribovje (brez najvišjega dela), Slavnik, Vremščica, deli Polhograjskega hribovja, Gorjancev, Orlice, Bohorja, pobočja ob zgornji Savi Bohinjki in Dolinki, Matajurja, Logarska dolina, okolica Mežice.	Kočevskoreški ravniki in Kolpska dolina. Pri naključni klasifikaciji tudi najvišji del Snežnika in Gorjancev. Pri ekspertni so izločeni Menišija, Suha krajina, najvišji deli Gorjancev in velik del Raduljskega hribovja. Pri ekspertni so vključene planote (Jelovica itd.), posamezna območja Polhograjskega in Posavskega hribovja, pri obeh klasifikacijah pa Vremščica, Slavnik, Bohor, Orlica oz. njihovi manjši deli. Vključene so tudi nekatere doline in pobočja znotraj alpskega gorovja.
dinarska podolja in ravniki (3.2)	Klasificirani so Pivška kotlina, Cerkljiško polje, Ljubljansko barje (z izjemo vršajev), deli Ribniško-Kočevskega podolja, Dobropolja, Bela krajina, obrobja Krške kotline, velik del Dolenjskega podolja, južno Kozjansko in deli Bizeljskega, bolj razgibani (a ne najvišji) deli osrednja Ljubljanskega polja (med Kamnikom, Medvodami in Brnikom), vzhodno obrobje Ljubljanske kotline.	Klasificirani so Pivška kotlina, Cerkljiško polje, Ljubljansko barje (z izjemo vršajev), deli Logaškega, Planinskega polja, Ribniško-Kočevskega podolja, Dobropolja, Kočevskoreškega ravnika, Bela krajina, deli Kolpske doline, zahodna Krška kotlina, velik del Dolenjskega podolja, južno Kozjansko in deli Bizeljskega, območje ob Pšati, vzhodno obrobje Ljubljanske kotline.	Pri naključni klasifikaciji so izločeni večji del Pivške kotline, območje Logaškega, Planinskega polja, velik del zahodne Krške kotline in območje Velikih Lašč. Vključeni so deli Suhe krajine, Kozjanskega, Biteljskega, vzhodnega roba Ljubljanskega kotline in (predvsem pri ekspertni) razgiban del Ljubljanskega polja. Pri naključni je vključen tudi del spodnje Kolpske doline.
sredozemska gričevja (4.1)	Klasificirani so Koprsko primorje, Vipavska dolina, Goriška Brda, osrednji del Brkinov, deli Soške doline ter manjši deli ob Idrijci, Kolpi, v Pivški kotlini, Planinskem polju.	Klasificirani so Koprsko primorje, Vipavska dolina, Goriška Brda, Brkini, deli Soške doline ter manjši deli ob Idrijci, Kolpi, v Pivški kotlini.	Pri ekspertni analizi je izločen del Brkinov ter manjši del Goriških Brd in Vipavske doline. Vključeni so nekateri deli Soške doline, območja ob Idrijci in Kolpi ter v Pivški kotlini. Pri ekspertni tudi del Planinskega polja.
sredozemske planote (4.2)	Klasificirani so Kras, Podgorski kras, Matarsko podolje (brez najvišjih delov), Slavinski ravniki, Košana dolina, Čepovanski dol, deli Pivške kotline, Kočevskoreškega ravnika in hribovij nad Kolpsko dolino, okolica Logatca in Godoviča, deli Cerkljanskega in Idrijskega hribovja, Banjšic, Kambreškega, Soške doline, Bohinja.	Klasificirani so Kras, Podgorski kras, Matarsko podolje (brez najvišjih delov), Košana dolina, Čepovanski dol, deli Pivške kotline, hribovij nad Kolpsko dolino, okolica Logatca in Godoviča, deli Cerkljanskega in Idrijskega hribovja, manjši del Banjšic, Kambreškega, Soške doline.	Izključeni so predvsem najvišji deli Čičarije med Podgorskim krasom in Matarskim podoljem. Vključeni so Kočevskoreški ravniki (predvsem pri ekspertni), območje med Logatcem in Godovičem, Čepovanski dol deli Banjšic, Cerkljanskega in Idrijskega hribovja, Pivške kotline, Slavinskega ravnika, Košana doline Bohinja (samo pri ekspertni), Soške doline, hribovij nad Kolpsko dolino.

Največje razlike so na območju tipov 1.1 (alpska gorovja), 1.2 (alpska hribovja), 3.1 (dinarske planote) in 3.2 (dinarska podolja in ravniki). Pri obeh modeliranih tipizacijah je opazno, da je del (po izvorni tipizaciji) alpskega hribovja v osrednji Sloveniji (med Ljubljano in Celjem) klasificiran kot panonsko gričevje, nekateri deli Pohorja ter dinarskih planot pa so klasificirani kot alpsko gorovje (Snežnik, Gorjanci, deli Kočevskega Roga, Trnovskega gozda in zgornje Kolpske doline; predvsem strma robna pobočja). Dobro ujemanje je vidno na območju panonskih gričevij in panonskih ravnin, sredozemskih gričevij ter sredozemskih planot. Pri tem je vidno, da je pri ekspertni nadzorovani klasifikaciji (pri naključni nadzorovani klasifikaciji manj izrazito) kot območje sredozemskih planot označena okolica Logatca, Cerknega in Tolmina.

Priloga 11: Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 in TIPI13

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 s pomočjo vseh podatkovnih slojev hkrati

Preglednica 145: Pearsonovi koeficienti stopnje povezanosti vrednotenja glede na vse podatkovne sloje hkrati. V drugi vrstici so zapisane ustrezne statistične značilnosti koeficientov.

	neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenj s posameznimi podatkovnimi sloji					
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminanci analize	delež enako klasificiranih celic z odločitvenim drevsom (CT)	delež enako klasificiranih celic z odločitvenim drevsom (CT)	informativni prispevek	razmerje informacijskega prispevka	koeficient η^2	Koeficient F	PUKV
povprečna oddaljenost celic od najbližjega centroida	1,000	-0,985	-0,267	-0,392	-0,637	-0,813	-0,908	-0,982	0,901
delež enako klasificiranih celic po modelu diskriminanci analize	0,000	0,000	0,337	0,148	0,011	0,000	0,000	0,000	0,000
delež enako klasificiranih celic z odločitvenim drevsom (CT)		1,000	0,315	0,349	0,697	0,833	0,920	0,991	-0,904
delež enako klasificiranih celic z odločitvenim drevsom (CT) (povprečje)		0,000	0,252	0,202	0,004	0,000	0,000	0,000	0,000
informativni prispevek (povprečje)			1,000	0,087	0,607	0,594	0,287	0,315	-0,208
razmerje informacijskega prispevka (povprečje)			0,000	0,759	0,016	0,019	0,300	0,253	0,457
koeficient η^2 (povprečje)				1,000	0,309	0,312	0,479	0,406	-0,490
Koeficient F (povprečje)				0,000	0,263	0,258	0,071	0,134	0,064
PUKV (povprečje)					1,000	0,895	0,691	0,677	-0,762
					0,000	0,000	0,004	0,006	0,001
						1,000	0,810	0,831	-0,782
						0,000	0,000	0,000	0,001
							1,000	0,946	-0,927
							0,000	0,000	0,000
								1,000	-0,903
								0,000	0,000
									1,000
									0,000

Preglednica 146: Spearmanovi koeficienti stopnje povezanosti vrednotenja glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.

	neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenja s posameznimi podatkovnimi sloji					
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminanci analize	delež enako klasificiranih celic z odločitvenim drevsom (CT)	delež enako klasificiranih celic z odločitvenim drevsom (CT)	informativni prispevek	razmerje informacijskega prispevka	koeficient η^2	Koeficient F	PUKV
povprečna oddaljenost celic od najbližjega centroida	1,000	-0,896	-0,041	-0,471	-0,693	-0,789	-0,929	-0,914	0,957
delež enako klasificiranih celic po modelu diskriminanci analize	0,000	0,000	0,884	0,076	0,004	0,000	0,000	0,000	0,000
delež enako klasificiranih celic z odločitvenim drevsom (CT)		1,000	0,193	0,493	0,736	0,821	0,939	0,950	-0,946
delež enako klasificiranih celic z odločitvenim drevsom (CT) (povprečje)		0,000	0,491	0,062	0,002	0,000	0,000	0,000	0,000
informativni prispevek (povprečje)			1,000	0,116	0,513	0,343	0,213	0,197	-0,138
razmerje informacijskega prispevka (povprečje)									
koeficient η^2 (povprečje)									
Koeficient F (povprečje)									
PUKV (povprečje)									

klasificiranih celic z odločitvenim drevesom (CT)			0,000	0,680	0,051	0,210	0,447	0,482	0,625
delež enako klasificiranih celic z odločitvenim drevesom (CT) (povprečje)				1,000	0,557*	0,496	0,486	0,454	-0,486
informatijski prispevek (povprečje)					1,000	0,896	0,682	0,714	-0,714
razmerje informacijskega prispevka (povprečje)						1,000	0,793	0,800	-0,793
koeficient eta ² (povprečje)							1,000	0,979	-0,982
koeficient F (povprečje)								1,000	-0,975
PUKV (povprečje)									1,000
									0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnega sloja naklon

Preglednica 147: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informacijskega prispevka	koeficient eta ²	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,815	0,821	0,735	0,725	-0,777
	0,000	0,000	0,000	0,002	0,002	0,001
informatijski prispevek		1,000	0,990	0,892	0,905	-0,952
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,870	0,880	-0,927
			0,000	0,000	0,000	0,000
koeficient eta ²				1,000	0,995	-0,984
				0,000	0,000	0,000
koeficient F					1,000	-0,986
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 148: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informacijskega prispevka	koeficient eta ²	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,790	0,825	0,804	0,785	-0,810
	0,000	0,000	0,000	0,000	0,001	0,000
informatijski prispevek		1,000	0,989	0,893	0,893	-0,954
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,895	0,893	-0,952
			0,000	0,000	0,000	0,000
koeficient eta ²				1,000	0,992	-0,956

				0,000	0,000	0,000
koeficient F					1,000	-0,939
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnega sloja padavinski režim

Preglednica 149: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,514	0,516*	-0,301	-0,241	0,181
	0,000	0,050	0,049	0,276	0,388	0,519
informacijski prispevek		1,000	0,961	0,403	0,405	-0,514
		0,000	0,000	0,137	0,134	0,050
razmerje informacijskega prispevka			1,000	0,498	0,511	-0,612*
			0,000	0,059	0,051	0,015
koeficient η^2				1,000	0,990	-0,985
				0,000	0,000	0,000
koeficient F					1,000	-0,986
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 150: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,424	0,545	-0,314	-0,345	0,200
	0,000	0,115	0,036	0,255	0,208	0,474
informacijski prispevek		1,000	0,974	0,543	0,524	-0,656
		0,000	0,000	0,036	0,045	0,008
razmerje informacijskega prispevka			1,000	0,440	0,421	-0,571
			0,000	0,101	0,118	0,026
koeficient η^2				1,000	0,994	-0,969
				0,000	0,000	0,000
koeficient F					1,000	-0,968
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnega sloja prepustnost

Preglednica 151: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informatijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,817	0,819	0,721	0,730	-0,784
	0,000	0,000	0,000	0,002	0,002	0,001
informatijski prispevek		1,000	10,000	0,826	0,907	-0,920
		0,000	0,000	0,000	0,000	0,000
razmerje informatijskega prispevka			1,000	0,829	0,909	-0,923
			0,000	0,000	0,000	0,000
koeficient η^2				1,000	0,872	-0,877
				0,000	0,000	0,000
koeficient F					1,000	-0,974
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 152: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informatijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,636	0,642	0,573	0,561	-0,604
	0,000	0,011	0,010	0,026	0,030	0,017
informatijski prispevek		1,000	0,996	0,736	0,782	-0,807
		0,000	0,000	0,002	0,001	0,000
razmerje informatijskega prispevka			1,000	0,744	0,792	-0,817
			0,000	0,001	0,000	0,000
koeficient η^2				1,000	0,836	-0,893
				0,000	0,000	0,000
koeficient F					1,000	-0,986
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI9 s pomočjo podatkovnega sloja nadmorska višina

Preglednica 153: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informatijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,659	0,586	0,612	0,651	-0,739
	0,000	0,008	0,022	0,015	0,009	0,002
informatijski prispevek		1,000	0,986	0,756	0,725	-0,895

prispevek		0,000	0,000	0,001	0,002	0,000
razmerje informacijskega prispevka			1,000	0,702	0,661	-0,832
koeficient η^2				1,000	0,987	-0,945
koeficient F				0,000	0,000	0,000
PUKV					1,000	-0,935
						0,000
						1,000
						0,000

Preglednica 154: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,608	0,531	0,680	0,717	-0,770
informacijski prispevek	0,000	0,016	0,042	0,005	0,003	0,001
razmerje informacijskega prispevka		1,000	0,963	0,820	0,800	-0,925
koeficient η^2		0,000	0,000	0,000	0,000	0,000
koeficient F			1,000	0,733	0,713	-0,847
PUKV			0,000	0,002	0,003	0,000
				1,000	0,993	-0,932
				0,000	0,000	0,000
					1,000	-0,932
					0,000	0,000
						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIP13 s pomočjo vseh podatkovnih slojev hkrati

Preglednica 155: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.

	neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenje s posameznimi podatkovnimi sloji						
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminancijske analize	delež enako klasificiranih celic z odločitvenim drevesom (CT)	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV	
povprečna oddaljenost celic od najbližjega centroida	1,000	-0,967	-0,519	-0,629	-0,508	-0,696	-0,981	-0,967	0,883	
delež enako klasificiranih celic po modelu diskriminancijske analize	0,000	0,000	0,047	0,012	0,053	0,004	0,000	0,000	0,000	
delež enako klasificiranih celic z odločitvenim drevesom (CT)		1,000	0,609	0,708	0,579	0,696	0,983	0,972	-0,946	
delež enako klasificiranih celic z odločitvenim drevesom (CT) (povprečje)		0,000	0,016	0,003	0,024	0,004	0,000	0,000	0,000	
informacijski prispevek			1,000	0,490	0,866	0,827	0,571	0,667	-0,550	
			0,000	0,064	0,000	0,000	0,026	0,007	0,034	
				1,000	0,322	0,419	0,631	0,625	-0,579	
				0,000	0,242	0,120	0,012	0,013	0,024	
					1,000	0,928	0,614	0,655	-0,653	

(povprečje)					0,000	0,000	0,015	0,008	0,008
razmerje informacijskega prispevka (povprečje)						1,000	0,744	0,773	-0,690
						0,000	0,001	0,001	0,004
koeficient η^2 (povprečje)							1,000	0,980	-0,952
							0,000	0,000	0,000
koeficient F (povprečje)								1,000	-0,914
								0,000	0,000
PUKV (povprečje)									1,000
									0,000

Preglednica 156: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na vse podatkovne sloje hkrati. V drugi koloni so zapisane statistične značilnosti koeficientov.

	neposredno vrednotenje z vsemi podatkovnimi sloji				povprečje vrednotenje s posameznimi podatkovnimi sloji					
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminanci ne analize	delež enako klasificiranih celic z odločitvenim drevesom (CT)	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV	
povprečna oddaljenost celic od najbližjega centroida	1,000	-0,971	-0,586	-0,561	-0,604	-0,689	-0,982	-0,918	0,971	
	0,000	0,000	0,022	0,030	0,017	0,004	0,000	0,000	0,000	
delež enako klasificiranih celic po modelu diskriminanci ne analize		1,000	0,657	0,643	0,643	0,696	0,964	0,932	-0,954	
		0,000	0,008	0,010	0,010	0,004	0,000	0,000	0,000	
delež enako klasificiranih celic z odločitvenim drevesom (CT)			1,000	0,621	0,843	0,868	0,604	0,775	-0,571	
			0,000	0,013	0,000	0,000	0,017	0,001	0,026	
delež enako klasificiranih celic z odločitvenim drevesom (CT) (povprečje)				1,000	0,504	0,600	0,557	0,589	-0,507	
				0,000	0,056	0,018	0,031	0,021	0,054	
informacijski prispevek (povprečje)					1,000	0,868	0,643	0,771	-0,675	
					0,000	0,000	0,010	0,001	0,006	
razmerje informacijskega prispevka (povprečje)						1,000	0,714	0,779	-0,689	
						0,000	0,003	0,001	0,004	
koeficient η^2 (povprečje)							1,000	0,929	-0,989	
							0,000	0,000	0,000	
koeficient F (povprečje)								1,000	-0,918	
								0,000	0,000	
PUKV (povprečje)									1,000	
									0,000	

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI13 s pomočjo podatkovnega sloja naklon

Preglednica 157: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,770	0,797	0,674	0,662	-0,697
	0,000	0,001	0,000	0,006	0,007	0,004
informacijski prispevek		1,000	0,981	0,900	0,924	-0,942
		0,000	0,000	0,000	0,000	0,000

razmerje informacijskega prispevka			1,000	0,846	0,865	-0,890
			0,000	0,000	0,000	0,000
koeficient η^2				1,000	0,979	-0,992
				0,000	0,000	0,000
koeficient F					1,000	-0,987
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 158: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj naklon. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,815	0,851	0,713	0,713	-0,735
	0,000	0,000	0,000	0,003	0,003	0,002
informatijski prispevek		1,000	0,976	0,904	0,904	-0,929
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,858	0,858	-0,889
			0,000	0,000	0,000	0,000
koeficient η^2				1,000	1,000	-0,993
				0,000	0,000	0,000
koeficient F					1,000	-0,993
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIP13 s pomočjo podatkovnega sloja padavinski režim

Preglednica 159: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informatijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,715	0,685	0,651	0,614	-0,606
	0,000	0,003	0,005	0,009	0,015	0,017
informatijski prispevek		1,000	0,979	0,697	0,607	-0,651
		0,000	0,000	0,004	0,016	0,009
razmerje informacijskega prispevka			1,000	0,797	0,725	-0,763
			0,000	0,000	0,002	0,001
koeficient η^2				1,000	0,980	-0,995
				0,000	0,000	0,000
koeficient F					1,000	-0,988
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 160: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj padavinski režim. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,740	0,726	0,699	0,690	-0,654
	0,000	0,002	0,002	0,004	0,004	0,008
informacijski prispevek		1,000	0,943	0,745	0,757	-0,743
		0,000	0,000	0,001	0,001	0,002
razmerje informacijskega prispevka			1,000	0,815	0,825	-0,811
			0,000	0,000	0,000	0,000
koeficient η^2				1,000	0,999	-0,996
				0,000	0,000	0,000
koeficient F					1,000	-0,996
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIPI13 s pomočjo podatkovnega sloja prepustnost

Preglednica 161: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,793	0,793	0,899	0,826	-0,877
	0,000	0,000	0,000	0,000	0,000	0,000
informacijski prispevek		1,000	1,000	0,915	0,923	-0,930
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,915	0,922	-0,929
			0,000	0,000	0,000	0,000
koeficient η^2				1,000	0,957	-0,996
				0,000	0,000	0,000
koeficient F					1,000	-0,975
					0,000	0,000
PUKV						1,000
						0,000

Preglednica 162: Spearmanov k koeficient stopnje povezanosti vrednotenj glede na podatkovni sloj prepustnost. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,512	0,512	0,839	0,839	-0,855
	0,000	0,051	0,051	0,000	0,000	0,000
informacijski prispevek		1,000	1,000	0,718	0,718	-0,714
		0,000	0,000	0,003	0,003	0,003

razmerje informacijskega prispevka			1,000	0,718	0,718	-0,714
			0,000	0,003	0,003	0,003
koeficient η^2				1,000	1,000	-0,986
				0,000		0,000
koeficient F					1,000	-0,986
					0,000	0,000
PUKV						1,000
						0,000

Izračunane stopnje povezanosti raznih načinov vrednotenja naravnopokrajinskih tipizacij TIP13 s pomočjo podatkovnega sloja nadmorska višina

Preglednica 163: Pearsonovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.

	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,636	0,555	0,691	0,734	-0,692
	0,000	0,011	0,032	0,004	0,002	0,004
informacijski prispevek		1,000	0,971	0,880	0,838	-0,939
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,792	0,744	-0,846
			0,000	0,000	0,001	0,000
koeficient η^2				1,000	0,985	-0,977
				0,000	0,000	0,000
koeficient F					1,000	-0,949
					0,000	0,000
PUKV						1,000
						0,000

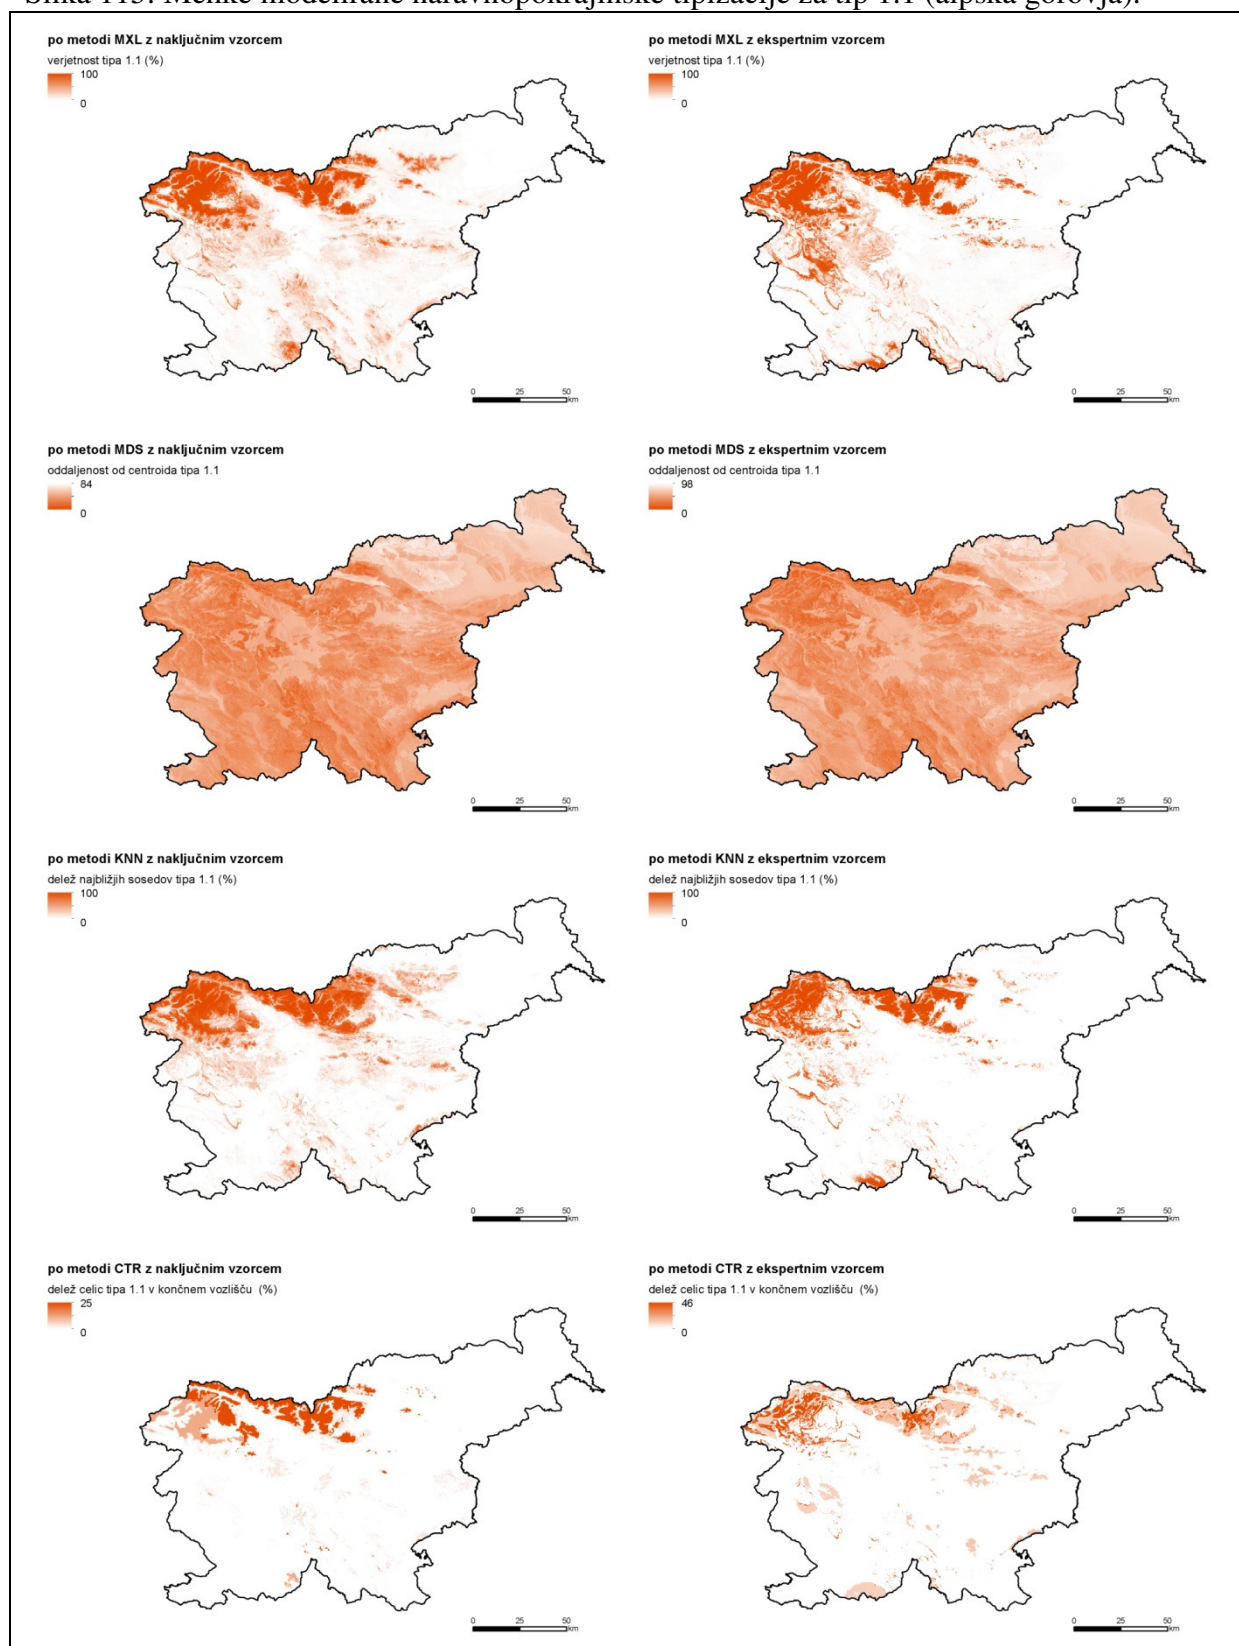
Preglednica 164: Spearmanovi koeficienti stopnje povezanosti vrednotenj glede na podatkovni sloj nadmorska višina. V drugi koloni so zapisane statistične značilnosti koeficientov.

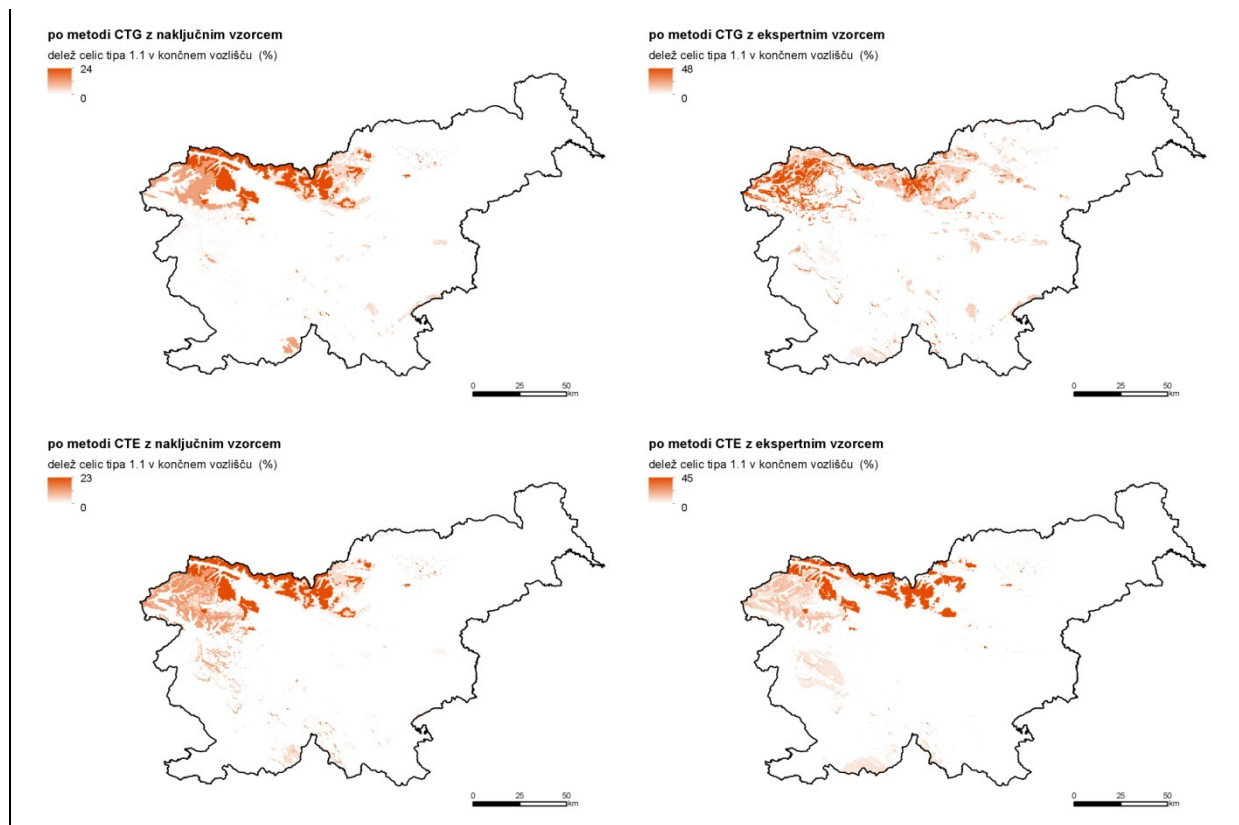
	delež enako klasificiranih celic z odločitvenim drevesom (CT)	informacijski prispevek	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV
delež enako klasificiranih celic z odločitvenim drevesom (CT)	1,000	0,781	0,656	0,810	0,810	-0,797
	0,000	0,001	0,008	0,000	0,000	0,000
informacijski prispevek		1,000	0,907	0,886	0,886	-0,918
		0,000	0,000	0,000	0,000	0,000
razmerje informacijskega prispevka			1,000	0,732	0,732	-0,750
			0,000	0,002	0,002	0,001
koeficient η^2				1,000	1,000	-0,971
				0,000	0,000	0,000
koeficient F					1,000	-0,971
					0,000	0,000
PUKV						1,000
						0,000

Priloga 12: Kartografski prikaz posameznih mehkih klasifikacij

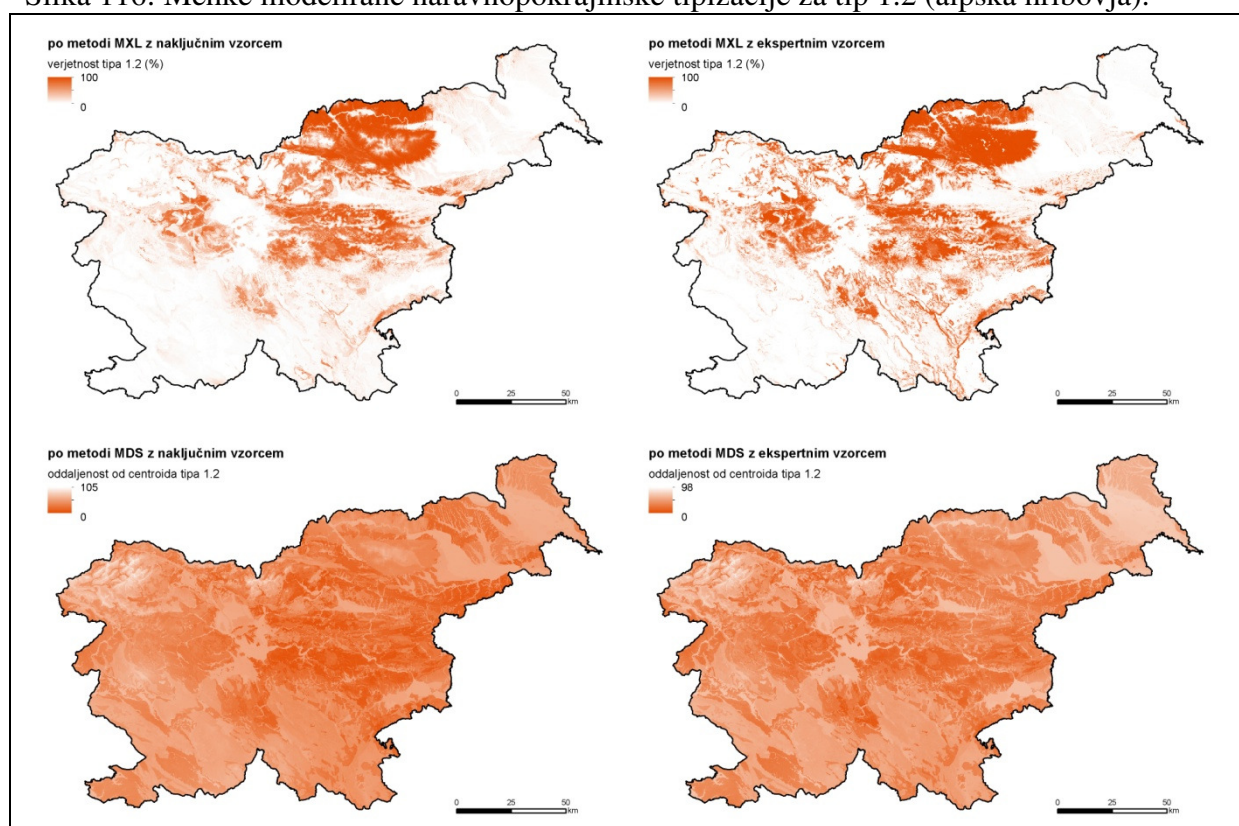
Kartografski prikaz posameznih mehkih klasifikacij za TIPI9

Slika 115: Mehke modelirane naravnopokrajinske tipizacije za tip 1.1 (alpska gorovja).



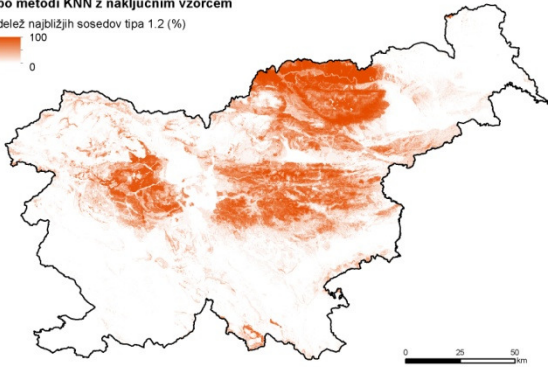


Slika 116: Mehke modelirane naravnopokrajinske tipizacije za tip 1.2 (alpska hribovja).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 1.2 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 1.2 (%)



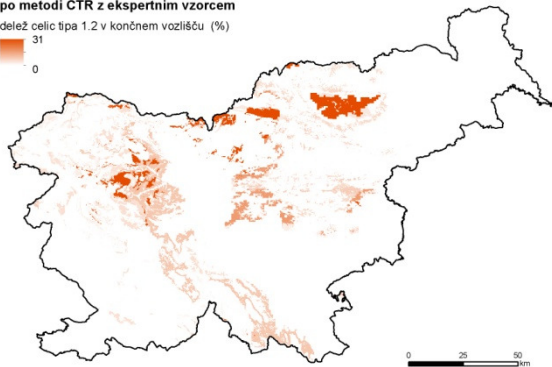
po metodi CTR z naključnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)



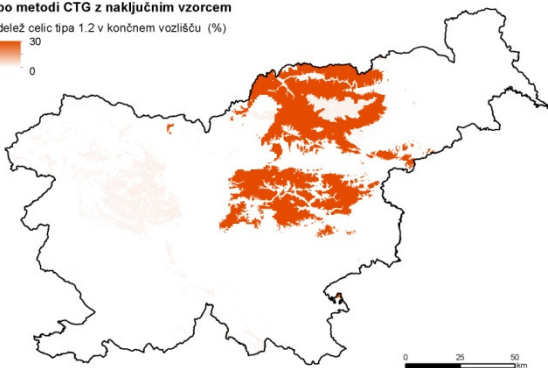
po metodi CTR z ekspertnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)



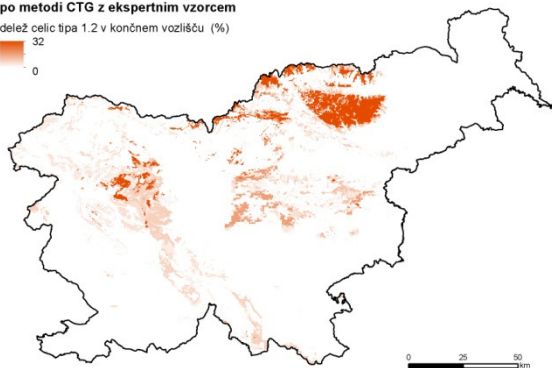
po metodi CTG z naključnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)



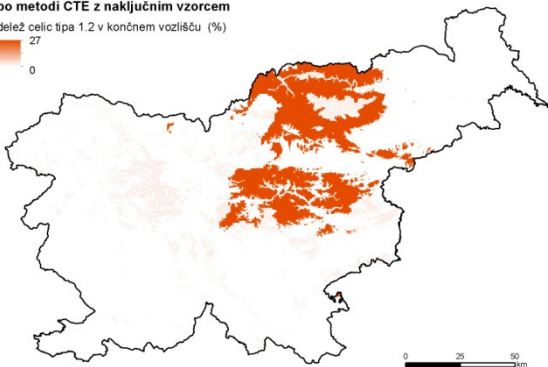
po metodi CTG z ekspertnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)



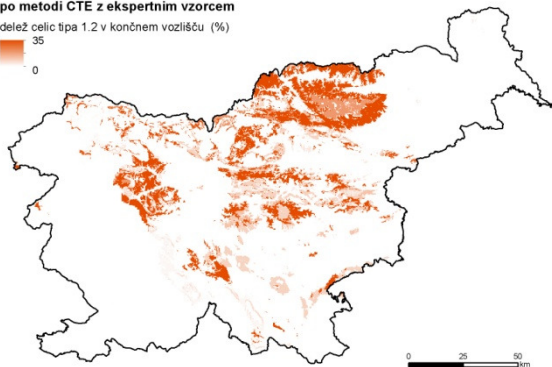
po metodi CTE z naključnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)

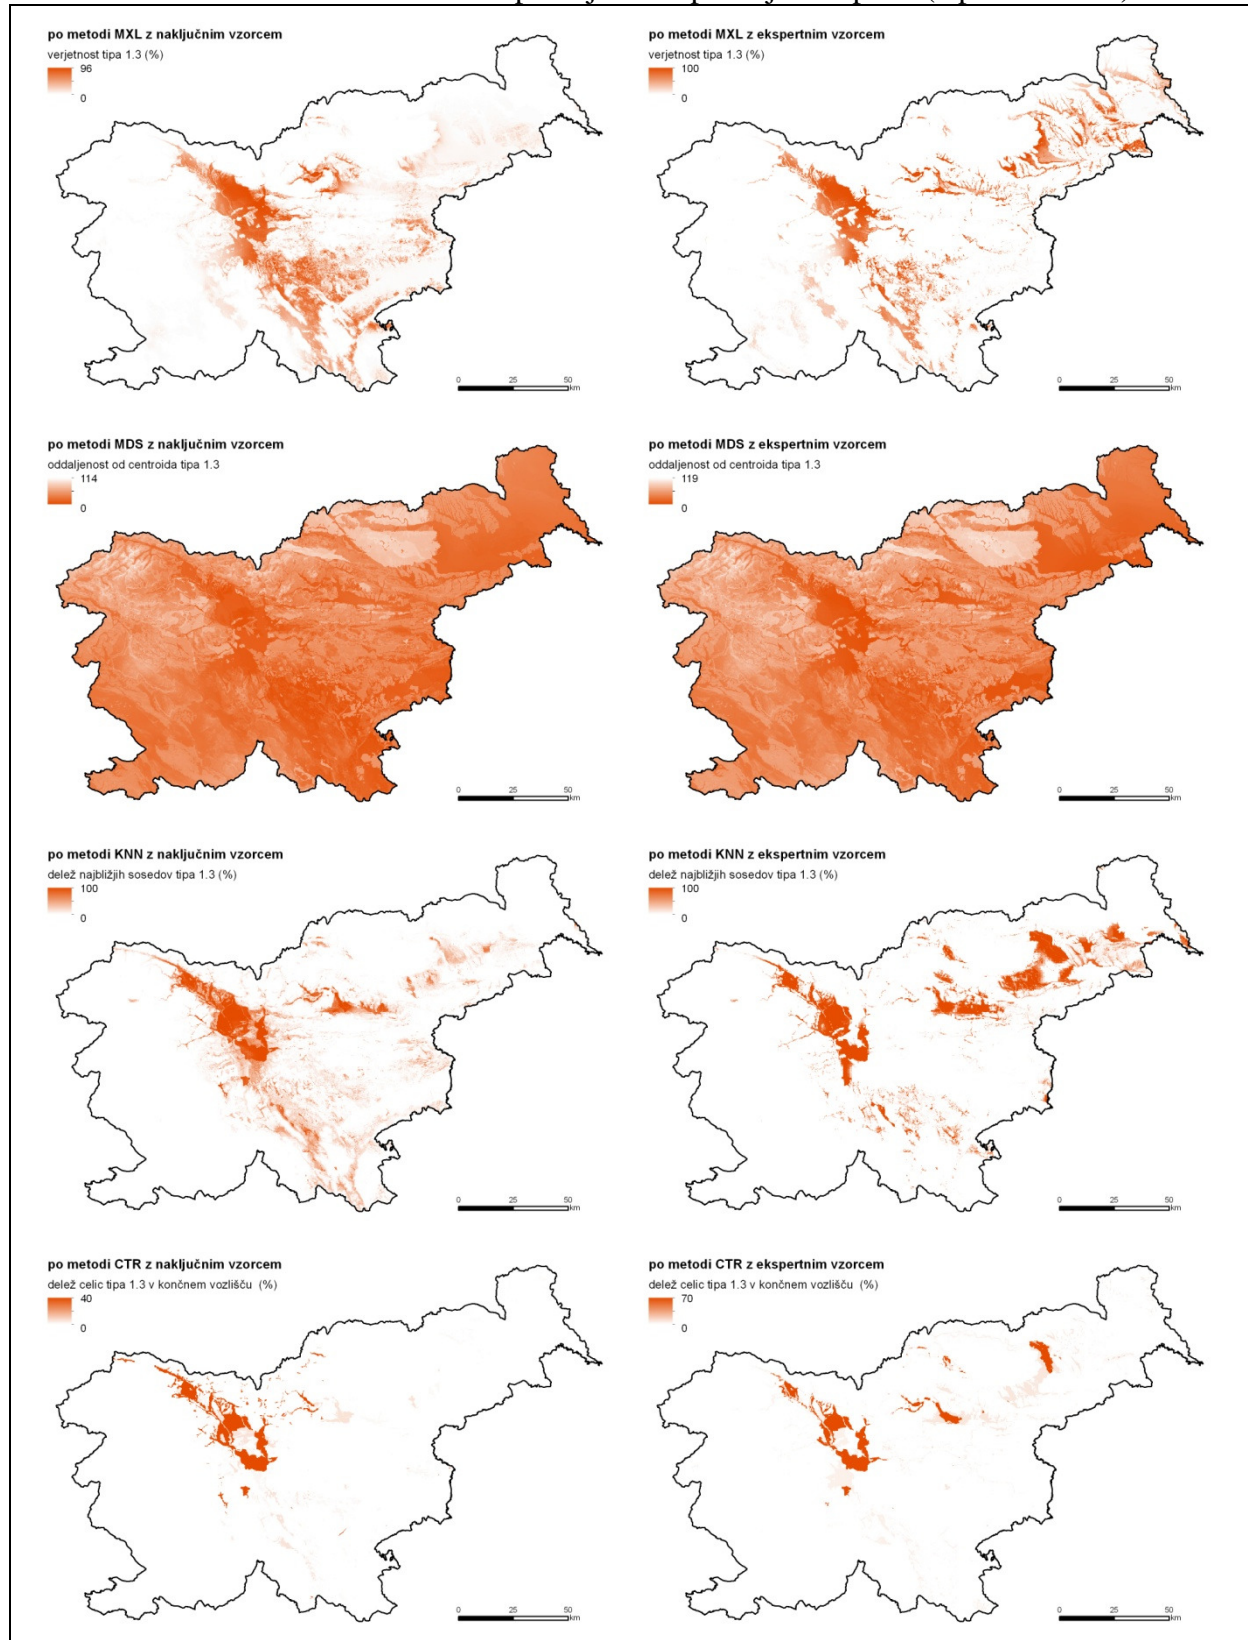


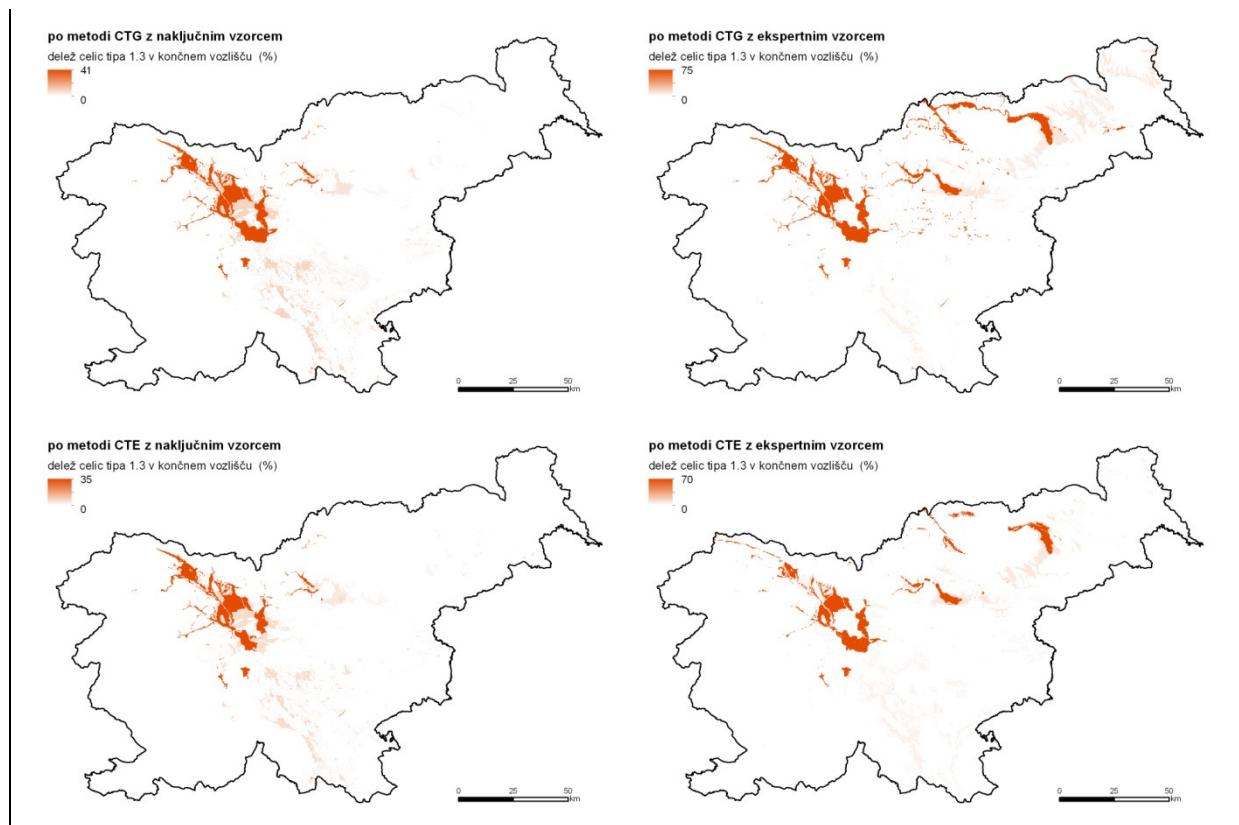
po metodi CTE z ekspertnim vzorcem

delež celic tipa 1.2 v končnem vozlišču (%)

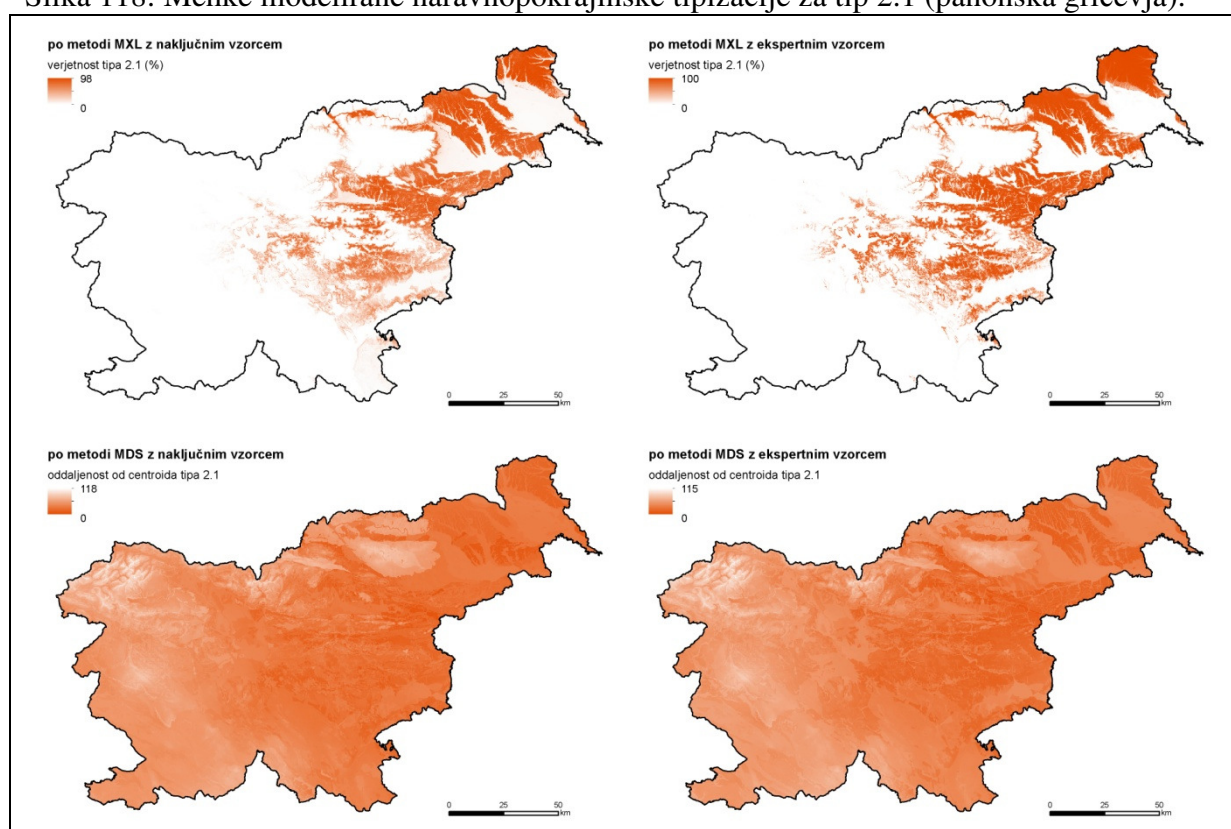


Slika 117: Mehke modelirane naravnopokrajinske tipizacije za tip 1.3 (alpske ravnine).






Slika 118: Mehke modelirane naravnopokrajinske tipizacije za tip 2.1 (panonska gričevja).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 2.1 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 2.1 (%)



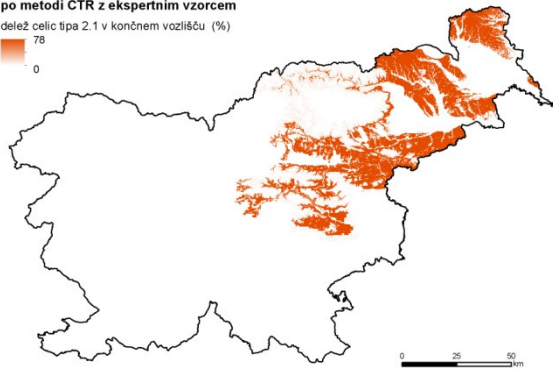
po metodi CTR z naključnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)




po metodi CTR z ekspertnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)



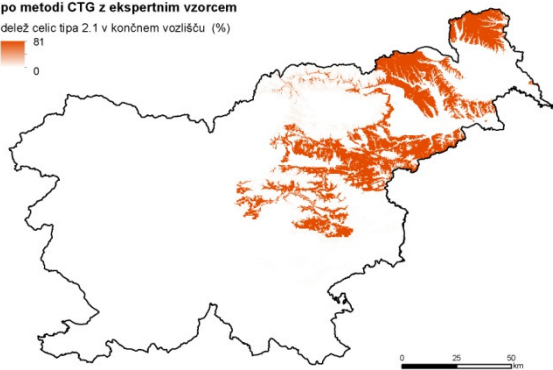
po metodi CTG z naključnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)



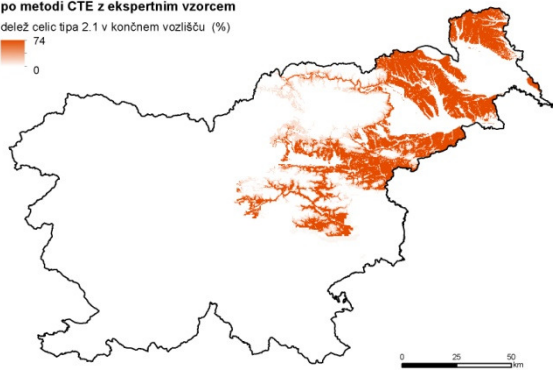
po metodi CTE z naključnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)

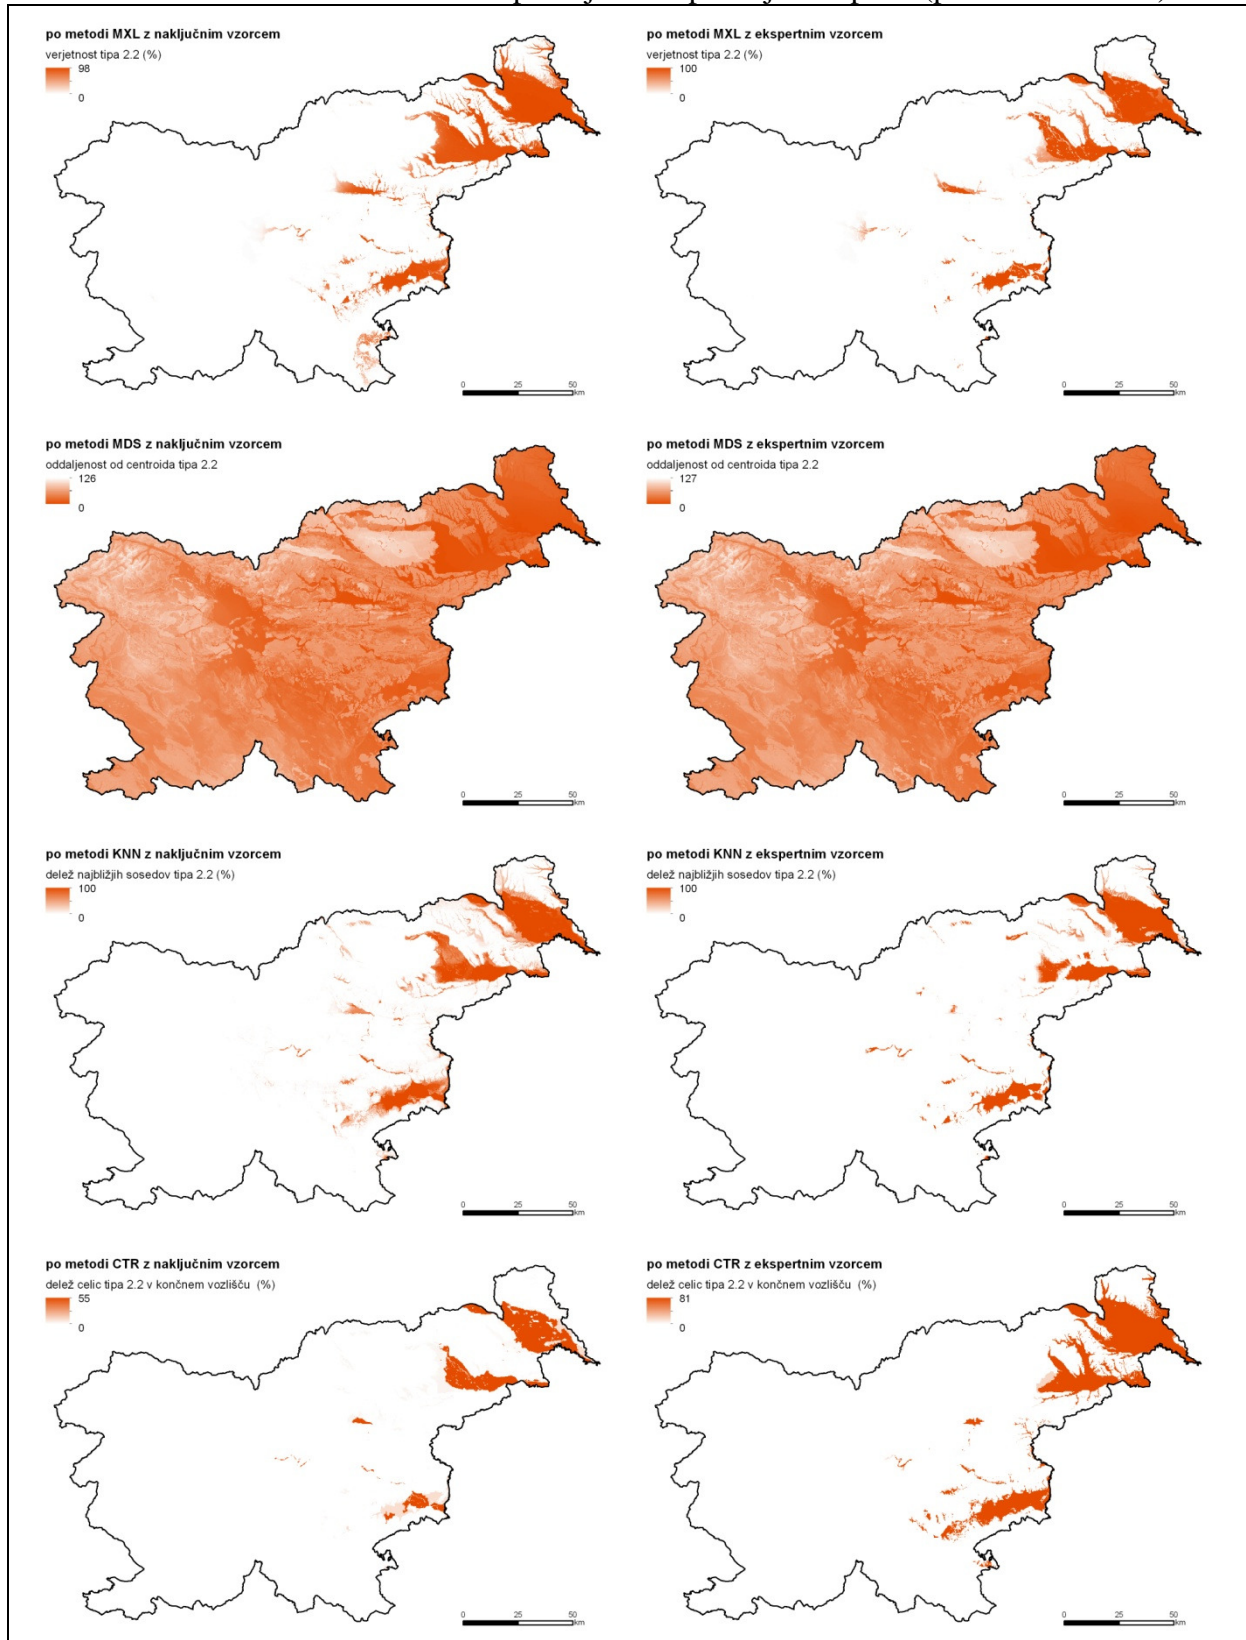


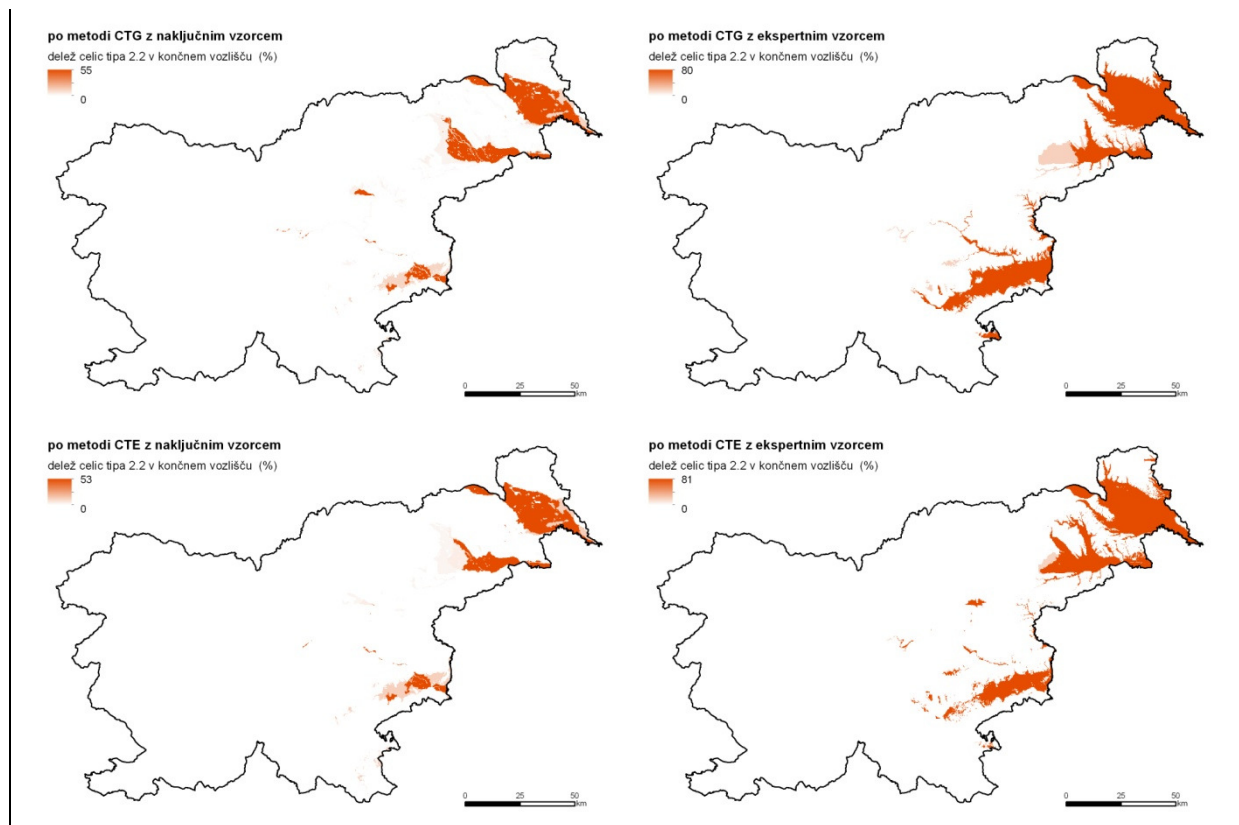
po metodi CTE z ekspertnim vzorcem

delež celic tipa 2.1 v končnem vozlišču (%)

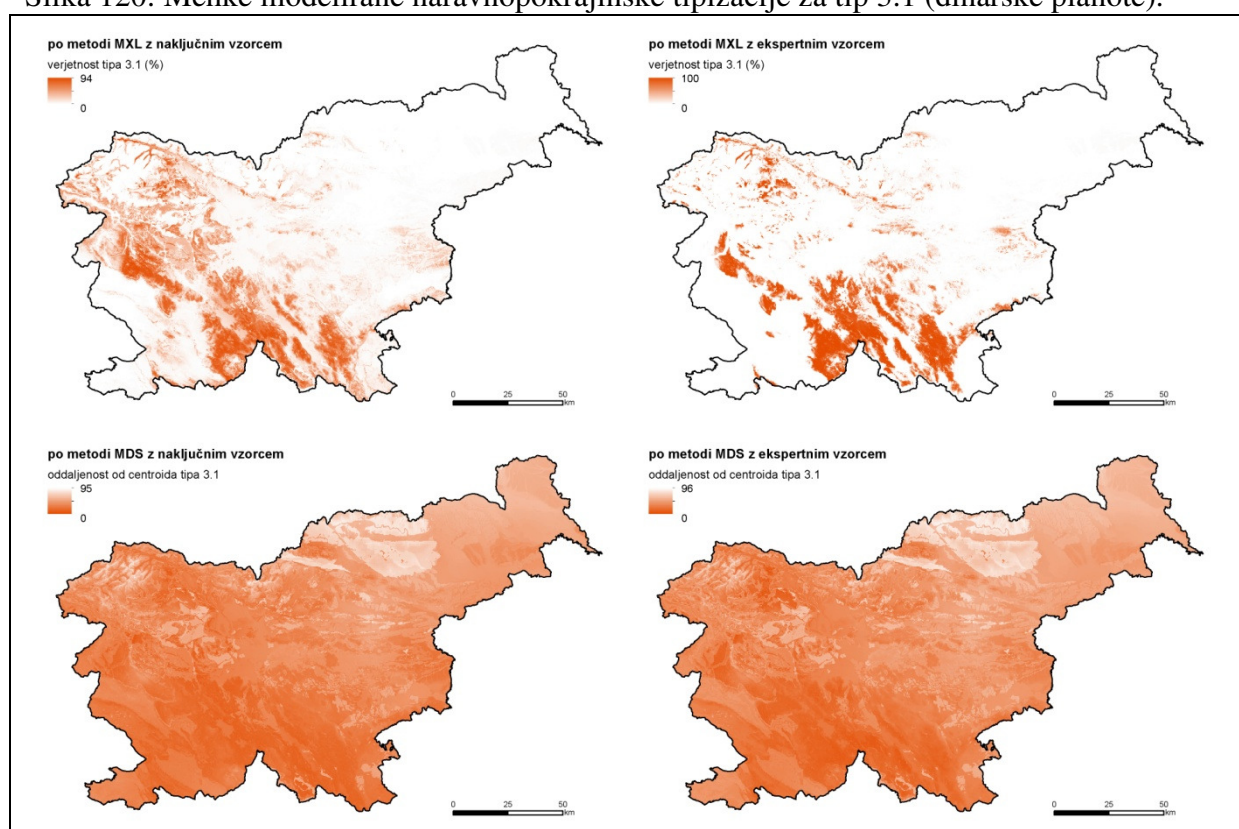


Slika 119: Mehke modelirane naravnopokrajinske tipizacije za tip 2.2 (panonske ravnine).



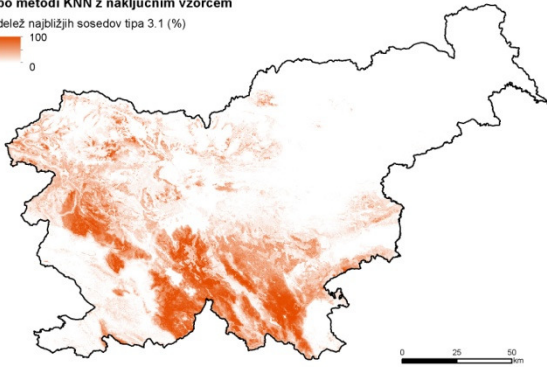


Slika 120: Mehke modelirane naravnopokrajinske tipizacije za tip 3.1 (dinarske planote).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 3.1 (%)



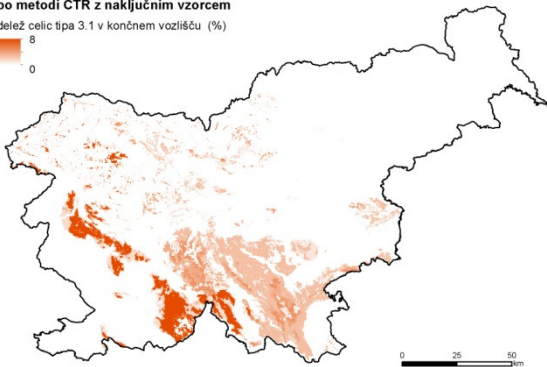
po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 3.1 (%)



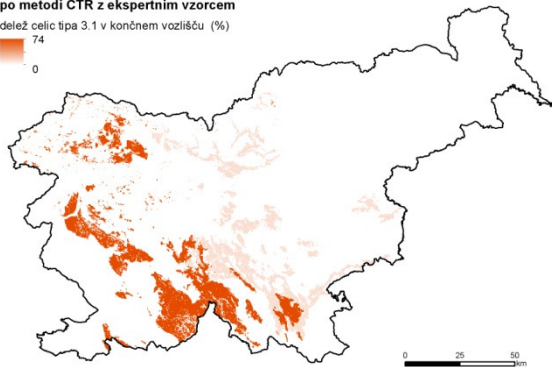
po metodi CTR z naključnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)



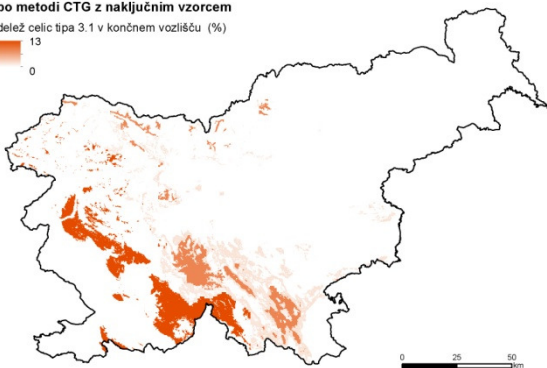
po metodi CTR z ekspertnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)



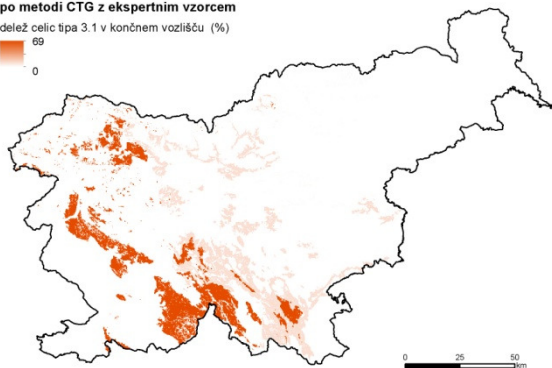
po metodi CTG z naključnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)



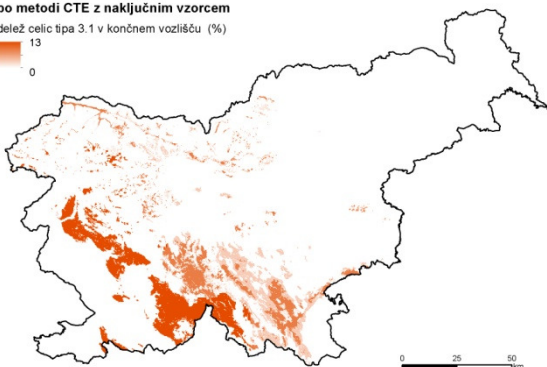
po metodi CTG z ekspertnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)



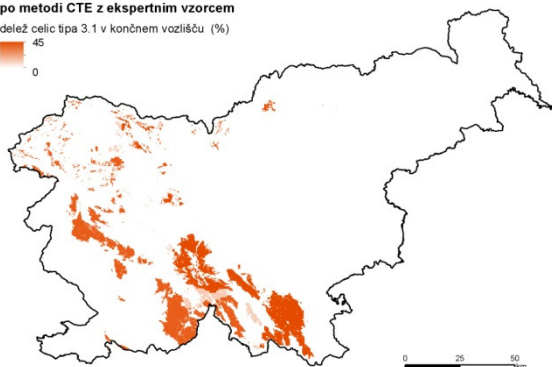
po metodi CTE z naključnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)

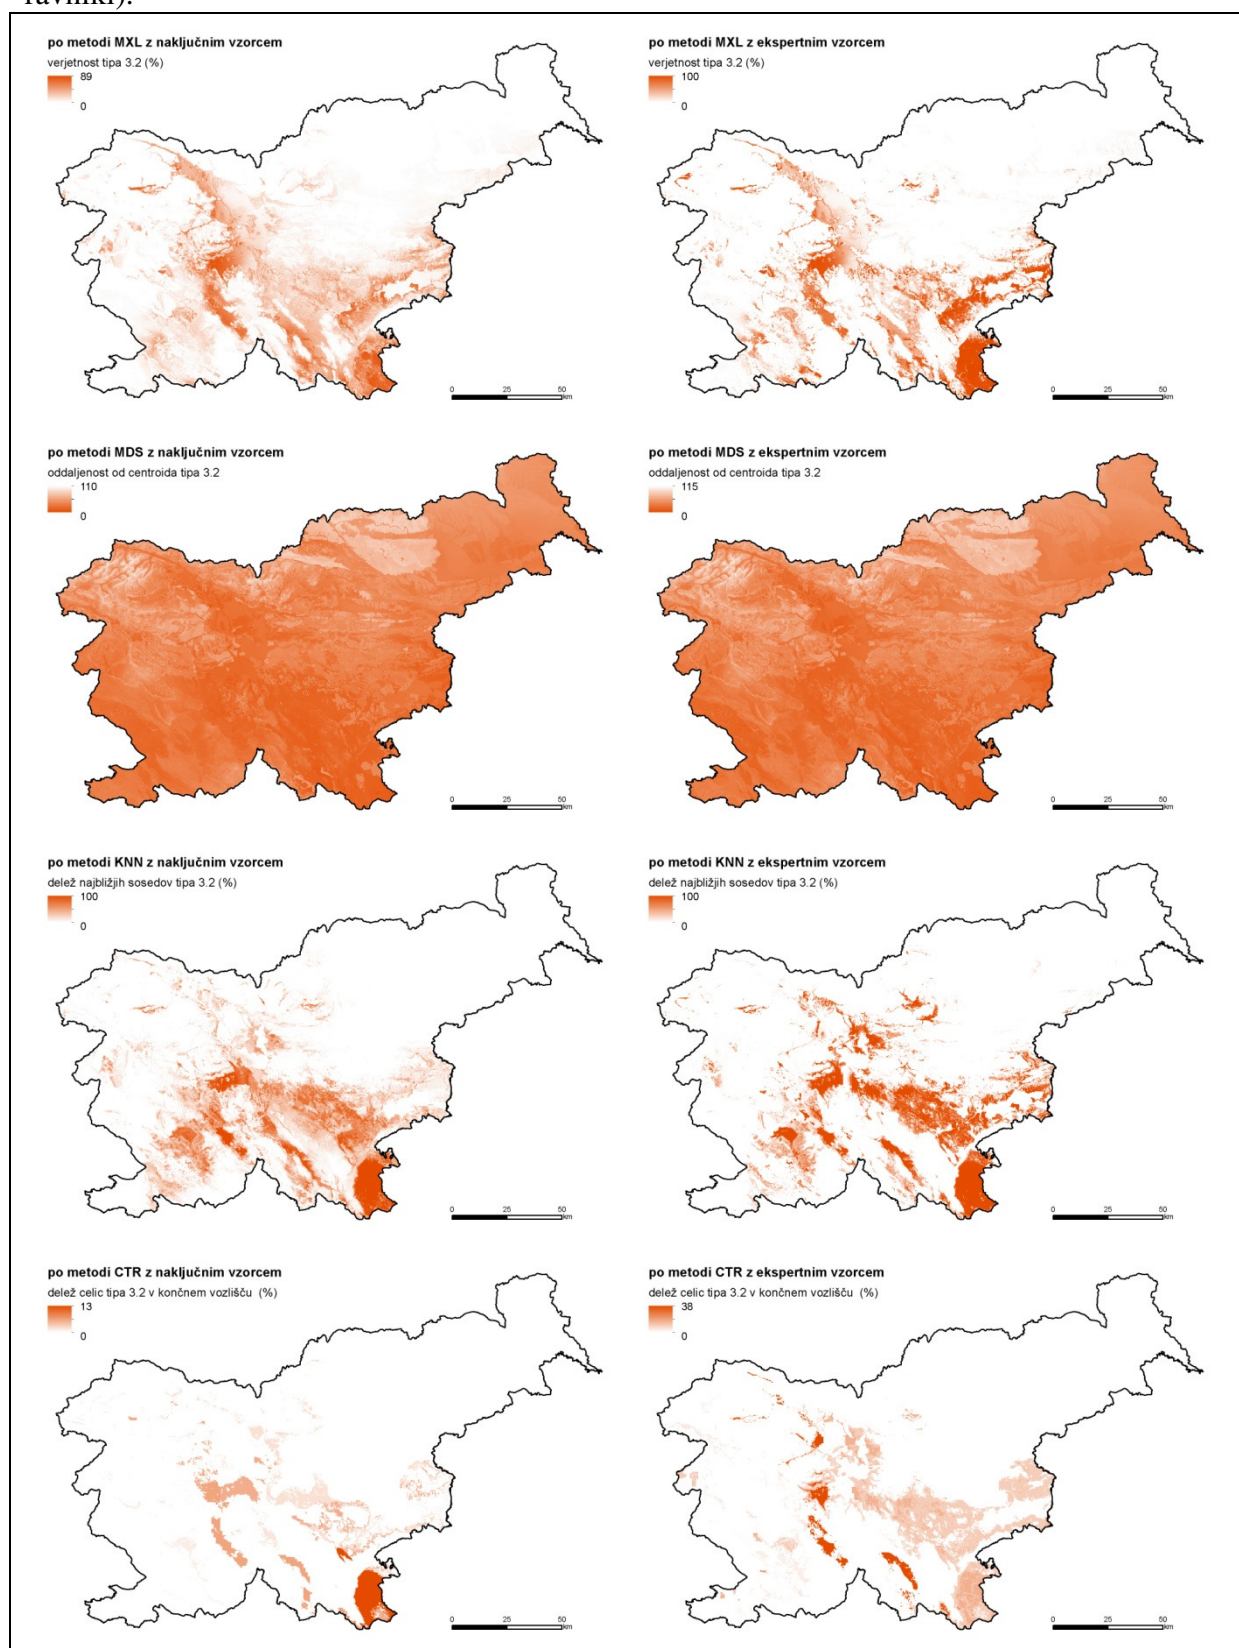


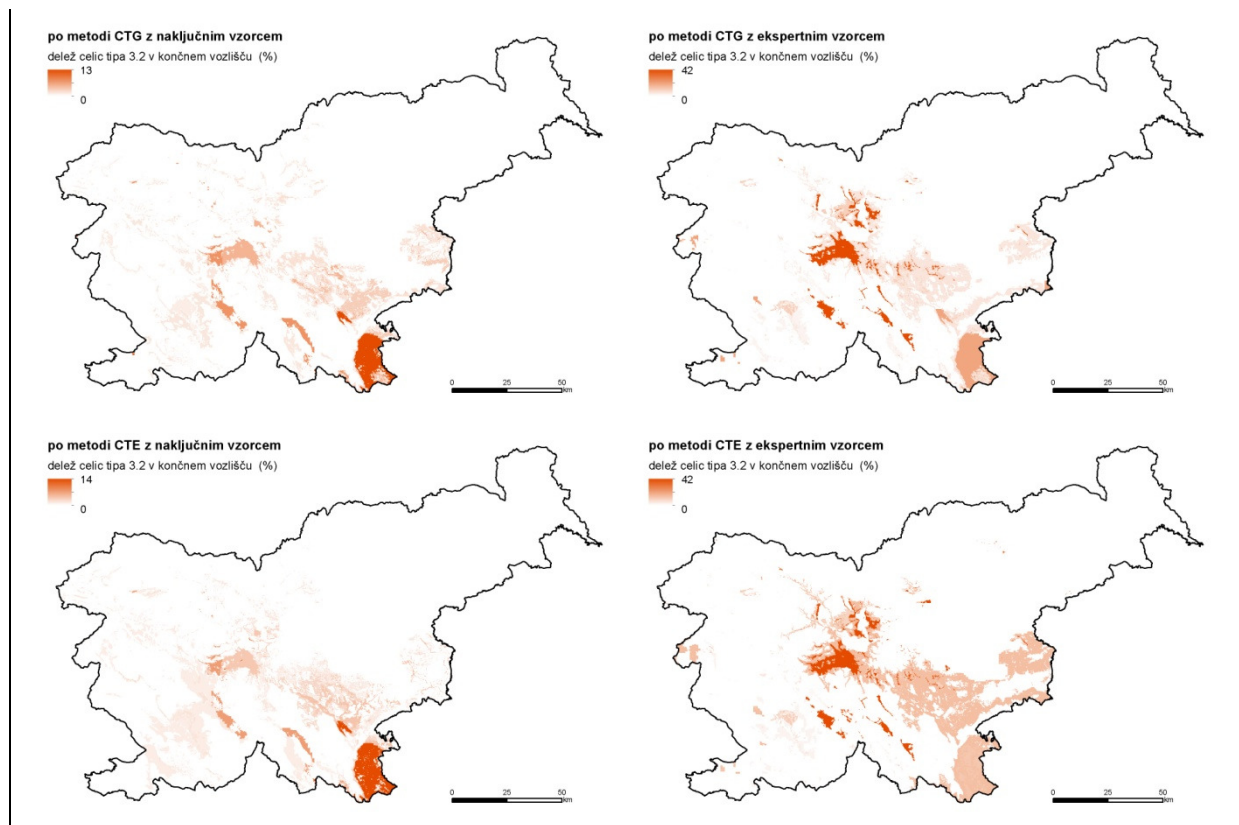
po metodi CTE z ekspertnim vzorcem

delež celic tipa 3.1 v končnem vozlišču (%)

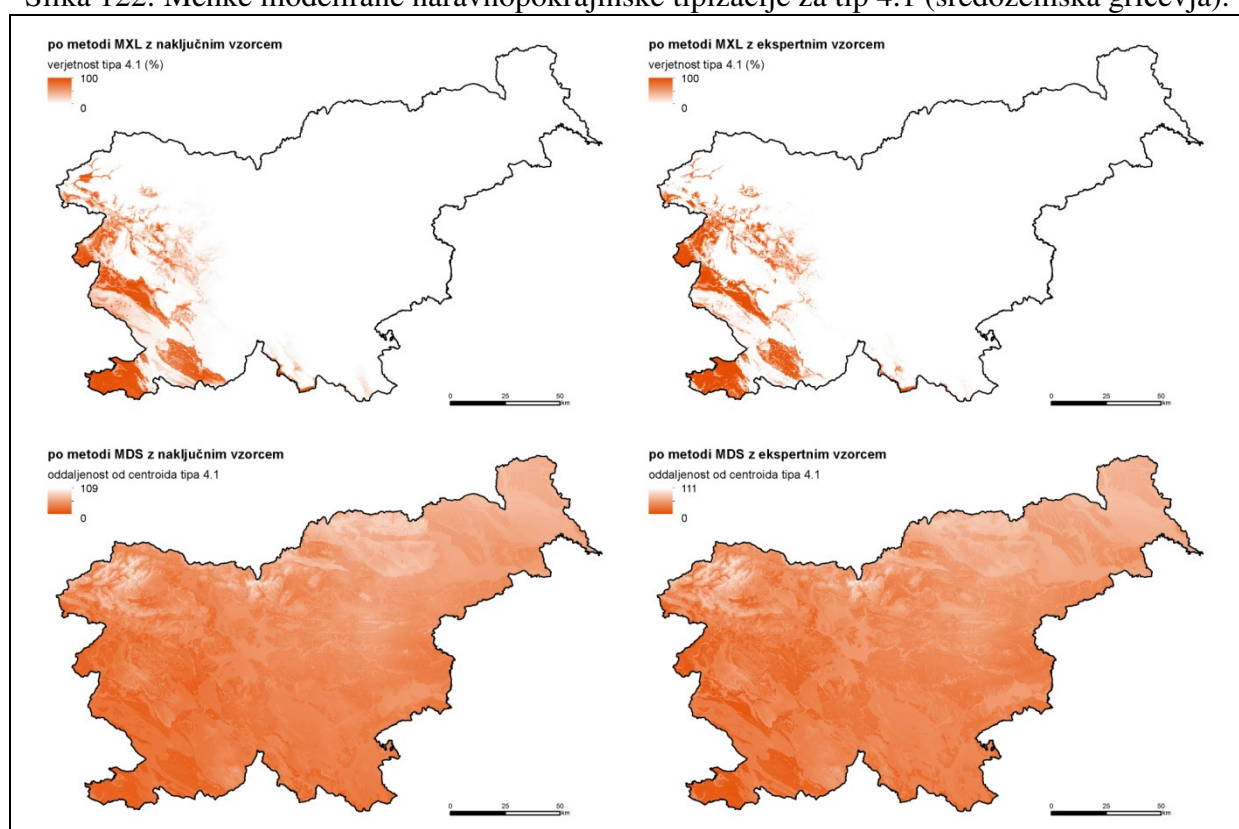


Slika 121: Mehke modelirane naravnopokrajinske tipizacije za tip 3.2 (dinarska podolja in ravniki).






Slika 122: Mehke modelirane naravnopokrajinske tipizacije za tip 4.1 (sredozemska gričevja).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 4.1 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 4.1 (%)




po metodi CTR z naključnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)




po metodi CTR z ekspertnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)




po metodi CTG z naključnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)




po metodi CTE z naključnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)

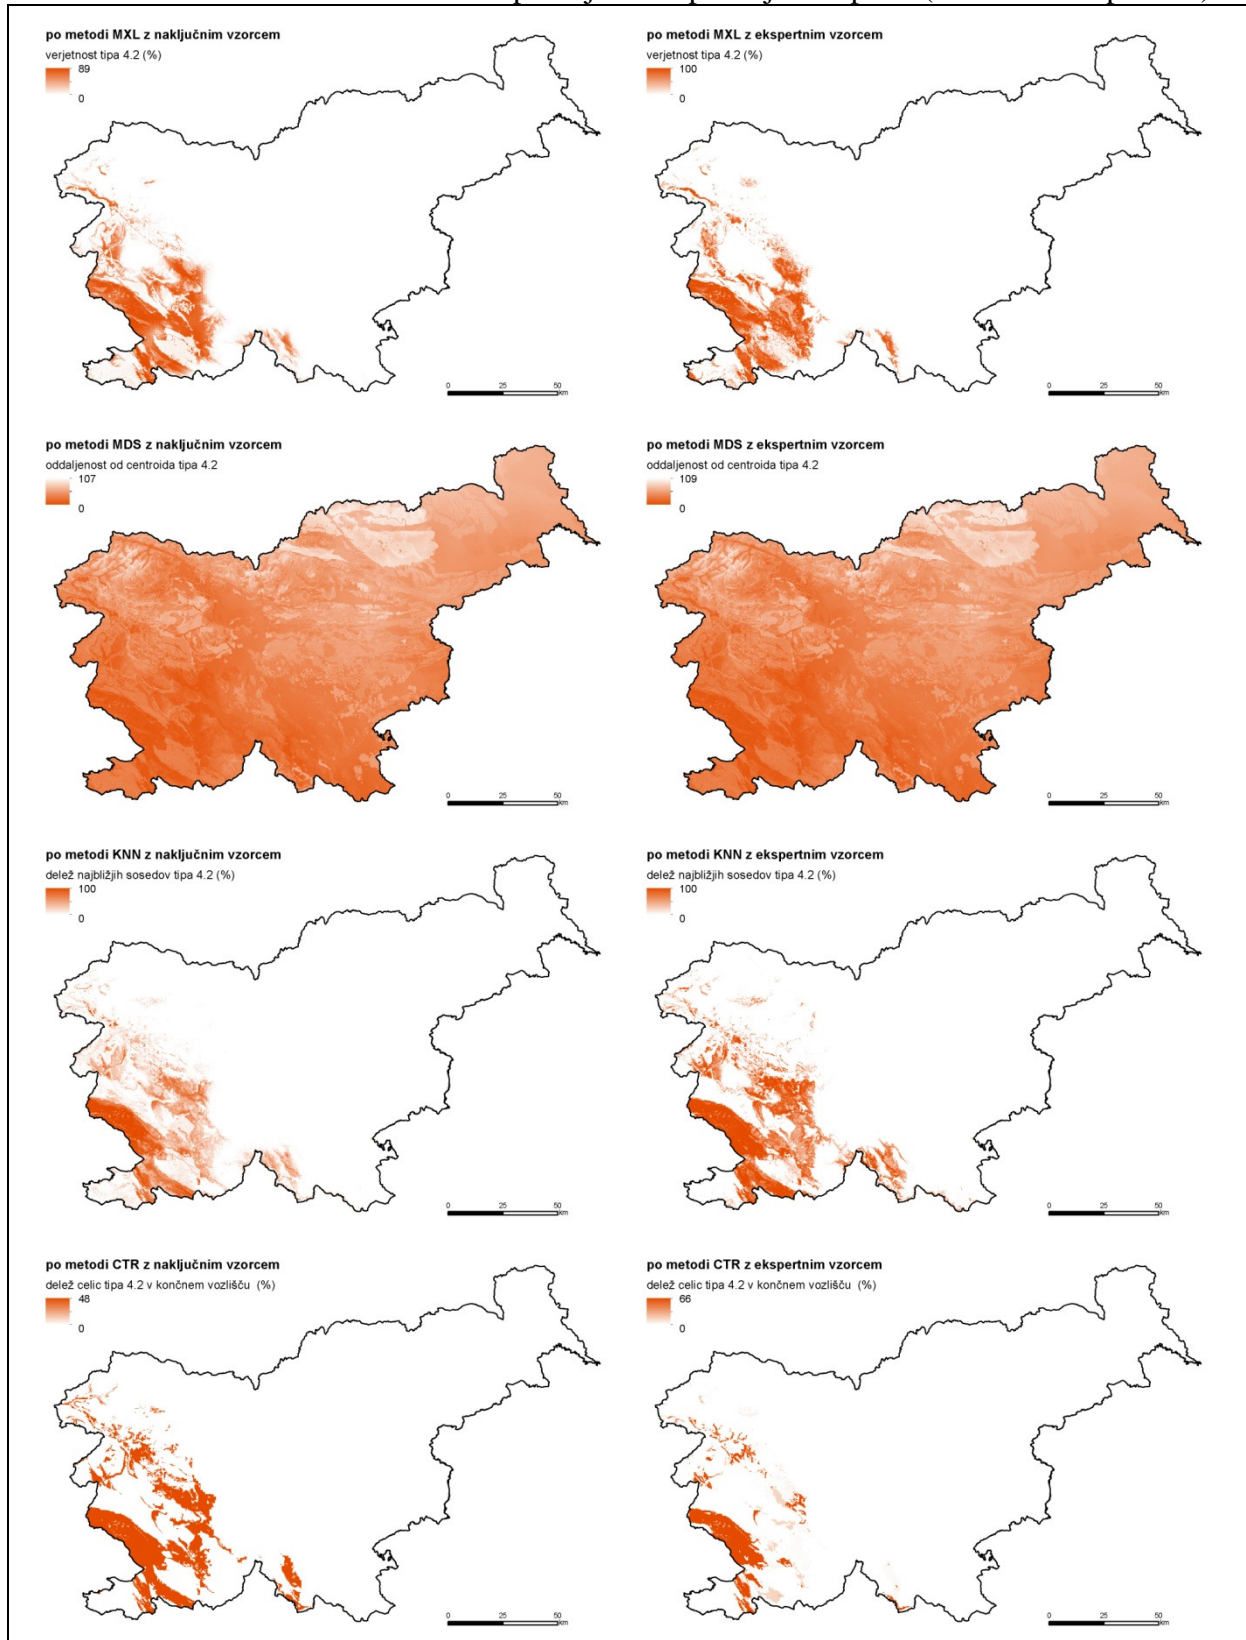


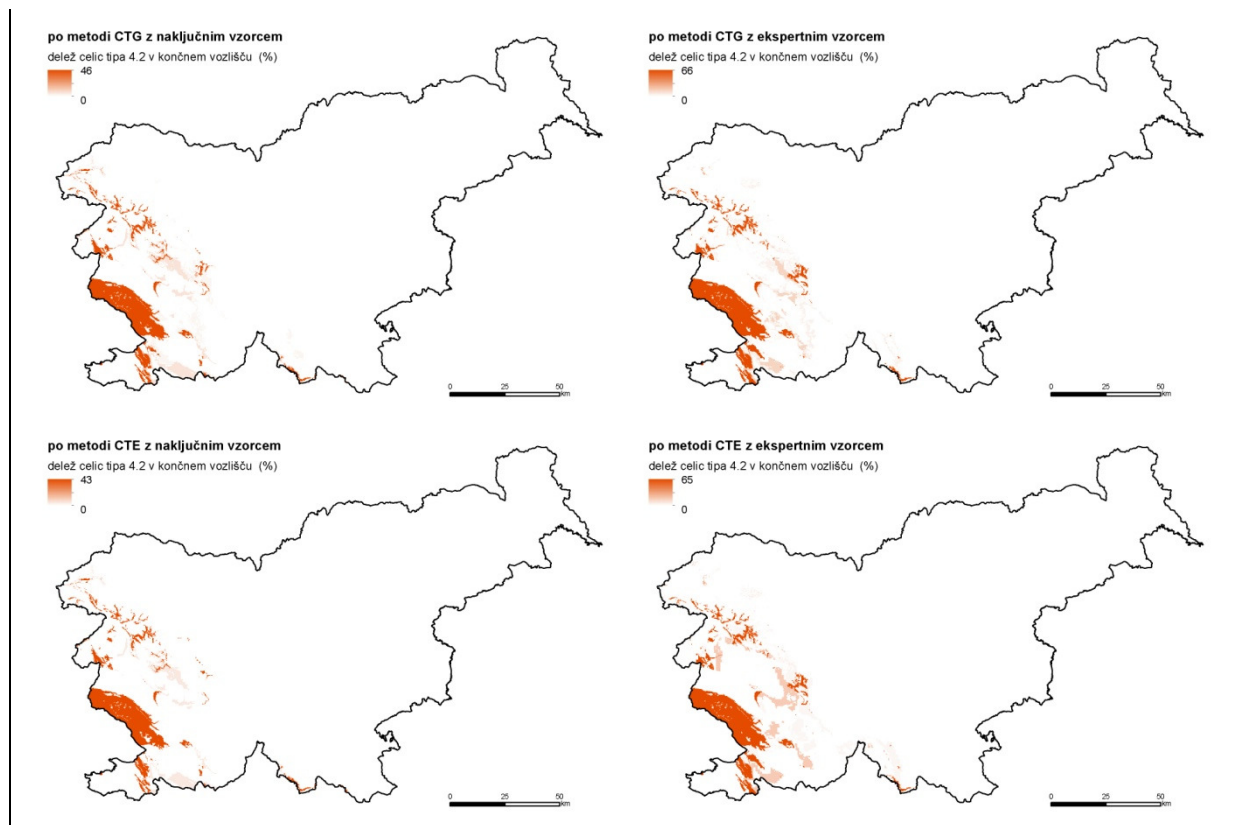
po metodi CTE z ekspertnim vzorcem

delež celic tipa 4.1 v končnem vozišču (%)



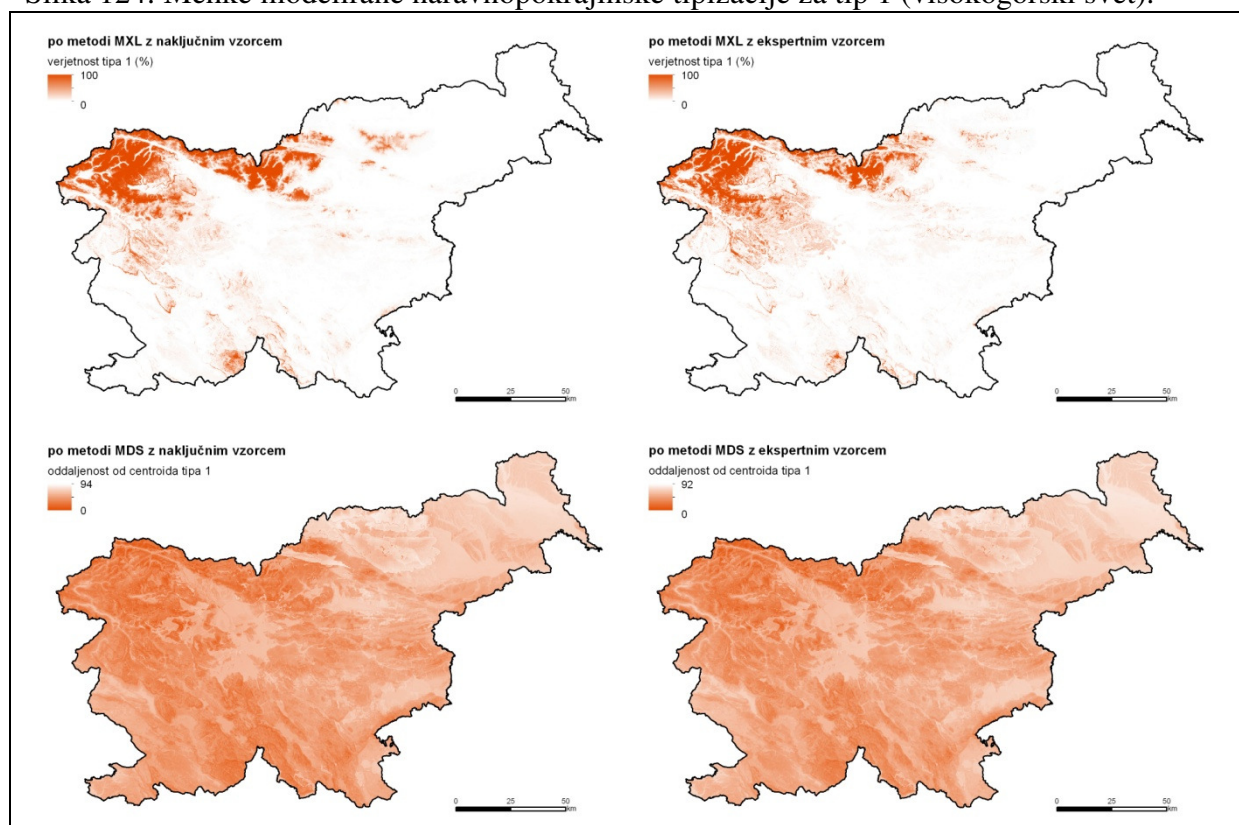
Slika 123: Mehke modelirane naravnopokrajinske tipizacije za tip 4.2 (sredozemske planote).






Kartografski prikaz posameznih mehkih klasifikacij za TIPI13

Slika 124: Mehke modelirane naravnopokrajinske tipizacije za tip 1 (visokogorski svet).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 1 (%)



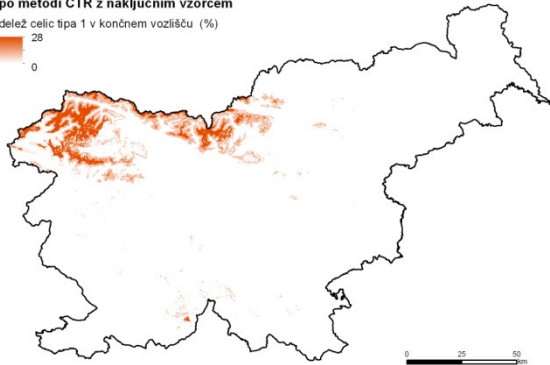
po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 1 (%)



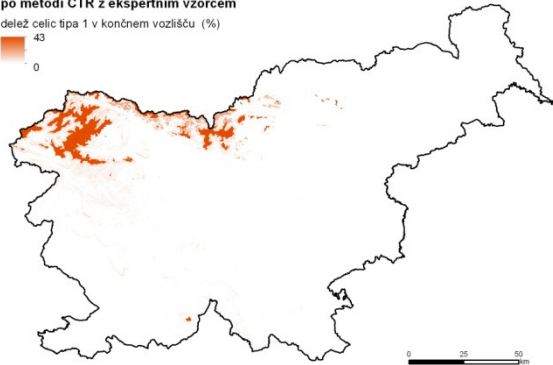
po metodi CTR z naključnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)



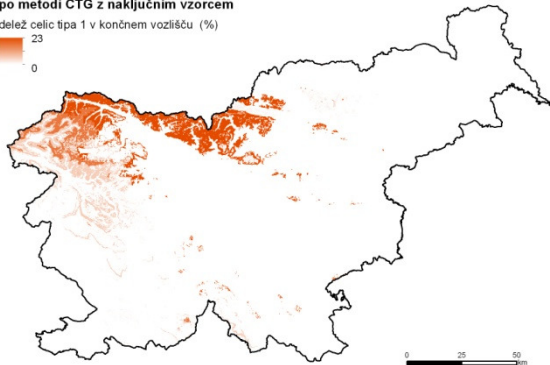
po metodi CTR z ekspertnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)



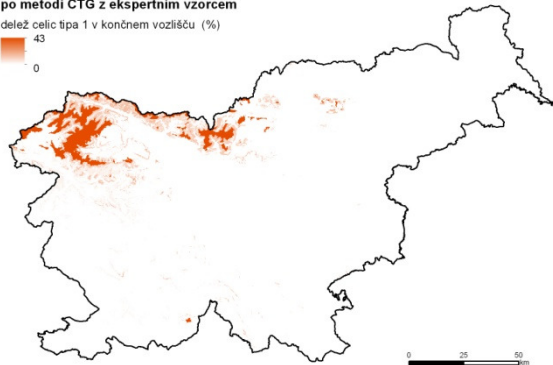
po metodi CTG z naključnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)



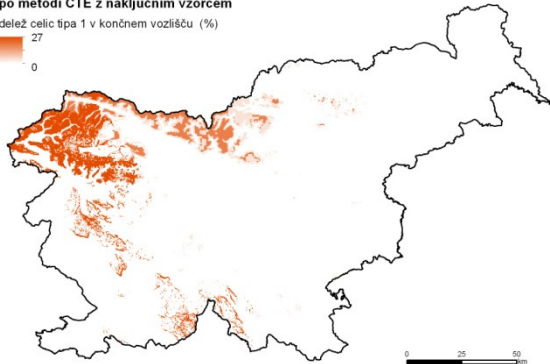
po metodi CTG z ekspertnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)



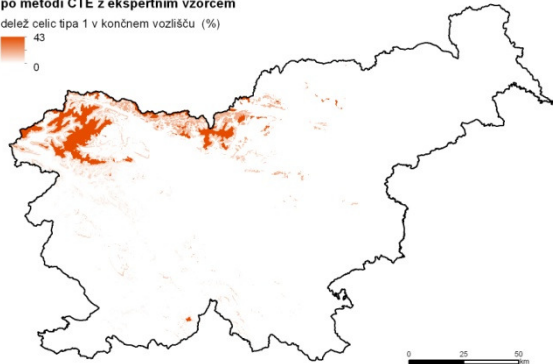
po metodi CTE z naključnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)

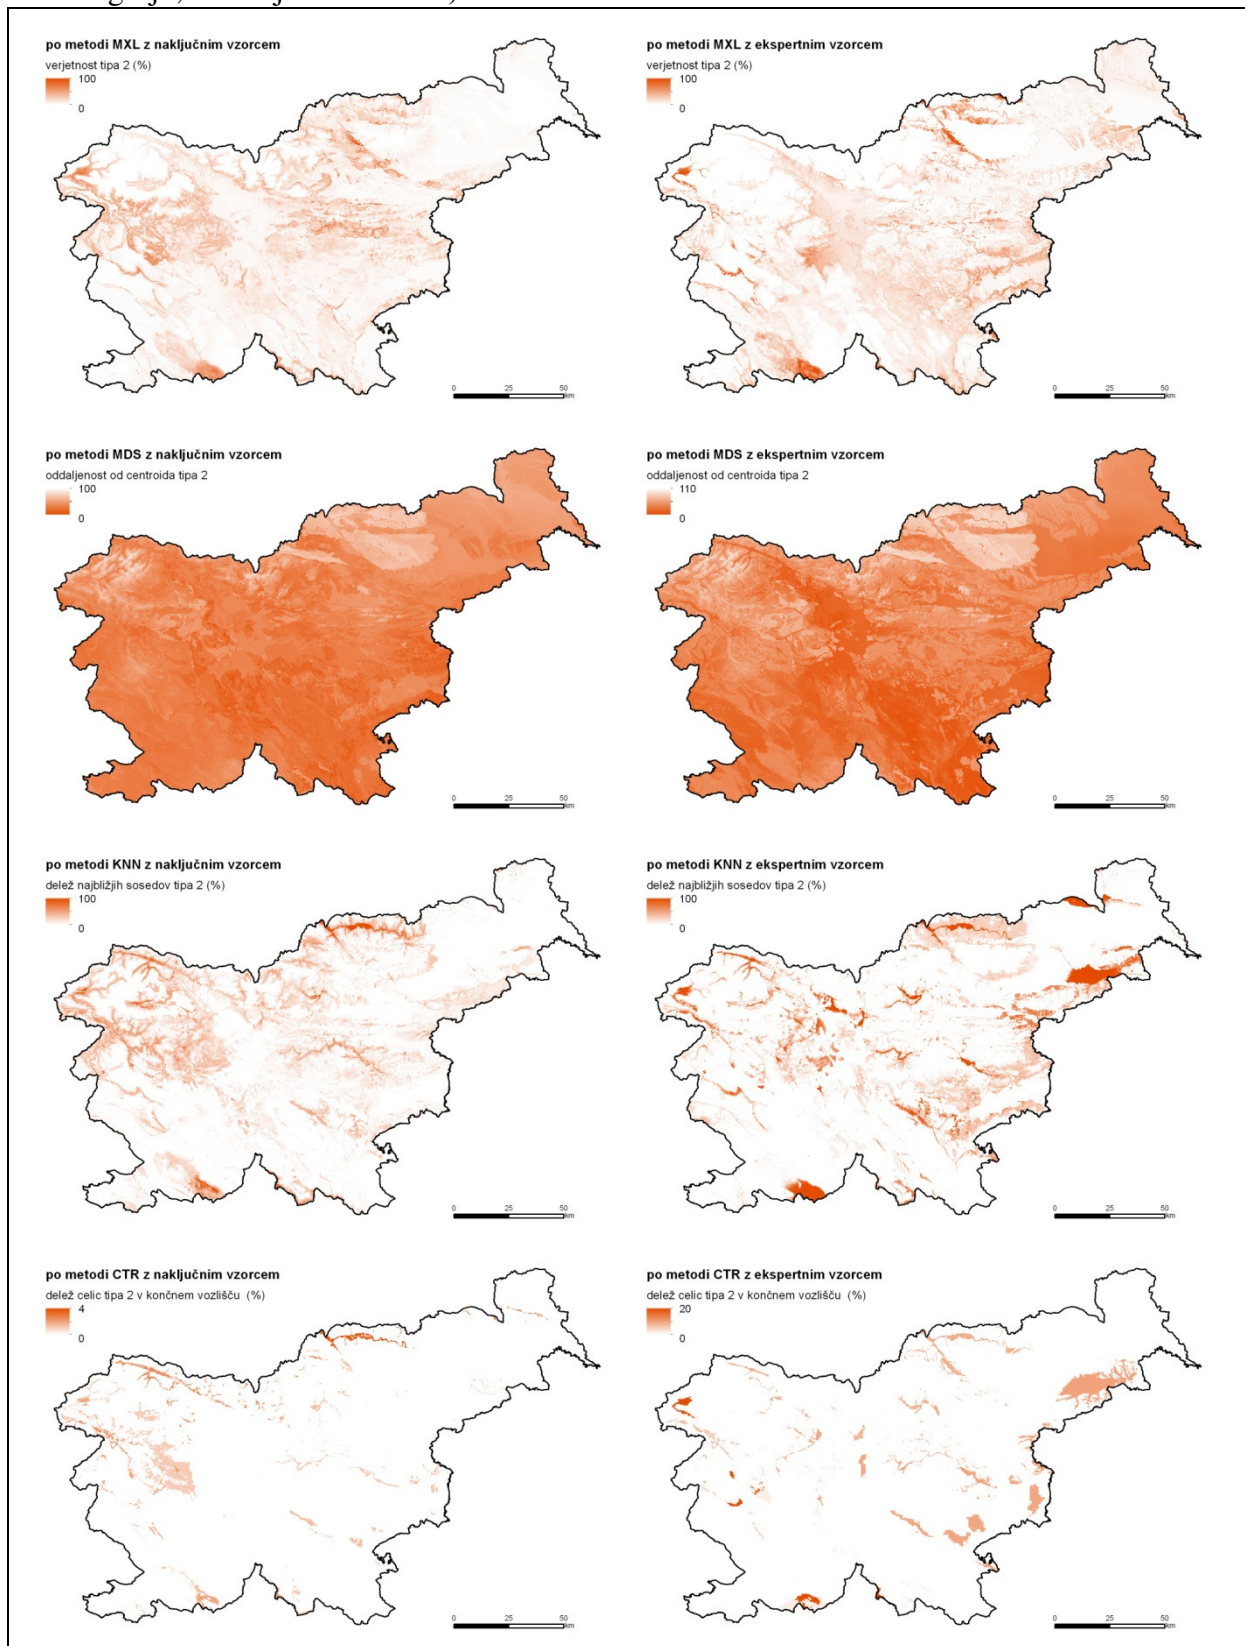


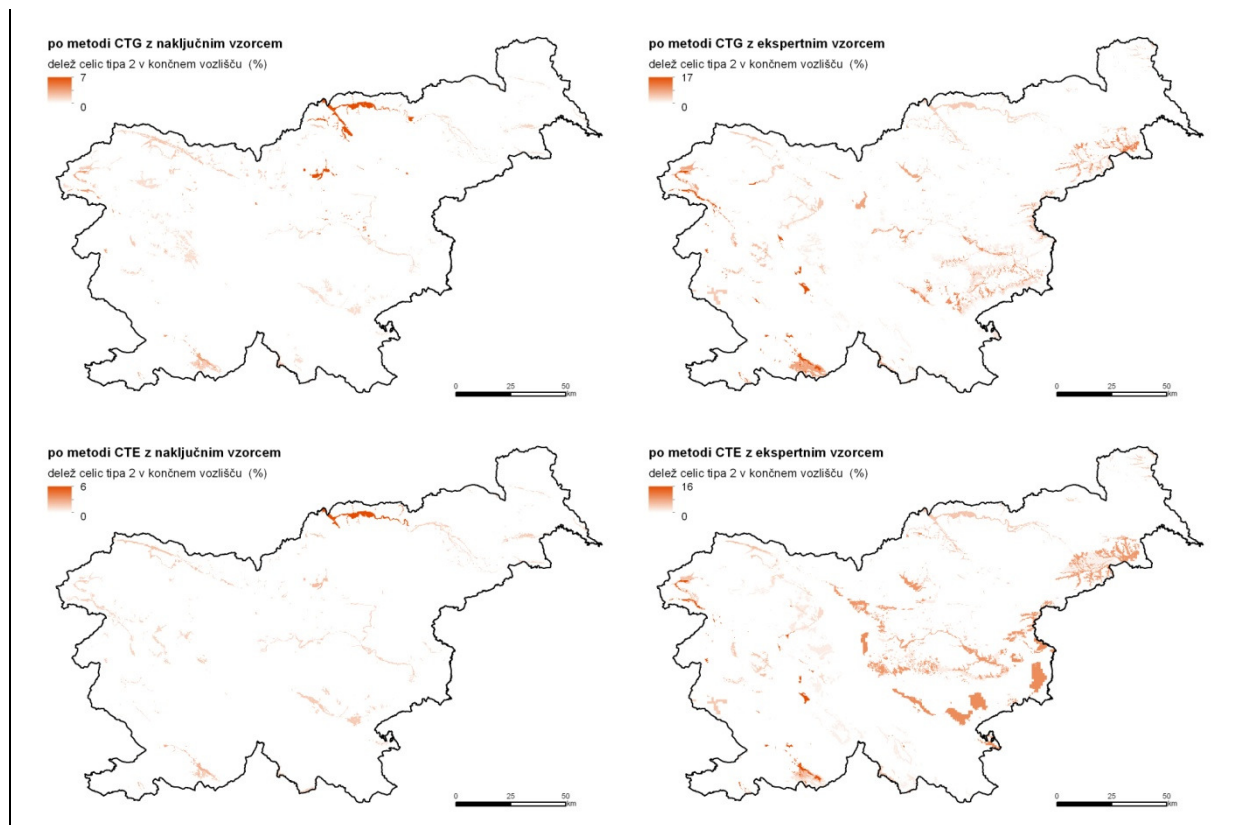
po metodi CTE z ekspertnim vzorcem

delež celic tipa 1 v končnem vozlišču (%)

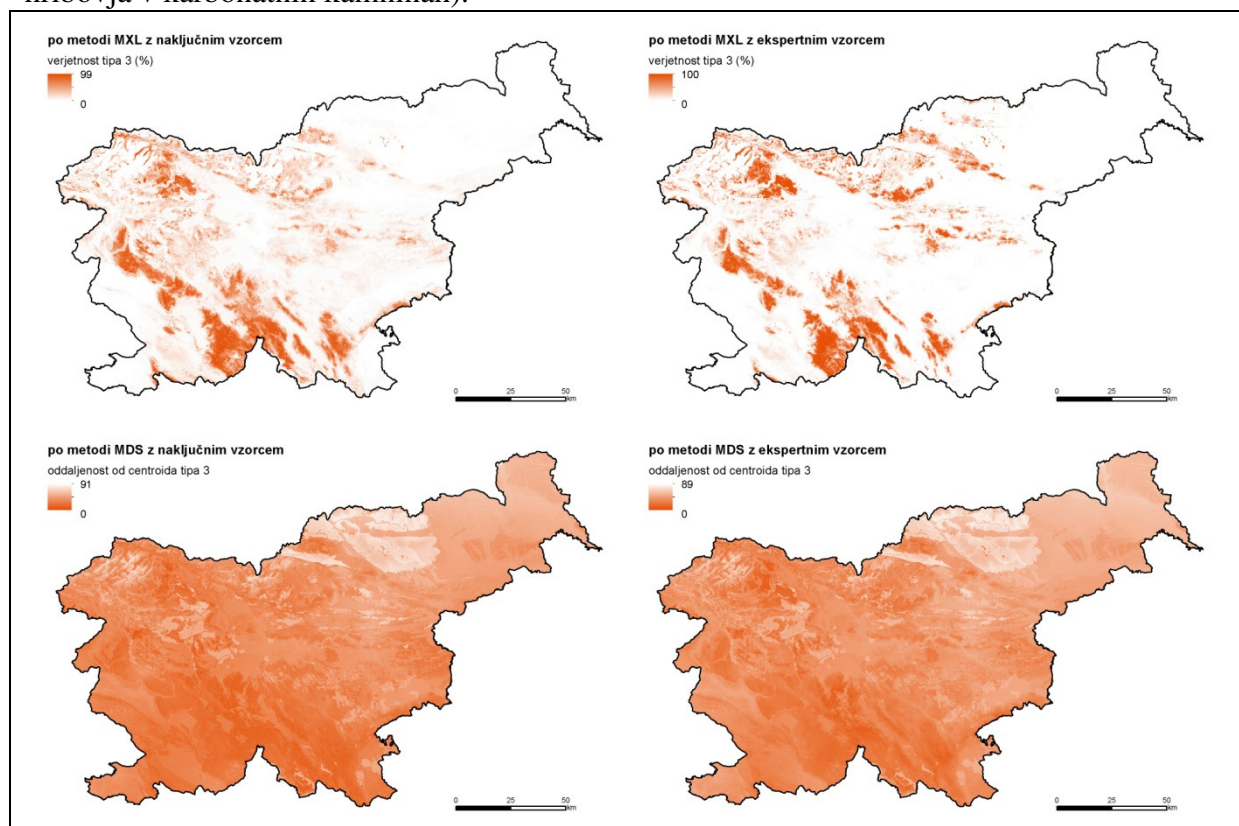


Slika 125: Mehke modelirane naravnopokrajinske tipizacije za tip 2 (širše rečne doline v visokogorju, hribovju in na krasu).



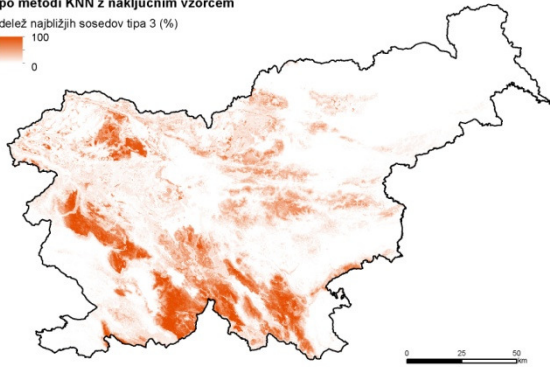


Slika 126: Mehke modelirane naravnopokrajinske tipizacije za tip 3 (visoke kraške planote in hribovja v karbonatnih kamninah).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 3 (%)



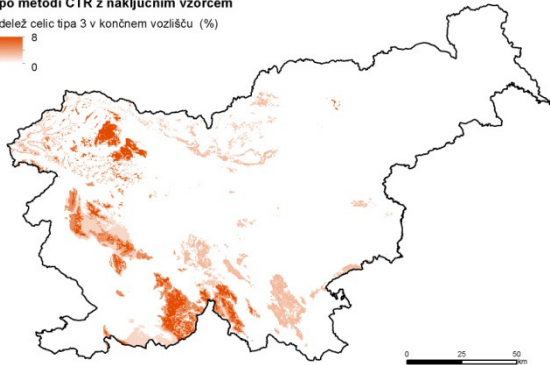
po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 3 (%)




po metodi CTR z naključnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)




po metodi CTR z ekspertnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)



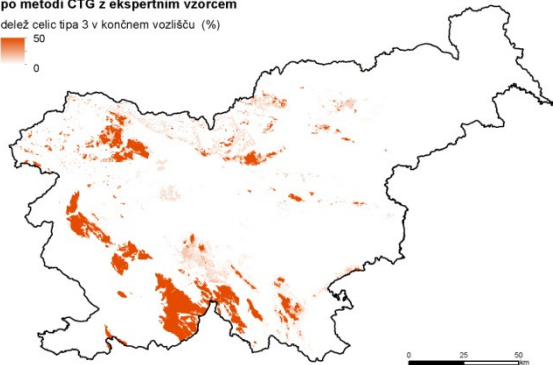
po metodi CTG z naključnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)



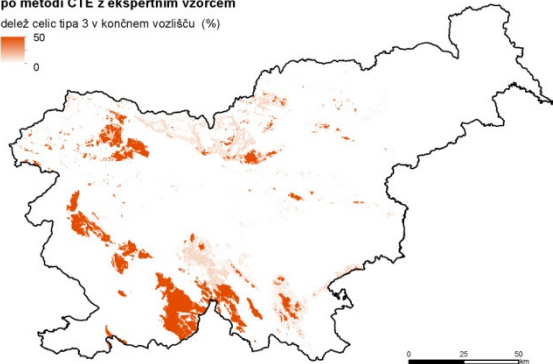
po metodi CTE z naključnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)

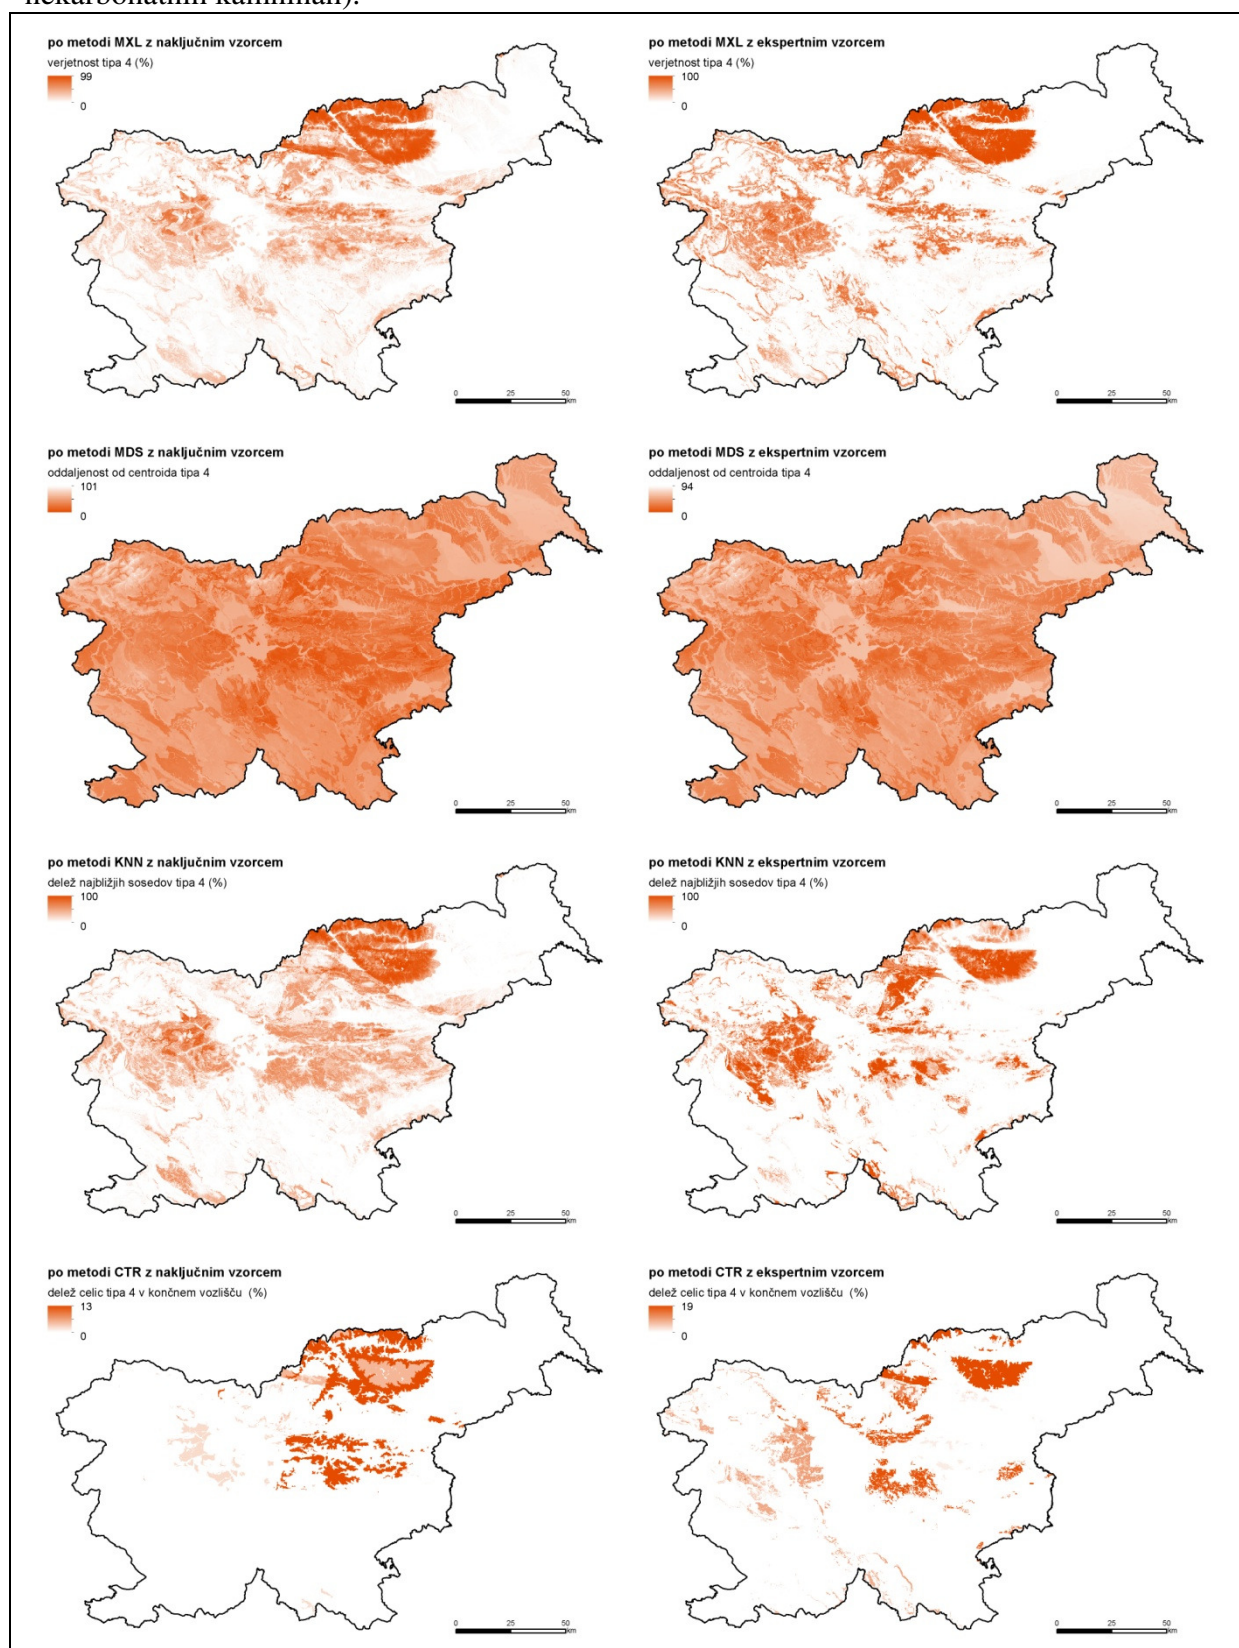


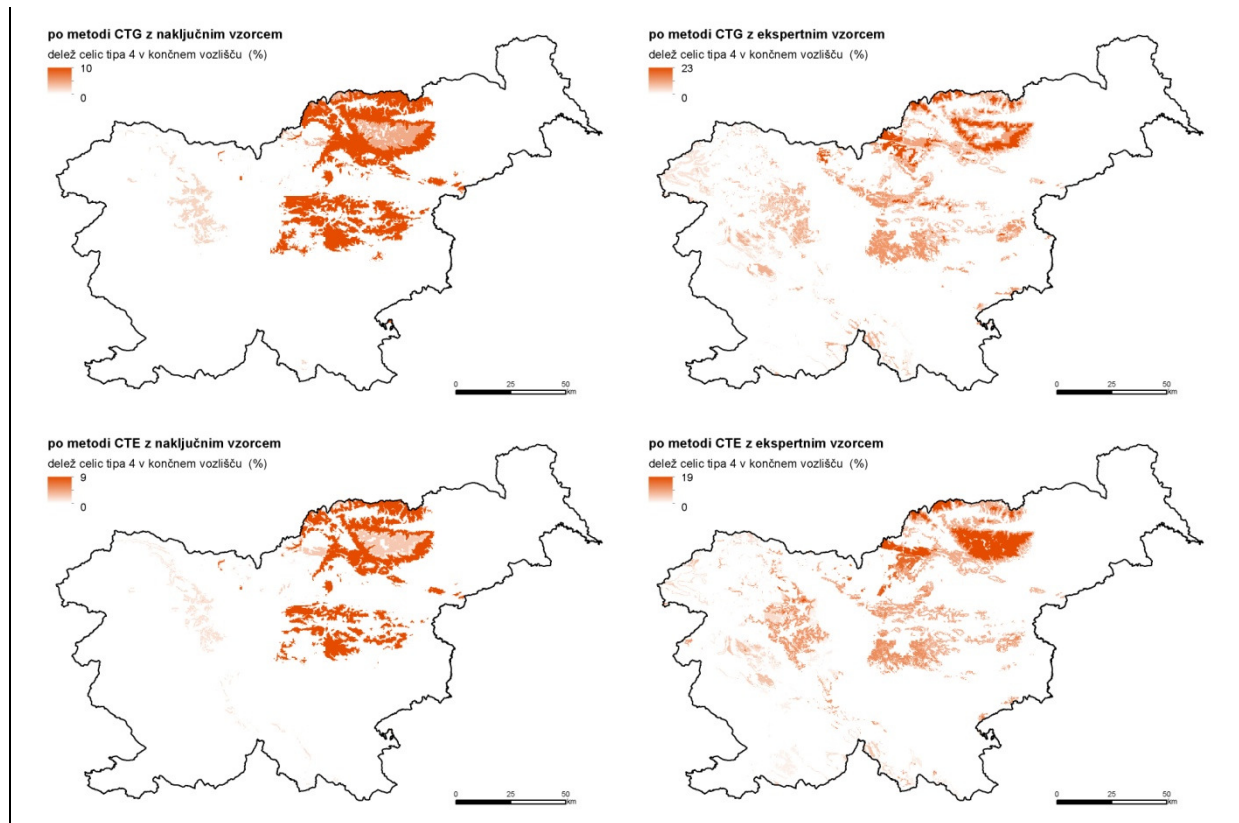
po metodi CTE z ekspertnim vzorcem

delež celic tipa 3 v končnem vozlišču (%)

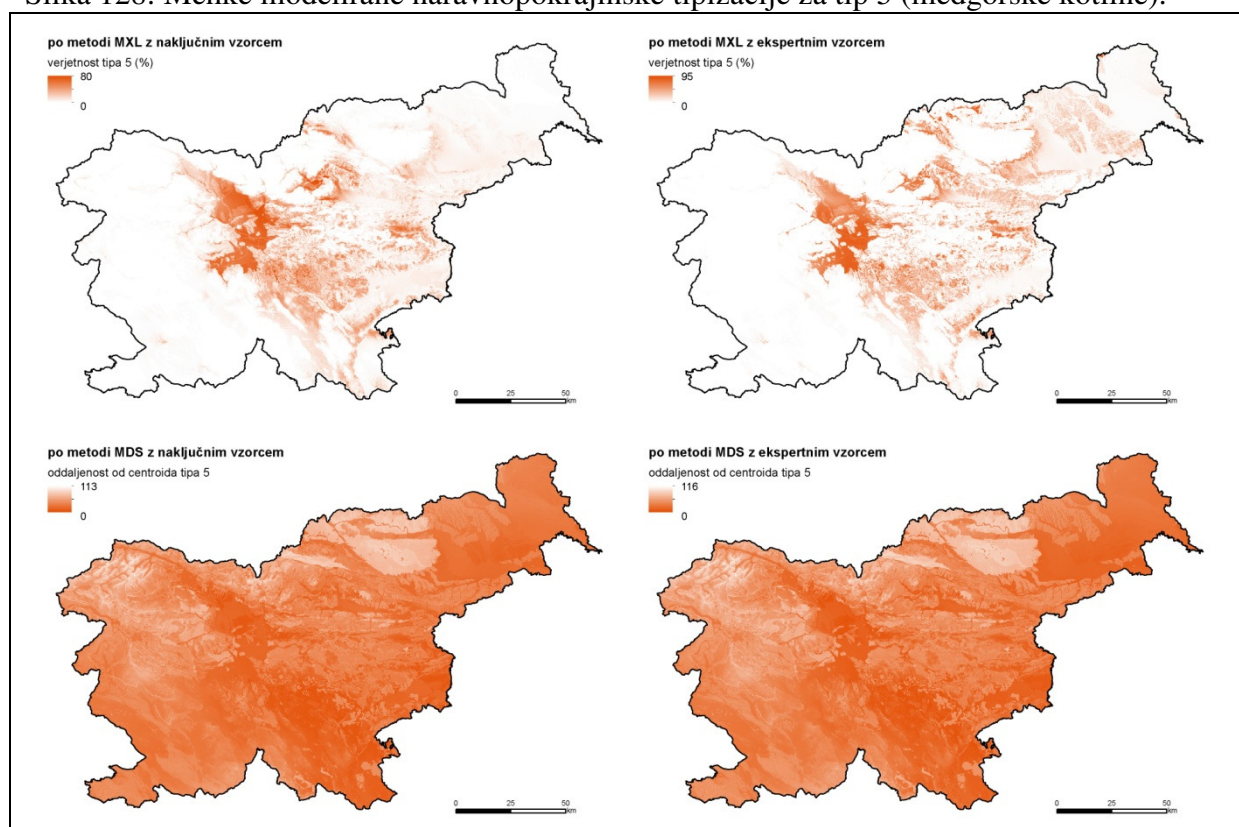


Slika 127: Mehke modelirane naravnopokrajinske tipizacije za tip 4 (hribovja v pretežno nekarbonatnih kamninah).






Slika 128: Mehke modelirane naravnopokrajinske tipizacije za tip 5 (medgorske kotline).



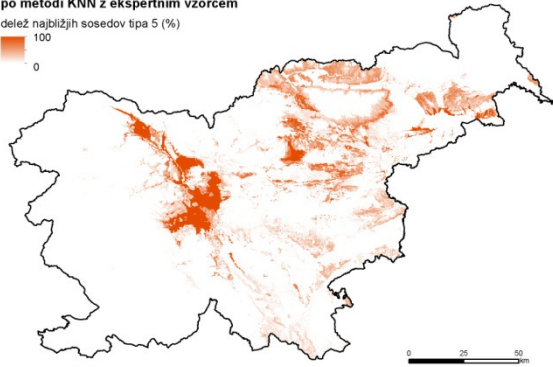
po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 5 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 5 (%)



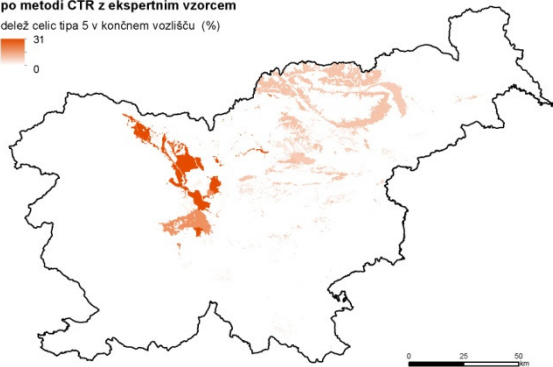
po metodi CTR z naključnim vzorcem

delež celic tipa 5 v končnem vozišču (%)




po metodi CTR z ekspertnim vzorcem

delež celic tipa 5 v končnem vozišču (%)



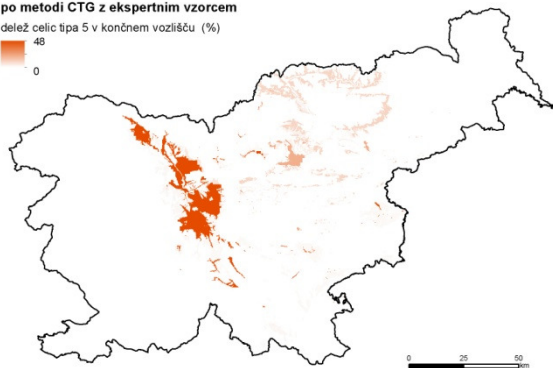
po metodi CTG z naključnim vzorcem

delež celic tipa 5 v končnem vozišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 5 v končnem vozišču (%)



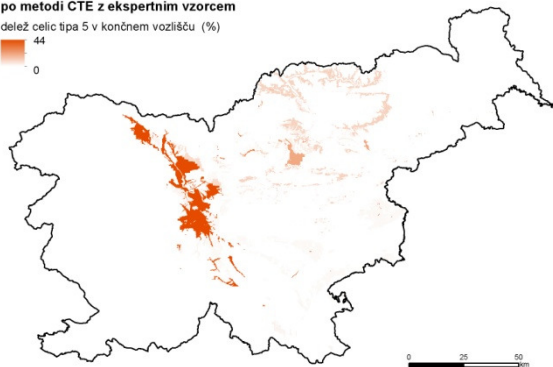
po metodi CTE z naključnim vzorcem

delež celic tipa 5 v končnem vozišču (%)

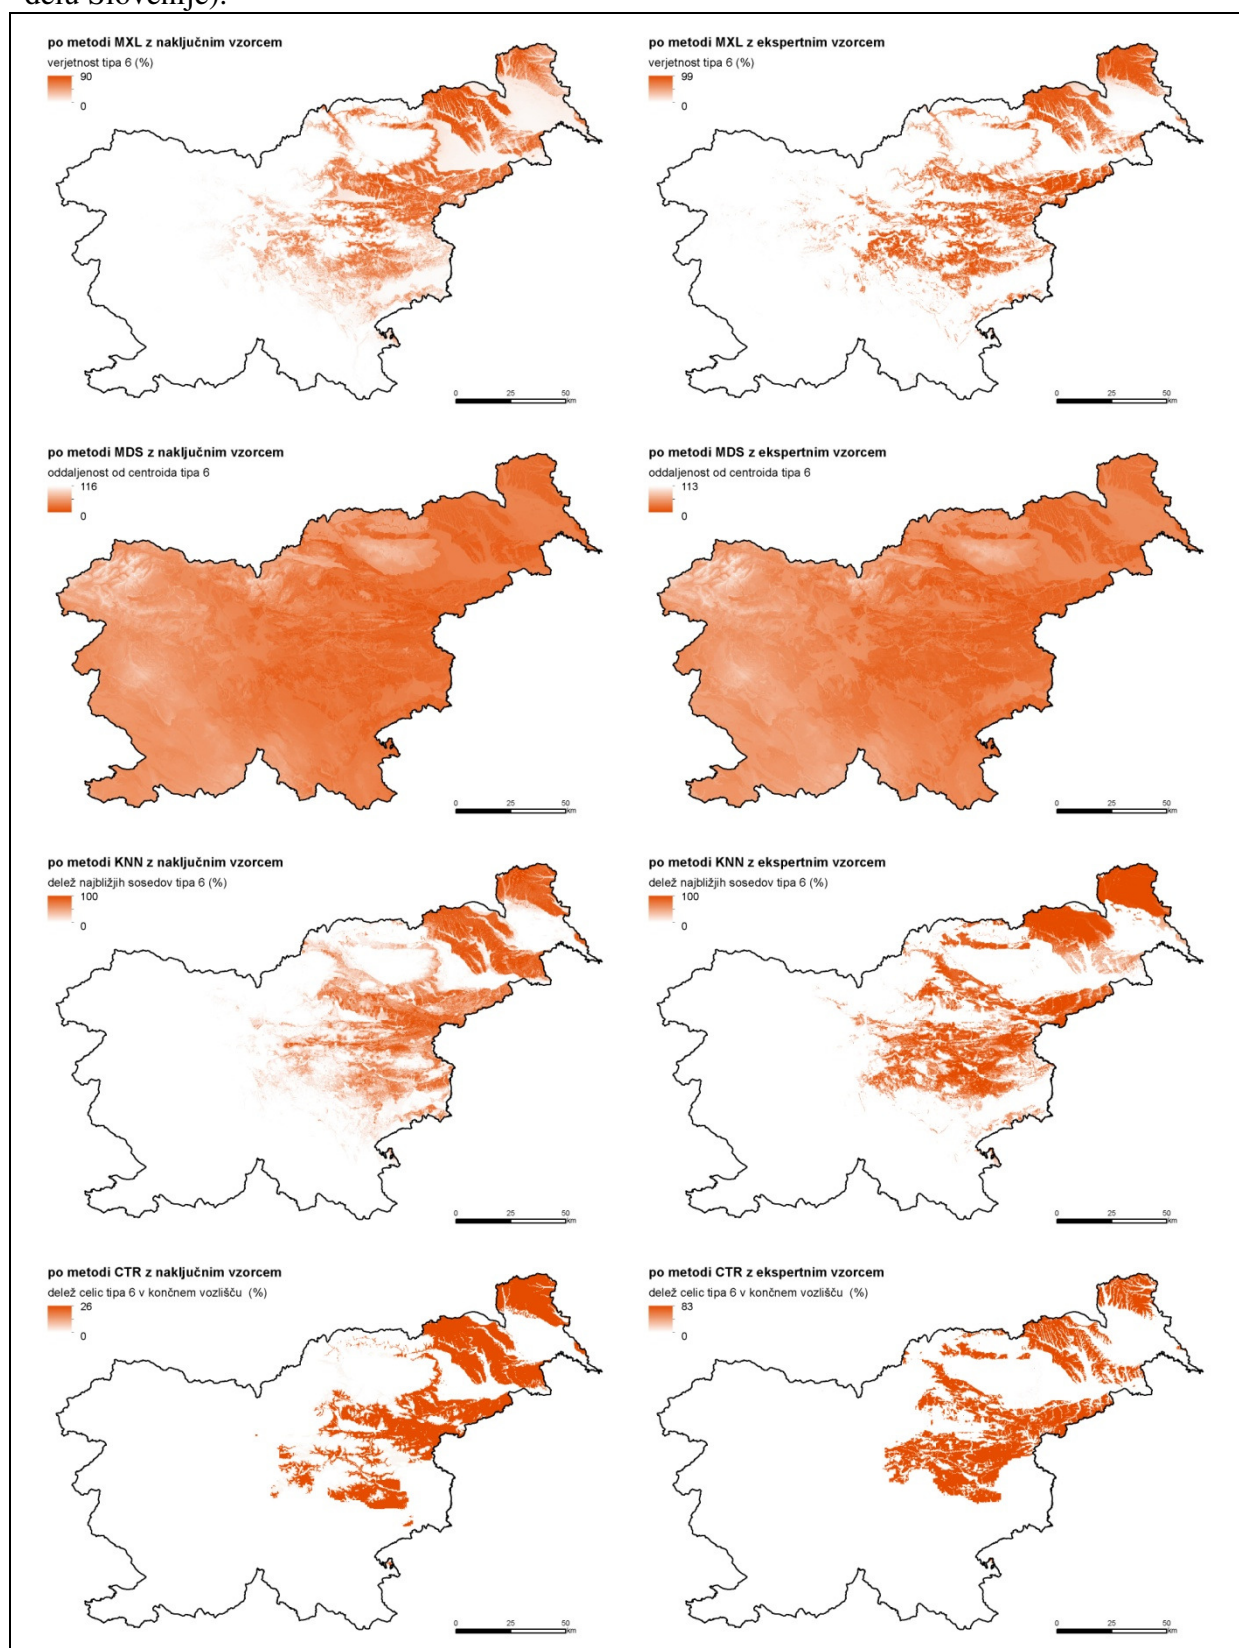


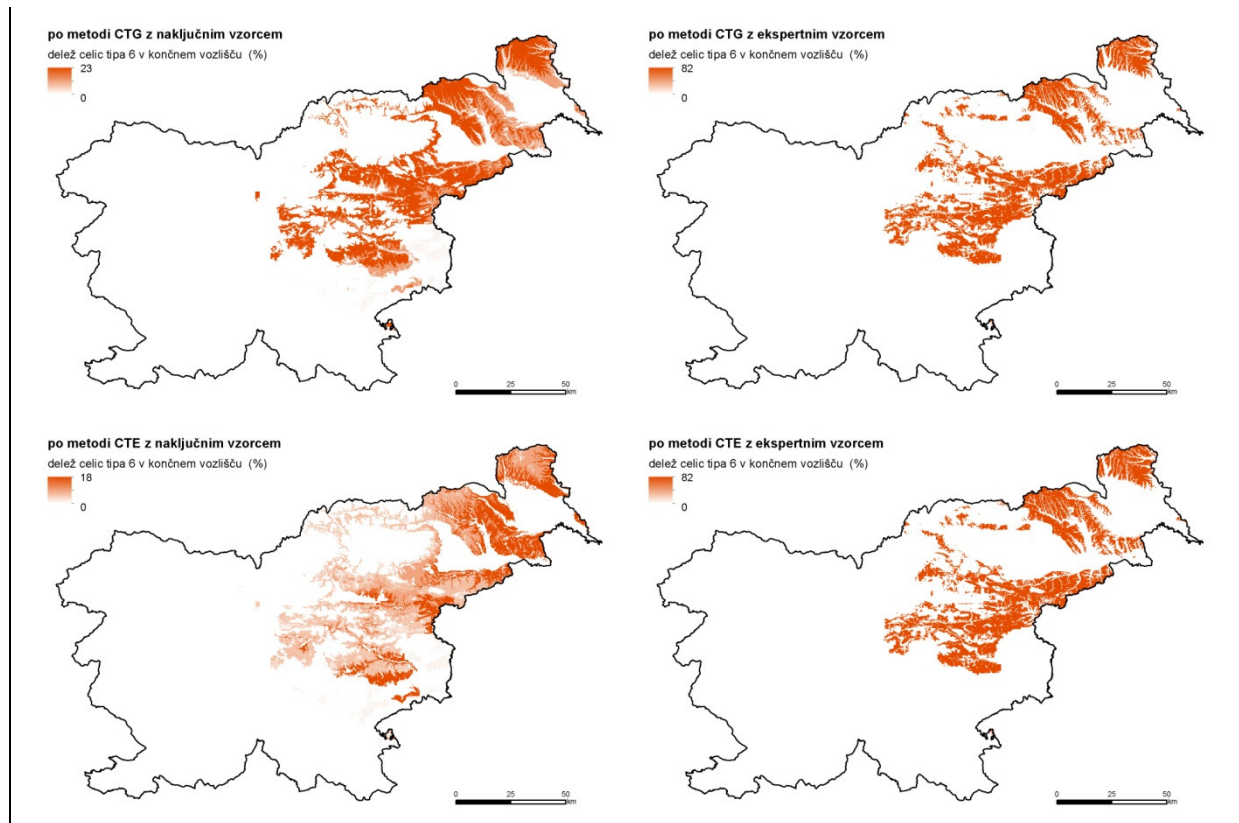
po metodi CTE z ekspertnim vzorcem

delež celic tipa 5 v končnem vozišču (%)

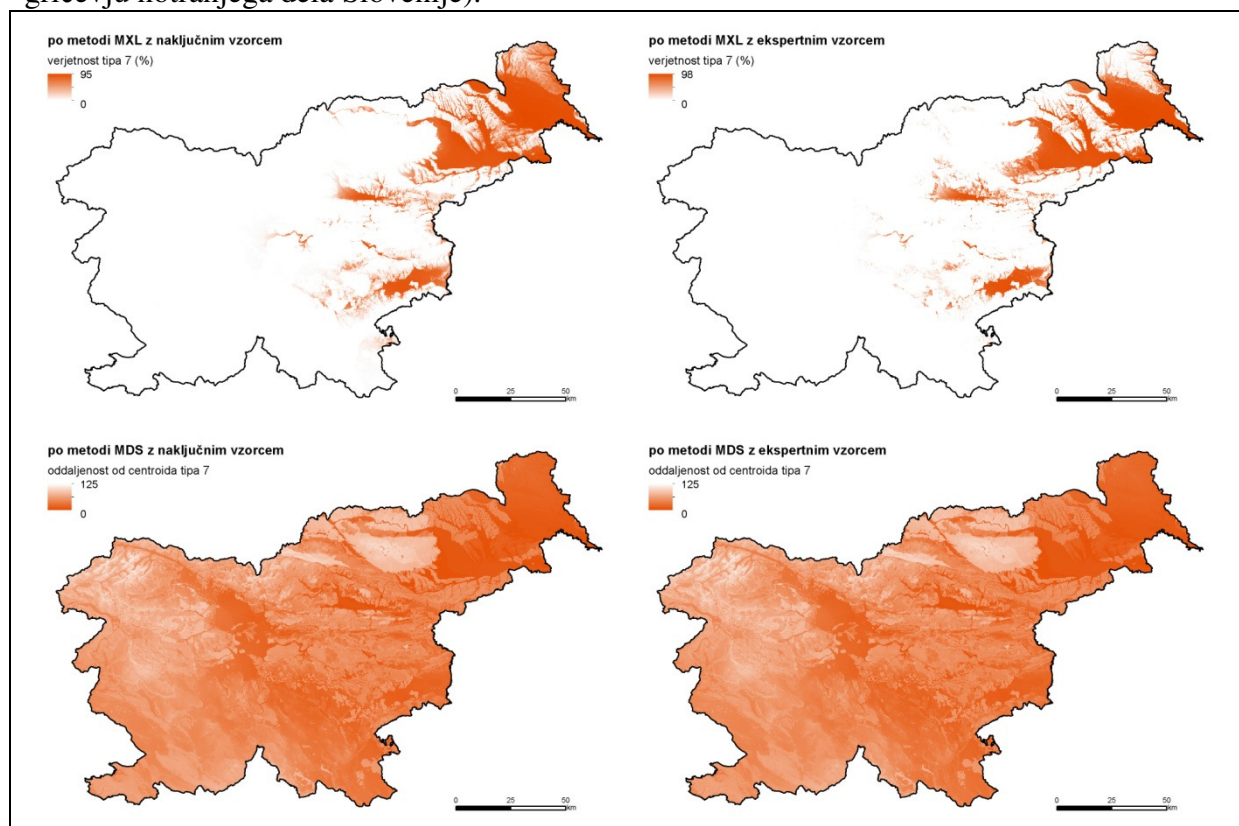


Slika 129: Mehke modelirane naravnopokrajinske tipizacije za tip 6 (gričevje v notranjem delu Slovenije).






Slika 130: Mehke modelirane naravnopokrajinske tipizacije za tip 7 (ravnine in širše doline v gričevju notranjega dela Slovenije).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 7 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 7 (%)



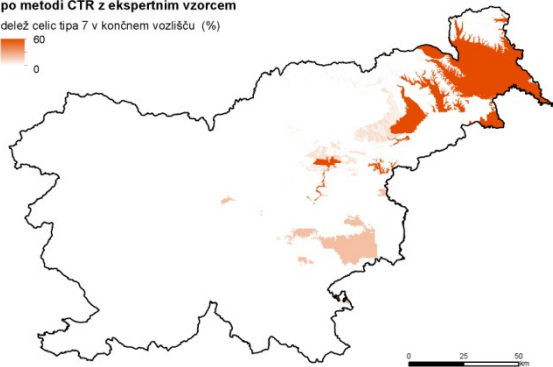
po metodi CTR z naključnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)



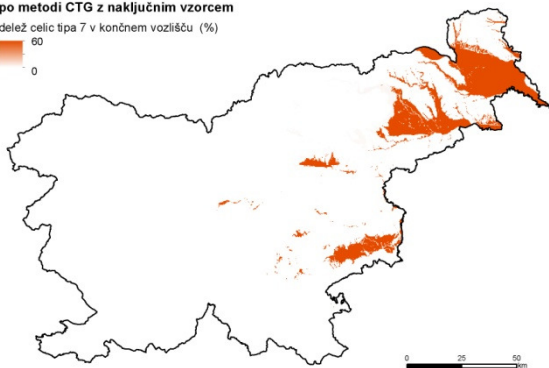
po metodi CTR z ekspertnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)



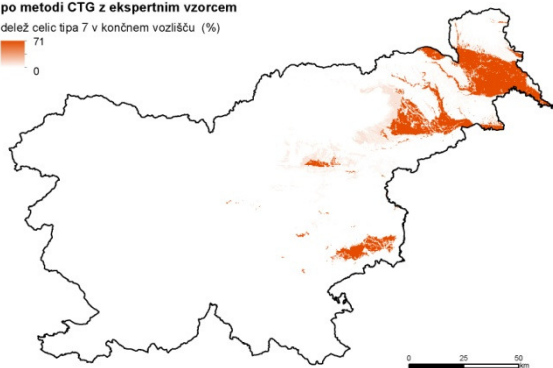
po metodi CTG z naključnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)



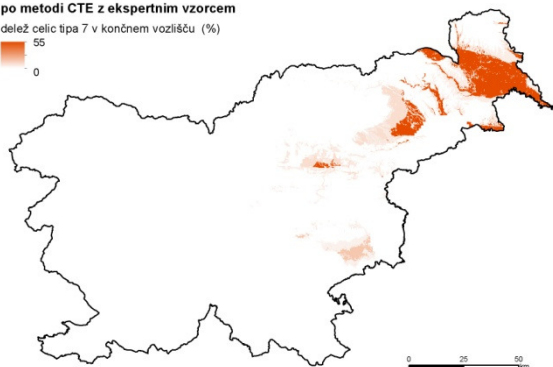
po metodi CTE z naključnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)

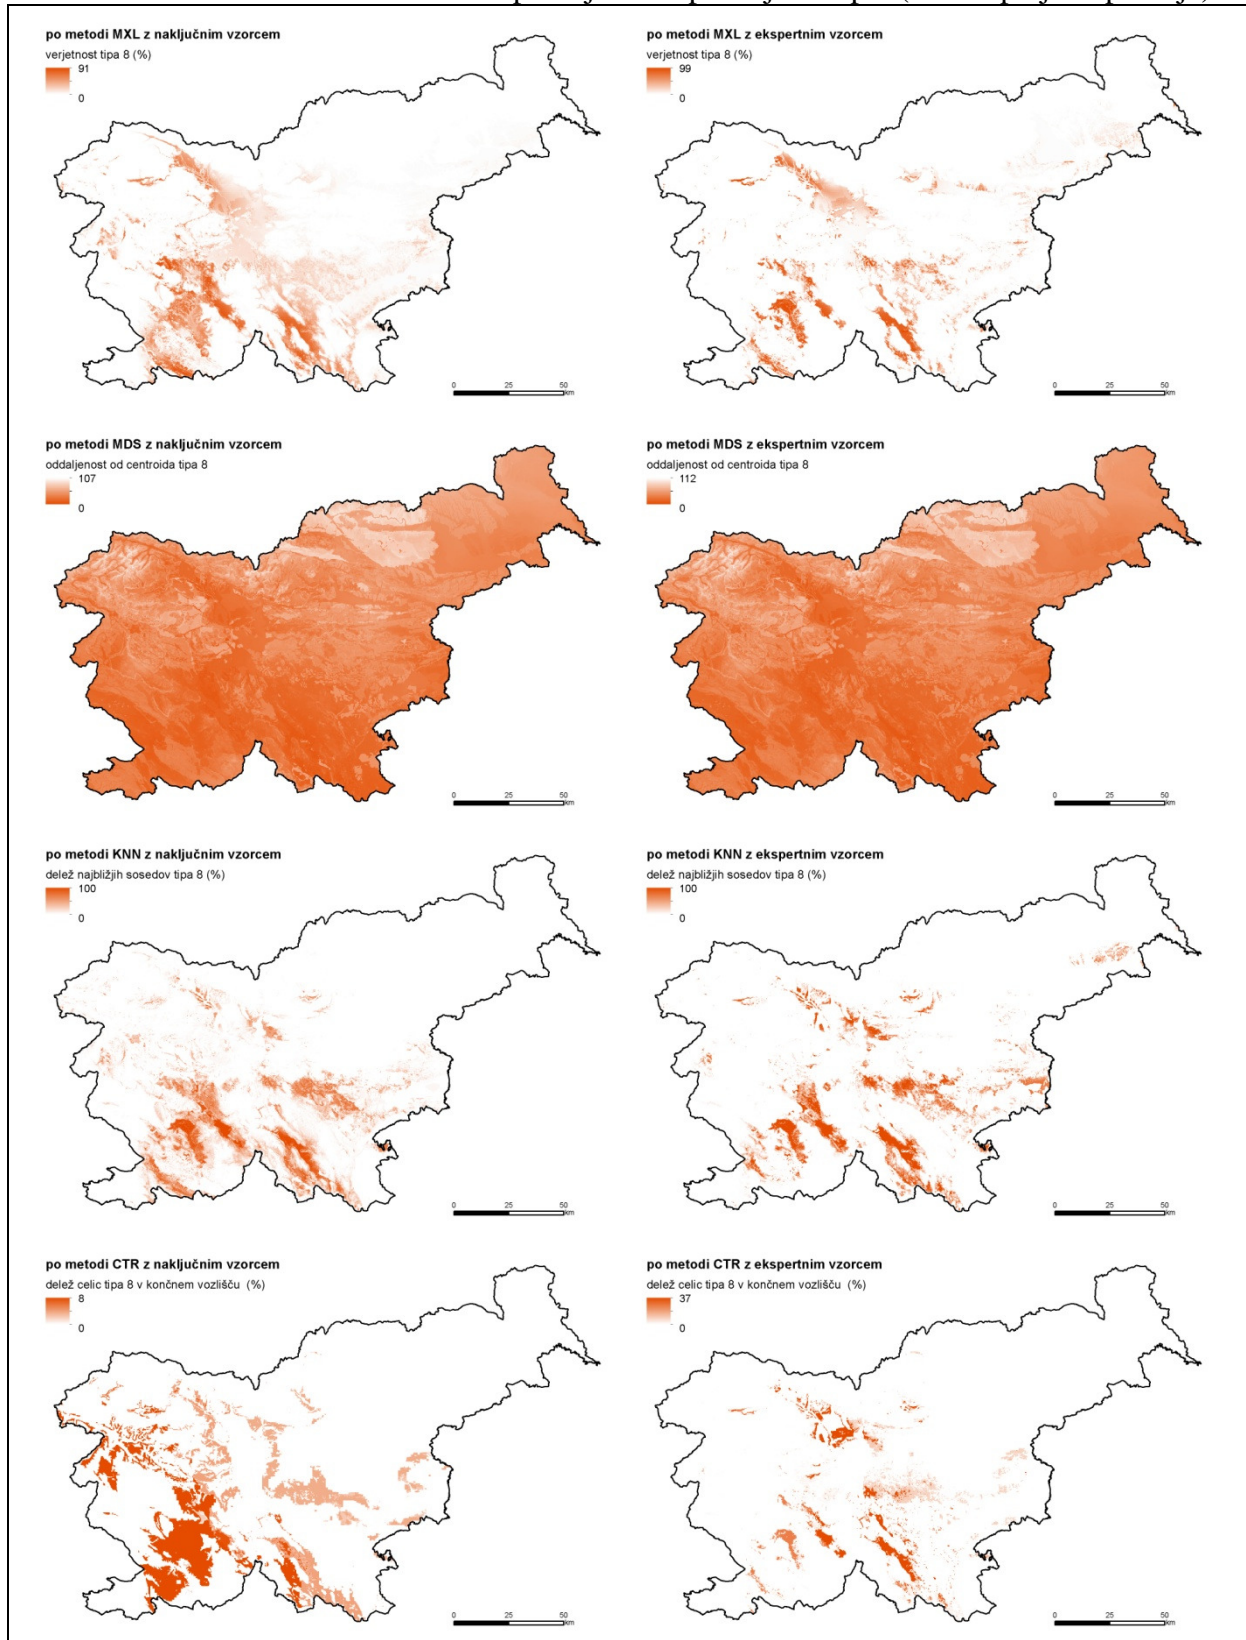


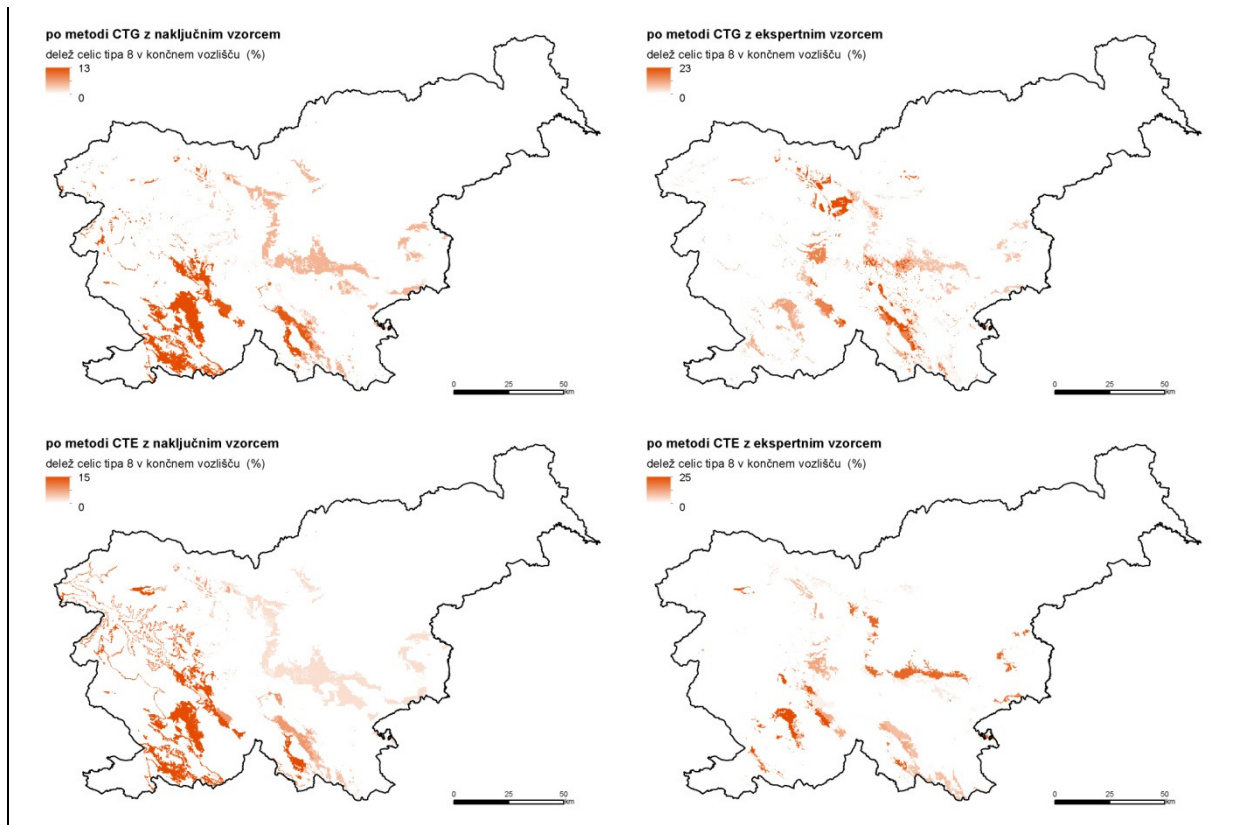
po metodi CTE z ekspertnim vzorcem

delež celic tipa 7 v končnem vozlišču (%)

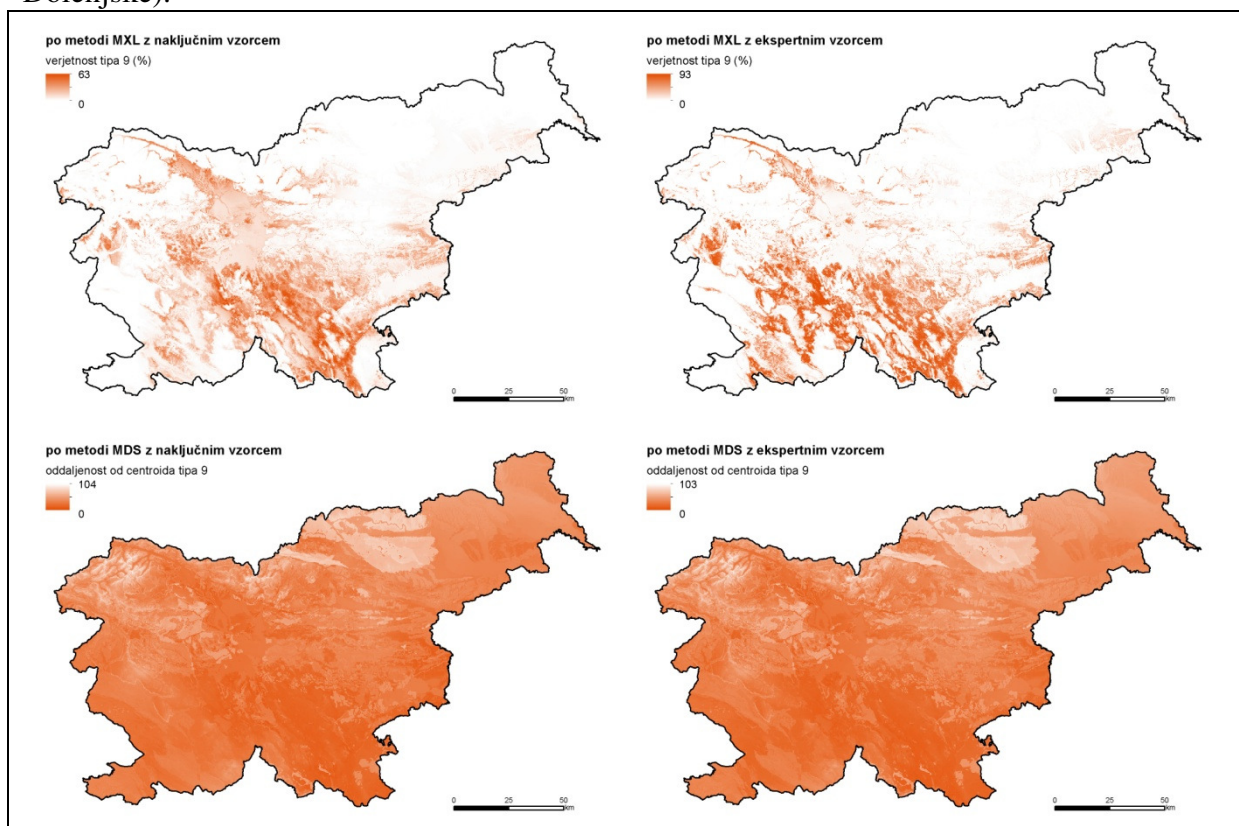


Slika 131: Mehke modelirane naravnopokrajinske tipizacije za tip 8 (kraška polja in podolja).



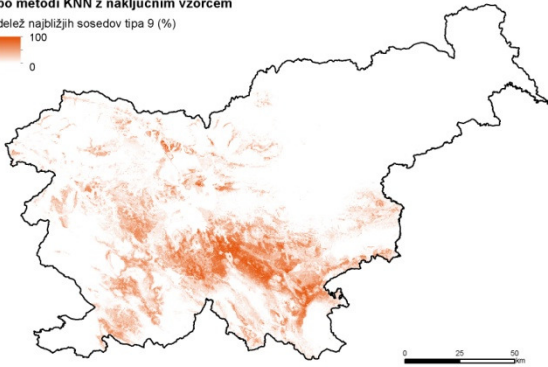


Slika 132: Mehke modelirane naravnopokrajinske tipizacije za tip 9 (nizki kras Notranjske in Dolenjske).



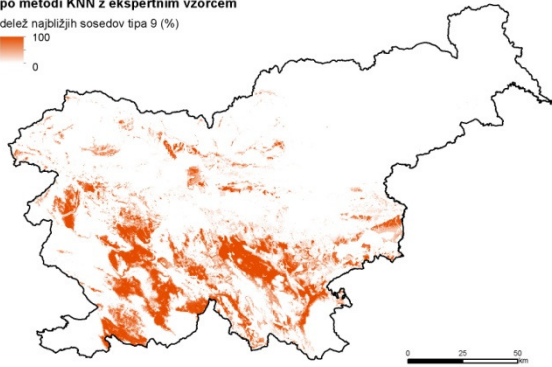
po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 9 (%)



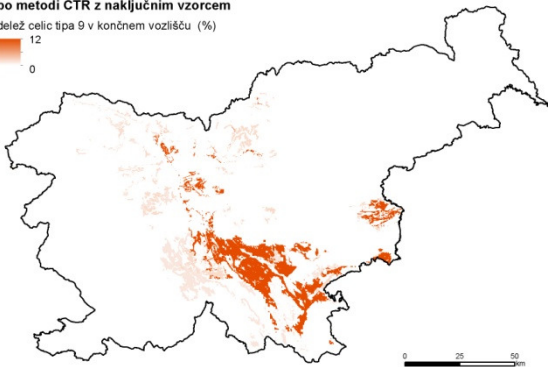
po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 9 (%)



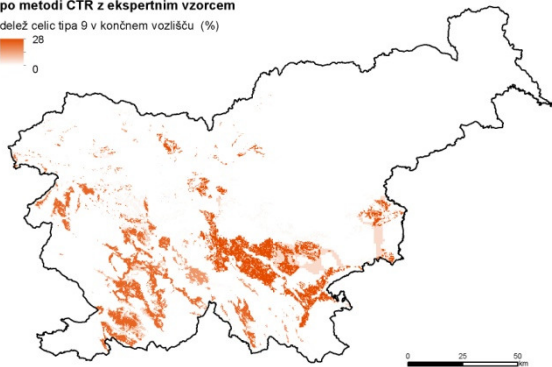
po metodi CTR z naključnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)



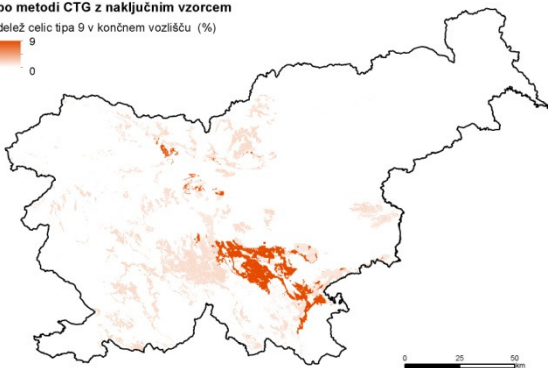
po metodi CTR z ekspertnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)



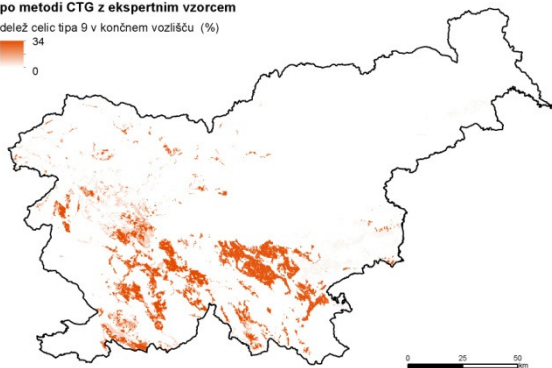
po metodi CTG z naključnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)



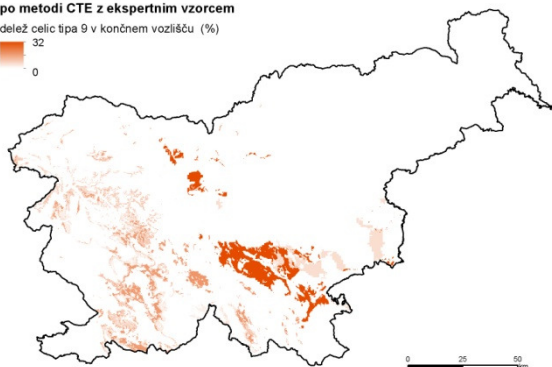
po metodi CTE z naključnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)

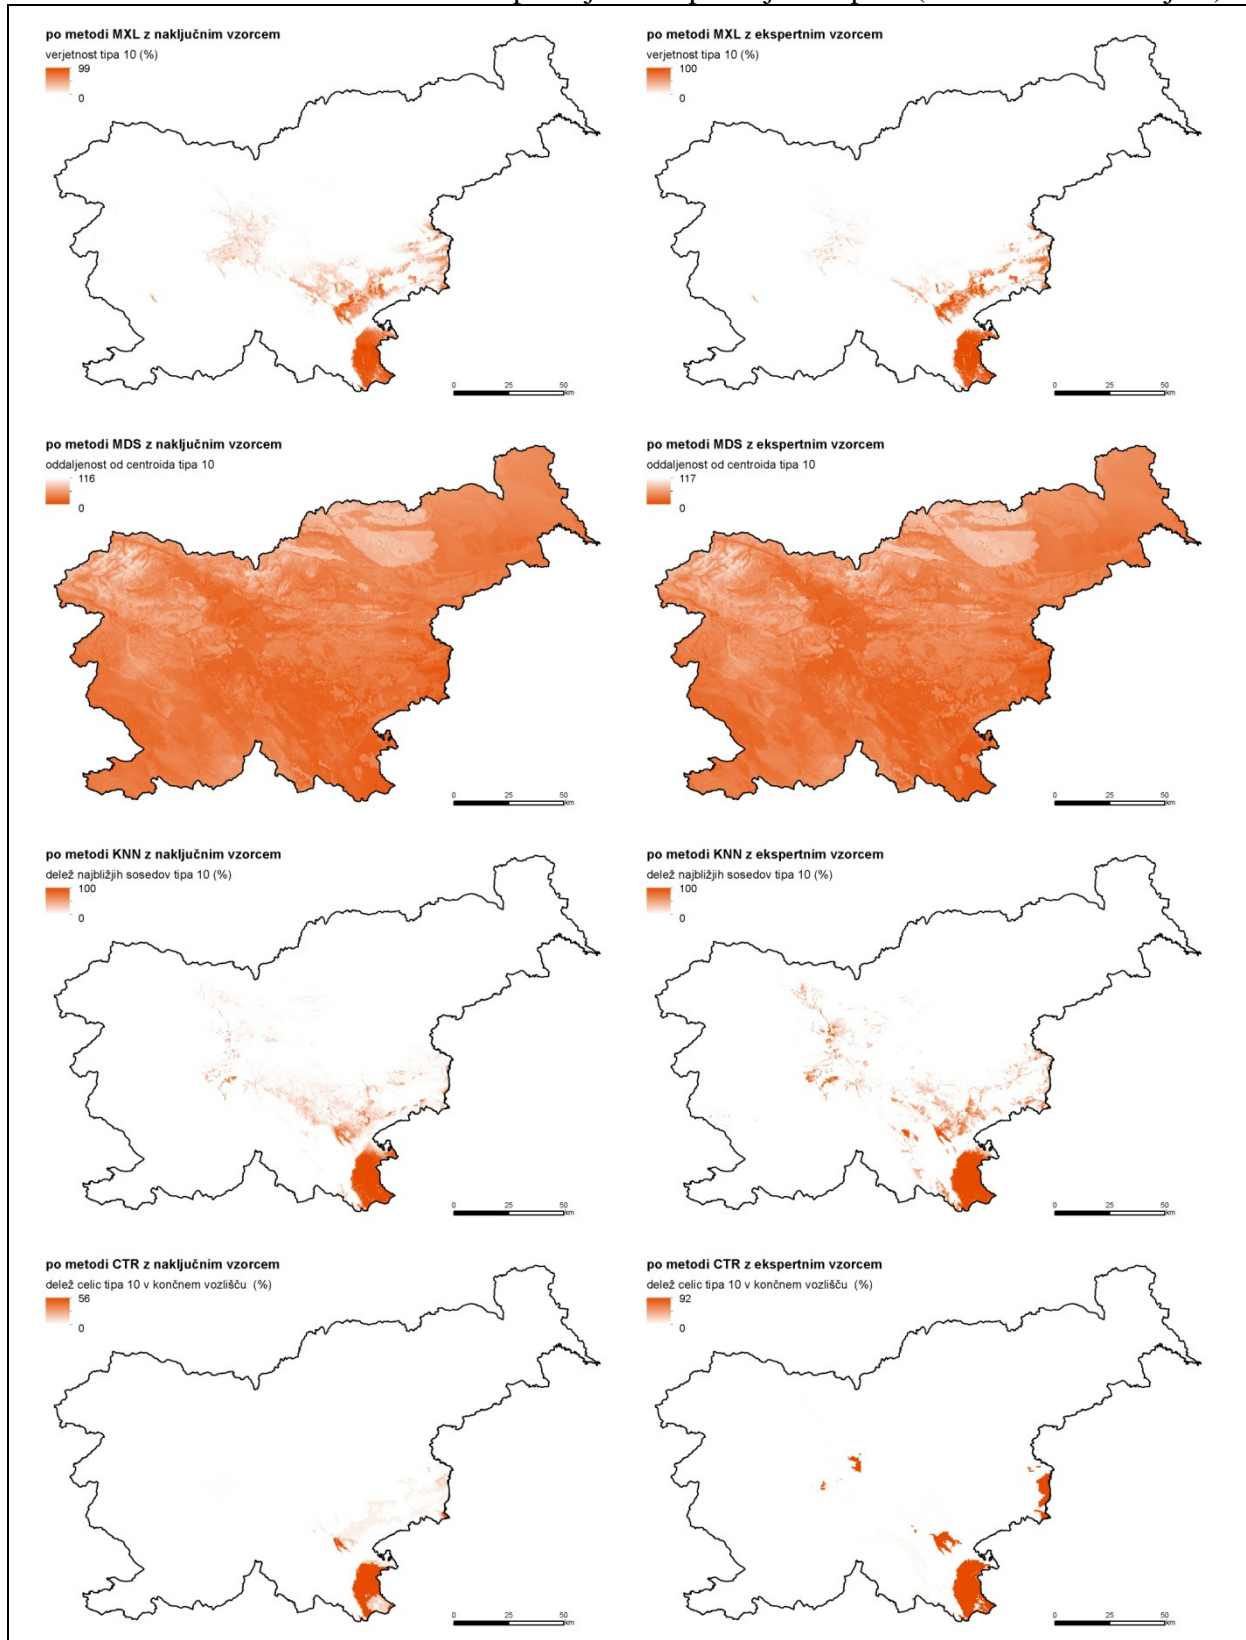


po metodi CTE z ekspertnim vzorcem

delež celic tipa 9 v končnem vozlišču (%)

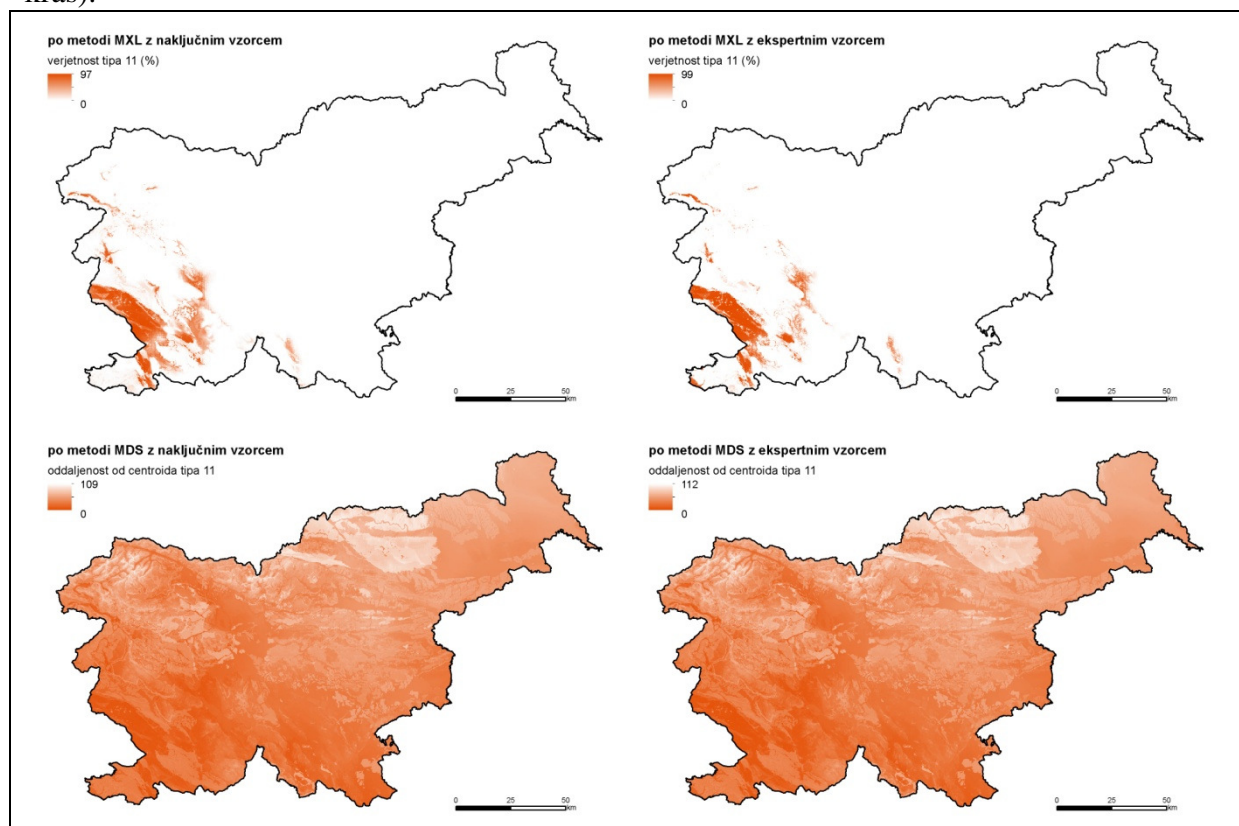


Slika 133: Mehke modelirane naravnopokrajinske tipizacije za tip 10 (nizki kras Bele krajine).



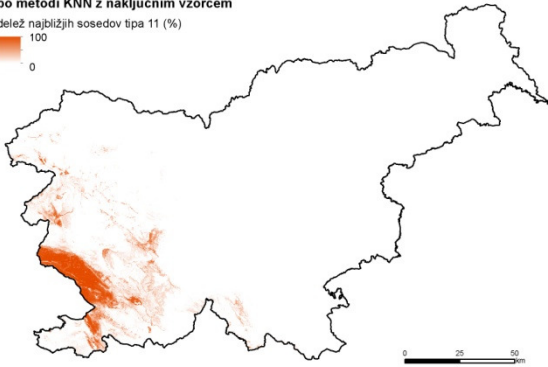


Slika 134: Mehke modelirane naravnopokrajinske tipizacije za tip 11 (Kras in Podgorski kras).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 11 (%)




po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 11 (%)




po metodi CTR z naključnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)




po metodi CTR z ekspertnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)




po metodi CTG z naključnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)




po metodi CTG z ekspertnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)




po metodi CTE z naključnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)

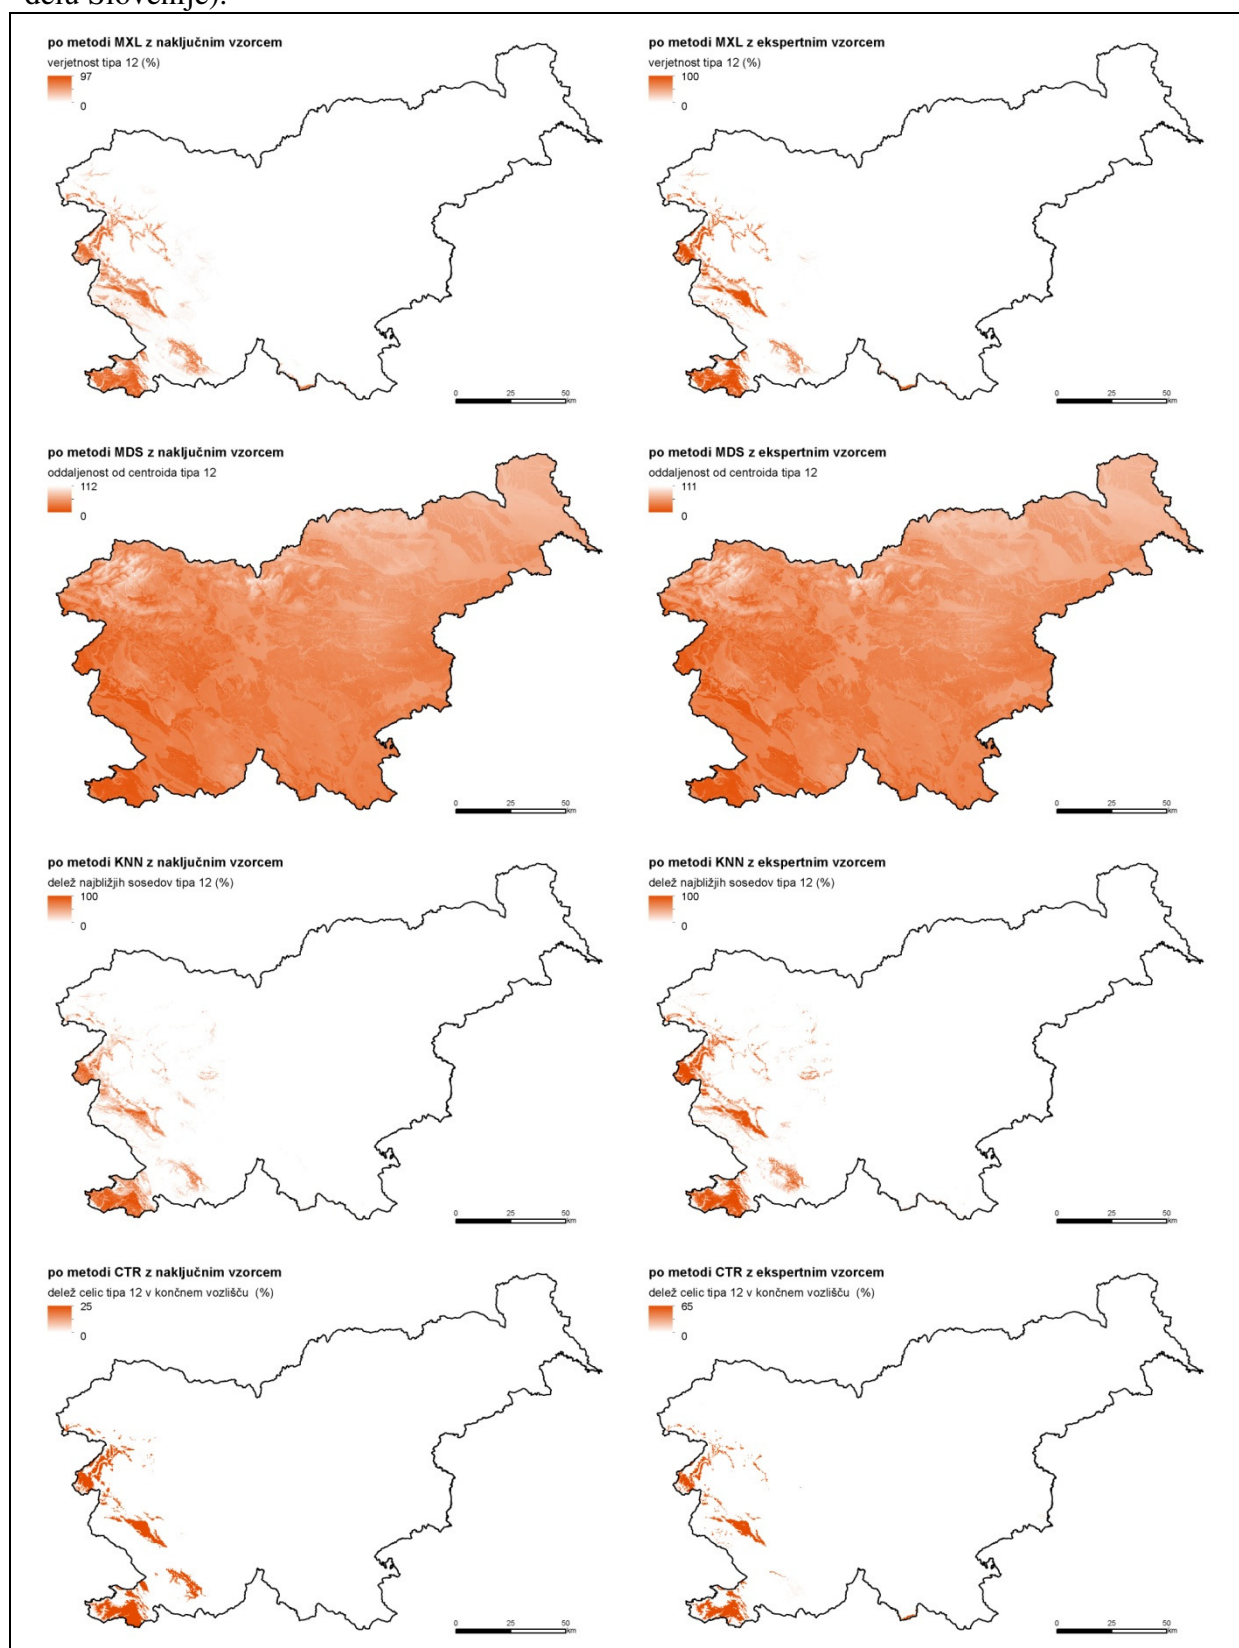


po metodi CTE z ekspertnim vzorcem

delež celic tipa 11 v končnem vozlišču (%)

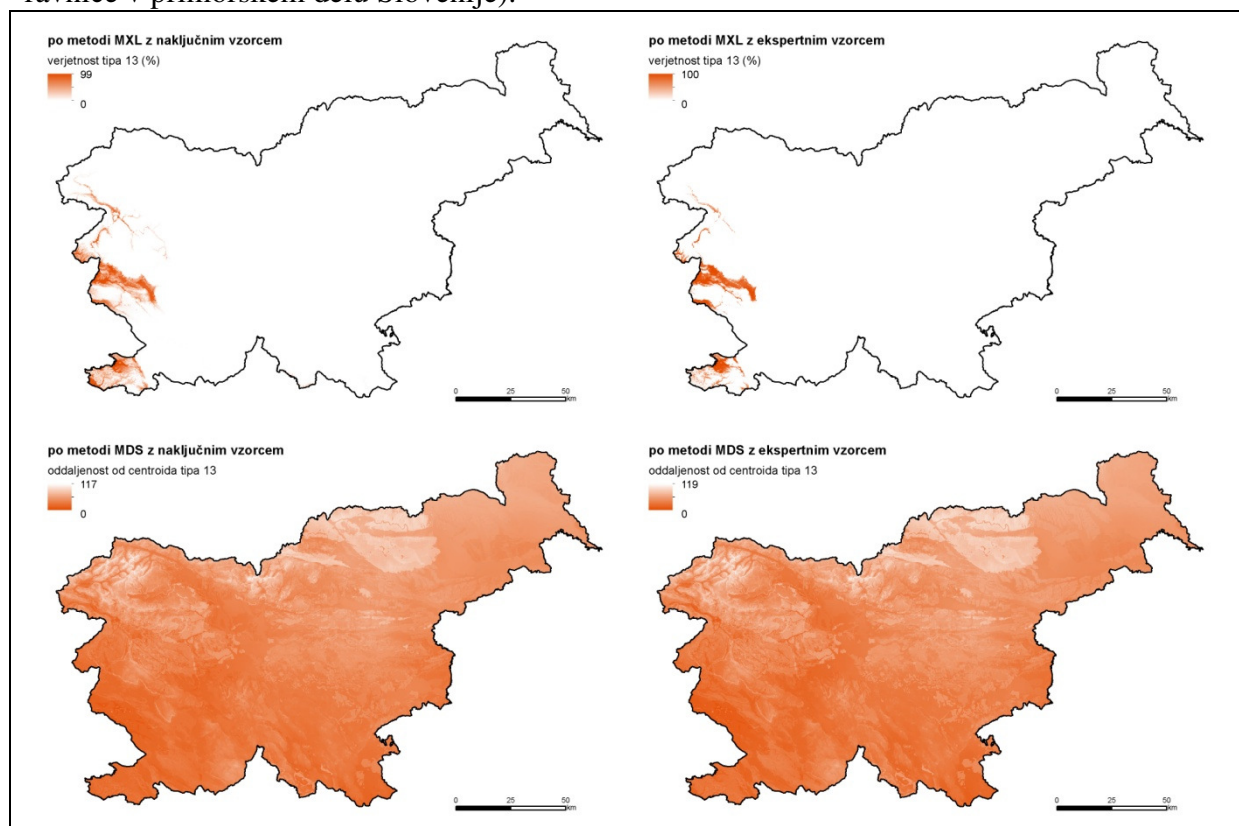


Slika 135: Mehke modelirane naravnopokrajinske tipizacije za tip 12 (gričevje v primorskem delu Slovenije).






Slika 136: Mehke modelirane naravnopokrajinske tipizacije za tip 13 (širše doline in obalne ravnice v primorskem delu Slovenije).




po metodi KNN z naključnim vzorcem

delež najbližjih sosedov tipa 13 (%)



po metodi KNN z ekspertnim vzorcem

delež najbližjih sosedov tipa 13 (%)




po metodi CTR z naključnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)



po metodi CTR z ekspertnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)




po metodi CTG z naključnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)



po metodi CTG z ekspertnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)



po metodi CTE z naključnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)



po metodi CTE z ekspertnim vzorcem

delež celic tipa 13 v končnem vozlišču (%)



Priloga 13: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij

V prilogi sta preglednici (preglednici 165 in 166), v katerih so navedeni Pearsonovi in Spearmanovi koeficienti povezanosti med seštevkom trdnih klasifikacij in mehkiimi nadzorovanimi klasifikacijami.

Oznake pomenijo: S.T.K. – seštevka trdnih klasifikacij; MDS – metode najmanjše razdalje (mehka različica), MXL – metoda največje verjetnosti (mehka različica), CTE – odločitveno drevo CTE (mehka različica), CTG – odločitveno drevo CTG (mehka različica), CTR – odločitveno drevo CTA (mehka različica), KNN – metoda k najbližjih sosedov (mehka različica).

V predzadnji koloni preglednic so povprečne vrednosti koeficientov posamezne vrstice. V zadnji koloni je označeno, če je statistična značilnost povprečja $p \leq 0,006$ oziroma če je stopnja tveganja enaka oziroma manjša od 0,6 %. Primerjava med povprečnimi koeficienti (na primer določitev največjega povprečnega koeficienta) ima še nekoliko manjšo statistično značilnost kot $p=0,006$. Pri lestvici ne moremo upoštevati statistično neznačilnih koeficientov. Povprečni koeficient koeficientov, kjer je vedno vključen seštevka trdnih klasifikacij, je vedno statistično značilen $p < 0,006$.

Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij (TIPI9)

Preglednica 165: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij za tipizacijo TIPI9.

tip 1.1 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja $< 0,006$
S.T.K.	1,00	0,56	0,68	0,50	0,75	0,73	0,84	0,68	da
MDS	0,56	1,00	0,67	0,42	0,43	0,41	0,47	0,50	da
MXL	0,68	0,67	1,00	0,44	0,47	0,44	0,66	0,56	da
CTE	0,50	0,42	0,44	1,00	0,33	0,35	0,47	0,42	da
CTG	0,75	0,43	0,47	0,33	1,00	0,92	0,60	0,58	da
CTR	0,73	0,41	0,44	0,35	0,92	1,00	0,58	0,57	da
KNN	0,84	0,47	0,66	0,47	0,60	0,58	1,00	0,60	da
tip 1.1 (po naključnem vzorcu)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja $< 0,006$
S.T.K.	1,00	0,58	0,73	0,63	0,85	0,75	0,80	0,72	da
MDS	0,58	1,00	0,69	0,43	0,43	0,36	0,51	0,50	da
MXL	0,73	0,69	1,00	0,56	0,50	0,42	0,72	0,60	da
CTE	0,63	0,43	0,56	1,00	0,42	0,37	0,56	0,50	da
CTG	0,85	0,43	0,50	0,42	1,00	0,80	0,61	0,60	da
CTR	0,75	0,36	0,42	0,37	0,80	1,00	0,52	0,54	da
KNN	0,80	0,51	0,72	0,56	0,61	0,52	1,00	0,62	da
tip 1.1 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja $< 0,006$
S.T.K.	1,00	0,16	0,84	0,72	0,68	0,67	0,82	0,65	da
MDS	0,16	1,00	0,09	0,09	0,08	0,10	-0,02	0,08	da
MXL	0,84	0,09	1,00	0,63	0,62	0,64	0,78	0,60	da
CTE	0,72	0,09	0,63	1,00	0,86	0,78	0,62	0,62	da
CTG	0,68	0,08	0,62	0,86	1,00	0,87	0,63	0,62	da

CTR	0,67	0,10	0,64	0,78	0,87	1,00	0,64	0,62	da
KNN	0,82	-0,02	0,78	0,62	0,63	0,64	1,00	0,58	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,16	0,84	0,84	0,82	0,74	0,81	0,70	da
MDS	0,16	1,00	0,04	0,08	0,06	0,16	-0,06	0,07	da
MXL	0,84	0,04	1,00	0,71	0,66	0,69	0,80	0,62	da
CTE	0,84	0,08	0,71	1,00	0,85	0,73	0,71	0,65	da
CTG	0,82	0,06	0,66	0,85	1,00	0,75	0,70	0,64	da
CTR	0,74	0,16	0,69	0,73	0,75	1,00	0,67	0,62	da
KNN	0,81	-0,06	0,80	0,71	0,70	0,67	1,00	0,61	da
tip 1.2 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,30	0,62	0,65	0,68	0,56	0,59	0,57	da
MDS	0,30	1,00	0,20	0,31	0,02	0,09	0,26	0,20	da
MXL	0,62	0,20	1,00	0,61	0,42	0,31	0,48	0,44	da
CTE	0,65	0,31	0,61	1,00	0,45	0,23	0,41	0,44	da
CTG	0,68	0,02	0,42	0,45	1,00	0,60	0,36	0,42	da
CTR	0,56	0,09	0,31	0,23	0,60	1,00	0,22	0,34	da
KNN	0,59	0,26	0,48	0,41	0,36	0,22	1,00	0,39	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,30	0,64	0,66	0,77	0,61	0,61	0,60	da
MDS	0,30	1,00	0,18	0,21	0,05	0,09	0,26	0,18	da
MXL	0,64	0,18	1,00	0,55	0,36	0,22	0,53	0,41	da
CTE	0,66	0,21	0,55	1,00	0,46	0,27	0,41	0,43	da
CTG	0,77	0,05	0,36	0,46	1,00	0,59	0,35	0,43	da
CTR	0,61	0,09	0,22	0,27	0,59	1,00	0,19	0,33	da
KNN	0,61	0,26	0,53	0,41	0,35	0,19	1,00	0,39	da
tip 1.2 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,15	0,79	0,78	0,79	0,76	0,81	0,63	da
MDS	-0,15	1,00	-0,09	0,00	-0,01	0,02	-0,19	-0,07	ni
MXL	0,79	-0,09	1,00	0,67	0,66	0,65	0,70	0,56	da
CTE	0,78	0,00	0,67	1,00	1,00	0,95	0,55	0,66	ni
CTG	0,79	-0,01	0,66	1,00	1,00	0,95	0,55	0,66	da
CTR	0,76	0,02	0,65	0,95	0,95	1,00	0,55	0,65	da
KNN	0,81	-0,19	0,70	0,55	0,55	0,55	1,00	0,49	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,18	0,80	0,82	0,86	0,85	0,81	0,66	da
MDS	-0,18	1,00	-0,09	-0,07	-0,18	-0,19	-0,21	-0,15	da
MXL	0,80	-0,09	1,00	0,67	0,63	0,66	0,71	0,56	da
CTE	0,82	-0,07	0,67	1,00	0,86	0,82	0,60	0,62	da
CTG	0,86	-0,18	0,63	0,86	1,00	0,90	0,63	0,62	da

CTR	0,85	-0,19	0,66	0,82	0,90	1,00	0,64	0,61	da
KNN	0,81	-0,21	0,71	0,60	0,63	0,64	1,00	0,53	da
tip 1.3 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,27	0,57	0,67	0,70	0,71	0,64	0,59	da
MDS	0,27	1,00	0,51	0,21	0,15	0,25	0,05	0,24	da
MXL	0,57	0,51	1,00	0,31	0,20	0,37	0,35	0,38	da
CTE	0,67	0,21	0,31	1,00	0,78	0,88	0,44	0,55	da
CTG	0,70	0,15	0,20	0,78	1,00	0,76	0,41	0,50	da
CTR	0,71	0,25	0,37	0,88	0,76	1,00	0,51	0,58	da
KNN	0,64	0,05	0,35	0,44	0,41	0,51	1,00	0,40	da
tip 1.3 (po naključnem vzorcu)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,28	0,54	0,61	0,81	0,77	0,54	0,59	da
MDS	0,28	1,00	0,68	0,04	0,03	0,22	0,19	0,24	da
MXL	0,54	0,68	1,00	0,23	0,26	0,36	0,38	0,41	da
CTE	0,61	0,04	0,23	1,00	0,56	0,57	0,32	0,39	da
CTG	0,81	0,03	0,26	0,56	1,00	0,65	0,40	0,45	da
CTR	0,77	0,22	0,36	0,57	0,65	1,00	0,53	0,52	da
KNN	0,54	0,19	0,38	0,32	0,40	0,53	1,00	0,39	da
tip 1.3 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,20	0,65	0,73	0,77	0,66	0,85	0,64	da
MDS	0,20	1,00	0,42	0,14	0,15	0,11	0,10	0,19	da
MXL	0,65	0,42	1,00	0,41	0,44	0,35	0,54	0,47	da
CTE	0,73	0,14	0,41	1,00	0,94	0,86	0,68	0,63	da
CTG	0,77	0,15	0,44	0,94	1,00	0,91	0,72	0,66	da
CTR	0,66	0,11	0,35	0,86	0,91	1,00	0,67	0,60	da
KNN	0,85	0,10	0,54	0,68	0,72	0,67	1,00	0,59	da
tip 1.3 (po naključnem vzorcu)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,17	0,65	0,73	0,81	0,71	0,74	0,64	da
MDS	0,17	1,00	0,43	0,05	-0,08	-0,03	0,03	0,10	da
MXL	0,65	0,43	1,00	0,44	0,42	0,34	0,53	0,47	da
CTE	0,73	0,05	0,44	1,00	0,74	0,68	0,62	0,54	da
CTG	0,81	-0,08	0,42	0,74	1,00	0,71	0,60	0,53	da
CTR	0,71	-0,03	0,34	0,68	0,71	1,00	0,62	0,51	da
KNN	0,74	0,03	0,53	0,62	0,60	0,62	1,00	0,52	da
tip 2.1 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,35	0,67	0,72	0,79	0,80	0,56	0,65	da
MDS	0,35	1,00	0,34	0,22	0,26	0,28	0,27	0,29	da
MXL	0,67	0,34	1,00	0,58	0,58	0,60	0,46	0,54	da
CTE	0,72	0,22	0,58	1,00	0,72	0,80	0,40	0,57	da

CTG	0,79	0,26	0,58	0,72	1,00	0,85	0,33	0,59	da
CTR	0,80	0,28	0,60	0,80	0,85	1,00	0,38	0,62	da
KNN	0,56	0,27	0,46	0,40	0,33	0,38	1,00	0,40	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,41	0,71	0,79	0,86	0,85	0,60	0,70	da
MDS	0,41	1,00	0,30	0,26	0,25	0,26	0,25	0,29	da
MXL	0,71	0,30	1,00	0,66	0,56	0,57	0,54	0,56	da
CTE	0,79	0,26	0,66	1,00	0,73	0,78	0,44	0,61	da
CTG	0,86	0,25	0,56	0,73	1,00	0,83	0,33	0,59	da
CTR	0,85	0,26	0,57	0,78	0,83	1,00	0,38	0,61	da
KNN	0,60	0,25	0,54	0,44	0,33	0,38	1,00	0,42	da
tip 2.1 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,27	0,74	0,71	0,80	0,82	0,78	0,69	da
MDS	0,27	1,00	0,22	0,09	0,10	0,12	0,34	0,19	da
MXL	0,74	0,22	1,00	0,54	0,66	0,65	0,63	0,57	da
CTE	0,71	0,09	0,54	1,00	0,46	0,58	0,60	0,50	da
CTG	0,80	0,10	0,66	0,46	1,00	0,91	0,51	0,57	da
CTR	0,82	0,12	0,65	0,58	0,91	1,00	0,53	0,60	da
KNN	0,78	0,34	0,63	0,60	0,51	0,53	1,00	0,57	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,36	0,77	0,71	0,80	0,79	0,80	0,71	da
MDS	0,36	1,00	0,25	0,08	0,13	0,14	0,34	0,22	da
MXL	0,77	0,25	1,00	0,52	0,65	0,63	0,68	0,58	da
CTE	0,71	0,08	0,52	1,00	0,49	0,58	0,60	0,50	da
CTG	0,80	0,13	0,65	0,49	1,00	0,89	0,53	0,58	da
CTR	0,79	0,14	0,63	0,58	0,89	1,00	0,53	0,59	da
KNN	0,80	0,34	0,68	0,60	0,53	0,53	1,00	0,58	da
tip 2.2 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,40	0,78	0,89	0,71	0,87	0,82	0,75	da
MDS	0,40	1,00	0,49	0,33	-0,01	0,29	0,40	0,32	da
MXL	0,78	0,49	1,00	0,64	0,43	0,58	0,74	0,61	da
CTE	0,89	0,33	0,64	1,00	0,59	0,94	0,67	0,68	da
CTG	0,71	-0,01	0,43	0,59	1,00	0,61	0,53	0,48	da
CTR	0,87	0,29	0,58	0,94	0,61	1,00	0,63	0,65	da
KNN	0,82	0,40	0,74	0,67	0,53	0,63	1,00	0,63	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,44	0,79	0,87	0,76	0,86	0,80	0,75	da
MDS	0,44	1,00	0,64	0,36	0,04	0,32	0,42	0,37	da
MXL	0,79	0,64	1,00	0,71	0,42	0,65	0,80	0,67	da
CTE	0,87	0,36	0,71	1,00	0,61	0,93	0,68	0,69	da

CTG	0,76	0,04	0,42	0,61	1,00	0,64	0,53	0,50	da
CTR	0,86	0,32	0,65	0,93	0,64	1,00	0,64	0,67	da
KNN	0,80	0,42	0,80	0,68	0,53	0,64	1,00	0,64	da
tip 2.2 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,36	0,75	0,70	0,75	0,75	0,93	0,71	da
MDS	0,36	1,00	0,50	0,16	0,22	0,23	0,28	0,29	da
MXL	0,75	0,50	1,00	0,50	0,52	0,53	0,73	0,59	da
CTE	0,70	0,16	0,50	1,00	0,89	0,91	0,72	0,65	da
CTG	0,75	0,22	0,52	0,89	1,00	0,97	0,72	0,68	da
CTR	0,75	0,23	0,53	0,91	0,97	1,00	0,73	0,69	da
KNN	0,93	0,28	0,73	0,72	0,72	0,73	1,00	0,68	da
tip 3.1 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,42	0,80	0,85	0,90	0,89	0,90	0,79	da
MDS	0,42	1,00	0,44	0,18	0,23	0,27	0,28	0,30	da
MXL	0,80	0,44	1,00	0,72	0,71	0,75	0,80	0,70	da
CTE	0,85	0,18	0,72	1,00	0,88	0,91	0,84	0,73	da
CTG	0,90	0,23	0,71	0,88	1,00	0,89	0,85	0,75	da
CTR	0,89	0,27	0,75	0,91	0,89	1,00	0,85	0,76	da
KNN	0,90	0,28	0,80	0,84	0,85	0,85	1,00	0,75	da
tip 3.1 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,52	0,77	0,66	0,71	0,65	0,70	0,67	da
MDS	0,52	1,00	0,59	0,33	0,44	0,49	0,50	0,48	da
MXL	0,77	0,59	1,00	0,53	0,51	0,51	0,64	0,59	da
CTE	0,66	0,33	0,53	1,00	0,38	0,33	0,52	0,46	da
CTG	0,71	0,44	0,51	0,38	1,00	0,85	0,35	0,54	da
CTR	0,65	0,49	0,51	0,33	0,85	1,00	0,31	0,52	da
KNN	0,70	0,50	0,64	0,52	0,35	0,31	1,00	0,50	da
tip 3.1 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,59	0,76	0,65	0,79	0,71	0,69	0,70	da
MDS	0,59	1,00	0,70	0,39	0,39	0,50	0,50	0,51	da
MXL	0,76	0,70	1,00	0,54	0,46	0,51	0,67	0,61	da
CTE	0,65	0,39	0,54	1,00	0,36	0,27	0,55	0,46	da
CTG	0,79	0,39	0,46	0,36	1,00	0,73	0,37	0,52	da
CTR	0,71	0,50	0,51	0,27	0,73	1,00	0,33	0,51	da
KNN	0,69	0,50	0,67	0,55	0,37	0,33	1,00	0,52	da

CTE	0,73	0,29	0,53	1,00	0,84	0,62	0,52	0,59	da
CTG	0,74	0,24	0,51	0,84	1,00	0,61	0,53	0,58	da
CTR	0,63	0,19	0,44	0,62	0,61	1,00	0,55	0,51	da
KNN	0,76	0,41	0,62	0,52	0,53	0,55	1,00	0,56	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,57	0,63	0,78	0,84	0,64	0,75	0,70	da
MDS	0,57	1,00	0,39	0,36	0,38	0,25	0,44	0,40	da
MXL	0,63	0,39	1,00	0,48	0,45	0,31	0,60	0,48	da
CTE	0,78	0,36	0,48	1,00	0,79	0,58	0,55	0,59	da
CTG	0,84	0,38	0,45	0,79	1,00	0,53	0,56	0,59	da
CTR	0,64	0,25	0,31	0,58	0,53	1,00	0,53	0,47	da
KNN	0,75	0,44	0,60	0,55	0,56	0,53	1,00	0,57	da
tip 3.2 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,15	0,34	0,58	0,52	0,55	0,60	0,46	da
MDS	0,15	1,00	0,22	0,08	0,18	0,13	0,16	0,15	da
MXL	0,34	0,22	1,00	0,05	0,13	0,20	0,43	0,23	da
CTE	0,58	0,08	0,05	1,00	0,81	0,40	0,33	0,38	da
CTG	0,52	0,18	0,13	0,81	1,00	0,39	0,36	0,40	da
CTR	0,55	0,13	0,20	0,40	0,39	1,00	0,32	0,33	da
KNN	0,60	0,16	0,43	0,33	0,36	0,32	1,00	0,37	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,18	0,32	0,69	0,77	0,73	0,59	0,55	da
MDS	0,18	1,00	0,42	-0,04	0,10	0,03	0,21	0,15	da
MXL	0,32	0,42	1,00	-0,01	0,05	0,11	0,49	0,23	ni
CTE	0,69	-0,04	-0,01	1,00	0,60	0,55	0,28	0,35	ni
CTG	0,77	0,10	0,05	0,60	1,00	0,53	0,33	0,40	da
CTR	0,73	0,03	0,11	0,55	0,53	1,00	0,35	0,38	da
KNN	0,59	0,21	0,49	0,28	0,33	0,35	1,00	0,37	da
tip 3.2 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,29	0,51	0,64	0,69	0,59	0,75	0,58	da
MDS	0,29	1,00	0,20	0,21	0,17	0,16	0,27	0,22	da
MXL	0,51	0,20	1,00	0,39	0,41	0,39	0,50	0,40	da
CTE	0,64	0,21	0,39	1,00	0,85	0,78	0,58	0,58	da
CTG	0,69	0,17	0,41	0,85	1,00	0,81	0,58	0,58	da
CTR	0,59	0,16	0,39	0,78	0,81	1,00	0,52	0,54	da
KNN	0,75	0,27	0,50	0,58	0,58	0,52	1,00	0,53	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,30	0,46	0,63	0,72	0,56	0,71	0,56	da
MDS	0,30	1,00	0,33	0,22	0,22	0,12	0,31	0,25	da
MXL	0,46	0,33	1,00	0,24	0,21	0,25	0,47	0,33	da

CTE	0,63	0,22	0,24	1,00	0,48	0,41	0,50	0,41	da
CTG	0,72	0,22	0,21	0,48	1,00	0,47	0,43	0,42	da
CTR	0,56	0,12	0,25	0,41	0,47	1,00	0,39	0,37	da
KNN	0,71	0,31	0,47	0,50	0,43	0,39	1,00	0,47	da
tip 4.1 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,43	0,75	0,73	0,73	0,72	0,83	0,70	da
MDS	0,43	1,00	0,59	0,45	0,47	0,50	0,35	0,47	da
MXL	0,75	0,59	1,00	0,56	0,60	0,61	0,64	0,63	da
CTE	0,73	0,45	0,56	1,00	0,86	0,95	0,55	0,68	da
CTG	0,73	0,47	0,60	0,86	1,00	0,89	0,54	0,68	da
CTR	0,72	0,50	0,61	0,95	0,89	1,00	0,53	0,70	da
KNN	0,83	0,35	0,64	0,55	0,54	0,53	1,00	0,57	da
tip 4.1 (po naključnem vzorcu)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,55	0,78	0,86	0,91	0,87	0,81	0,80	da
MDS	0,55	1,00	0,68	0,41	0,46	0,52	0,40	0,50	da
MXL	0,78	0,68	1,00	0,60	0,67	0,71	0,66	0,68	da
CTE	0,86	0,41	0,60	1,00	0,84	0,83	0,68	0,70	da
CTG	0,91	0,46	0,67	0,84	1,00	0,86	0,70	0,74	da
CTR	0,87	0,52	0,71	0,83	0,86	1,00	0,67	0,74	da
KNN	0,81	0,40	0,66	0,68	0,70	0,67	1,00	0,65	da
tip 4.1 (po naključnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,40	0,80	0,69	0,78	0,75	0,89	0,72	da
MDS	0,40	1,00	0,49	0,34	0,47	0,40	0,33	0,41	da
MXL	0,80	0,49	1,00	0,77	0,72	0,70	0,73	0,70	da
CTE	0,69	0,34	0,77	1,00	0,83	0,89	0,60	0,69	da
CTG	0,78	0,47	0,72	0,83	1,00	0,91	0,73	0,74	da
CTR	0,75	0,40	0,70	0,89	0,91	1,00	0,69	0,72	da
KNN	0,89	0,33	0,73	0,60	0,73	0,69	1,00	0,66	da
tip 4.1 (po naključnem vzorcu)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,46	0,81	0,79	0,89	0,82	0,84	0,77	da
MDS	0,46	1,00	0,52	0,27	0,44	0,35	0,33	0,39	da
MXL	0,81	0,52	1,00	0,78	0,71	0,66	0,72	0,70	da
CTE	0,79	0,27	0,78	1,00	0,77	0,80	0,68	0,68	da
CTG	0,89	0,44	0,71	0,77	1,00	0,86	0,81	0,75	da
CTR	0,82	0,35	0,66	0,80	0,86	1,00	0,77	0,71	da
KNN	0,84	0,33	0,72	0,68	0,81	0,77	1,00	0,69	da
tip 4.2 (po ekspertnem vzorcu)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,55	0,68	0,67	0,67	0,65	0,69	0,65	da
MDS	0,55	1,00	0,61	0,30	0,30	0,28	0,60	0,44	da

MXL	0,68	0,61	1,00	0,33	0,32	0,31	0,43	0,45	da
CTE	0,67	0,30	0,33	1,00	0,97	0,94	0,47	0,62	da
CTG	0,67	0,30	0,32	0,97	1,00	0,96	0,46	0,61	da
CTR	0,65	0,28	0,31	0,94	0,96	1,00	0,44	0,60	da
KNN	0,69	0,60	0,43	0,47	0,46	0,44	1,00	0,51	da
Spearmanov koeficient									
S.T.K.	1,00	0,65	0,67	0,78	0,81	0,82	0,70	0,74	stat. znač. povprečja <0,006
MDS	0,65	1,00	0,67	0,39	0,37	0,41	0,59	0,51	da
MXL	0,67	0,67	1,00	0,38	0,39	0,38	0,46	0,49	da
CTE	0,78	0,39	0,38	1,00	0,79	0,80	0,54	0,61	da
CTG	0,81	0,37	0,39	0,79	1,00	0,82	0,57	0,63	da
CTR	0,82	0,41	0,38	0,80	0,82	1,00	0,52	0,62	da
KNN	0,70	0,59	0,46	0,54	0,57	0,52	1,00	0,56	da
tip 4.2 (po naključnem vzorcu)									
Pearsonov koeficient									
S.T.K.	1,00	0,40	0,59	0,65	0,70	0,69	0,82	0,64	stat. znač. povprečja <0,006
MDS	0,40	1,00	0,67	0,10	0,11	0,13	0,48	0,32	da
MXL	0,59	0,67	1,00	0,22	0,24	0,21	0,58	0,42	da
CTE	0,65	0,10	0,22	1,00	0,93	0,41	0,58	0,48	da
CTG	0,70	0,11	0,24	0,93	1,00	0,46	0,61	0,51	da
CTR	0,69	0,13	0,21	0,41	0,46	1,00	0,50	0,40	da
KNN	0,82	0,48	0,58	0,58	0,61	0,50	1,00	0,60	da
Spearmanov koeficient									
S.T.K.	1,00	0,55	0,62	0,74	0,86	0,70	0,79	0,71	stat. znač. povprečja <0,006
MDS	0,55	1,00	0,73	0,14	0,25	0,33	0,53	0,42	da
MXL	0,62	0,73	1,00	0,22	0,28	0,25	0,61	0,45	da
CTE	0,74	0,14	0,22	1,00	0,86	0,47	0,57	0,50	da
CTG	0,86	0,25	0,28	0,86	1,00	0,64	0,64	0,59	da
CTR	0,70	0,33	0,25	0,47	0,64	1,00	0,49	0,48	da
KNN	0,79	0,53	0,61	0,57	0,64	0,49	1,00	0,61	da

Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij (TIPI13)

Preglednica 166: Povezanost mehkih nadzorovanih klasifikacij in seštevka trdnih klasifikacij za tipizacijo TIPI13.

tip 1 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,36	0,77	0,61	0,69	0,62	0,78	0,64	da
MDS	0,36	1,00	0,32	0,12	0,20	0,12	0,18	0,22	da
MXL	0,77	0,32	1,00	0,57	0,62	0,58	0,69	0,59	da
CTE	0,61	0,12	0,57	1,00	0,93	0,95	0,49	0,61	da
CTG	0,69	0,20	0,62	0,93	1,00	0,95	0,50	0,65	da
CTR	0,62	0,12	0,58	0,95	0,95	1,00	0,51	0,62	da

KNN	0,78	0,18	0,69	0,49	0,50	0,51	1,00	0,52	da
tip 1 (naključni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,35	0,78	0,68	0,83	0,79	0,80	0,70	da
MDS	0,35	1,00	0,32	0,12	0,28	0,16	0,16	0,23	da
MXL	0,78	0,32	1,00	0,49	0,59	0,61	0,72	0,58	da
CTE	0,68	0,12	0,49	1,00	0,67	0,74	0,58	0,55	da
CTG	0,83	0,28	0,59	0,67	1,00	0,71	0,57	0,61	da
CTR	0,79	0,16	0,61	0,74	0,71	1,00	0,67	0,61	da
KNN	0,80	0,16	0,72	0,58	0,57	0,67	1,00	0,58	da
tip 2 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,36	0,88	0,54	0,67	0,68	0,85	0,66	da
MDS	0,36	1,00	0,31	0,31	0,25	0,15	0,18	0,26	da
MXL	0,88	0,31	1,00	0,51	0,52	0,69	0,84	0,62	da
CTE	0,54	0,31	0,51	1,00	0,17	0,44	0,43	0,40	da
CTG	0,67	0,25	0,52	0,17	1,00	0,63	0,56	0,47	da
CTR	0,68	0,15	0,69	0,44	0,63	1,00	0,71	0,55	da
KNN	0,85	0,18	0,84	0,43	0,56	0,71	1,00	0,60	da
tip 3 (ekspertni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,35	0,88	0,60	0,69	0,82	0,86	0,70	da
MDS	0,35	1,00	0,24	0,35	0,23	0,20	0,13	0,25	da
MXL	0,88	0,24	1,00	0,53	0,51	0,76	0,85	0,63	da
CTE	0,60	0,35	0,53	1,00	0,26	0,47	0,46	0,45	da
CTG	0,69	0,23	0,51	0,26	1,00	0,65	0,56	0,48	da
CTR	0,82	0,20	0,76	0,47	0,65	1,00	0,76	0,61	da
KNN	0,86	0,13	0,85	0,46	0,56	0,76	1,00	0,60	da
tip 4 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,19	0,34	0,57	0,63	0,71	0,55	0,43	da
MDS	-0,19	1,00	-0,11	-0,08	-0,03	-0,12	-0,33	-0,14	da
MXL	0,34	-0,11	1,00	0,02	0,16	0,19	0,10	0,12	da
CTE	0,57	-0,08	0,02	1,00	0,47	0,52	0,15	0,28	da
CTG	0,63	-0,03	0,16	0,47	1,00	0,35	0,28	0,31	da
CTR	0,71	-0,12	0,19	0,52	0,35	1,00	0,38	0,34	da
KNN	0,55	-0,33	0,10	0,15	0,28	0,38	1,00	0,19	da
tip 5 (ekspertni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,27	0,17	0,64	0,76	0,69	0,49	0,42	da
MDS	-0,27	1,00	0,00	-0,23	-0,22	-0,23	-0,45	-0,23	ni
MXL	0,17	0,00	1,00	-0,09	0,14	0,01	0,04	0,05	ni

CTE	0,64	-0,23	-0,09	1,00	0,47	0,56	0,23	0,26	da
CTG	0,76	-0,22	0,14	0,47	1,00	0,38	0,35	0,31	da
CTR	0,69	-0,23	0,01	0,56	0,38	1,00	0,34	0,29	da
KNN	0,49	-0,45	0,04	0,23	0,35	0,34	1,00	0,17	da
tip 2 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,28	0,15	0,60	0,62	0,64	0,66	0,40	da
MDS	-0,28	1,00	-0,29	-0,31	-0,31	-0,32	-0,50	-0,34	da
MXL	0,15	-0,29	1,00	-0,14	-0,08	-0,07	0,16	-0,04	da
CTE	0,60	-0,31	-0,14	1,00	0,66	0,58	0,46	0,31	da
CTG	0,62	-0,31	-0,08	0,66	1,00	0,50	0,43	0,30	da
CTR	0,64	-0,32	-0,07	0,58	0,50	1,00	0,47	0,30	da
KNN	0,66	-0,50	0,16	0,46	0,43	0,47	1,00	0,28	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,30	0,13	0,54	0,64	0,53	0,56	0,35	da
MDS	-0,30	1,00	-0,26	-0,29	-0,30	-0,34	-0,49	-0,33	da
MXL	0,13	-0,26	1,00	-0,28	-0,18	-0,10	0,19	-0,08	da
CTE	0,54	-0,29	-0,28	1,00	0,62	0,39	0,28	0,21	da
CTG	0,64	-0,30	-0,18	0,62	1,00	0,50	0,32	0,27	da
CTR	0,53	-0,34	-0,10	0,39	0,50	1,00	0,32	0,22	da
KNN	0,56	-0,49	0,19	0,28	0,32	0,32	1,00	0,20	da
tip 3 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,46	0,70	0,78	0,79	0,74	0,68	0,69	da
MDS	0,46	1,00	0,50	0,37	0,39	0,39	0,34	0,41	da
MXL	0,70	0,50	1,00	0,65	0,63	0,58	0,45	0,59	da
CTE	0,78	0,37	0,65	1,00	0,91	0,89	0,41	0,67	da
CTG	0,79	0,39	0,63	0,91	1,00	0,95	0,39	0,68	da
CTR	0,74	0,39	0,58	0,89	0,95	1,00	0,35	0,65	da
KNN	0,68	0,34	0,45	0,41	0,39	0,35	1,00	0,44	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,51	0,69	0,84	0,87	0,72	0,68	0,72	da
MDS	0,51	1,00	0,54	0,40	0,42	0,38	0,33	0,43	da
MXL	0,69	0,54	1,00	0,55	0,54	0,43	0,47	0,54	da
CTE	0,84	0,40	0,55	1,00	0,82	0,70	0,50	0,64	da
CTG	0,87	0,42	0,54	0,82	1,00	0,76	0,46	0,65	da
CTR	0,72	0,38	0,43	0,70	0,76	1,00	0,40	0,57	da
KNN	0,68	0,33	0,47	0,50	0,46	0,40	1,00	0,47	da
tip 3 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja

									<0,006
S.T.K.	1,00	0,43	0,84	0,66	0,66	0,63	0,79	0,67	da
MDS	0,43	1,00	0,45	0,11	0,15	0,04	0,38	0,26	da
MXL	0,84	0,45	1,00	0,58	0,49	0,58	0,74	0,61	da
CTE	0,66	0,11	0,58	1,00	0,77	0,60	0,53	0,54	da
CTG	0,66	0,15	0,49	0,77	1,00	0,45	0,49	0,50	da
CTR	0,63	0,04	0,58	0,60	0,45	1,00	0,55	0,48	da
KNN	0,79	0,38	0,74	0,53	0,49	0,55	1,00	0,58	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,44	0,81	0,63	0,79	0,62	0,74	0,67	da
MDS	0,44	1,00	0,44	0,21	0,24	0,02	0,39	0,29	da
MXL	0,81	0,44	1,00	0,43	0,54	0,52	0,69	0,57	da
CTE	0,63	0,21	0,43	1,00	0,68	0,36	0,39	0,45	da
CTG	0,79	0,24	0,54	0,68	1,00	0,43	0,55	0,54	da
CTR	0,62	0,02	0,52	0,36	0,43	1,00	0,51	0,41	da
KNN	0,74	0,39	0,69	0,39	0,55	0,51	1,00	0,55	da
tip 4 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,12	0,50	0,73	0,72	0,66	0,71	0,57	da
MDS	0,12	1,00	-0,08	-0,04	-0,03	0,02	0,26	0,04	da
MXL	0,50	-0,08	1,00	0,36	0,24	0,21	0,38	0,27	da
CTE	0,73	-0,04	0,36	1,00	0,63	0,68	0,45	0,47	da
CTG	0,72	-0,03	0,24	0,63	1,00	0,60	0,39	0,42	da
CTR	0,66	0,02	0,21	0,68	0,60	1,00	0,45	0,44	da
KNN	0,71	0,26	0,38	0,45	0,39	0,45	1,00	0,44	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,13	0,49	0,72	0,77	0,65	0,68	0,57	da
MDS	0,13	1,00	-0,08	-0,03	-0,04	-0,01	0,25	0,04	ni
MXL	0,49	-0,08	1,00	0,29	0,19	0,21	0,39	0,25	da
CTE	0,72	-0,03	0,29	1,00	0,62	0,56	0,43	0,43	da
CTG	0,77	-0,04	0,19	0,62	1,00	0,54	0,37	0,41	da
CTR	0,65	-0,01	0,21	0,56	0,54	1,00	0,48	0,41	ni
KNN	0,68	0,25	0,39	0,43	0,37	0,48	1,00	0,43	da
tip 4 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,28	0,82	0,73	0,72	0,77	0,74	0,58	da
MDS	-0,28	1,00	-0,37	-0,23	-0,23	-0,27	-0,32	-0,28	da
MXL	0,82	-0,37	1,00	0,54	0,50	0,60	0,72	0,47	da
CTE	0,73	-0,23	0,54	1,00	0,77	0,93	0,42	0,53	da
CTG	0,72	-0,23	0,50	0,77	1,00	0,72	0,41	0,48	da
CTR	0,77	-0,27	0,60	0,93	0,72	1,00	0,47	0,54	da
KNN	0,74	-0,32	0,72	0,42	0,41	0,47	1,00	0,41	da

Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,24	0,80	0,72	0,75	0,77	0,74	0,59	da
MDS	-0,24	1,00	-0,28	-0,30	-0,24	-0,32	-0,28	-0,28	da
MXL	0,80	-0,28	1,00	0,54	0,52	0,62	0,67	0,48	da
CTE	0,72	-0,30	0,54	1,00	0,72	0,86	0,43	0,49	da
CTG	0,75	-0,24	0,52	0,72	1,00	0,67	0,45	0,48	da
CTR	0,77	-0,32	0,62	0,86	0,67	1,00	0,49	0,51	da
KNN	0,74	-0,28	0,67	0,43	0,45	0,49	1,00	0,42	da

tip 5 (ekspertni vzorec)

Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,07	0,45	0,72	0,74	0,66	0,64	0,52	da
MDS	-0,07	1,00	0,27	0,11	0,15	-0,10	-0,11	0,04	da
MXL	0,45	0,27	1,00	0,35	0,41	0,26	0,23	0,33	da
CTE	0,72	0,11	0,35	1,00	0,91	0,72	0,55	0,56	da
CTG	0,74	0,15	0,41	0,91	1,00	0,69	0,57	0,58	da
CTR	0,66	-0,10	0,26	0,72	0,69	1,00	0,52	0,46	da
KNN	0,64	-0,11	0,23	0,55	0,57	0,52	1,00	0,40	da

Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,04	0,36	0,80	0,86	0,57	0,52	0,51	da
MDS	-0,04	1,00	0,38	-0,16	-0,15	-0,29	-0,25	-0,09	da
MXL	0,36	0,38	1,00	0,19	0,21	0,07	0,13	0,22	da
CTE	0,80	-0,16	0,19	1,00	0,85	0,55	0,48	0,45	da
CTG	0,86	-0,15	0,21	0,85	1,00	0,53	0,50	0,47	da
CTR	0,57	-0,29	0,07	0,55	0,53	1,00	0,49	0,32	da
KNN	0,52	-0,25	0,13	0,48	0,50	0,49	1,00	0,31	da

tip 5 (naključni vzorec)

Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,22	0,65	0,74	0,76	0,77	0,86	0,67	da
MDS	0,22	1,00	0,34	0,16	0,17	0,13	0,11	0,19	da
MXL	0,65	0,34	1,00	0,50	0,59	0,50	0,58	0,53	da
CTE	0,74	0,16	0,50	1,00	0,77	0,56	0,69	0,57	da
CTG	0,76	0,17	0,59	0,77	1,00	0,66	0,70	0,61	da
CTR	0,77	0,13	0,50	0,56	0,66	1,00	0,74	0,56	da
KNN	0,86	0,11	0,58	0,69	0,70	0,74	1,00	0,61	da

Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,08	0,56	0,70	0,79	0,61	0,68	0,57	da
MDS	0,08	1,00	0,27	-0,11	0,00	-0,21	-0,14	-0,02	ni
MXL	0,56	0,27	1,00	0,31	0,35	0,38	0,48	0,39	da
CTE	0,70	-0,11	0,31	1,00	0,71	0,46	0,57	0,44	da
CTG	0,79	0,00	0,35	0,71	1,00	0,54	0,58	0,50	ni
CTR	0,61	-0,21	0,38	0,46	0,54	1,00	0,57	0,39	da
KNN	0,68	-0,14	0,48	0,57	0,58	0,57	1,00	0,46	da

tip 6 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,59	0,59	0,92	0,92	0,85	0,67	0,75	da
MDS	0,59	1,00	0,36	0,54	0,52	0,58	0,41	0,50	da
MXL	0,59	0,36	1,00	0,49	0,47	0,33	0,39	0,44	da
CTE	0,92	0,54	0,49	1,00	0,95	0,87	0,51	0,71	da
CTG	0,92	0,52	0,47	0,95	1,00	0,84	0,51	0,70	da
CTR	0,85	0,58	0,33	0,87	0,84	1,00	0,55	0,67	da
KNN	0,67	0,41	0,39	0,51	0,51	0,55	1,00	0,51	da
tip 6 (ekspertni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,65	0,61	0,88	0,88	0,84	0,70	0,76	da
MDS	0,65	1,00	0,38	0,53	0,53	0,56	0,37	0,50	da
MXL	0,61	0,38	1,00	0,53	0,51	0,33	0,46	0,47	da
CTE	0,88	0,53	0,53	1,00	0,94	0,86	0,55	0,72	da
CTG	0,88	0,53	0,51	0,94	1,00	0,82	0,54	0,70	da
CTR	0,84	0,56	0,33	0,86	0,82	1,00	0,55	0,66	da
KNN	0,70	0,37	0,46	0,55	0,54	0,55	1,00	0,53	da
tip 6 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,38	0,72	0,53	0,80	0,74	0,72	0,65	da
MDS	0,38	1,00	0,28	0,04	0,13	0,16	0,49	0,25	da
MXL	0,72	0,28	1,00	0,20	0,58	0,50	0,52	0,47	da
CTE	0,53	0,04	0,20	1,00	0,28	0,59	0,45	0,35	da
CTG	0,80	0,13	0,58	0,28	1,00	0,61	0,44	0,47	da
CTR	0,74	0,16	0,50	0,59	0,61	1,00	0,58	0,53	da
KNN	0,72	0,49	0,52	0,45	0,44	0,58	1,00	0,53	da
tip 6 (naključni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,41	0,76	0,58	0,75	0,76	0,72	0,66	da
MDS	0,41	1,00	0,28	0,02	0,15	0,15	0,47	0,25	da
MXL	0,76	0,28	1,00	0,30	0,57	0,51	0,52	0,49	da
CTE	0,58	0,02	0,30	1,00	0,33	0,66	0,50	0,40	da
CTG	0,75	0,15	0,57	0,33	1,00	0,61	0,42	0,47	da
CTR	0,76	0,15	0,51	0,66	0,61	1,00	0,59	0,55	da
KNN	0,72	0,47	0,52	0,50	0,42	0,59	1,00	0,54	da
tip 7 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,33	0,74	0,65	0,60	0,71	0,74	0,63	da
MDS	0,33	1,00	0,50	0,27	0,33	0,25	0,25	0,32	da
MXL	0,74	0,50	1,00	0,55	0,64	0,44	0,63	0,58	da
CTE	0,65	0,27	0,55	1,00	0,82	0,68	0,55	0,59	da
CTG	0,60	0,33	0,64	0,82	1,00	0,45	0,51	0,56	da
CTR	0,71	0,25	0,44	0,68	0,45	1,00	0,36	0,48	da
KNN	0,74	0,25	0,63	0,55	0,51	0,36	1,00	0,50	da

Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,51	0,77	0,87	0,81	0,74	0,74	0,74	da
MDS	0,51	1,00	0,64	0,28	0,32	0,19	0,41	0,39	da
MXL	0,77	0,64	1,00	0,59	0,67	0,47	0,63	0,63	da
CTE	0,87	0,28	0,59	1,00	0,78	0,74	0,67	0,66	da
CTG	0,81	0,32	0,67	0,78	1,00	0,51	0,60	0,62	da
CTR	0,74	0,19	0,47	0,74	0,51	1,00	0,40	0,51	da
KNN	0,74	0,41	0,63	0,67	0,60	0,40	1,00	0,58	da
tip 7 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,38	0,73	0,82	0,91	0,77	0,88	0,75	da
MDS	0,38	1,00	0,60	0,20	0,25	0,26	0,21	0,31	da
MXL	0,73	0,60	1,00	0,58	0,61	0,57	0,64	0,62	da
CTE	0,82	0,20	0,58	1,00	0,89	0,89	0,79	0,69	da
CTG	0,91	0,25	0,61	0,89	1,00	0,79	0,80	0,71	da
CTR	0,77	0,26	0,57	0,89	0,79	1,00	0,72	0,67	da
KNN	0,88	0,21	0,64	0,79	0,80	0,72	1,00	0,67	da
tip 8 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,43	0,82	0,89	0,91	0,90	0,85	0,80	da
MDS	0,43	1,00	0,50	0,25	0,31	0,29	0,26	0,34	da
MXL	0,82	0,50	1,00	0,76	0,71	0,77	0,76	0,72	da
CTE	0,89	0,25	0,76	1,00	0,95	0,94	0,82	0,77	da
CTG	0,91	0,31	0,71	0,95	1,00	0,89	0,80	0,76	da
CTR	0,90	0,29	0,77	0,94	0,89	1,00	0,82	0,77	da
KNN	0,85	0,26	0,76	0,82	0,80	0,82	1,00	0,72	da
tip 8 (ekspertni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,28	0,48	0,67	0,77	0,64	0,52	0,56	da
MDS	0,28	1,00	0,27	0,12	0,26	0,23	0,32	0,25	da
MXL	0,48	0,27	1,00	0,20	0,30	0,32	0,44	0,34	da
CTE	0,67	0,12	0,20	1,00	0,41	0,32	0,37	0,35	da
CTG	0,77	0,26	0,30	0,41	1,00	0,48	0,25	0,41	da
CTR	0,64	0,23	0,32	0,32	0,48	1,00	0,26	0,38	da
KNN	0,52	0,32	0,44	0,37	0,25	0,26	1,00	0,36	da

tip 8 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,31	0,63	0,50	0,70	0,29	0,73	0,53	da
MDS	0,31	1,00	0,55	-0,01	0,16	0,09	0,41	0,25	da
MXL	0,63	0,55	1,00	0,24	0,35	0,18	0,64	0,43	da
CTE	0,50	-0,01	0,24	1,00	0,66	0,26	0,30	0,32	da
CTG	0,70	0,16	0,35	0,66	1,00	0,35	0,45	0,45	da
CTR	0,29	0,09	0,18	0,26	0,35	1,00	0,17	0,22	da
KNN	0,73	0,41	0,64	0,30	0,45	0,17	1,00	0,45	da
tip 8 (naključni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,32	0,55	0,62	0,77	0,26	0,59	0,52	da
MDS	0,32	1,00	0,63	-0,06	0,12	0,10	0,51	0,27	da
MXL	0,55	0,63	1,00	0,13	0,30	0,16	0,65	0,40	da
CTE	0,62	-0,06	0,13	1,00	0,68	0,12	0,23	0,29	da
CTG	0,77	0,12	0,30	0,68	1,00	0,25	0,37	0,41	da
CTR	0,26	0,10	0,16	0,12	0,25	1,00	0,17	0,18	da
KNN	0,59	0,51	0,65	0,23	0,37	0,17	1,00	0,42	da
tip 9 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,29	0,51	0,58	0,77	0,65	0,59	0,57	da
MDS	0,29	1,00	0,63	0,18	0,25	0,19	0,29	0,31	da
MXL	0,51	0,63	1,00	0,09	0,39	0,24	0,36	0,37	da
CTE	0,58	0,18	0,09	1,00	0,63	0,42	0,42	0,39	da
CTG	0,77	0,25	0,39	0,63	1,00	0,47	0,42	0,49	da
CTR	0,65	0,19	0,24	0,42	0,47	1,00	0,34	0,38	da
KNN	0,59	0,29	0,36	0,42	0,42	0,34	1,00	0,40	da
tip 9 (ekspertni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,31	0,51	0,64	0,77	0,64	0,57	0,57	da
MDS	0,31	1,00	0,69	0,05	0,15	0,08	0,25	0,26	da
MXL	0,51	0,69	1,00	0,11	0,31	0,16	0,38	0,36	da
CTE	0,64	0,05	0,11	1,00	0,61	0,45	0,41	0,38	da
CTG	0,77	0,15	0,31	0,61	1,00	0,43	0,43	0,45	da
CTR	0,64	0,08	0,16	0,45	0,43	1,00	0,29	0,34	da
KNN	0,57	0,25	0,38	0,41	0,43	0,29	1,00	0,39	da
tip 9 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,34	0,36	0,68	0,67	0,71	0,66	0,57	da
MDS	0,34	1,00	0,60	0,23	0,23	0,39	0,45	0,37	da
MXL	0,36	0,60	1,00	0,20	0,16	0,27	0,43	0,34	da
CTE	0,68	0,23	0,20	1,00	0,81	0,68	0,47	0,51	da
CTG	0,67	0,23	0,16	0,81	1,00	0,61	0,50	0,50	da
CTR	0,71	0,39	0,27	0,68	0,61	1,00	0,44	0,52	da

KNN	0,66	0,45	0,43	0,47	0,50	0,44	1,00	0,49	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,35	0,33	0,67	0,62	0,66	0,57	0,53	da
MDS	0,35	1,00	0,65	0,12	0,04	0,35	0,45	0,33	da
MXL	0,33	0,65	1,00	0,00	-0,04	0,20	0,45	0,27	ni
CTE	0,67	0,12	0,00	1,00	0,55	0,49	0,23	0,34	ni
CTG	0,62	0,04	-0,04	0,55	1,00	0,34	0,32	0,30	da
CTR	0,66	0,35	0,20	0,49	0,34	1,00	0,33	0,40	da
KNN	0,57	0,45	0,45	0,23	0,32	0,33	1,00	0,39	da
tip 10 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,24	0,65	0,85	0,87	0,83	0,73	0,70	da
MDS	0,24	1,00	-0,04	0,17	0,12	0,17	0,20	0,14	da
MXL	0,65	-0,04	1,00	0,56	0,60	0,57	0,55	0,48	da
CTE	0,85	0,17	0,56	1,00	0,87	0,92	0,50	0,65	da
CTG	0,87	0,12	0,60	0,87	1,00	0,82	0,55	0,64	da
CTR	0,83	0,17	0,57	0,92	0,82	1,00	0,49	0,64	da
KNN	0,73	0,20	0,55	0,50	0,55	0,49	1,00	0,51	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,42	0,57	0,75	0,85	0,76	0,66	0,67	da
MDS	0,42	1,00	0,25	0,33	0,26	0,31	0,34	0,32	da
MXL	0,57	0,25	1,00	0,36	0,55	0,39	0,60	0,45	da
CTE	0,75	0,33	0,36	1,00	0,71	0,79	0,39	0,56	da
CTG	0,85	0,26	0,55	0,71	1,00	0,68	0,55	0,60	da
CTR	0,76	0,31	0,39	0,79	0,68	1,00	0,38	0,55	da
KNN	0,66	0,34	0,60	0,39	0,55	0,38	1,00	0,49	da
tip 10 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,19	0,72	0,78	0,78	0,73	0,77	0,66	da
MDS	0,19	1,00	-0,04	0,11	0,09	0,04	0,17	0,09	da
MXL	0,72	-0,04	1,00	0,64	0,64	0,65	0,67	0,55	da
CTE	0,78	0,11	0,64	1,00	0,92	0,82	0,75	0,67	da
CTG	0,78	0,09	0,64	0,92	1,00	0,85	0,74	0,67	da
CTR	0,73	0,04	0,65	0,82	0,85	1,00	0,73	0,64	da
KNN	0,77	0,17	0,67	0,75	0,74	0,73	1,00	0,64	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,27	0,70	0,84	0,90	0,80	0,71	0,70	da
MDS	0,27	1,00	0,07	0,15	0,14	0,10	0,19	0,15	da
MXL	0,70	0,07	1,00	0,58	0,60	0,60	0,65	0,53	da
CTE	0,84	0,15	0,58	1,00	0,89	0,73	0,66	0,64	da
CTG	0,90	0,14	0,60	0,89	1,00	0,80	0,66	0,66	da
CTR	0,80	0,10	0,60	0,73	0,80	1,00	0,59	0,60	da

KNN	0,71	0,19	0,65	0,66	0,66	0,59	1,00	0,58	da
tip 11 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,39	0,81	0,73	0,79	0,66	0,87	0,71	da
MDS	0,39	1,00	0,55	0,38	0,41	0,27	0,42	0,41	da
MXL	0,81	0,55	1,00	0,70	0,74	0,60	0,74	0,69	da
CTE	0,73	0,38	0,70	1,00	0,89	0,65	0,66	0,67	da
CTG	0,79	0,41	0,74	0,89	1,00	0,72	0,71	0,71	da
CTR	0,66	0,27	0,60	0,65	0,72	1,00	0,59	0,58	da
KNN	0,87	0,42	0,74	0,66	0,71	0,59	1,00	0,66	da
tip 11 (naključni vzorec)									
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,40	0,65	0,73	0,79	0,75	0,80	0,69	da
MDS	0,40	1,00	0,73	0,36	0,29	0,29	0,43	0,42	da
MXL	0,65	0,73	1,00	0,47	0,55	0,44	0,67	0,58	da
CTE	0,73	0,36	0,47	1,00	0,66	0,57	0,60	0,57	da
CTG	0,79	0,29	0,55	0,66	1,00	0,49	0,70	0,58	da
CTR	0,75	0,29	0,44	0,57	0,49	1,00	0,57	0,52	da
KNN	0,80	0,43	0,67	0,60	0,70	0,57	1,00	0,63	da
tip 12 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,45	0,90	0,79	0,80	0,82	0,86	0,77	da
MDS	0,45	1,00	0,58	0,34	0,37	0,40	0,51	0,44	da
MXL	0,90	0,58	1,00	0,70	0,71	0,74	0,83	0,75	da
CTE	0,79	0,34	0,70	1,00	0,90	0,88	0,64	0,71	da
CTG	0,80	0,37	0,71	0,90	1,00	0,91	0,65	0,72	da

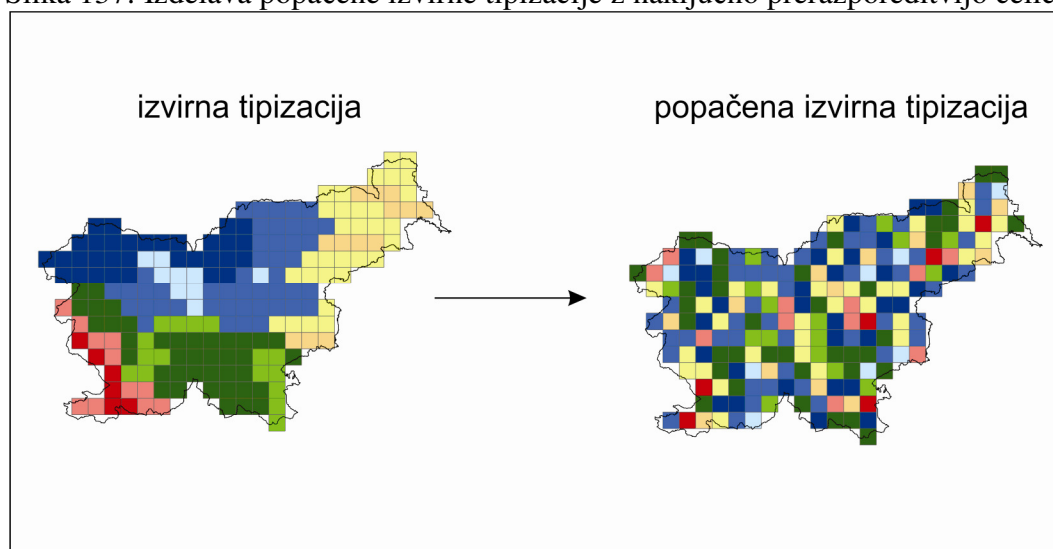
CTR	0,82	0,40	0,74	0,88	0,91	1,00	0,67	0,74	da
KNN	0,86	0,51	0,83	0,64	0,65	0,67	1,00	0,69	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,48	0,82	0,86	0,82	0,78	0,81	0,76	da
MDS	0,48	1,00	0,69	0,30	0,28	0,46	0,60	0,47	da
MXL	0,82	0,69	1,00	0,67	0,63	0,66	0,81	0,71	da
CTE	0,86	0,30	0,67	1,00	0,87	0,80	0,65	0,69	da
CTG	0,82	0,28	0,63	0,87	1,00	0,75	0,61	0,66	da
CTR	0,78	0,46	0,66	0,80	0,75	1,00	0,66	0,68	da
KNN	0,81	0,60	0,81	0,65	0,61	0,66	1,00	0,69	da
tip 12 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,56	0,87	0,82	0,76	0,85	0,87	0,79	da
MDS	0,56	1,00	0,61	0,41	0,36	0,47	0,54	0,49	da
MXL	0,87	0,61	1,00	0,72	0,64	0,72	0,79	0,72	da
CTE	0,82	0,41	0,72	1,00	0,68	0,84	0,69	0,69	da
CTG	0,76	0,36	0,64	0,68	1,00	0,66	0,70	0,64	da
CTR	0,85	0,47	0,72	0,84	0,66	1,00	0,69	0,70	da
KNN	0,87	0,54	0,79	0,69	0,70	0,69	1,00	0,71	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,63	0,84	0,84	0,87	0,86	0,85	0,81	da
MDS	0,63	1,00	0,69	0,49	0,48	0,54	0,63	0,58	da
MXL	0,84	0,69	1,00	0,69	0,75	0,71	0,79	0,74	da
CTE	0,84	0,49	0,69	1,00	0,81	0,82	0,74	0,73	da
CTG	0,87	0,48	0,75	0,81	1,00	0,82	0,76	0,75	da
CTR	0,86	0,54	0,71	0,82	0,82	1,00	0,77	0,75	da
KNN	0,85	0,63	0,79	0,74	0,76	0,77	1,00	0,76	da
tip 13 (ekspertni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,22	0,74	0,63	0,74	0,79	0,84	0,66	da
MDS	0,22	1,00	0,39	0,37	0,35	0,27	0,17	0,30	da
MXL	0,74	0,39	1,00	0,54	0,65	0,60	0,67	0,60	da
CTE	0,63	0,37	0,54	1,00	0,74	0,62	0,61	0,59	da
CTG	0,74	0,35	0,65	0,74	1,00	0,69	0,69	0,64	da
CTR	0,79	0,27	0,60	0,62	0,69	1,00	0,68	0,61	da
KNN	0,84	0,17	0,67	0,61	0,69	0,68	1,00	0,61	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,23	0,77	0,77	0,89	0,81	0,84	0,72	da
MDS	0,23	1,00	0,44	0,31	0,28	0,17	0,15	0,26	da
MXL	0,77	0,44	1,00	0,60	0,71	0,55	0,72	0,63	da
CTE	0,77	0,31	0,60	1,00	0,75	0,64	0,71	0,63	da
CTG	0,89	0,28	0,71	0,75	1,00	0,71	0,77	0,69	da

CTR	0,81	0,17	0,55	0,64	0,71	1,00	0,67	0,59	da
KNN	0,84	0,15	0,72	0,71	0,77	0,67	1,00	0,64	da
tip 13 (naključni vzorec)									
Pearsonov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	-0,05	0,68	0,69	0,62	0,61	0,84	0,57	da
MDS	-0,05	1,00	0,23	0,01	0,01	-0,01	-0,12	0,01	ni
MXL	0,68	0,23	1,00	0,62	0,59	0,55	0,64	0,55	da
CTE	0,69	0,01	0,62	1,00	0,84	0,81	0,67	0,61	ni
CTG	0,62	0,01	0,59	0,84	1,00	0,90	0,61	0,60	ni
CTR	0,61	-0,01	0,55	0,81	0,90	1,00	0,61	0,58	ni
KNN	0,84	-0,12	0,64	0,67	0,61	0,61	1,00	0,54	da
Spearmanov koeficient	S.T.K.	MDS	MXL	CTE	CTG	CTR	KNN	povprečje	stat. znač. povprečja <0,006
S.T.K.	1,00	0,06	0,70	0,83	0,81	0,71	0,83	0,66	da
MDS	0,06	1,00	0,33	0,03	-0,02	-0,14	-0,04	0,04	ni
MXL	0,70	0,33	1,00	0,61	0,59	0,44	0,65	0,56	da
CTE	0,83	0,03	0,61	1,00	0,81	0,57	0,72	0,60	da
CTG	0,81	-0,02	0,59	0,81	1,00	0,58	0,69	0,58	ni
CTR	0,71	-0,14	0,44	0,57	0,58	1,00	0,66	0,47	da
KNN	0,83	-0,04	0,65	0,72	0,69	0,66	1,00	0,59	da

1. Analiza objektivnosti izvirnih naravnopokrajinskih tipizacij TIPI9 in TIPI13

Da bi dokazali, da so pokrajinskoekološki tipi (Špes s sod., 2002) in pokrajinski tipi (Perko, 1998a; Perko, 1998b; Perko, 2007b) oziroma izvirni naravnopokrajinski tipizaciji TIPI9 in TIPI 13 objektivni, kakovostni in primerni za modeliranje, smo preverili, kako bi se obnesli različni modeli oziroma metode nadzorovane klasifikacije, če bi za izhodišče imeli tipizacijo, ki bi bila narejena zelo slabo oziroma povsem naključno. Za ta preizkus smo popačili izvirni naravnopokrajinski tipizaciji TIPI9 in TIPI13. Pri obeh smo ohranili vse tipe v enakem razmerju in z enakim številom celic, celice smo le naključno prerazporedili (slika 137). Na ta način smo dobili popačeno (naključno, neekspertno ali nesmiselno) izvirno tipizacijo, ki naj bi bila težja za določanje pravil in modeliranja.

Slika 137: Izdelava popačene izvirne tipizacije z naključno prerazporeditvijo celic.




1.1 Priprava popačenih izvirnih naravnopokrajinskih tipizacij TIPI9 in TIPI13

Najprej smo izvorno tipizacijo in s tem tudi nabor naključnih učnih celic naključno prerazporedili po prostoru⁷³ (sliki 138 in 139). Izdelali smo torej nenavadno tipizacijo, za katero lahko rečemo, da je narejena naključno, in za katero lahko pričakujemo, da ne bo dosegala takšnih ocen in uspešnosti modeliranja kot pa izvirni tipizaciji TIPI9 in TIPI13. Izvirna tipizacija TIPI9 se s popačeno izvorno tipizacijo TIP9 ujema v 15,1 %, kar je enako izračunu teoretične verjetnosti ujemanja (izračunano po formuli, ki je objavljena v: Discriminant function analysis, ... 2012). Izvirna tipizacija TIPI13 se s popačeno izvorno tipizacijo TIPI13 ujema v 13,1 %, kar je zelo blizu teoretičnemu izračunu verjetnosti ujemanja (ta je 13,4 %). Naključno ujemanje med izvorno in popačeno tipizacijo je dokaz, da smo tipizaciji ustrezno popačili.


⁷³ Primer za tipizacijo TIPI9:

prerazporeditev smo naredili tako, da smo najprej v programu SPSS obstoječima kolonama (GIAM9 – tipi in G9_NVZ – naključne učne celice) dodali kolono naključnih števil. Te smo določili z ukazom COMPUTE VARIABLE: RV.UNIFORM(1,506450). S tem smo določili naključne številke med 1 in 506.450 (slednje ustreza številu celic). Kolono s temi številkami smo poimenovali RV_G9. V naslednjem koraku smo podatke razvrstili po koloni RV_G9 (naraščajoče). Koloni GIAM9 in G9_NVZ smo nato s programom Statistica prenesli v Idrisi Taiga. Ker smo prvotno razporeditev celic (in s tem tudi lokacijo v prostoru) spremenili, obstoječi tipi (in z njimi tudi naključni vzorec učnih celic) niso več na enaki lokaciji kot v izvorni tipizaciji, pri tem pa je število celic v posameznem tipu ostalo enako.

Slika 138: Popačena tipizacija TIPI9.



Slika 139: Popačena tipizacija TIPI13.

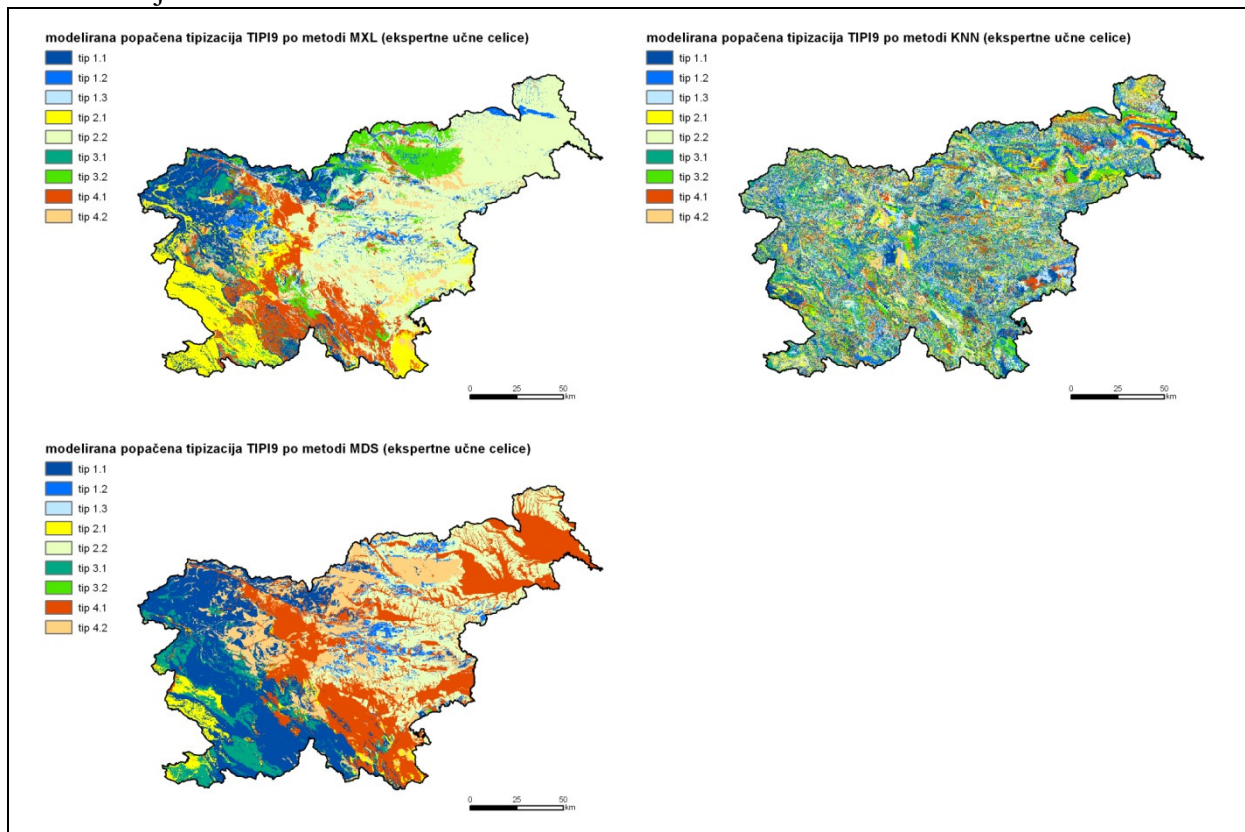


1.2 Priprava modeliranih popačenih naravnopokrajinskih tipizacij TIPI9 in TIPI13

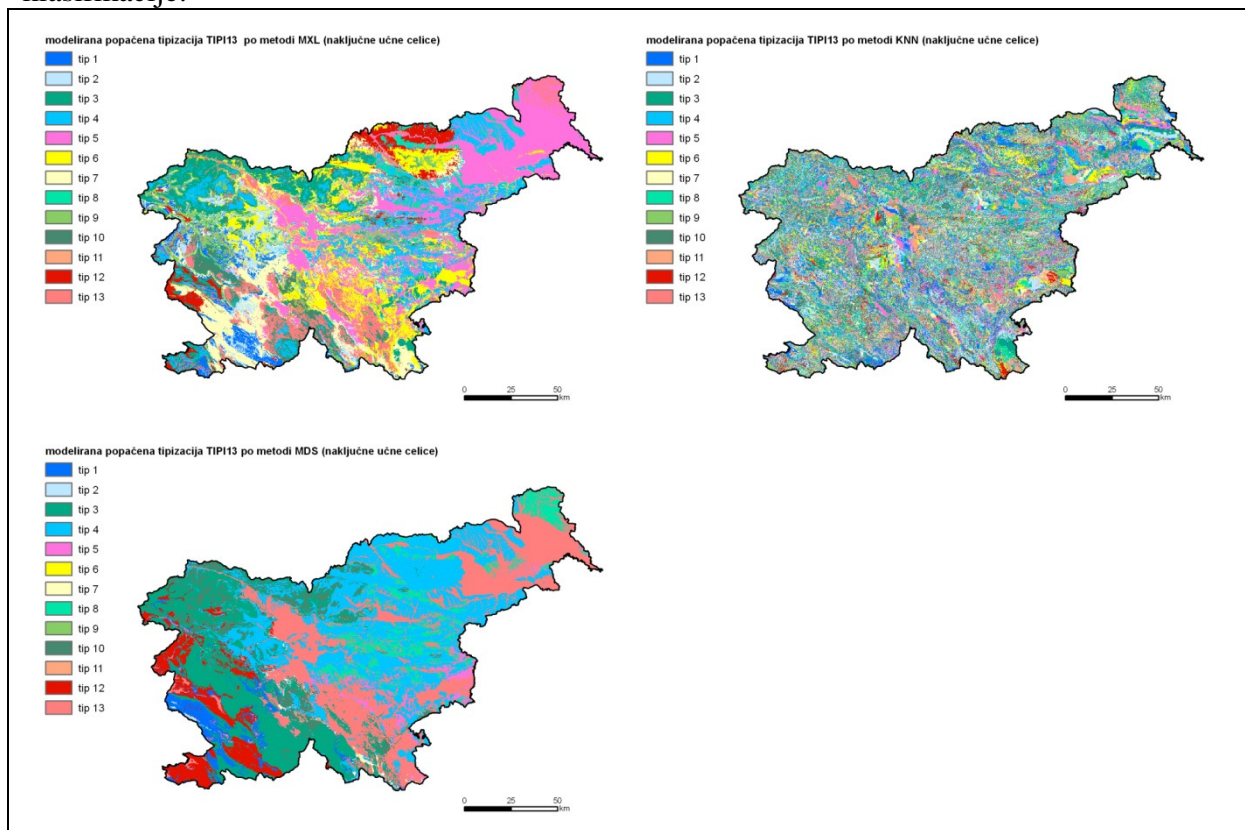
Ko smo imeli popačeno izvirno tipizacijo in določene učne celice (2000 celic za posamezen tip), smo izdelali posamezne modelirane tipizacije po izbranih metodah v programu Idrisi Taiga ter programu SPSS. To so metode z oznako CT, MDS, MXL, KNN, CTR, CTG, CTE (preglednica 43 vsebuje podroben opis in nastavitve metod). Modelirane tipizacije smo izdelali le z naključnim vzorcem učnih celic, saj ekspertnega vzorčenja pri popačeni tipizaciji ne more biti.

Zaradi nesmiselnosti popačene izvirne tipizacije smo opazili, da metode CTR, CTG, CTE ter CT niso bile sposobne izdelati smiselnih pravil. Z metodami KNN, MXL in MDS pa smo uspeli izdelati modelirane tipizacije tudi na podlagi popačenih tipizacij TIPI9 (slika 140, preglednica 167) in TIPI13 (slika 141, preglednica 168).

Slika 140: Modelirane popačene tipizacije TIPI9 po uspehlih metodah nadzorovane klasifikacije.



Slika 141: Modelirane popačene tipizacije TIPI13 po uspehlih metodah nadzorovane klasifikacije.



Preglednica 167: Delež tipov po posameznih modeliranih popačenih tipizacijah TIPI9 in po popačeni izvorni tipizaciji TIPI9.

oznaka tipa	delež tipov (%)			
	popačena izvorna tipizacija	modelirane popačene tipizacije		
		KNN	MAX	MDS
1.1	15,1	14,9	12,6	24,5
1.2	23,0	14,3	4,1	3,4
1.3	4,0	12,0	3,2	0,6
2.1	14,8	11,1	12,5	3,6
2.2	6,4	10,4	38,1	20,3
3.1	18,8	9,9	3,5	6,3
3.2	9,4	9,2	6,4	<0,1
4.1	5,2	9,4	13,6	27,9
4.2	3,3	8,8	6,0	13,4
skupaj	100,0	100,0	100,0	100,0

Preglednica 168: Delež tipov po posameznih modeliranih popačenih tipizacijah in po popačeni izvorni tipizaciji TIPI13.

oznaka tipa	delež tipov (%)			
	popačena izvorna tipizacija	modelirane popačene tipizacije		
		KNN	MAX	MDS
1	8,3	12,1	3,7	3,6
2	3,6	11,8	4,6	0,3
3	17,7	9,8	9,0	19,5
4	22,4	8,8	13,5	28,5
5	6,2	8,5	22,2	2,0
6	16,2	7,6	12,4	/
7	8,8	7,4	9,7	0,4
8	4,4	6,2	2,3	6,7
9	5,4	5,7	5,7	<0,1
10	1,6	6,2	3,4	5,8
11	2,5	6,1	0,1	<0,1
12	1,7	4,6	4,4	6,6
13	1,2	5,1	9,0	26,6
skupaj	100,0	100,0	100,0	100,0

1.3 Vrednotenje modeliranih popačenih naravnopokrajinskih tipizacij

1.3.1 Vrednotenje modeliranih popačenih naravnopokrajinskih tipizacij TIPI9

Modelirani popačeni tipizaciji po metodah najmanjše razdalje (MDS) in največje verjetnosti (MXL) sta precej bolj ovrednoteni po več načinih vrednotenja kot pa izvorna popačena tipizacija in modelirana popačena tipizacija po metodi najbližjih sosedov (KNN) (preglednice 169–173). Modelirani popačeni tipizaciji po metodah najmanjše razdalje in največje verjetnosti imata zelo dobro oceno celo v primerjavi z modeliranimi tipizacijami na podlagi izvorne nepopačene(!) tipizacije (glej preglednice v poglavju 8.3.1.1) glede na vrednotenje z deležem enako klasificiranih z odločitvenim drevesom (ODL) in glede na delež enako klasificiranih po modelu z diskriminančno analizo (DA). Zelo dobro oceno ima modelirana tipizacija po metodi najmanjše razdalje tudi pri povprečni oddaljenosti od centroida (ODDP). Pri vrednotenju z informacijskim prispevkom, razmerjem informacijskega prispevka, koeficientom F in povprečnim umerjenim koeficientom variacije so modelirane tipizacije, ki so izdelane na podlagi popačene tipizacije, slabše kot tiste modelirane tipizacije, ki so izdelane na podlagi izvorne nepopačene tipizacije (glej preglednice v poglavju 8.3.1.1); le modelirana popačena tipizacija po metodi najmanjše razdalje ima visoke vrednosti pri ocenah na podlagi podatkovnega sloja prepustnost. Razlog za to je, da ima prepustnost s širokim

razponom vrednosti (dobro frekvenčno distribucijo) velik vpliv na rezultat pri metodah najmanjše razdalje. Nekoliko boljše ocenjeni so pri nekaterih načinih vrednotenja tudi rezultati metode največje verjetnosti.

Preglednica 169: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi vseh podatkovnih slojev hkrati.

tipizacija	neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenje s posameznimi podatkovnimi sloji					
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminacijske analize (%)	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	34,2	7,5	23,0	23,0	0,00	0,00	0,00	0,8	52,7
KNN	34,1	14,2	19,4	17,0	0,06	0,01	0,01	387,6	52,5
MXL	25,1	67,1	76,5	49,5	0,63	0,12	0,47	57204,9	36,3
MDS	20,6	72,5	86,3	51,7	0,79	0,17	0,56	95484,6	34,3

Preglednica 170: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja naklon.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija TIPI9	23,0	0,00	0,00	0,00	0,9	73,2
KNN	16,2	0,04	0,01	0,00	253,5	72,9
MXL	46,0	0,55	0,10	0,50	64440,3	50,9
MDS	44,9	0,55	0,11	0,43	47824,9	52,6

Preglednica 171: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja padavinski režim.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija TIPI9	23,0	0,00	0,00	0,00	0,5	40,4
KNN	17,7	0,09	0,01	0,01	730,5	40,2
MXL	52,2	0,71	0,09	0,54	73467,7	26,9
MDS	50,8	0,87	0,11	0,65	119570,0	23,3

Preglednica 172: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja prepustnost.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija TIPI9	23,0	0,00	0,00	0,00	0,4	33,0
KNN	17,3	0,05	0,01	0,00	245,0	32,9
MXL	51,3	0,65	0,20	0,35	33903,3	25,7
MDS	63,2	1,17	0,35	0,73	170910,1	15,8

Preglednica 173: Vrednotenje modeliranih tipizacij, ki so izdelane na podlagi popačene tipizacije TIPI9, na podlagi podatkovnega sloja nadmorska višina.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija TIPI9	23,0	0,00	0,00	0,00	1,3	64,3
KNN	16,7	0,06	0,01	0,01	321,4	63,8
MXL	48,5	0,61	0,11	0,47	57008,1	41,7
MDS	47,9	0,56	0,10	0,41	43633,2	45,7

Pri vrednotenju modeliranih popačenih tipizacij se moramo tudi vprašati, kako dobro smo se približali izhodiščni, torej popačeni izvorni tipizaciji (tisti, ki smo jo modelirali). Zato smo primerjali modelirane popačene tipizacije in izvorno popačeno tipizacijo ter izračunali koeficient kappa in Cramerjev koeficient (preglednica 174), nato pa smo primerjali tudi, koliko celic je enako klasificiranih kot v izhodiščni popačeni izvorni tipizaciji (preglednica 175).

Ugotovili smo, da je ujemanje s popačeno izvorno tipizacijo izredno majhno, kar pomeni, da se modelirane popačene tipizacije precej razlikujejo od tistega, čemur bi ob ustreznih modelih morale biti podobne, če naj bi bila tipizacija smiselna. Cramerjev koeficient, koeficient kappa in delež enako klasificiranih celic so povsod zelo nizki, najnižji pri modeliranih tipizacijah po metodah največje verjetnosti in najmanjše razdalje. To pomeni, da metode »vsilijo« svojo strukturo; manjše kot je ujemanje, bolj vsiljena je določena struktura metode.

Nekatere dobre ocene na podlagi vrednotenja modeliranih tipizacij na podlagi podatkovnih slojev so dejansko posledica tega, da metode klasificirajo celice po določenih pravilih kar dobro, a dejansko vsilijo svojo strukturo in ne upoštevajo izhodiščne tipizacije.

Zaradi tega je tudi medsebojno ujemanje (preglednici 176 in 177) med uspešnimi modeliranimi tipizacijami po metodah najbližjih sosedov, največje verjetnosti in najkrajše razdalje precej manjše kot pa v primeru modeliranja nepopačene izvorne tipizacije TIPI9 (preglednici 88 in 89). Manjše upoštevanje izhodiščne popačene izvorne tipizacije in vsiljevanje lastne strukture posamezne metode sta posledici tega, da je popačena tipizacija TIPI9 slaba oziroma neobjektivna in ne omogoča ustreznega modeliranja.

Preglednica 174: Koeficient kappa in Cramerjev koeficient za primerjavo posameznih modeliranih popačenih tipizacij s popačeno izvorno tipizacijo TIPI9.

modelirana popačena tipizacija	Cramerjev koeficient	koeficient kappa
KNN	0,006 (stat. značilen $p=0,001$)	0,04 % (stat. značilen $p=0,001$)
MXL	0,004 (ni stat. značilno)	0,0 % (ni stat. značilno)
MDS	0,004 (ni stat. značilno)	0,0 % (ni stat. značilno)

Preglednica 175: Ujemanje modeliranih popačenih tipizacij z popačeno izvorno tipizacijo TIPI9.

modelirana popačena tipizacija	delež enako klasificiranih celic od vseh celic (%)	delež enako klasificiranih učnih celic od vseh učnih celic (%)
KNN	12,2	21,1
MXL	9,4	11,8
MDS	9,4	11,7

Preglednica 176: Cramerjev koeficient povezanosti med modeliranimi popačenimi tipizacijami TIPI9 ($p=0,001$).

	MXL	MDS
KNN	0,079	0,076
MXL		0,385

Preglednica 177: Koeficient kappa (%) povezanosti med modeliranimi popačenimi tipizacijami TIPI9 ($p=0,001$).

	MXL	MDS
KNN	2,7	2,3
MXL		2,7

1.3.2 Vrednotenje modeliranih popačenih naravnopokrajinski tipizacij TIPI13

Že na začetku je treba opozoriti, da je bilo po metodi najmanjše razdalje prepoznanih samo 12 od 13 tipov, kar pomeni, da so rezultati vrednotenja modelirane tipizacije po tej metodi nekoliko manj zanesljivi. Pri vrednotenju (preglednice 178–182) je (tako kot pri popačeni tipizaciji TIPI9) model po metodi najmanjše razdalje zelo dobro ocenjen (tudi če primerjamo z rezultati nepopačenih modelov v preglednicah 73–76) pri vrednotenju glede na povprečno razdaljo od centroida, delež enako klasificiranih celic po odločitvenem drevesu (z vsemi sloji in s posameznimi sloji) in diskriminanci analizi. Z informacijskim prispevkom, razmerjem informacijskega prispevka, koeficientom η^2 , koeficientom F in povprečnim umerjenim koeficientom variacije so izračunane ocene povsod nizke, le tipizacija po metodi najmanjše razdalje je pri vrednotenju glede na prepustnost zelo dobro ocenjena (večinoma tudi v primerjavi z vrednotenji v preglednicah 77–81 v poglavju 8). Razlog za to je (tako kot pri TIPI9) večmodalna frekvenčna distribucija prepustnosti brez večjih odstopanj skrajnih vrednosti, ki sta pomembni pri uporabi metode najmanjše razdalje; zaradi velikih razdalj med celicami (v primerjavi z ostalimi podatkovnimi sloji) se tipi oblikujejo v veliki meri ravno po podatkovnem sloju prepustnost. Ker metoda najmanjše razdalje tudi »vsili« svojo strukturo, so ocene relativno dobre, a (kot bomo videli v nadaljevanju) se model zato ne ujema z izhodiščno popačeno izvorno tipizacijo TIPI13. V povprečju je modelirana popačena tipizacija po metodi najmanjše razdalje dobro ocenjena tudi pri koeficientih η^2 in F, obkrajat predvsem zaradi visoke ocene glede na prepustnost.

Preglednica 178: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi vseh podatkovnih slojev hkrati.

tipizacija	neposredno vrednotenje z vsemi podatkovnimi sloji			povprečje vrednotenje s posameznimi podatkovnimi sloji					
	povprečna oddaljenost celic od najbližjega centroida	delež enako klasificiranih celic po modelu diskriminanci analize (%)	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	34,2	3,7	22,4	22,4	0,00	0,00	0,00	ni stat. znač.	52,7
KNN	34,1	7,4	15,0	13,5	0,06	0,01	0,13	216,5	52,5
MXL	25,6	50,2	59,9	34,8	0,70	0,14	0,36	24678,1	38,6
MDS (12 skupin!)	19,6	76,4	88,8	52,0	0,83	0,18	0,58	91247,4	33,4

Preglednica 179: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja naklon.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koef. η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	22,4	0,00	0,00	0,00	ni stat. znač.	73,2

KNN	13,3	0,05	0,01	0,00	200,4	72,8
MXL	33,3	0,62	0,12	0,42	30709,7	53,0
MDS (12 skupin!)	48,1	0,55	0,11	0,43	35414,0	52,3

Preglednica 180: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja padavinski režim.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	22,4	0,00	0,00	0,00	ni stat. znač.	40,4
KNN	13,9	0,09	0,01	0,00	166,4	40,3
MXL	32	0,69	0,09	0,41	29211,5	29,9
MDS (12 skupin!)	47	0,80	0,10	0,59	65425,0	25,0

Preglednica 181: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja prepustnost.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	22,4	0,00	0,00	0,00	ni stat. znač.	33,0
KNN	13,5	0,05	0,02	0,01	292,0	32,8
MXL	38,9	0,77	0,23	0,30	17956,8	26,0
MDS (12 skupin!)	67,8	1,40	0,43	0,83	223591,3	12,5

Preglednica 182: Vrednotenje modeliranih popačenih tipizacij, ki so izdelane na podlagi popačene izvorne tipizacije TIPI13, na podlagi podatkovnega sloja nadmorska višina.

tipizacija	delež enako klasificiranih celic z odločitvenim drevesom CT (%)	informacijski prispevek (bit)	razmerje informacijskega prispevka	koeficient η^2	koeficient F	PUKV (%)
popačena izvorna tipizacija	22,4	0,00	0,00	0,00	ni stat. znač.	64,3
KNN	13,4	0,07	0,01	0,49	207,2	63,9
MXL	34,8	0,71	0,12	0,33	20834,5	45,6
MDS (12 skupin!)	45,2	0,56	0,10	0,47	40559,2	43,9

Tudi pri modeliranju popačene izvorne tipizacije TIPI13 smo za modelirane tipizacije po nekaterih metodah (predvsem po metodi najmanjše razdalje) dobili dobre ocene. Ker sklepamo, da gre za podoben pojav kot pri TIPI19, smo tudi tukaj nadaljevali analizo in izračunali, kako dobro se modelirane popačene tipizacije povezujejo z izhodiščno popačeno tipizacijo TIPI13. Izračunali smo koeficient kappa in Cramerjev koeficient (preglednica 183), nato pa smo primerjali tudi, koliko celic je klasificiranih enako kot v izhodiščni popačeni tipizaciji TIPI13 (preglednica 184). Opazno je, da je ujemanje s popačeno izvorno tipizacijo izredno majhno, kar pomeni, da se modelirane popačene tipizacije precej razlikujejo od svojega izvornika. Cramerjev koeficient, koeficient kappa in delež enako klasificiranih celic so zelo nizki. Delež enako klasificiranih celic glede na vse celice je zelo majhen pri vseh modeliranih tipizacijah (okrog 10 %). Nekatere dobre ocene na podlagi vrednotenja na podlagi podatkovnih slojev (preglednice 178–182) so dejansko posledica dejstva, da metode klasificirajo celice po določenih pravilih kar dobro, a je opazno to, da vsilijo svojo strukturo. Zaradi tega je tudi medsebojno ujemanje med uspešnimi modeliranimi popačenimi tipizacijami manjše kot pa v primeru modeliranja nepopačene izvorne tipizacije TIPI13. V analizi smo namreč preverili, kolikšno je ujemanje med modeliranimi popačenimi tipizacijami, in ugotovili, da je ujemanje šibko (preglednici 185 in 186).

Manjše upoštevanje izhodiščne popačene izvorne tipizacije in vsiljevanje lastne strukture posamezne metode sta posledici tega, da je popačena tipizacija TIPI13 dejansko slaba oziroma neobjektivna ter ne omogoča ustreznega modeliranja.

Preglednica 183: Koeficient kappa in Cramerjev koeficient za primerjavo modeliranih popačenih tipizacij TIPI13.

modelirana popačena tipizacija	Cramerjev koeficient	koeficient kappa (%)
KNN	0,009 (stat. značilno za $p < 0,001$)	0,5 (stat. značilno za $p < 0,001$)
MXL	0,005 (ni stat. značilno)	0,0 (ni stat. značilno)
MDS (12 skupin!)	0,005 (ni stat. značilno)	0,1 (ni stat. značilno) ⁷⁴

Preglednica 184: Ujemanje modeliranih popačenih tipizacij z izvorno popačeno tipizacijo TIPI13.

modelirana popačena tipizacija	delež vseh celic (%)	delež enako klasificiranih učnih celic (%)
KNN	9,0	17,0
MXL	10,0	8,5
MDS (12 skupin!)	11,2	8,1

Preglednica 185: Cramerjev koeficient povezanosti med modeliranimi popačenimi tipizacijami TIPI13 ($p=0,001$).

	MXL	MDS (12 skupin!)
KNN	0,071	0,069
MXL		0,364

Preglednica 186: Koeficient kappa med modeliranimi popačenimi tipizacijami TIPI13 ($p=0,001$).

	MXL	MDS (12 skupin!)
KNN	0,023	0,014 ⁷⁴
MXL		0,144 ⁷⁴

2. Sklep analize objektivnosti izvirnih naravnopokrajinskih tipizacij TIPI9 in TIPI13

V obeh sklopih modeliranja popačenih izvirnih tipizacij (TIPI9 in TIPI13) smo prišli do zelo podobnih ugotovitev. Izvirni popačeni tipizaciji TIPI9 in TIPI13 lahko objektivno označimo kot slabi, saj:

- nekateri načini modeliranja niso uspeli izdelati modela zaradi nesmiselnosti popačene tipizacije,
- se izdelane modelirane popačene tipizacije kljub nekaterim relativno dobrim ocenam z vidika podatkovnih slojev niso ujemale z izvorno popačeno tipizacijo.

V disertaciji smo uspeli izvorni (nepopačeni!) tipizaciji TIPI9 in TIPI13 z modelom opisati prav na vse izbrane načine (preglednica 43), hkrati pa smo za izdelane modelirane tipizacije ugotovili, da se precej dobro ujema s svojim izvirnikom (ujemanje je precej višje, kot bi bilo le po naključju).

Zato lahko za naravnopokrajinsko tipizacijo TIPI13 oziroma pokrajinskoekološke tipe (Špes s sod., 2002) ter naravnopokrajinsko tipizacijo TIPI9 oziroma pokrajinske tipe (Perko, 1998a; Perko, 1998b; Perko, 2007b) trdimo, da so objektivno in kakovostno izdelani.

⁷⁴ Ročno smo eni celici spremenili tip iz 8 v 6 zato, da so bili zastopani vsi tipi in je bilo možno izračunati koeficient kappa.