

Klasifikacija satelitskih posnetkov z metodami umetne inteligence

Satellite image classification with artificial intelligence methods

Janez Hafner

Geološki zavod Slovenije, Dimičeva 14, SI-1000 Ljubljana, Slovenija,
Email:janez.hafner@geo-zs.si

Ključne besede: digitalna obdelava podob, daljinsko zaznavanje, statistika, klasifikacija, umetna inteligenca, umetne nevronske mreže

Key words: image processing, remote sensing, statistics, classification, artificial intelligence, artificial neural networks

Povzetek

Namen tega članka je predstaviti osnove obdelave satelitskih posnetkov, še zlasti njihove klasifikacije. V zvezi s tem je bila izvedena litološka klasifikacija širšega območja Kopra in Kozine. Standardne klasifikacijske metode, ki temeljijo na statističnih načelih, se mnogokrat izkažejo za prešibke. Zato se strokovnjaki, ki se ukvarjajo z obdelavo digitalnih podob, trudijo osvojiti nove metode, ki bi jih pripeljale do uporabnejših rezultatov. Na tem mestu je potrebno poudariti, da metode opisane v tem članku niso uporabne le za interpretacijo satelitskih posnetkov ampak se lahko uporabljajo tudi nad katerikoli drugimi prostorskimi podatki (geofizikalnimi, geokemičnimi ...). Ena od vej, ki na nov način poiskuje reševati klasifikacijsko vprašanje so tudi umetne nevronske mreže (UNN). V članku je predstavljena tehnika strojnega učenja, ki kombinira nenadzorovano (ang. Self Organising Maps - SOM) in nadzorovano učenje (ang. backpropagation - BPG). Primerjava s standardnim pristopom je pokazala, da uporaba umetnih nevronske mreže mnogokrat boljše rešuje klasifikacijske probleme. Izkazalo se je, da je končna natančnost odvisna predvsem od števila razredov in njihove linearne ločljivosti. Z uporabo umetnih nevronske mreže se odpirajo nove interpretativne možnosti. V učni proces lahko dodatno uvedemo X in Y koordinati, kar pri standardnih metodah zaradi njihovih omejenih sposobnosti pri razdelitvi multivariatnega prostora vhodnih podatkov ni smiselno.

Abstract

The scope of this article is to acquaint Slovene geologic public with rudiments of image processing of satellite data and especially with classification issue. These methods are not useful only with remotely sensed data but can be also used with any other kind of spatial data (geophysical, geochemical etc.). Standard classification methods based on statistical principles do not always give satisfactory results. Therefore a variety of new approaches are being tested in order to achieve better accuracy. One of the most promising fields is artificial intelligence where artificial neural networks (ANN) have proven to be useful. In this article two methods have been

tested, unsupervised learning with Self Organising Maps and supervised learning with backpropagation network. In comparison with standard approach better results were gained especially in more complicated cases where classes are not linearly separable. One of the advantages of ANN is that X and Y coordinates can be incorporated in learning process. In this way much better accuracy is achieved. This kind of model has ability to favour certain classes according to spatial position of input data, but has disadvantage of not being the general model. It is strictly applicable only to examined area.

Uvod

Članek obravnava interpretacijo podatkov pridobljenih z metodami daljinskega zaznavanja (ang. remote sensing), njihovo uporabo v geologiji in perspektive, ki se odpirajo na tem področju. Poseben poudarek je dan naprednim klasifikacijskim metodam večspektralnih satelitskih posnetkov.

Uporaba satelitskih posnetkov se je zlasti razmahnila po letu 1972 z lansiranjem satelita Landsat, ki je začel zbirati velike količine komercialnih satelitskih posnetkov. Za vsak košček zemlje velikosti 57×79 metrov je satelit vsakih 18 dni izmeril elektromagnetno sevanje v štirih različnih pasovih valovne dolžine. Sledila je cela vrsta satelitov, ki so sistematično zbirali podatke o zemeljskem površju. Količine podatkov pridobljene na ta način so tako velike, da jih ni mogoče obdelati drugače kot z uporabo računalniških metod. Trdimo lahko, da je pojav satelitskih posnetkov povzročil hiter razvoj tehnik računalniške obdelave podob (ang. image processing). V zadnjih nekaj letih razvoj na tem področju poteka v smeri iskanja novih metod, ki naj bi v bodočnosti nadomestile v tem trenutku standardni pristop z uporabo statističnih klasifikatorjev. Kot uporabne so se pokazale metode umetne inteligence, še zlasti uporaba umetnih nevronske mreže in mehke logike. V nadaljevanju je izvedena klasifikacija satelitskega posnetka širšega območja Kopra in Kozine s standardnimi klasičnimi metodami in z uporabo posebne nevronske mreže - Samo Organizirajoče Matrike (SOM) ter njeno nadgradnjo z uporabo gradientnih algoritmov - FMC (Feature Map Classifier).

Digitalna obdelava podob

Digitalna obdelava satelitskih posnetkov se šteje za enega najpomembnejših delov obdelave podob (ang. image processing). Te metode so zadosti univerzalne, da lahko z računanikom obdelamo praktično katerokoli podobo - od fotografij, posnetih iz zraka do geofizikalnih podatkov (K v a m m e et al., 1997). Digitalno podobo si matematično lahko predstavljamo kot funkcijo $f(x, y)$. To pomeni, da je barva (ali osvetlitev) rasterske celice funkcija njenega položaja (x, y) . V nadaljevanju so vse podobe obravnavane v sivih odtenkih - barvne slike so namreč le združba treh osnovnih barv (rdeča, zelena, modra) in jih zato lahko obdelujemo enako kot sivinske. Digitalna podoba je rezultat vzorčenja in kvantiziranja nekega objekta ali njegove podobe. V postopku kvantiziranja vsaki točki rastra dodelimo določeno število, ki kot sivi odtenek predstavlja osvetlitev te točke. V večini primerov je opisu namenjen en podatkovni bajt, kar pomeni, da v tem primeru dobimo na voljo 256 različnih vrednosti osvetlitve. V primeru Landsat-5 (TM skener) posnetka, to pomeni, da je vsaka celica velikega 30 krat 30 metrov predstavljena z nizom sedmih sivih vrednosti od 0 do 255. Tematski kartograf (TM - Thematic Mapper) je predelan multispektralni skener druge

generacije, ki deluje v sedmih območjih elektromagnetnega spektra, med $0.45 \mu\text{m}$ in $12.5 \mu\text{m}$. Razen šestega kanala, ki ima ločljivost 120 metrov, je ločljivost vseh kanalov enaka 30 metrov. V geologiji sta se kot uporabna izkazala zlasti kanala 5 in 7, ki predstavljata sevanje v srednjem IR (infra rdečem) območju.

V grobem lahko obdelavo podob delimo v tri sklope:

- pred obdelavo; Ta faza vsebuje odstranitev šuma, geometrično in radiometrično korekcijo. Sem spadajo zlasti korekcije napak nastalih zaradi napak v delovanju senzorjev, atmosferskih efektov in ukrivljenosti zemeljskega površja. Ponavadi večino dela opravi že distributer podatkov.
- izboljšave; V ta sklop spada množica metod za raztegovanje, filtriranje in transformacijo podatkov z namenom izboljšati kontraste preiskovanih objektov.
- klasifikacija; Namen klasifikacije je avtomatična uvrstitev celic večspektralnega satelitskega posnetka v razrede. Za osnovo pri tem služijo sivinske vrednosti za posamezne celice.

Osnove klasifikacije

V osnovi ločimo dva tipa klasificiranja: nadzorovani in nenadzorovani. Pri nadzorovanem načinu v klasifikacijski način vstopa poleg vhodnih podatkov tudi pravilna razvrstitev v razrede medtem, ko pri nenadzorovanem načinu algoritem samostojno sklepa na podobnost med vhodnimi podatki.

Za boljše razumevanje procesa razvrščanja opazovanj v prostoru si oglejmo proces klasifikacije iz nekoliko drugačnega zornega kota (B r a t k o et al, 1998). Vzemimo, da se nek pojav v prostoru U obnaša po zakonitosti C . Zakonitost C predstavlja torej podmnožico v prostoru U

$$C: C \subset U.$$

Naš cilj je izdelati hipotezo C' , ki za vse objekte (opazovanja) X iz prostora U pravilno ugotovi ali so ali niso del podmnožice, ki jo definira C . Pri tem je napaka hipoteze enaka


$$(C - C') \cup (C' - C),$$

delež pravilno klasificiranih objektov pa je enak

$$|U - (C - C') - (C' - C)| / |U|$$

Hipotezo C' lahko izrazimo na vrsto različnih načinov. Tako je na primer v eksperimentalnih sistemih hipoteza C' predstavljena v obliki $\mathcal{H}$ pravil:


If *spremenljivka 1* $< a$ and *spremenljivka 2* $< b$ then X je plus
else X je minus.



Sl. 1. Zakonitost C in hipoteza C'


Kot je razvidno (slika 2) je tovrstna hipoteza v dvorazsežnostnem prostoru predstavljena z dvema med seboj pravokotnima črtama, ki delita prostor v dva razreda.

Spremenljivka 2




Sl. 2. Način delitve kot ga izdelata ekspertni sistem

Mnogo boljše rešitev predstavlja poševna meja, še boljše pa zakrčljena meja med razredoma (slika 3). Prvi tip razmejitev med razredi lahko izdelamo z uporabo postopka na osnovi minimalne razdalje do srednje vrednosti ali regresijskimi drevesi medtem, ko drugi tip rešitve lahko izdelamo s klasifikacijo po principu Gaussove maksimalne podobnosti.



Sl. 3. Delitev na osnovi minimalne razdalje do srednje vrednosti in po principu Gaussove maksimalne podobnosti

Postavlja se vprašanje katera hipoteza je najboljša. Pogosto se srečujemo z avtorji, ki za najboljšo določajo tisto hipotezo, ki najbolje kategorizira vhodne podatke. V resnici pa to ne drži. Zavedati se je potrebno, da vsako vzorčenje/pridobivanje podatkov neizogibno v podatke uvede tudi šum - napako. Zato se lahko zgodi, da s tem, ko izdelamo rešitev, ki se maksimalno prilega vhodnim podatkom, nehotе izdelamo model v katerega je vključena tudi napaka vzorčenja. S tem smo izdelali hipotezo C' , ki se najbolj prilega vhodnim podatkom ne pa zakonitosti C . Taka hipoteza se sicer izkaže za optimalno v primeru učnih podatkov, ni pa nujno, da se enako dobro obnese tudi na testnih podatkih. Zato je naš cilj izdelati hipotezo C' , ki bo poleg tega, da se čim bolj prilagaja vhodnim podatkom vsebovala tudi veliko sposobnost posploševanja.



Sl. 4. Napaka v vhodnih podatkih zahteva sposobnost posploševanja

Za vsak problem obstaja več možnih rešitev C' , ki vse enako dobro razvrščajo vhodne podatke.

Izbor pravilne hipoteze pa je možno izvesti po različnih kriterijih:

- izberemo lahko hipotezo, ki najbolje klasificira vhodne podatke,
- izberemo lahko hipotezo, katere napaka da najmanjšo vsoto kvadratov,
- izberemo lahko hipotezo, ki najbolje posplošuje,
- Occamovo rezilo - kriterij enostavnosti.


Standardne klasifikacijske metode

Pod standardne klasifikacijske metode štejemo predvsem klasterske statistične metode, ki so ponavadi vgrajene v vse programske pakete, ki služijo interpretaciji digitalnih podob. Najboljše rezultate dajo nadzorovane klasterske metode. Zato je v nadaljevanju dan poudarek predvsem tem metodam.

Vsaka celica satelitskega Landsat TM posnetka vsebuje sedem vrednosti - tonov sivine, ki predstavljajo sedem kanalov elektromagnetnega spektra. S tem je vsaki celici določen položaj v sedem razsežnostnem prostoru, ki ga definirajo kanali TM skenerja. V procesu klasifikacije je ta prostor razdeljen med razrede v katere uvrščamo vhodne podatke. Z uporabo reprezentativnih učnih podatkov za katere je že znana pravilna klasifikacija, se zgradi klasifikacijski model, ki ga lahko v bodočnosti uporabimo kot klasifikator. Način izdelave klasifikacijskega modela zavisi od postopka, ki ga izberemo. Ponavadi se uporabljajo naslednji postopki (L i l l e s a n d i n K i e f e r, 1994):

- metoda na osnovi minimalne razdalje do srednje vrednosti. Za vsak razred se iz učnih podatkov izračuna njegova srednja vrednost. Klasifikator deluje tako, da se posamezni vhodni podatek uvrsti v razred z najmanjšo evklidsko razdaljo do njegovega centroida (povprečja).
- Metoda z uporabo Mahalanobisove razdalje. Medtem ko metoda na osnovi minimalne razdalje do srednje vrednosti uporablja za mero razdalje evklidsko razdaljo, je v tem primeru razdalja odvisna od porazdelitve znotraj posameznega razreda. Pri izračunu razdalj uporablja matriko kovarianc.
- Metoda največje podobnosti se od metode z uporabo Mahalanobisove razdalje razlikuje po tem da mera za razdaljo temelji na verjetnostih, da posamezni vhodni podatek pripada k določenemu razredu.

Poznavanje in uporaba zgoraj naštetih metod je obvezna za vsakogar, ki resno pristopa k interpretaciji satelitskih posnetkov. Tako kot v vseh podobnih primerih so se zelo hitro pokazale tudi omejitve. Zato so se strokovnjaki s področja obdelave digitalnih podob v zadnjih letih usmerili v iskanje novih močnejših postopkov, ki ne temeljijo na statistiki. Zlasti so se izkazale za uporabne metode umetne inteligence in med njimi umetne nevronske mreže.



Sl. 5. Različne metode različno delijo podatkovni prostor

Rezultati obdelav

Geografska lega

Obravnavano območje zavzema južno polovico lista (OGK1) Gorica in skoraj celotni list Trst. Mejne koordinate območja so po Gauss-Krugerju:

$$\begin{aligned}x_{\min} &= 5.388.407,00 \text{ m} \\x_{\max} &= 5.422.207,00 \text{ m} \\y_{\min} &= 5.039.989,00 \text{ m} \\y_{\max} &= 5.068.009,00 \text{ m}\end{aligned}$$

Geologija

Geologija za obravnavano območje je povzeta po Osnovni geološki karti 1:1000.000, listov Trst (P l e n i č a r et al, 1965) in Gorica (B u s e r, 1965) ter ustreznih tolmačev. Kamnine, ki sestavljajo obravnavano območje pripadajo krednim, paleocenskim, eocenskim in kvartarnim plastem.

Kreda

Kredne plasti zastopajo karbonatne kamnine, od katerih so najstarejše albijsko-cenomanijski ($K_{1,2}$) dolomiti, breča in apnenec. Nad temi leže plasti cenomanijsko-turonijskega (K_2^2) rudistnega apnenca z vložki dolomita. Sledijo turonski ($K_3^{1,2}$) skladi z temno sivim apnencem, ki se menja s sivim rudistnim apnencem nato plasti turonij-sko-senonijskega ($K_2^{2,3}$) sivega in temno sivega apnenca z radioliti, tem pa plasti senonskih (K_2^3) apnencev in plasti temno sivega apnenca z giropleurami, danijske starosti (K, Pc).

Paleocen, eocen

Te starosti so spodnjepaleocenski (${}_2Pc_1$) kozinski apnenec s haracejami, zgornjepaleocenski (Pc_2) miliolidni apnenec, spodnjeeocenski in srednje-eocenski (E_1) alveolinski apnenec, numulitni apnenec (Pc , E) in flišne oziroma flišu podobne srednjeeocenske (E_2) plasti. Foraminiferni apneneci so debelo plastnati in sive barve.

Kvartar

Kvartar je zastopan z morskimi sedimenti, jamskimi sedimenti, ki sestojijo iz ilovice in gruša, aluvijalnimi nanosi po rečnih dolinah in glinasto-grušnatimi nanosi s pobočij, debeline od enega do več metrov.

Standardni klasifikacijski pristop

Posnetek Landsat TM iz leta 1993 je bil pridobljen preko *Zavoda republike Slovenije za statistiko*. Po izrezu obravnavanega območja je bilo opaziti, da je posnetek v veliki meri prekrit z oblaki, meglicami in njihovimi sencami, kar onemogoča izdelavo optimalnega klasifikacijskega modela. Vendar pa to ne vpliva na uporabnost posnetka za primerjavo različnih klasifikacijskih metod.

V ta namen je bilo potrebno posnetek najprej ustrezno pripraviti:

- Pregled možnih napak. Izvedena je bila analiza glavnih komponent (PCA). Na sedmi komponenti je lepo opaziti napako pasov (ang. striping), ki nastane kot posledica delovanja večih senzorjev. Ker je napaka ponavljajoče narave, jo je bilo razmeroma lahko odstraniti z uporabo hitre fourierjeve transformacije.
- Z nadzorovano klasifikacijo je bilo potrebno odstraniti oblake in njihove sence, ki bi v nadaljni klasifikaciji pomenili le dodatni šum. Po eni strani je to ena od nalažjih operacij, saj so oblaki zelo dobro razvidni, po drugi pa se pojavlja vprašanje kdaj je potrebno oblak še izločiti in kdaj ne. Prehod iz oblačnega v neoblačno nebo je namreč pogosto zvezen - zamegljen. Kot se je pokazalo kasneje je to močno vplivalo na točnost klasifikacije, saj so območja v bližini oblakov pogosto napačno klasificirana.

Klasifikacija - 16 razredov

Na osnovi geološke karte je bilo na obravnavanem področju določeno začetnih 16 razredov:

1. Q melišča in pobočni grušč
2. Q aluvij
3. Q morski sedimenti
4. E_2 fliš
5. ${}^{1,2}E_2$ lapor
6. Pc, E alveolinski in numulitni apneneci
7. Pc_2 miliolidni apnenec
8. ${}_2Pc_1$ kozinski skladi

9. K_{1Pc} apnenci z giropleurami
10. K_2^3 črni ploščasti apnenci
11. K_2^2 rudistni apnenec
12. $K_2^{2,3}$ apnenec z radioliti
13. K_2^2 temno sivi apnenec v menjavi z rudistnim apnencem
14. $K_{1,2}^3$ rudistni apnenec z vložki dolomita
15. $K_{1,2}$ dolomit, breča in apnenec
16. $K_{1,2}$ pretežno dolomit

V nadaljevanju so razredi zaradi enostavnosti označeni kar z njihovo zaporedno številko (R1, R2, ... R16).

V procesu nadzirane klasifikacije je najprej potrebno določiti učne vzorce, v nadaljevanju poteka klasifikacija avtomatično. Najpogosteje se uporabljajo tri različne metode

- metoda na osnovi minimalne razdalje do srednje vrednosti,
- metoda z uporabo Mahalanobisove razdalje,
- metoda največje podobnosti.

Izkazalo se je, da metoda po kriteriju največje podobnosti ne glede na število uporabljenih razredov praviloma da najboljše rezultate. Pri ugotavljanju pravilnosti klasifikacije so zanimivi predvsem trije parametri (L i l l e s a n d i n K i e f e r, 1994):

- Natančnost postopka za razred n je mera, ki nam pove koliko celic iz vsakega razreda je pravilno klasificiranih.

$$NP_n = \frac{\text{število pravilno klasificiranih celic razreda } n}{\text{skupno število vseh celic klasificiranih v razredu } n}$$

- Uporabna natančnost za razred n je mera, ki podaja pravilnost klasificiranega razreda. V primeru, ko je NP_n 100% to še ne pomeni, da je klasifikacija dobra, saj nam lahko razred n »požre« druge razrede in s tem zgubi na svoji pravilnosti.

$$UN_n = \frac{\text{število pravilno klasificiranih celic razreda } n}{\text{skupno število celic v razredu } n}$$

- skupna natančnost podaja odstotek vseh pravilno klasificiranih razredov.

$$SN = \frac{\text{število pravilno klasificiranih celic}}{\text{skupno število celic}}$$

Ker je ponavadi med obema natančnostima NP_n in UN_n velika razlika se je včasih težko odločiti, kako ovrednotiti pravilnost razreda. Zato lahko kot mero pravilnosti uvedemo P_n , definirano kot

$$P_n = \sqrt{NP_n \times UN_n}$$

V tabeli 1 je prikazan rezultat klasifikacije za vseh 16 razredov po metodi največje podobnosti.

Tabela 1. Pravilnost klasifikacije z metodo največje podobnosti za 16 razredov

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	8328	6388	---	---	---
1	138	8644	106	76.81%	1.23%	9.71%
2	1408	4252	698	49.57%	16.42%	28.53%
3	411	585	148	36.01%	25.30%	30.18%
4	14999	1003	790	5.27%	78.76%	20.37%
5	242	1585	24	9.92%	1.51%	3.87%
6	6616	200	146	2.21%	73.00%	12.7%
7	960	273	17	1.77%	6.23%	3.32%
8	1656	58	5	0.30%	8.62%	1.61%
9	1585	16	3	0.19%	18.75%	1.88%
10	304	6911	169	55.59%	2.45%	11.67%
11	1664	230	20	1.20%	8.70%	3.23%
12	1204	2034	218	18.11%	10.72%	13.93%
13	2608	749	290	11.12%	38.72%	20.75%
14	1403	1565	279	19.89%	17.83%	18.83%
15	1380	2430	468	33.91%	19.26%	25.56%
16	652	5397	582	89.26%	10.78%	31.02%
Povprečna vrednost:				25.69%	21.14%	14.82%
Skupna natančnost SN:				23.39%		

Kot je razvidno iz tabele 1 rezultat klasifikacije ni uporaben saj tako majhne natančnosti praktično ne prinašajo rezultata (klasificirane karte). Zato je nujno zmanjšati število razredov. Združevanje razredov lahko poteka na različne načine, kjer je nujno potrebno upoštevati namen klasifikacije, hkrati pa si pomagamo s statističnimi parametri in s klasifikacijsko matriko. Ko govorimo o statističnih parametrih si predstavljamo, da je vsak razred predstavljen v sedem razsežnostnem prostoru s sedem razsežnostnim elipsoidom, definiranim s srednjo vrednostjo in variancami v vseh sedmih dimenzijah.

Pri nadaljnjem združevanju je bila uporabljena metoda transformirane divergen-
ce, ki za merilo podobnosti med dvema razredoma uporablja naslednji enačbi
(Swain in Davies, 1978):

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j)(C_i^{-1} - C_j^{-1})) + \frac{1}{2} ((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T)$$

$$TD_{ij} = 2 \left(2 - e^{-\frac{D_{ij}}{\sigma}} \right),$$

kjer so:


TD_{ij} - transformirana divergenca med razredoma i in j C_i - matrika kovarianc za razred i
 D_{ij} - divergenca med razredoma i in j i, j - razreda, ki ju primerjamo
 μ_i - glavni vektor razreda i tr - vsoto diagonalnih el. matrike

TD_{ij} zavzame vrednosti od 0 do 2000. Nizke vrednosti pomenijo, da sta si dva razreda zelo podobna (se prekrivata), visoke vrednosti pa pomenijo, da sta si razreda med seboj različna. Tabela 2 predstavlja vrednosti TD_{ij} za klasifikacijo izvedeno s 16 razredi.

Tabela 2. Transformirane divergence za 16 razredov (označene vrednosti, ki označujejo podobnost razredov R6, R7, R8, R9, R11 in R13)

	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15	R16
R1	1695	2000	1166	517	1946	1522	1807	1999	743	1845	969	1452	1880	1114	1777
R2	-	1775	390	1199	1194	1282	1198	1560	1094	1384	1592	986	1837	1364	2000
R3	-	-	1890	2000	1584	1863	1732	1648	2000	1807	2000	1811	1992	2000	2000
R4	-	-	-	590	848	668	735	1364	661	819	1076	509	1459	930	1983
R5	-	-	-	-	1685	940	1382	1972	555	1489	503	822	1632	632	1788
R6	-	-	-	-	-	290	155	356	1829	376	1702	717	877	1763	1991
R7	-	-	-	-	-	-	154	695	1271	196	1059	430	951	1106	1880
R8	-	-	-	-	-	-	-	535	1614	294	1406	584	775	1522	1959
R9	-	-	-	-	-	-	-	-	1988	347	1981	1092	1395	1969	2000
R10	-	-	-	-	-	-	-	-	-	1643	1180	1083	1861	683	1965
R11	-	-	-	-	-	-	-	-	-	-	1622	471	1207	1475	1972
R12	-	-	-	-	-	-	-	-	-	-	-	1230	1336	1363	1378
R13	-	-	-	-	-	-	-	-	-	-	-	-	1592	718	1978
R14	-	-	-	-	-	-	-	-	-	-	-	-	-	1905	1798
R15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	1979

Rezultat nadzorovane klasifikacije je klasificirana karta 16 razredov (glej sliko 6), razporeditev vhodnih podatkov v ciljne razrede pa je podana s klasifikacijsko matriko v tabeli 3. Stolpci predstavljajo dejanske razrede, vrstice pa razporeditev kot smo jo izdelali s klasifikacijo.



Sl. 6. Geološka karta Slovenskega Primorja (zgoraj) in rezultat nadzorovane klasifikacije po metodi največje podobnosti za 16 razredov (spodaj)

Na podlagi spektralne podobnosti razredov (glej tabelo 2) sem se v nadaljevanju odločil za iz geološkega vidika sicer ne povsem dosledno združevanje:

- R6, R7, R8, R9, R11 in R13
- R5 in R12
- R2 in R4

Tabela 3. Klasifikacijska tabela za 16 razredov

	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15	R16
0	0	10	40	339	7	516	102	113	165	15	178	46	229	24	152	4
R1	106	51	9	4037	100	1296	234	279	561	81	676	41	768	13	275	3
R2	2	698	167	2934	5	194	13	24	45	12	8	25	81	14	27	0
R3	1	83	148	148	0	75	1	6	4	0	11	0	81	1	7	0
R4	0	105	0	790	1	35	9	13	4	2	9	9	19	4	3	0
R5	4	10	0	739	24	350	29	29	50	3	74	34	107	11	16	2
R6	2	0	0	17	3	146	3	6	2	0	1	5	0	8	0	0
R7	0	1	2	39	3	105	17	26	10	5	21	16	4	5	3	6
R8	0	2	2	15	0	23	3	5	1	1	2	1	2	1	0	0
R9	0	1	0	2	0	2	0	4	3	0	0	0	0	0	4	0
R10	13	410	2	3697	14	545	153	420	418	169	321	43	284	29	377	2
R11	0	4	0	64	0	45	11	9	4	5	20	1	49	5	9	1
R12	1	7	0	324	11	882	76	126	44	1	23	218	64	195	2	15
R13	1	0	2	140	3	114	13	22	11	2	42	15	290	1	34	1
R14	0	5	0	161	9	751	33	114	49	0	9	93	22	279	3	36
R15	1	21	39	705	18	212	59	55	149	8	110	11	376	1	468	0
R16	7	0	0	848	44	1325	214	405	65	0	159	646	232	812	0	582

Klasifikacija - 9 razredov

Na podlagi transformiranih divergenc je bila izdelana nova klasifikacijska shema z 9 razredi:

1. Q melišča in pobočni grušč
2. Q aluvij + 1E_2 fliš
3. Q morski sedimenti
4. $^{1,2}E_2$ lapor + $K_2^{2,3}$ apneneci z radioliti
5. Pc, E alveolinski in numulitni apnenec + Pc_2 miliolidni apnenec + 2Pc_1 kozinski skladi + K, Pc apnenec z giropleurami + K_2^3 rudistni apnenec + K_1^2 apnenec
6. K_2^3 črni ploščasti apneneci
7. $K_1^{1,2}$ rudistni apnenec z vložki dolomita
8. $K_{1,2}$ dolomit, breča in apnenec
9. $K_{1,2}$ pretežno dolomit

Po določitvi novih razredov je bila ponovno izvedena klasifikacija. Natančnost klasifikacije in podatki o transformirani divergenci so podani v tabelah 4 in 5, rezultat pa je prikazan v sliki 7.

Tabela 4. Natančnost za klasifikacijo z 9 razredi

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	8076	6321	---	---	---
1	138	9067	111	80.43%	1.22%	9.90%
2	16407	4841	4191	25.54%	86.57%	47.02%
3	411	1071	196	47.69%	18.30%	29.32%
4	1446	3072	261	18.05%	8.50%	12.38%
5	15088	453	339	2.25%	74.83%	12.98%
6	304	7241	176	57.89%	2.43%	11.86%
7	1403	1840	326	23.24%	17.72%	20.29%
8	1380	3233	516	37.39%	15.96%	24.43%
9	652	5365	584	89.57%	10.89%	31.23%
Povprečna vrednost:				42.45%	26.27%	22.16%
Skupna natančnost SN:				29.42%		

Tabela 5. Transformirane divergence za 9 razredov (označene najnižje vrednosti)


	R2	R3	R4	R5	R6	R7	R8	R9
R1	1226	2000	832	1918	743	1880	1114	1777
R2		1873	952	765	691	1499	957	1989
R3			2000	1570	2000	1992	2000	2000
R4				1609	1021	1356	1161	1464
R5					1761	1055	1645	1989
R6						1861	683	1965
R7							1905	1798
R8								1979

Tabela 6. Klasifikacijska matrika za 9 razredov

	<i>R1</i>	<i>R2</i>	<i>R3</i>	<i>R4</i>	<i>R5</i>	<i>R6</i>	<i>R7</i>	<i>R8</i>	<i>R9</i>
<i>0</i>	0	319	38	54	1166	11	22	142	3
<i>R1</i>	111	4333	9	159	3915	81	13	277	3
<i>R2</i>	1	4191	124	32	433	10	24	21	0
<i>R3</i>	2	556	196	11	269	1	1	14	0
<i>R4</i>	2	710	0	261	1768	3	175	8	20
<i>R5</i>	1	51	1	10	339	7	3	16	0
<i>R6</i>	13	4334	3	58	2233	176	27	383	2
<i>R7</i>	0	185	0	131	1153	0	326	3	40
<i>R8</i>	2	900	40	36	1427	15	3	516	0
<i>R9</i>	6	828	0	694	2385	0	809	0	584

Tabela 7. Natančnost za klasifikacijo z 5 razredi

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	7902	6255	---	---	---
1	16545	13056	10125	61.20%	77.55%	68.89%
2	411	1053	195	47.45%	18.52%	29.64%
3	18241	3775	3329	18.25%	88.19%	40.12%
4	1380	11279	1085	78.62%	9.62%	27.50%
5	652	7194	611	93.71%	8.49%	28.21%
Povprečna vrednost:				59,85%	40,47%	38,87%
Skupna natančnost SN:				48.80%		



Sl. 7. Geološka karta Slovenskega Primorja (zgoraj) in rezultat nadzorovane klasifikacije po metodi največje podobnosti za 9 razredov (spodaj)

Kot je razvidno iz tabel 5 in 6 so si zelo podobni razredi R2, R6 in R8. Če bi nadaljevali s takim združevanjem bi to pomenilo, da bi združili apnenec in fliš, kar pa ne bi bilo smiselno, saj bi s tem združili dve glavni litološki enoti na tem področju, s tem pa bi klasifikacija izgubila svoj namen. Zato v nadaljevanju združevanje poteka predvsem glede na potrebe uporabnika.

Klasifikacija - 5 razredov

Zadnja klasifikacija je bila izvedena nad 5 razredi:

1. Q melišča in pobočni grušč + Q aluvij + 1E_2 fliš
2. Q morski sedimenti
3. $^{1,2}E_2$ lapor + $K_2^{1,2}$ apnenec z radioliti + Pc, E alveolinski in numulitni apnenec + Pc_2 miliolidni apnenec + 2Pc , kozinski skladi + K, Pc apnenec z giropleurami + K_2^3 rudistni apnenec + K_2^2 apnenec + K_2^3 črni ploščasti apnenec + $K_2^{1,2}$ rudistni apnenec z vložki dolomita
4. $K_{1,2}$ dolomit, breča in apnenec
5. $K_{1,2}$ pretežno dolomit

Transformirana divergenca in rezultati klasifikacije so razvidni iz tabel 7, 8 in 9 rezultat klasifikacije pa je prikazan na sliki 8.

Po pregledu rezultatov v tabelah je razvidno:

- da je relativno dobro klasificiran le prvi razred (Q melišča in pobočni grušč + Q aluvij + 1E_2 fliš),
- medtem ko za razred 3 (večina apnenecv in lapor) velja, da je pravilno klasificiran le manjši del,
- razredi 2 (Q morski sedimenti), 4 ($K_{1,2}$ dolomit, breča in apnenec) in 5 ($K_{1,2}$ pretežno dolomit) imajo zadovoljivo natančnost postopka in majhno uporabno natančnost, kar pomeni, da v veliki meri posegajo na področja, ki jim ne pripadajo.

Tabela 8. Klasifikacijska tabela za klasifikacijo s 5 razredi


	<i>R1</i>	<i>R2</i>	<i>R3</i>	<i>R4</i>	<i>R5</i>
<i>0</i>	295	37	1179	133	3
<i>R1</i>	10125	134	2626	124	1
<i>R2</i>	548	195	275	13	0
<i>R3</i>	307	2	3329	22	35
<i>R4</i>	3897	43	5741	1085	2
<i>R5</i>	1373	0	5091	3	611

Tabela 9. Transformirane divergence za 5 razredov

	<i>R2</i>	<i>R3</i>	<i>R4</i>	<i>R5</i>
<i>R1</i>	1875	732	954	1989
<i>R2</i>		1628	2000	2000
<i>R3</i>			1597	1980
<i>R4</i>				1979

Končni rezultat vseh treh klasifikacij ni možno oceniti za zadovoljivega, kar je posledica naslednjih dejstev:

- Satelitski posnetek, ki je bil uporabljen za izvedbo klasifikacije še zdaleč ne dosega ustrezne kvalitete. Severni del posnetka je v veliki meri prekrit z oblaki in njihovimi sencami. Odkriti deli posnetka so v veliki meri prekriti z meglicami, ki sicer še omogočajo izvedbo klasifikacije a že na začetku v podatke vnašajo šum. Za boljši rezultat bi bilo nujno potrebno pridobiti kvalitetnejši posnetek.
- Posnetek ni dobro georeferenciran, saj kljub velikim naporom pri vpenjanju posnetka RMS napaka na nekaterih delih še vedno presega 60 metrov. Vpenjanje je bilo oteženo zlasti zaradi prisotnosti oblačnih delov, kjer ni bilo mogoče poiskati dovolj velikega števila povezovalnih točk.
- Število uporabljenih kanalov (7) je relativno majhno. Kvaliteto klasifikacije bi bilo nujno potrebno izboljšati z vpeljavo novih posnetkov - npr. SPOT posnetka s čimer bi tudi izboljšali prostorsko ločljivost.
- Omejene sposobnosti uporabljenih klasifikacijskih metod. Natančnost je možno izboljšati z vpeljavo novih metod. Ena od njih - SOM (Samo Organizirajoče Matrike) bo prikazana v nadaljevanju.



Sl. 8. Geološka karta Slovenskega Primorja (zgoraj) in rezultat nadzorovane klasifikacije po metodi največje podobnosti za 5 razredov (spodaj)

Umetna inteligenca

Že skozi stoletja si je človek želel ustvariti misleče stroje. Z razvojem računalništva ter petdesetletnim razvojem na področju programskih tehnik te sanje počasi postajajo realnost. Raziskovalci na različnih področjih izdelujejo sisteme, ki so sposobni oponašati človeško razmišljanje, razumejo človeški govor, berejo rokopise, premagujejo vele mojstre šaha... Umetna inteligenca (UI) je področje računalniških znanosti, ki se ukvarja z izdelovanjem inteligentnih strojev – to so stroji, ki oponašajo človeško obnašanje na tak način, da jih lahko imenujemo inteligentne. Seveda se pri tem postavi vprašanje, kaj je to inteligenca... Do kakšne mere inteligenca sestoji iz reševanja kompleksnih problemov, posploševanja, percepcije, razumevanja... Razvijalci umetne inteligence so bili in so še danes postavljeni pred zahtevno nalogo izgraditi sistem, ki oponaša delovanje človeških možganov – verjetno najbolj kompleksne nam znane materije.

Umetna inteligenca je prehodila v obdobju svojega nastanka dolgo pot. Začetki segajo v predelektronsko dobo, ko so različni filozofi, matematiki in drugi ustvarjali temelje za današnji razvoj. Resen razmah je UI doživela z izumom elektronskega računalnika 1941. S tem je svet dobil tehnologijo, vsaj tako je izgledalo, za simuliranje inteligentnega delovanja.

UI je že od nekdaj predstavljala naprednejši del računalniške znanosti, saj vsi računalniški jeziki, računalniški vmesniki, urejevalniki besedil... dolgujejo svoj obstoj razvoju na področju umetne inteligence. Teorija in poglobljen vpogled v UI postavljata razvojne smernice v računalništvu. Sodobni izdelki predstavljajo majhne korake v smeri vsesplošne uporabe metod umetne inteligence, ki v bodočnosti napoveduje razmah na vsa področja našega življenja. Ne glede na naše želje ali pomisleke umetna inteligenca počasi in neopazno prodira v pore našega bivanja, tako da se temu ne bo mogoče izogniti.

Nevronske mreže


Končni cilj umetne inteligence je pripraviti računalnike do tega, da bi bili enakovredni človeku na področjih kot so učenje, zaznavanje, govor, robotsko premikanje... V tem trenutku je tudi najbolj optimističnim strokovnjakom na področju UI postalo jasno, da je ta naloga če že ne neuresničljiva vsaj zelo težko dosegljiva. Zanimivo je, da so nekatere naloge, ki jih ljudje z lahkoto vsakodnevno in samoumevno opravljamo, za računalnik tako rekoč neizvedljive. Seveda je najlažje tak ali podobno težak problem proglasiti za nerešljivega, vendar pa hkrati lahko opazimo, da isti problem vsak dan z največjo lahkoto rešujejo številna živa bitja. Prav zaradi tega je logično, da se zgledujemo po edinih nam znanih sistemih, ki so sposobni reševati tako zapletene naloge – možganih. Ob tem se moramo zavedati, da bi lahko enako uspešno delovale tudi kakšne druge metode in se zato ni priporočljivo stoddostno držati sistemov uveljavljenih v naravi. Tipičen primer je na primer letenje. Kljub temu, da smo natančno seznanjeni z načinom letenja ptic, se je kot najbolj enostavna in praktična rešitev razvila tehnika letenja z letali. Pretirano posnemanje bioloških sistemov ni smiselno tudi iz razloga, da naše poznavanje teh sistemov še zdaleč ni popolno ampak se sproti dopolnjuje in spreminja. Na podlagi vsega zgoraj opisanega so se kot ena izmed najbolj obetajočih vej umetne inteligence razvile umetne nevronske mreže (v nadaljevanju – NM, nevronske mreže). Pri tem je potrebno poudariti, da ne obstajajo zagotovi-

la, da so NM sposobne rešiti vse težave umetne inteligence. Metoda bo enkrat v bodočnosti verjetno sposobna reševati tudi težje naloge, ki pa jim zaenkrat še ni kos.

Umetne nevronske mreže lahko smatramo za poenostavljene matematične računalniško podprte modele človeških možganov. Od običajnih računalniških programov, ki jih je potrebno programirati za reševanje problemov, jih loči to, da so se NM sposobne učiti in jih zato ne programiramo ampak učimo.

Človeški možgani

Zaradi svoje kompleksnosti in neverjetnih sposobnosti so človeški možgani skozi vso zgodovino privlačili znanstvenike različnih področij. Kljub temu, da možganske celice delujejo sedemkrat počasneje kot preklopni elementi v sodobnih računalnikih, so človeški možgani sposobni opravljati operacije, ki so za računalnike popolnoma neizvedljive. Glavni razlog za to leži v ogromnem številu nevronov, povezavah med njimi in v zapletenih kombinacijah vzporednih in asinhronskih obdelav podatkov. Človeški možgani so sestavljeni iz približno 10^{11} nevronov. Vsak od njih je z 1.000 do 10.000 vezmi povezan z drugimi nevroni. Vsaka povezava ima svojo utežno funkcijo, ki se spreminja skladno z razvojem človeške osebnosti. Poznamo več tipov nevronskih celic, ki pa v osnovi vse opravljajo nekaj osnovnih funkcij. Nevron je sestavljen iz telesa celice, dendritov in aksona. Osnovno delovanje poteka tako, da dendriti na stičnih mestih, ki se imenujejo sinapse, sprejemajo signale od drugih nevronov in jih nato posredujejo celičnemu telesu. Tu se signali povprečijo z ostalimi podobnimi signali. V primeru, da je povprečje v nekem kratkem časovnem intervalu dovolj veliko (preseže aktivacijski prag), se nevron »vžge« in po aksonu posreduje impulz drugim nevronom. Skrivnost učenja se skriva v delovanju sinaps. Njihova funkcija ni samo prenos impulzov ampak se v sinapsah impulzi ojačajo ali oslabijo. To pomeni, da je v sinapsi določena moč povezave med dvema nevronoma. Ugotovljeno je bilo, da večkratna zaporedna aktivacija sinapse poveča njeno prevodnost (H e b b, 1949). To predstavlja ključ učenja v človeških možganih saj večkratni pojav enakega aktivacijskega vzorca povzroči, da se ta preko povečanja prevodnosti v sinapsah »zapiše«. Iz tega sledi da se v možganih znanje zapisuje v obliki sinaptičnih prevodnosti.



Sl. 9. Struktura nevrona (G a l l a n t, 1993)

Nevron kot preklopni element


Analogijo biološkemu nevronu v teoriji umetnih nevronske mreže predstavlja umetna nevronska celica (v nadaljevanju nevron), ki je osnovni gradnik zveznih modelov. Delovanje nevrona (glej sliko 10) poteka tako, da vsak nevron u_i , glede na prispele impulze izračuna svojo izhodno vrednost – aktivacijo in jo posreduje naslednjem nevronu. Praviloma vsi nevroni uporabljajo enake algoritme za računanje svoje aktivacije. Vstopni podatki so aktivacije spodaj ležečih nevronov in njihove uteži, kjer oznaka w_{ij} predstavlja utež od nevrona u_i proti nevronu u_j . V i -tem nevronu se aktivacija u_i izračuna na naslednji način (G a l l a n t, 1993):

1. Nevron najprej izračuna obteženo vsoto aktivacij iz direktno povezanih spodaj ležečih nevronov:

$$S_i = \sum_{j=0}^n w_{ij} u_j$$

2. V naslednjem koraku s pomočjo preklopne funkcije izračuna aktivacijo

$$u_i = f(S_i)$$




Sl. 10. Umetni nevron - preklopna celica (G a l l a n t, 1993)

V nadaljevanju sta na kratko opisana dva modela nevronske mreže, ki skupno tvorita FMC (ang. Feature Map Classifier) mrežo: BPG in SOM.

BPG (ang. BackPropagation)

BPG nevronska mreža je verjetno v tem trenutku najbolj razširjena, najlažje razumljiva in najbolj pogosto uporabljena nevronska mreža za reševanju klasifikacijskih problemov. Bistvo BPG mreže je njena večnivojska struktura in sistem učenja, razvit ter izpopolnjen v sedemdesetih in osemdesetih letih (W e r b o s, 1976, M c C l e l l a n d in R u m e l h a r t, 1986 ter P a r k e r, 1985). Nevroni so organizirani v večih nivojih (glej sliko 11), tako da signal potuje od spodnjega nivoja proti zgornjemu. Prvi nivo imenujemo tudi vhodni nivo. Vanj vstopajo vhodni podatki. V primeru klasifikacije satelitskega posnetka ga sestavlja 7 nevronov (za 7 spektralnih kanalov). Klasifikacija poteka na nmaslednji način. Signal se iz vhodnega nivoja preko obteženih povezav med nevroni prenese na višje ležeče skrite nivoje vse dokler ne doseže zadnjega izhodnega nivoja, ki predstavlja ciljne klasifikacijske razrede. Vsak od nevronov v tem razredu predstavlja po en razred. Ko signal doseže izhodni nivo, se v njem izračunajo obtežene vsote. Nevron z največjo obteženo vsoto je proglašen za zmagovalca, kar pomeni, da se vhodnim podatkom pripiše razred, ki ga ta nevron predstavlja.



Sl. 11. Večnivojska nevronska mreža


BPG mreža je svoje ime dobila po nadzorovanem načinu učenja, ki poteka v dveh korakih. V prvem koraku signal potuje preko celotne mreže do izhodnega nivoja. V izhodnem nivoju se dobljeni rezultat primerja z že prej znanim pravilnim rezultatom. Na ta način se izračuna napaka mreže. V drugem koraku napaka potuje navzdol po mreži, od izhodnega proti vhodnemu nivoju. Za vsako povezavo (utež) med nevroni se najprej izračuna njen prispevek k napaki ter nato utež premakne v smeri zmanjšanja skupna napake. Proces učenja je iterativen in poteka dokler se napaka ne ustali in se z nadaljnjim učenjem ne zmanjšuje več.

Matematično ozadje je dokaj zapleteno in presega okvire tega članka. Zato svetujem bralcu, ki ga področje bolj zanima, da si ogleda strokovno literaturo (Gallant, 1993).

SOM - Samo Organizirajoče Matrike

V prejšnjem poglavju je opisana tipična metoda za nadzorovanega učenja, ki zahteva, da v procesu učenja mreži skupaj z vhodnimi podatki predstavimo tudi pravilne rezultate. Poleg takih metod so se zelo uveljavili tudi postopki nenadzorovanega učenja, ki med seboj združujejo podatke glede na njihovo podobnost. Izjemno zanimivo področje samoorganiziranja pri nevronske mrežah je prvi načel Kohonen (Kohonen, 1984), ki ni le razvil ustrezne teorije ampak jo je tudi na široko uveljavil in vpeljal v reševanje praktičnih problemov.

Kadarkoli upravljamo z večdimenzionalnimi podatki, se vedno zastavlja vprašanje njihove najboljše predstavitve. S teorijo SOM (ang. Self Organising Maps) je Kohonen razvil učinkovit sistem predstavitve podatkov v dvodimenzionalnem (lahko tudi več-dimenzionalnem) prostoru. SOM mreža je sestavljena iz dveh nevronske nivoje, vhodnega in Kohonenovega (izhodnega) nivoja, kjer nevroni Kohonenovega nivoja tvorijo dvodimenzionalno matriko (glej sliko 12). Na ta način lahko vsakemu nev-



Sl. 12. Struktura SOM (Gallant, 1993)

ronu Kohonenovega nivoja določimo njegove sosedje. V fazi učenja se uteži med obema nivojema samo organizirajo tako, da podobni vhodni podatki aktivirajo bližnje ležeče izhodne nevrone. S tem je doseženo, da razdalja med nevroni predstavlja mero za podobnost. Zgled za tako strukturo najdemo v možganih sesalcev, kjer dražljaji bližnjih točk na telesu sprožajo tudi bližnje nevronske celice v možganih.

Moč SOM je v sposobnosti hitrega organiziranja velikega števila podatkov v n -dimenzionalno matriko. To je v bistvu nelinearna projekcija verjetnostne gostote funkcije visoko-dimenzijskih podatkov v dvo ali več dimenzionalni prostor (Kohonen et al., 1995). Na ta način lahko učinkovito preučujemo strukturo vhodnih podatkov in ugotavljamo relacije med njimi. Če primerjamo to metodo s klasičnimi statističnimi clustreskimi metodami, je njena glavna prednost v nelinearnosti projekcije.

V procesu samoorganiziranja je včasih zaželeno, da vhodne vektorje povežemo z že znanimi končnimi rezultati (klasifikacija) podobno kot to dela BPG mreža. V takem primeru se SOM razširi z dodatnim izhodnim nivojem. Uteži med Kohonenovim nivojem in izhodnim nivojem nato določimo z BPG pravilom. Na ta način dobimo FMC (Feature Map Classifier) nevronske mreže.

Prednosti in slabosti umetnih nevronskih mrež

Delo z umetnimi nevronskimi mrežami lahko pod pogojem, da nam je dostopna ustrezna programska oprema, izpade dokaj enostavno – podatki se vstavijo v mrežo, požene se učni proces in počaka na rezultat. Vendar pa v praksi resničnost izgleda povsem drugače. Kdor želi dobiti dobre rezultate, to je rezultate, ki so boljši ali vsaj enaki od tistih pridobljenih s standardnimi statističnimi metodami, mora k delu pristopiti na resen način. Umetne nevronske mreže, tako kot vsaka druga znanstvena metoda, lahko dajo dobre rezultate, kakšni pa ti bodo je odvisno predvsem od izbora metode ter od načina uporabe. Danes v svetu obstaja široka paleta različnih nevronskih mrež – razvoj se odvija s tako naglico, da se vsako leto pojavi nekaj novih modelov. Vsak od njih vsebuje svoje posebne značilnosti, ki ga razlikujejo od ostalih. Izbor metode je odvisen predvsem od vrste problema ter od strukture vhodnih podatkov. Vsaka metoda nadalje predstavlja nepregledno množico različnih variant. Z izborom števila nevronskih nivojev, povezav med njimi, števila nevronov v posameznih nivojih, pragovnih funkcij, učilnih algoritmov, Ō, doseže število možnih kombinacij nesluteno razsežnost. Trenutno še ni razvite metodologije za pravilno določitev prej omenjenih parametrov. Uporabnik je zato prepuščen samemu sebi, da z uporabo intuicije in s čim večjim številom poiskusnih mrež najde optimalno rešitev. Vendar pa se tudi v primeru, da je izbrana metoda optimalna in je mreža pravilno zgrajena lahko zgodi, da bo končni rezultat slabši od naših pričakovanj. Predvsem v primerih, ko rešujemo linearne oziroma skoraj linearne pojave, se izkaže, da se z uporabo umetnih nevronskih mrež v najboljšem primeru lahko le približamo statističnim rešitvam. Zaradi vsega prej naštetega je za uporabnika zelo pomembno, da se zaveda tako prednosti, kot tudi slabosti umetnih nevronskih mrež.

Prednosti

Umetne nevronske mreže odlikujejo predvsem naslednje lastnosti:


- Sposobne so se učiti iz podatkov. Tudi v primerih, ko nam ni dostopno znanje o zakonitostih, ki vplivajo na nek pojav, lahko z uporabo nevronske mreže uspešno modeliramo njegovo delovanje.
- Rešitve pridobljene na tak način so nelinearne.
- Vsebujejo prirojeno sposobnost posploševanja.
- Odlično rešuje težave, ki pri statističnih metodah lahko nastanejo zaradi medsebojne odvisnosti vhodnih spremenljivk.
- Zaradi velike sposobnosti posploševanja zelo dobro rešuje težave, ki nastanejo zaradi šuma v vhodnih podatkih.
- Tudi v primerih, ko v mrežo vstopajo le delni vhodni podatki, torej ko del podatkov manjka, so nevronske mreže zaradi razpršenega zapisa znanja v utežeh sposobne izdelati relativno dobre rešitve. To pomeni, da so sposobne sklepati, kakšen naj bi bil manjkajoči del podatkov.
- Ko je mreža enkrat naučena, lahko z njo zelo hitro obdelujemo podatke.

Slabosti

Ob vsestranski uporabnosti se je potrebno zavedati tudi slabih strani nevronske mreže. Mnoge od njih so bile omenjene že v prejšnjih poglavjih, kljub temu pa je dobro če si jih na tem mestu še enkrat ogledamo v združenih oblikah. Z vsakodnevnim razvojem sicer prihajajo nove in nove rešitve, vendar so uporabniki trenutno še vedno soočeni z naslednjimi slabostmi:

- Za uspešno učenje potrebujemo veliko število kvalitetnih vhodnih podatkov. V primeru, da podatki niso kvalitetni, je taka tudi rešitev (ang. garbage in - garbage out).
- Iskanje optimalne nevronske mreže ter njeno učenje je lahko zelo dolgotrajen proces.
- Razen ART druge nevronske mreže ne rešujejo problema hkratnega pomnjenja novih in ohranjanja starih vzorcev. Zato je zelo pomembno, da so vhodni podatki pravilno strukturirani - v primeru klasifikacijskih nevronske mreže morajo biti v vhodnih podatkih vsi razredi enako zastopani.
- Pri gradientnih učilnih algoritmih se pojavlja problem lokalnih minimumov.
- Rešitve, ki jih pridobimo, so ponavadi nejasne. V večini primerov je nemogoče ugotoviti kakšne so zakonitosti, ki privedejo sistem do pravilnega delovanja. V literaturi pogosto nevronske mreže primerjajo s črno skrinjico - na eni strani podatki vstopajo, na drugi izstopajo, kakšni so notranji mehanizmi pa ostaja očem skrito. Iz tega sledi, da moramo biti zelo previdni pri izboru metode s katero želimo interpretirati podatke. Vnaprej moramo določiti namen našega dela. Če želimo le postaviti nek model, ki bo pravilno deloval in nas mehanizmi ne zanimajo, so nevronske mreže vsekakor priporočljive. Nasprotno pa v primeru, ko želimo analizirati postopke in dognati zakonitosti, nevronske mreže le redkokdaj pridejo v poštev.
- Težave zaradi »pretreniranosti«. Cilj procesa učenja je doseči čim boljše prilagajanje učnim podatkom. S spreminjanjem uteži v mreži skušamo delovanje modela privedi do čim manjše napake. Seveda pa je glavni cilj izdelati model, ki ne bo deloval le na učnih podatkih ampak se bo enako dobro obnesel tudi na katerikoli

drugih podatkih. Zato je potrebno v postopku učenja neprenehoma izvajati tudi postopke testiranja. V ta namen je potrebno uporabiti testne podatke, ki niso enaki učnim. Preučevanje napake (glej sliko 13) kaže na to, da se ta za učne in testne podatke ne zmanjšuje enako hitro. V neki točki pa se napaka na testnih podatkih začne povečevati kljub temu, da se nad učnimi podatki še naprej zmanjšuje. V tej prevojni točki je dosežen trenutek, ko rečemo, da je od tu naprej mreža »pretrenirana«. Predolg proces učenja vodi v efekt slabega posploševanja. Z drugimi besedami lahko rečemo, da je mreža izgubila sposobnost posploševanja, pričel pa se je proces memoriranja učnih podatkov. S tem se v utežeh v bistvu zapisuje vsak učni podatek posebej, hkrati s tem pa se izgublja sposobnost uspešne obdelave doslej še neznanih podatkov. Učenje je potrebno v prevojni točki prekiniti. Načeloma bi napako nad učnimi podatki lahko poljubno zmanjšali z povečevanjem števila nevronov, vendar pa bi hkrati s tem izgubili sposobnost posploševanja.



Sl. 13. Napaka na učnih in testnih podatkih ni enaka

Klasifikacija satelitskega posnetka z uporabo FMC

V nadaljevanju sledi prikaz klasifikacije z FMC (ang. Feature Map Classifier). To je metoda, ki kombinira nenadzorovano učenje SOM in nadzorovano učenje po metodi BPG. Uporabljena mreža je bila sestavljena iz:

- vhodnega nivoja nevronov, ki vsebuje sedem vhodnih nevronov od katerih vsak predstavlja po en kanal Landsat TM posnetka.
- SOM nivo oziroma Kohonenov nivo sestavlja matriko 20×20 nevronov, kar pomeni, da je sestavljen iz 400 nevronov.
- Izhodni nivo nevronov je bil odvisno od primera (števila razredov) sestavljen iz 16, 9 in 5 izhodnih nevronov od katerih vsak predstavlja po en razred.

Učenje je potekalo v dveh korakih. V prvem je bil izveden nenadzorovani del učenja, v katerem so se določile uteži med vhodnim in Kohonenovim nivojem. S tem se je izvedla samo-organizacija matrike. To pomeni, da bližnji nevroni zmagujejo

(vsota vseh prispevkov iz vhodnega nivoja je najvišja) kadar so si vhodni podatki podobni. V drugi fazi učenja uteži Kohonenovega nivoja mirujejo, nadzorovano učenje pa po BPG metodi poteka med Kohonenovim in izhodnim nivojem. Za učenje in testiranje sta bili izdelani dve datoteki s po 4000 vhodnih in izhodnih podatkov v vsaki. Učenje je potekalo tako, da je v vsakem iteracijskem koraku v učni proces vstopilo 200 naključno izbranih vektorjev (vhodnih podatkov) in njim pripadajočih razredov. Na tej osnovi je bila izračunana napaka, utežni vektorji pa so se za majhen delež premaknili v smeri največjega zmanjšanja napake. Za uspešno organiziranje SOM nivoja je bilo potrebnih 80000 iteracij, učenje izhodnega nivoja pa je v odvisnosti od števila izhodnih razredov nihalo od 250000 za 16 razredov do 150000 za 5 razredov. Pri večjem številu iteracijskih korakov so se že pokazali prvi znaki »pretreniranosti«.

Klasifikacija - 16 razredov

Začetna klasifikacija je bila izvršena nad vsemi 16 izhodiščnimi razredi:


1. Q melišča in pobočni grušč
2. Q aluvij
3. Q morski sedimenti
4. E_2 fliš
5. $^{1,2}E_2$ lapor
6. Pc, E alveolinski in numulitni apnenec
7. Pc_2 miliolidni apnenec
8. $_{2}Pc_1$ kozinski skladi
9. K, Pc apnenec z giropleurami
10. K^2 črni ploščasti apnenec
11. K_2^2 rudistni apnenec
12. $K_2^{2,3}$ apnenci z radioliti
13. K_2^3 apnenec
14. $K_1^{1,2}$ rudistni apnenec z vložki dolomita
15. $K_{1,2}^2$ dolomit, breča in apnenec
16. $K_{1,2}$ pretežno dolomit

Rezultati dobljeni z uporabo FMC so zanimivi iz dveh zornih kotov. Po eni strani si lahko ogledamo natančnost klasifikacije, po drugi strani pa so še zlasti zanimivi rezultati nenadzorovane faze učenja - samoorganizacije nevronov v Kohonenovem nivoju. Ti predstavljajo dvodimenzionalno karto (v tem primeru razsežnosti 20×20), kjer je vsakemu nevronu predpisana pripadnost v določen razred. Na ta način za vsak razred dobimo SOM karto, kjer s temnejšo barvo označimo nevrone, ki bolj pogosto zmagujejo (imajo višjo vsoto vseh prispevkov iz vhodnega nivoja) in obratno s svetlejšo barvo označimo nevrone, ki ne izkazujejo pripadnosti k razredu. Pri litološki klasifikaciji v 16 razredov dobimo 16 SOM kart - za vsak razred po eno, kjer lahko glede na podobnost pojavljanja preučujemo podobnost oziroma razliko med razredi. Take karte so zlasti uporabne pri umetno postavljenih kategorizacijah (npr. razdelitev terena glede na stabilnost), kjer je na ta način možno odpraviti slabosti v klasifikaciji, oziroma na novo postaviti razrede, ki so med seboj bolj ločljivi. V primeru litološke klasifikacije temu ni tako, saj so razredi že vnaprej trdno določeni gle-

de na geološko podlago (karto).

Iz slike 14 je razvidno, da so zares dobro diferencirani le morski sedimenti, lapor in $K_{1,2}$ dolomit, breča in apnenec, medtem ko ostali razredi pokrivajo podoben prostor oziroma niso lahko ločljivi med sabo. Kljub vsemu se da ugotoviti, da nadaljnje združevanje razredov lahko poteka po enakem postopku kot pri delu s standardnimi metodami:

- R6, R7, R8, R9, R11 in R13
- R5 in R12
- R2 in R4




SL 14. SOM karte za 16 razredov

Nekoliko vprašljivo je le združevanje razredov R5 in R12, saj bi razred R12 veliko lažje uvrstili v razred, ki združuje razrede R6, R7, R8, R9, R11 in R13. Zaradi primerljivosti s standardnimi metodami je bilo v nadaljevanju izvedeno prvotno zastavljeno združevanje razredov.

Po zaključku nenadzorovane faze učenja, torej ko je SOM nivo že naučen in so uteži do vhodnega nivoja določene, je bila izvedena še nadzorovana faza učenja po metodi BPG. Za uspešno izvedeno učenje je bilo potrebnih še 250.000 učnih iteracij. Na ta način je bil izdelan FMC klasifikator za 16 razredov. V nadaljevanju je bila nad satelitskim posnetkom obravnavanega področja z uporabo FMC klasifikatorja izdelana klasifikacija. Rezultati so podani v tabelah 10 in 11 in na sliki 15.

Tabela 10. Pravilnost klasifikacije z FMC metodo za 16 razredov

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	8432	6507	---	---	---
1	138	3860	87	63.04%	2.25%	11.91%
2	1408	5583	801	56.89%	14.35%	28.57%
3	411	2160	321	78.10%	14.86%	34.07%
4	14999	1970	1375	9.17%	69.80%	25.30%
5	242	908	26	10.74%	2.86%	5.54%
6	6616	2288	1331	20.12%	58.17%	34.21%
7	960	780	59	6.15%	7.56%	6.82%
8	1656	816	107	6.46%	13.11%	9.20%
9	1585	1707	243	15.33%	14.24%	14.77%
10	304	2175	86	28.29%	3.95%	10.57%
11	1664	1620	186	11.18%	11.48%	11.33%
12	1204	948	206	17.11%	21.73%	19.28%
13	2608	4399	998	38.27%	22.69%	29.47%
14	1403	2123	661	47.11%	31.14%	38.30%
15	1380	2125	304	22.03%	14.31%	17.76%
16	652	2366	433	66.41%	18.30%	34.86%
Povprečna vrednost:				31.03%	20.05%	20.75%
Skupna natančnost SN:				31.02%		



Sl. 15. Rezultat FMC klasifikacije za 16 razredov (zgoraj) in enaka klasifikacija z uporabo X in Y koordinat (spodaj)

Tabela 11. Klasifikacijska tabela za FMC klasifikacijo v 16 razredov

	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15	R16
0	0	4	14	384	8	463	96	103	141	16	186	61	243	18	182	6
R1	87	27	1	1895	51	631	76	126	195	33	218	42	213	35	161	4
R2	2	801	51	4065	1	183	19	63	97	41	45	15	88	14	89	0
R3	0	376	321	1049	9	194	9	20	12	2	2	9	105	1	38	0
R4	6	30	0	1375	16	181	26	45	36	13	67	7	112	4	49	0
R5	2	2	0	303	26	278	39	24	36	3	71	31	35	10	11	8
R6	3	25	0	284	15	1331	63	91	96	4	75	98	66	93	11	9
R7	0	10	0	213	3	211	59	50	28	3	36	64	54	15	10	9
R8	0	7	23	140	2	217	38	107	98	9	41	34	27	37	13	5
R9	2	18	0	407	12	363	73	162	243	28	107	24	133	25	99	2
R10	9	73	0	1161	2	111	52	137	150	86	146	5	71	1	167	0
R11	4	12	0	659	13	289	44	52	52	24	186	26	175	13	43	1
R12	2	1	0	95	14	257	65	65	34	0	21	206	19	97	1	43
R13	8	4	0	1524	23	703	128	88	166	23	339	43	998	25	195	4
R14	4	1	0	132	11	482	66	248	64	0	12	271	31	661	7	128
R15	5	17	1	928	19	216	39	68	126	19	83	5	181	1	304	0
R16	4	0	0	385	17	506	68	207	11	0	29	263	57	353	0	433

Klasifikacija - 9 razredov

Klasifikacija za 9 razredov je zaradi lažje primerljivosti z statističnimi metodami potekala nad istimi devetimi razredi kot v poglavju o klasifikaciji s standardnimi metodami. Ciljni razredi so torej:

1. Q melišča in pobočni grušč
2. Q aluvij + 3E_2 fliš
3. Q morski sedimenti
4. $^{1,2}E_2$ lapor + $K_2^{2,3}$ apnenec z radioliti
5. Pc, E alveolinski in numulitni apnenec + Pc_2 miliolidni apnenec + 2Pc_1 kozinski skladi + K, Pc apnenec z giropleurami + K_2^3 rudistni apnenec + K_2^3 apnenec
6. K_2^3 črni ploščasti apneneci
7. $K_2^{1,2}$ rudistni apnenec z vložki dolomita
8. $K_{1,2}$ dolomit, breča in apnenec
9. $K_{1,2}$ pretežno dolomit

FMC klasifikacija za 9 razredov je potekala na enak način kot pri razvrščanju v 16 razredov, le da je izhodni nevronski nivo vseboval le 9 nevronov. Rezultati so podani v tabelah 12 in 13 ter na sliki 16.


Slika 16. Hromidni FMC klasifikacija po 9 razredih. Na sliki je prikazana klasifikacija v opredeljenih 9 razredih po FMC klasifikaciji.

Tabela 12. Natančnost za FMC klasifikacijo z 9 razredi

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	8287	6461	---	---	---
1	138	5507	91	65.94%	1.65%	32.99%
2	16407	6580	5330	32.49%	81.00%	51.30%
3	411	3253	360	87.59%	11.07%	31.14%
4	1446	4799	465	32.16%	9.69%	17.65%
5	15088	1084	737	4.88%	67.99%	18.22%
6	304	6321	185	60.86%	2.93%	13.35%
7	1403	3067	760	54.17%	24.78%	36.64%
8	1380	2871	302	21.88%	10.52%	15.17%
9	652	2490	407	62.42%	16.35%	31.95%
Povprečna vrednost:				46.93%	25.11%	27.60%
Skupna natančnost SN:				34.11%		

Tabela 13. Klasifikacijska matrika za FMC z 9 razredi

	R1	R2	R3	R4	R5	R6	R7	R8	R9
0	1	357	14	64	1166	17	15	182	10
R1	91	2223	0	117	2675	42	27	249	2
R2	3	5330	10	53	984	28	15	139	1
R3	3	2155	360	23	578	2	3	75	0
R4	2	1036	0	465	2873	6	143	15	62
R5	0	293	0	15	737	1	10	25	1
R6	22	3240	0	70	2353	185	43	387	5
R7	10	233	0	340	1546	2	760	6	164
R8	4	1121	4	27	1233	20	9	302	0
R9	2	419	23	272	943	1	378	0	407



Sl. 16. Rezultat FMC klasifikacije za 9 razredov (zg.) in enaka klasifikacija z uporabo X in Y koordinat (sp.)

Klasifikacija - 5 razredov

V zadnjem primeru klasifikacije z FMC je v proces učenja vstopilo pet razre-

1. Q melišča in pobočni grušč + Q aluvij + 3E_2 flis
2. Q morski sedimenti
3. $^{12}E_2$ lapor + K_2^{33} apnenec z radioliti + Pc, E alveolinski in numulitni apnenec + Pc_2 miliolidni apnenec + 3Pc_1 kozinski skladi + K, Pc apnenec z giropleurami + K_2^3 rudistni apnenec + K_2^3 apnenec + K_2^3 črni ploščasti apnenec + K_2^{32} rudistni apnenec z vložki dolomita
4. $K_{1,2}$ dolomit, breča in apnenec
5. $K_{1,2}$ pretežno dolomit


dov: FMC klasifikacija za 9 razredov je potekala na enak način kot pri razvrščanju v 9 in 16 razredov, le da je izhodni nevronske nivo vseboval le 5 nevronov. Rezultati so podani v tabelah 14 in 15 ter na sliki 17.

Tabela 14. Natančnost za FMC klasifikacijo s 5 razredi

Razred	Število celic v razredu	Število celic klasificiranih v razred	Število pravilno klasificiranih celic	NP _n	UN _n	P _n
neklas.	7030	7578	6224	---	---	---
1	16545	9896	6111	36.94%	61.75%	47.76%
2	411	3095	365	88.81%	11.79%	32.36%
3	18241	7887	5489	30.09%	69.60%	45.76%
4	1380	10992	908	65.80%	8.26%	23.31%
5	652	4811	590	90.49%	12.26%	33.31%
Povprečna vrednost:				62,43%	32,73%	36,50%
Skupna natančnost SN:				44,48%		

Tabela 15. Klasifikacijska tabela za FMC klasifikacijo s 5 razredi

	R1	R2	R3	R4	R5
0	283	14	921	133	3
R1	6111	6	3455	231	2
R2	2288	365	404	26	0
R3	2167	0	5489	81	55
R4	4910	26	4662	908	2
R5	786	0	3310	1	590



Sl. 17. Rezultat FMC klasifikacije za 9 razredov (zg.) in enaka klasifikacija z uporabo X in Y koordinat (sp.)

Analiza uspešnosti klasifikacijskih metod

Namen zgoraj opisanih del je bil ugotoviti uporabnost dveh različnih klasifikacijskih metod, standardne statistične metode z uporabo kriterija največje podobnosti in samoorganizirajočih matrik z nadgradnjo v FMC. Primerjava obeh metod je podana v tabeli 16.

Tabela 16. Primerjava klasifikacijskih metod

	Povprečje	Standardni pristop	FMC pristop
16 Razredov	NP_n	25.69%	31.03%
	UN_n	21.14%	20.05%
	P_n	14.82%	20.75%
	SN	23.39%	31.02%
9 Razredov	NP_n	42.45%	46.93%
	UN_n	26.27%	25.11%
	P_n	22.16%	27.60%
	SN	29.42%	34.11%
5 Razredov	NP_n	59.85%	62.43%
	UN_n	40.47%	32.73%
	P_n	38.87%	36.50%
	SN	48.80%	44.48%

Iz dobljenih rezultatov lahko ugotovimo, da klasifikacija z umetnimi nevronskimi mrežami - v tem primeru z metodo FMC ni vedno boljša od standardnih metod. V primeru klasifikacije 16 razredov se metoda po kriteriju največje podobnosti izkaže za slabšo v vseh kriterijih, razlika je že manjša v primeru klasifikacije v 9 razredov, medtem ko se v primeru klasifikacije v 5 razredov standardni pristop izkaže za boljšega v vseh kriterijih razen v povprečni natančnosti postopka. Natančnost obeh metod se z zmanjševanjem števila razredov približuje, pri majhnem številu razredov pa se standardni pristop izkaže za boljšega od FMC. To je posledica naslednjih dejstev:

- Večje število razredov zahteva močnejše razmejitvene sposobnosti multivariatnega prostora. To je ena od pglavitnih prednosti nevronskih mrež zato se te praviloma bolje izkažejo v primeru večih razredov.
- Standardne metode delujejo na statističnih načelih. To pomeni, da morajo biti vhodni podatki normalno porazdeljeni, prav tako pa mora biti porazdelitev normalna znotraj posameznih razredov. Z združevanjem razredov v splošnem pridobivamo na normalnosti, zato se klasifikacijske sposobnosti statističnih metod z manjšim številom razredov izboljšujejo.
- Združevanje med seboj podobnih si razredov - to je razredov, ki se med seboj prekrivajo/prepletajo prispeva k njihovi večji homogenosti in lažji ločljivosti od drugih razredov. Moč umetnih nevronskih mrež je med drugim tudi v boljšem omejevanju multivariatnega prostora zato homogenizacija razredov v manjši meri pripelje k boljši natančnosti kot je to primer pri standardnih metodah.

V nadaljevanju je potrebno opozoriti še na en način klasifikacij satelitskih posnetkov, ki v primeru statističnih metod ni smislen. Če k vhodnim podatkom dodamo X in Y koordinati (7 TM kanalov + X + Y) se klasifikacijske sposobnosti nevronske mreže izredno povečajo (glej tabelo 17 in slike 15, 16 in 17). V model smo s tem vpeljali še prostorsko lego točk. Tako naučen model glede na geografsko lego vhodnih podatkov že vnaprej določenim razredom predpisuje večjo verjetnost pojavljanja. Pri tem se je potrebno zavedati naslednjih omejitev:

- Učni podatki, ki vstopajo v model v učni fazi morajo biti enakomerno porazdeljeni po prostoru.
- Tako izdelan model je uporaben samo na tem področju. To ne more biti univerzalni klasifikator ampak je strogo vezan na specifični primer. Pri ugotavljanju litoloških mej se uporabnost tovrstnih klasifikatorjev izkaže zlasti pri prehodu iz manjših v večja merila.

Tabela 17. Natančnost FMC klasifikacij z upoštevanom prostorsko lego

	Povprečje	UNN + XY
16 razredov	NP _n	53.21%
	UN _n	40.17%
	SN	49.99%
9 razredov	NP _n	77.63%
	UN _n	42.08%
	SN	66.19%
5 razredov	NP _n	77.97%
	UN _n	50.52%
	SN	64.44%

Zaključek

Obdelava digitalnih podob, v našem primeru satelitskih posnetkov, v slovenskem prostoru še ni doživela uveljavitve ampak predstavlja le eno od metod, ki bi lahko v prihodnosti dala pozitivne rezultate. Zaradi poraščenosti slovenskega ozemlja je geološka interpretacija satelitskih posnetkov močno otežena, vendar pa v svetu v naslednjih nekaj letih na tem področju napovedujejo pravo revolucijo. Že letos bo lansiran prvi komercialni satelit z monokromatsko ločljivostjo 1m in pankromatsko 4m. Hkrati s tem se pričakuje prehod na hiperspektralne posnetke (skenerji z 200 in več kanali) in večjo radiometrično ločljivostjo. Vse večja komercializacija in ostri konkurenčni boj že sedaj znižuje cenovna razmerja, tako da lahko v kratkem pričakujemo, da bodo posnetki dostopni za razmeroma nizko ceno. Če k temu dodamo še razvoj novih interpretativnih metod, lahko zelo kmalu pričakujemo uporabne rezultate tudi za taka ozemlja kot je slovensko. Odpirajo se številne možnosti:

- Pomoč pri določanju skritih litoloških mej, zlasti pri prehodu iz manjših v večja merila.

- Pomoč terenskim geologom pri določanju obhodnih poti.
- Izdelava bolj natančnih tematskih kart (prehod v večje merilo) s korelacijo tematskih kart manjših meril in satelitskih posnetkov (npr. geokemične karte).
- Metode uporabljene pri digitalni obdelavi podob niso uporabne le za interpretacijo daljinsko pridobljenih podatkov ampak lahko na ta način obdelamo vse vrste prostorskih podatkov (geofizikalni, geokemični ...).
- ...

V članku je predstavljena uporaba samo-organizirajočih matrik ter njihova razširitev v FMC (ang. Feature Map Classifier) z dodajanjem BPG (ang. backpropagation) nevronskega nivoja. V primeru več razredov se je ta metoda pokazala za boljše od standardnega pristopa, ob zmanjševanju števila razredov pa se je zmanjševala tudi razlika med obema metodama. Statistične metode odlikujeta preglednost odločitvenega mehanizma in hitrost izračuna, njihova slabost pa je domneva normalne porazdelitve podatkov. V primeru, ko temu ni tako ali v primerih, ko je en razred zastopan na večih mestih spektralnega prostora statistične metode odpovejo. V nasprotju s tem umetne nevronske mreže niso odvisne od normalnosti porazdelitve in so mnogo bolj sposobne razmejiti spektralni prostor.

Velike razmejivne sposobnosti umetnih nevronske mreže bi v klasifikacijski model načeloma lahko dovoljevale vpeljavo zemljepisnih koordinat. Kljub boljši natančnosti je potrebno pri interpretaciji uporabiti veliko mero previdnosti. Uporaba zemljepisnih koordinat zahteva, da so učni podatki razporejeni enakomerno preko celotnega ozemlja, po drugi strani pa umetne nevronske mreže zahtevajo, da je vsak razred zastopan s podobnim številom primerov. Uspešnost metode je odvisna od uspešnosti v iskanju srednje poti med obema zahtevama. Postavlja se vprašanje ali uporaba zemljepisnih koordinat res prinaša željeni napredek. Če je za uspešen rezultat potrebna enakomerna zastopanost učnih podatkov preko celotnega ozemlja, to pomeni, da moramo ozemlje že vnaprej dobro poznati. V takih primerih je vprašljiva smiselnost raziskav. Pravzaprav vidim možnosti le pri prehodu iz manjših v večja merila, kjer lahko karte manjših meril služijo kot učni podatek za natančnejšo določitev mej med razredi. Ob tem bi bilo potrebno zmanjšati vpliv zemljepisnih koordinat kar bi bilo možno z njihovim »mehčanjem«¹ n predelavo v mehko obliko, kot jo pozna mehka logika (ang. fuzzy logic).

Literatura

- Bratko, I., Džeroski, S., Kompare, B., Walley, W.J. 1998: Analysis of Environmental Data with Machine Learning Methods, IJS, Ljubljana.
- Buser, S., 1965: Osnovna geološka karta SFRJ Gorica 100.000 (Geological map of SFRJ Gorica 1:100.000). - Zvezni geološki zavod, Beograd.
- Buser, S., 1964: Tolmač lista Gorica. Osnovna geološka karta SFRJ 1:100.000 (Explanatory text for sheet Gorica. Geological map of SFRJ 1:100.000). - Zvezni geološki zavod, 50 p., Beograd.
- Gallant, S., 1993: Neural Network Learning, The MIT Press, London.
- Gonzales, R.C. & Woods, R.E. 1993: Digital image processing. - Addison - Wesley Publishing Company, 716 p., Detroit.
- Gupta, R.P. 1991: Remote sensing geology. - Springer-Verlag, 356 p., Berlin.
- Hebb, D.O. 1949: The Organization of Behavior, Wiley, New York.
- Kohonen, T., 1984: Self-Organization and Associative Memory, Springer-Verlag, Berlin.
- Kohonen, T., Hynninen, J., Kangas, J., Laaksonen, J., 1995: SOM PAK The Self-Organizing Map Program Package, Helsinki University of Technology, Laboratory of Computer and Information Science, Helsinki.

Kostwinder, H. 1995: Introduction to image enhancement. - International Institute for Aerospace Survey and Earth Sciences, 4/1 - 4/13, Enschede.

Lillesand, T.M. & Kiefer, R.W. 1994: Remote sensing and image interpretation. - John Wiley & Sons, 750 p., New York.

Lippman, R.P. 1987: An Introduction to Computing with Neural Nets, IEEE ASSP Magazine, vol. 4.

McClelland, J., Rumelhart, D., 1986: Parallel Distributed Processing, MIT Press, Cambridge, MA.

Parker, D.B., 1985: Learning Logic, Technical Report TR-47, Centre for Computational Research in Economics and Management Science, MIT, Cambridge, MA.

Pleničar, M., Polšak, A., Šikić, D. 1965: Osnovna geološka karta SFRJ Trst 100.000 (Geological map of SFRJ Trieste 1:100.000). - Zvezni geološki zavod, Beograd.

Pleničar, M., Polšak, A., Šikić, D. 1965: Tolmač lista Trst. Osnovna geološka karta SFRJ 1:100.000 (Explanatory text for sheet Trieste. Geological map of SFRJ 1:100.000). - Zvezni geološki zavod, 68 p., Beograd.

Reeves, R.G. 1968: Introduction to electromagnetic remote sensing with emphasis on applications to geology and hydrology. - Am. Geol. Inst., Washington.

Sabins, F.F. JR. 1987: Remote sensing principles and interpretation, 2nd ed. - Freeman and Company, New York, 449 p., New York.

Swain, P.H. and Davis, S.M.(eds.) 1978. Remote Sensing: The Quantitative Approach, McGraw-Hill, Inc., New York, 396 p.

Vickers, R.S. & Lyon, R.J.P. 1967: Infrared sensing from spacecraft - a geological interpretation. - Proc. Thermophysics Spec. Conf., Am. Inst. Aeronautics Astronautics, 67-284, Washington.

Werbos, P. 1974: Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences, PhD thesis, Harvard, Cambridge, MA.

Widrow, B., Hoff, M.E., 1960: Adaptive Switching Circuits, Institute of Radio Engineers, Western Electronic Show and Convention, Convention Record, part 4

Zavod Republike Slovenije za statistiko 1993: Georeferencirani mozaik Slovenije izdelan iz podatkov satelita Landsat - TM (Georeferenced mosaic of Slovenia produced from LANDSAT-TM data). - 314,4 MB, Ljubljana.

