

Kartiranje ležišta ugljikovodika metodom umjetnih neuronskih mreža

Šapina, Marijan

Master's thesis / Diplomski rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering / Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:169:369345>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-09-12**



Repository / Repozitorij:

[Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU

RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Diplomski studij naftnog rudarstva

**KARTIRANJE LEŽIŠTA UGLJIKOVODIKA METODOM UMJETNIH
NEURONSKIH MREŽA**

Diplomski rad

Marijan Šapina

N 179

Zagreb, 2016.

KARTIRANJE LEŽIŠTA UGLJIKOVODIKA METODOM UMJETNIH NEURONSKIH
MREŽA

MARIJAN ŠAPINA

Diplomski rad izrađen: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za naftno inženjerstvo
Pijerottijeva 6, 10000 Zagreb

Sažetak

Računalno kartiranje ležišta ugljikovodika moguće je raznim metodama i tehnikama, primjerice metodama geostatističke procjene, ali i geomatematičkim metodama, kao što su primjena umjetnih neuronskih mreža. Metoda umjetnih neuronskih mreža se primarno koristi u slučaju manjkavih podataka i podataka u nelinearnom odnosu, a karakteristika te metode je da simulira postupak ljudskog učenja uvježbavanjem parametara nizom ponavljanja. U ovom radu je statističkom analizom i usporedbom s geostatističkim interpolacijskim metodama potvrđena postavljena hipoteza o uspješnom kartiranju izvornim algoritmom umjetne neuronske mreže izrađenom u programu za statističku obradu podataka „R“ na primjeru kartiranja dubine EK markera (elektrokarotaznog markera) Rs5 u području Bjelovarske subdepresije unutar Dravske depresije u hrvatskom dijelu Panonskog bazenskog sustava. Arhitektura mreže koja je dala najbolji izlaz je mreža s dva skrivena sloja, od kojih se prvi sastojao od 10 neurona, a drugi od 6. Korišten je algoritam s povratnim postupkom. Kros-validacijom su uspoređene dvije metoda kartiranja, s time da je algoritmom neuronske mreže dobivena vrijednost sume kvadrata pogreške 16294,5, a običnim krigranjem 14638,35.

Ključne riječi: Dravska depresija, geostatistika, kartiranje, povratni postupak, umjetne neuronske mreže.

Diplomski rad sadrži: 35 stranica, 2 tablice, 18 slika, 2 priloga i 25 referenci.

Jezik izvornika: hrvatski

Diplomski rad pohranjen: Knjižnica Rudarsko-geološko-naftnog fakulteta
Pierottijeva 6, Zagreb

Voditelj: Dr. sc. Tomislav Malvić, izvanredni profesor RGNF

Ocjenjivači: Dr. sc. Tomislav Malvić, izvanredni profesor RGNF
Dr. sc. Josipa Velić, profesor emerita RGNF
Dr. sc. Zdenko Krištafor, redoviti profesor RGNF

Datum obrane: 24. lipnja 2016.

MAPPING OF HYDROCARBON RESERVOIRS USING ARTIFICIAL NEURAL NETWORKS

MARIJAN ŠAPINA

Thesis completed at: University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering
Department of Petroleum Engineering
Pierottijeva 6, 10000 Zagreb

Abstract

Computerised mapping of hydrocarbon reservoirs can be achieved using a wide range of methods and techniques, for example, geostatistical interpolation. The use of geomathematical methods is also possible, for example, the use of artificial neural networks. Artificial neural networks are primarily used in case of flawed data and data that are in a non-linear relation. The characteristic of this method is that it simulates the process of human learning by training and optimizing parameters through a series of repetitions. In this thesis, using statistical analysis and comparison with geostatistical interpolation methods, the hypothesis of successful mapping using this original artificial neural network algorithm has been confirmed. The algorithm has been made in "R", a statistical computing software, and is used for mapping of depth of e-log border "Rs5" in the Bjelovar Subdepression, as a part of the Drava Depression in the Croatian part of the Pannonian Basin System. The neural network architecture that produced best responses is a network with two hidden layers, with 10 and 6 neurons, respectively. Backpropagation algorithm was used. Two methods were compared by cross-validation and the neural network produced a mean squared error as 16294.5, and Ordinary Kriging produced 14638.35.

Keywords: artificial neural networks, backpropagation, Drava depression, geostatistics, mapping.

Thesis contains: 35 pages, 2 tables, 18 figures, 2 appendices and 25 references.

Original in: Croatian

Thesis deposited at: Library of Faculty of Mining, Geology and Petroleum Engineering,
Pierottijeva 6, Zagreb

Supervisor: Associate Professor Tomislav Malvić, Ph.D.

Reviewers: Associate Professor Tomislav Malvić, Ph.D.
Professor Emerita Josipa Velić, Ph.D.
Full Professor. Zdenko Krištafor, Ph.D.

Date of defense: 24 June 2016

SADRŽAJ

I. POPIS TABLICA	II
II. POPIS SLIKA	III
III. POPIS OZNAKA KORIŠTENIH U RADU	IV
1. UVOD	1
2. ZEMLJOPISNI SMJEŠTAJ I GEOLOGIJA PROMATRANOG PODRUČJA	2
2.1. TALOŽNE STIJENE MEZOZOIKA	4
2.2. TALOŽNE STIJENE DONJEG I SREDNJEG MIOCENA	4
2.3. TALOŽNE STIJENE GORNJEG PANONA	5
2.4. TALOŽNE STIJENE DONJEG PONTA	6
2.5. TALOŽNE STIJENE GORNJEG PONTA	7
2.6. TALOŽNE STIJENE I TALOŽINE PLIOCENA, PLEISTOCENA I HOLOCENA	8
3. PREGLED REZULTATA DOSADAŠNJIH ISTRAŽIVANJA I RADOVA UPORABE NEURONSKIH MREŽA U ISTRAŽIVANJU I RAZRADBI LEŽIŠTA UGLJIKOVODIKA	11
3.1. PRIMJENA UMJETNIH NEURONSKIH MREŽA U NAFTNOM INŽENJERSTVU	11
4. METODOLOGIJA	13
4.1. UMJETNE NEURONSKE MREŽE	14
4.1.1. Višeslojne neuronske mreže	17
4.2. PROGRAM ZA STATISTIČKU OBRADU PODATAKA „R“	17
4.3. DIJAGRAM TOKA ALGORITMA UMJETNIH NEURONSKIH MREŽA	18
5. ALGORITAM NEURONSKE MREŽE	20
5.1. REZULTATI I ODABIR NAJBOLJE MREŽE	22
6. STATISTIČKA ANALIZA	25
7. INTERPOLACIJA DUBINA EK-MARKERA „Rs5“ OBIČNIM KRIGIRANJEM	27
7.1. VARIOGRAMSKA ANALIZA	28
7.2. INTERPOLACIJA OBIČNIM KRIGIRANJEM	29
8. DISKUSIJA I ZAKLJUČAK	31
9. LITERATURA	33

I. POPIS TABLICA

Tablica 5-1. Nasumično izabrani ulazni i izlazni podatci neuronske mreže	24
Tablica 6-1. Rezultati analize pouzdanosti i korelacijske analize	25

II. POPIS SLIKA

Slika 2-1 Zemljopisni položaj Bjelovarske subdepresije	2
Slika 2-2 Litostratigrafske jedinice unutar Dravske depresije	4
Slika 2-3. Karta debljine formacije Moslavačka gora	6
Slika 2-4. Karta debljine formacije Ivanić-Grad	7
Slika 2-5. Karta debljine formacije Kloštar-Ivanić	8
Slika 2-6. Karta debljine formacije Bilogora	9
Slika 2-7. Karta debljine formacije Lonja	10
Slika 4-1. Karta s položajem ulaznih, odnosno mjerenih, vrijednosti	13
Slika 4-1. Shema neuronske mreže s više ulaza i jednim izlazom	14
Slika 4-2. Sigmoidna aktivacijska funkcija	15
Slika 4-3. Prilagođavanje težinskih koeficijenata i smanjivanje pogreške	16
Slika 4-4. Dijagram toka algoritma neuronske mreže	19
Slika 5-1 Shematski prikaz neuronske mreže	22
Slika 5-2. Karta dubine EK markera „Rs5“ dobivena algoritmom neuronskih mreža	23
Slika 6-1. Dijagram odnosa ulaznih i izlaznih podataka	26
Slika 7-1. Eksperimentalni variogram s pripadajućom krivuljom	29
Slika 7-2. Aproksimacija variograma teoretskim modelom	29
Slika 7-3. Karta EK markera „Rs5“ dobivena metodom običnog krigiranja	30

III. POPIS OZNAKA KORIŠTENIH U RADU

E – funkcija pogrješke umjetne neuronske mreže;

f - aktivacijska funkcija umjetne neuronske mreže;

h – izlazni podatci kod mjerenja pogrješke sume kvadratne pogrješke;

l – promatrani, tj. ulazni podatci za mjerenje pogrješke sume kvadratne pogrješke;

$N(h)$ - broj parova podataka uspoređenih na udaljenosti ' h ' kod računa variograma;

o_{lh} – predviđena vrijednost izlaza kod računa sume kvadratne pogrješke;

p - vjerojatnost opažanja podataka kakvi su na promatranom uzorku (ili ekstremnijih podataka) kada je nulta hipoteza istinita;

w_i - težinski koeficijent i -tog ulaza umjetne neuronske mreže;

x_i - vrijednost i -tog ulaza umjetne neuronske mreže;

y_{lh} – promatrani izlaz kod računa sume kvadratne pogrješke;

Z_k - vrijednosti varijable na odabranoj lokaciji kod računa krigiranja;

z_i - postojeći podatci za kartiranje krigiranjem;

$Z_1...Z_n$ - mjerene vrijednosti u točkama za račun krigiranja;

z_n - vrijednost varijable na lokaciji ' n ';

z_{n+h} - vrijednost varijable na lokaciji udaljenoj za ' h ' od promatrane lokacije ' n '.

α – Cronbachov alfa koeficijent značajnosti;

$2\gamma(h)$ - vrijednost variograma;

γ - vrijednost semivariograma na udaljenosti dviju točaka;

λ - težinski koeficijent dodan podacima u računu krigiranja;

λ_i - težinski koeficijent za lokaciju ' i ';

τ – Kendallov tau koeficijent korelacije.

1. UVOD

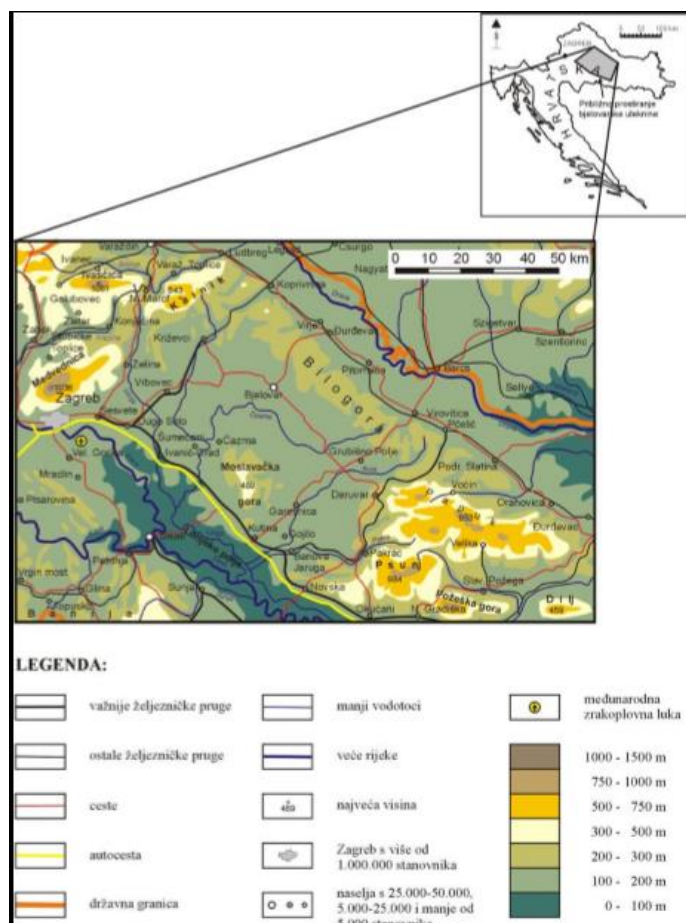
Geostatistika, znanstvena i stručna disciplina prostorne analize, nalazi značajnu primjenu u proučavanju geološke građe podzemlja te karakterizaciji geoloških modela. Kao polazište za temeljnu zadaću geostatistike, izradbu karte, koriste se različiti geološki podatci poput šupljikavosti, propusnosti, dubine, debljine i dr. Budući da prikupljeni podatci mogu biti manjkavi te u nelinearnom odnosu, u tom slučaju primjenu nalazi metoda umjetnih neuronskih mreža u kojoj se podatci ujedinjuju u jedan složeni ulazni skup. Karakteristika te metode je da simulira postupak ljudskog učenja uvježbavanjem i optimiziranjem parametara nizom ponavljanja. U geologiji ležišta fluida i naftnom inženjerstvu je metoda umjetnih neuronskih mreža razmjerno zahvalna metoda budući da se raspolaže velikim brojem podataka iz istraživačkih bušotina i postoji dugi kontinuitet prikupljanja podataka tijekom životnog vijeka proizvodnih bušotina pa se mogu izdvojiti i urediti ulazni skupovi podataka na najbolji način kako bi se minimizirala pogreška u predviđanju izlaza.

U ovomu radu je postavljena hipoteza uspješnog kartiranja metodom umjetnih neuronskih mreža izvornim algoritmom umjetne neuronske mreže izrađenom u programu za statističku obradu podataka „R“. Uspoređeni su rezultati kartiranja umjetnom neuronskom mrežom i geostatističkom interpolacijom, tj. metodom običnog kriginga. Metoda je primijenjena na kartiranju dubine EK markera (elektrokarotaznog markera) „Rs5“. EK marker je korelacijski horizont kojeg se izdvaja u stupovima bušotina, a izdvojen je temeljem određenog svojstva izmjenjenog bušotinskom karotazom. EK marker „Rs5“ predstavlja granicu formacija Moslavačka gora (taložne stijene donjeg i srednjeg miocena) te formacije Ivanić-grad (taložne stijene gornjega panona), a nalazi se u Bjelovarskoj subdepresiji koja je na jugozapadu Dravske depresije. U nastavku će biti detaljno objašnjen zemljopisni smještaj i geologija promatranog područja te metodologija istraživanja i način rada neuronske mreže čime će ovaj rad biti zaokružena cjelina.

2. ZEMLJOPISNI SMJEŠTAJ I GEOLOGIJA PROMATRANOG PODRUČJA

Hrvatski dio Panonskog bazenskog sustava smješten je na jugozapadu geološke makrojedinice najvećega reda nazvane Panonski bazenski sustav. Postojeće makrojedinice unutar Hrvatskog dijela Panonskog bazena su Murska, Dravska, Savska te Slavonsko-srijemska depresija.

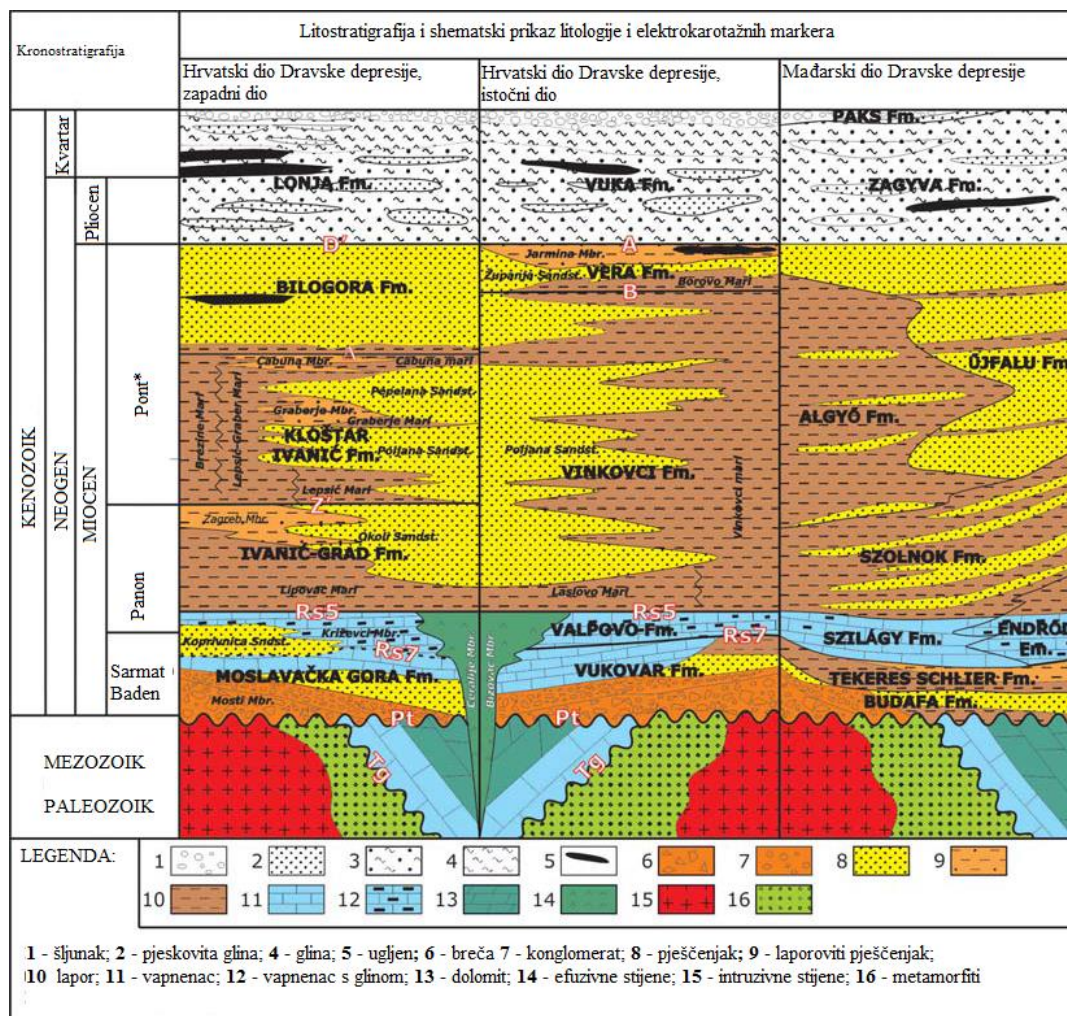
Dravska depresija se nalazi na području koje prelazi granice Republike Hrvatske na područje Republike Mađarske. Tako od ukupne površine od oko 12000 km² Republici Hrvatskoj pripada oko 9100 km² (Malvić & Cvetković, 2013). Na jugozapadu Dravske depresije se na površini od oko 2900 km² prostire Bjelovarska subdepresija. Zemljopisno, omeđena je Kalnikom na sjeverozapadu, Bilogorom na sjeveroistoku, Papukom, Ravnom gorom i Psunjem na istoku i jugoistoku te Moslavačkom gorom na jugu (slika 2-1).



Slika 2-1. Zemljopisni položaj Bjelovarske subdepresije (Malvić, 2003)

Dravsku depresiju općenito čine neogenske i kvartarne stijene i naslage (Malvić & Cvetković, 2013). Ukupne debljine naslaga mogu biti veće od 7000 m u središnjem dijelu depresije. Uz sedimentne stijene, mjestimice se mogu naći pojave efuzivnih stijena srednjomiocenske starosti kao i fluvijalnih i jezerskih sedimenata donjeg miocena. U većini slučajeva neogensko-kvartarna ispuna sastoji se od srednjo- i gornjomiocenskih, pliocenskih te pleistocenskih i holocenskih klastičnih i biogenih sedimenata. Stijene u podini neogensko-kvartarnoga slijeda su bitno drukčijeg litološkog sastava i stratigrafske pripadnosti. Radi se većinom o karbonatima (vapnencima i dolomitima), metamorfitima (amfibolitima, škriljavcima i gnajsevima) i magmatitima (granitima i gabrima) mezozojske i paleozojske starosti. Stijene u podini neogensko-kvartarnoga slijeda nisu litostratigrafski raščlanjene u Hrvatskom dijelu.

Na temelju brojnih bušotinskih (karotažnih) i seizmičkih podataka su razrađene proučavane kronostratigrafske i litostratigrafske jedinice Dravske depresije. Litostratigrafska raščlamba zapadnog dijela Dravske depresije načinjena je i prema raščlambi Savske depresije koje u pojedinim dijelovima odgovaraju jedna drugoj (slika 2-2). Ta dva područja zajedno predstavljaju krajnji južni (jugozapadni) dio Panonskog bazenskog sustava (PBS) u kojem su vladali slični mehanizmi i okoliši taloženja.



Slika 2-2. Litostratografske jedinice unutar Dravske depresije (Malvić & Cvetković, 2013)

U Bjelovarskoj subdepresiji su istraživačkim bušenjem otkrivene stijene koje su razvrstane u dvije skupine. Prvoj, mlađoj, pripadaju stijene neogensko-kvartarne starosti, a drugoj pripadaju mezozojski i paleozojski magmatiti, metamorfiti i karbonati (Malvić, 2003). U nastavku su detaljnije opisane taložne stijene, počevši od najstarijih.

2.1. TALOŽNE STIJENE MEZOZOIKA

Skupinu stijena mezozojske starosti čine vapnenci i dolomiti koji su iznimno trošeni i to do stupnja breče i konglomerata. Ove stijene svrstavaju se u podinu neogena unutar hrvatskoga dijela Panonskoga bazenskog sustava (skr. HPBS). Njihova starost

definirana je kao srednjotrijaska, što je načinjeno pomoću fosila i bušotinskih podataka koji su korelirani s izdancima na okolnim rubnim gorama, posebice taložinama srednjeg trijasa zapadnog Papuka. Litološki, radi se o istovrsnom dolomitu, dolomitičnom vapnencu te dolomitno-vapnenačkoj breči.


2.2. TALOŽNE STIJENE DONJEG I SREDNJEG MIOCENA

Sedimenti srednjega miocena označavaju početak sveobuhvatne transgresije na cijelom području subdepresije. Lokalno, u području Velike Ciglena i Dežanovca, pretpostavljeni su sedimenti i donjega miocena koji su taloženi u manjim jezerskim okolišima. Takvi manji prostori predstavljali su prethodnicu prve transtenzije koja je obilježila baden. Općenito, svi ti transtenzijski sedimenti taloženi su diskordantno na paleozojske te mezozojske stijene i sedimente u podini. Litostratigrafski pripadaju formaciji Moslavačka gora koja je podijeljena na član Mosti, približne starosti od badena, mjestimice donjeg miocena, pa do sarmata te mlađi član Križevci približno donjopanonske starosti (Malvić, 2003). Granica s paleozojskim i mezozojskim stijenama u podini je određena EK reperom „Tg“, a u krovini je određena EK markerom „Rs5“, koja čini granicu s formacijom Ivanić-Grad.

U vrijeme badena dolazi do taloženja sedimenata u marinskoj sredini zbog izrazite ekstenzijske tektonike. Samo su veće gore, poput Moslavačke, Kalnika, Papuka i Psunja ostale dijelom iznad morske razine i postale otoci. Trošenjem kopnenih i plitkomorskih dijelova paleozojskih stijena u priobalju je taložen siliciklastični materijal, najčešće mehanizmom aluvijalnih lepeznih delti. Dolazi do taloženja krupnoklastičnih sedimenata kao što su breče, konglomerati i krupnozrnati pješčenjaci. Krajem badena ekstenzijski pokreti slabe, opada veličina zrna te je taložen sitnozrnati pješčenjak, a zatim lapor i vapnenac.

Tijekom donjeg panona talože se međusobne izmjene tanjih slojeva glinovitog vapnenca, kalcitnog, siltnoga ili pjeskovitog lapora, čistog lapora te ponekad pješčenjaka. Dominira karbonatni materijal čiji izvor predstavljaju algni grebeni. Mjestimice dijelovi paleoreljefa izviruju iznad površine vode i predstavljaju izvor siliciklastičnog materijala,

no puno siromašniji nego u badenu. Karta debljine formacija Moslavačka gora prikazana je na slici 2-3.




Slika 2-3. Karta debljine formacije Moslavačka gora (Malvić, 2003)

2.3. TALOŽNE STIJENE GORNJEG PANONA

Prva sljedeća mlađa litostratigrafska jedinica ranga formacije koja je izdvojena unutar Dravske depresije, a slijedi formaciju Moslavačka gora, imenovana je Ivanić-Grad (slika 2-4). U starijim bušotinama sedimenti ove formacije često su označeni kao «naslage Banatica» prema karakterističnom fosilnom školjkašu *Congerina banatica*. Taloženje vremenski odgovara gornjem panonu. Formacija Ivanić-Grad graniči s formacijom Moslavačka gora u podini, a granica je predstavljena elektrokarotažnim markerom Rs5, a u krovini graniči s formacijom Kloštar Ivanić koja je predstavljena elektrokarotažnim markerom „Z“. Formacija je dalje podijeljena na litostratigrafske jedinice ranga član, a započinje lipovačkim laporom, a nastavlja se zagrebačkim članom ili njegovim bočnim

ekvivalentom okoljskim pješčenjacima. Gornjopanonska starost određena je uglavnom na temelju fosilnih nalazaka (Malvić, 2003).

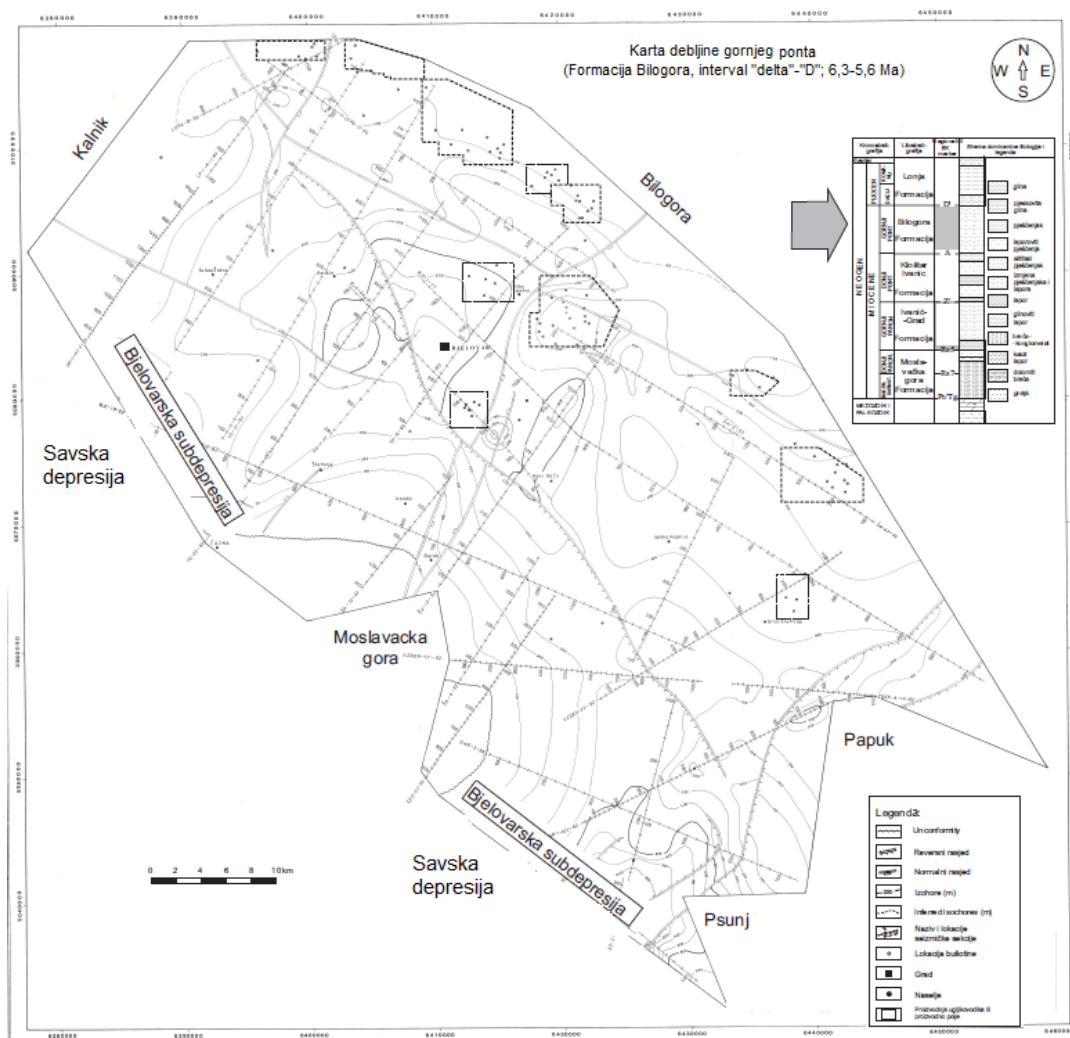


Slika 2-4. Karta debljine formacije Ivanić-Grad (Malvić, 2011)

2.4. TALOŽNE STIJENE DONJEG PONTA

Sedimenti donjeg pontata formacije Kloštar-Ivanić (slika 2-5) najčešće se nazivaju „naslagama Abichi“ prema karakterističnom fosilu *Paradachna abichi* (Malvić, 2003). Naslage su definirane kao pojedini članovi unutar formacije Kloštar-Ivanić, a to su najstariji lepsički lapori, a vremenskim slijedom nastavljaju se poljanski pješčenjaci, graberski lapor, pepelanski pješčenjaci i cabunski lapor (Šimon, 1968). Kod izrazite dominacije nepropusnih sedimenata svi ti članovi prelaze u jedan nazvan lapor Kloštar-

Ivanić (Šimon, 1968). Granica u podini, prema formaciji Ivanić-Grad, označena je E markerom „Z“, dok EK marker „Δ“ u krovinskom dijelu cabunskog lapora predstavlja približnu granicu s formacijom Bilogora. Gotovo na cijelom prostoru su zabilježeni svi članovi (Malvić, 2003).

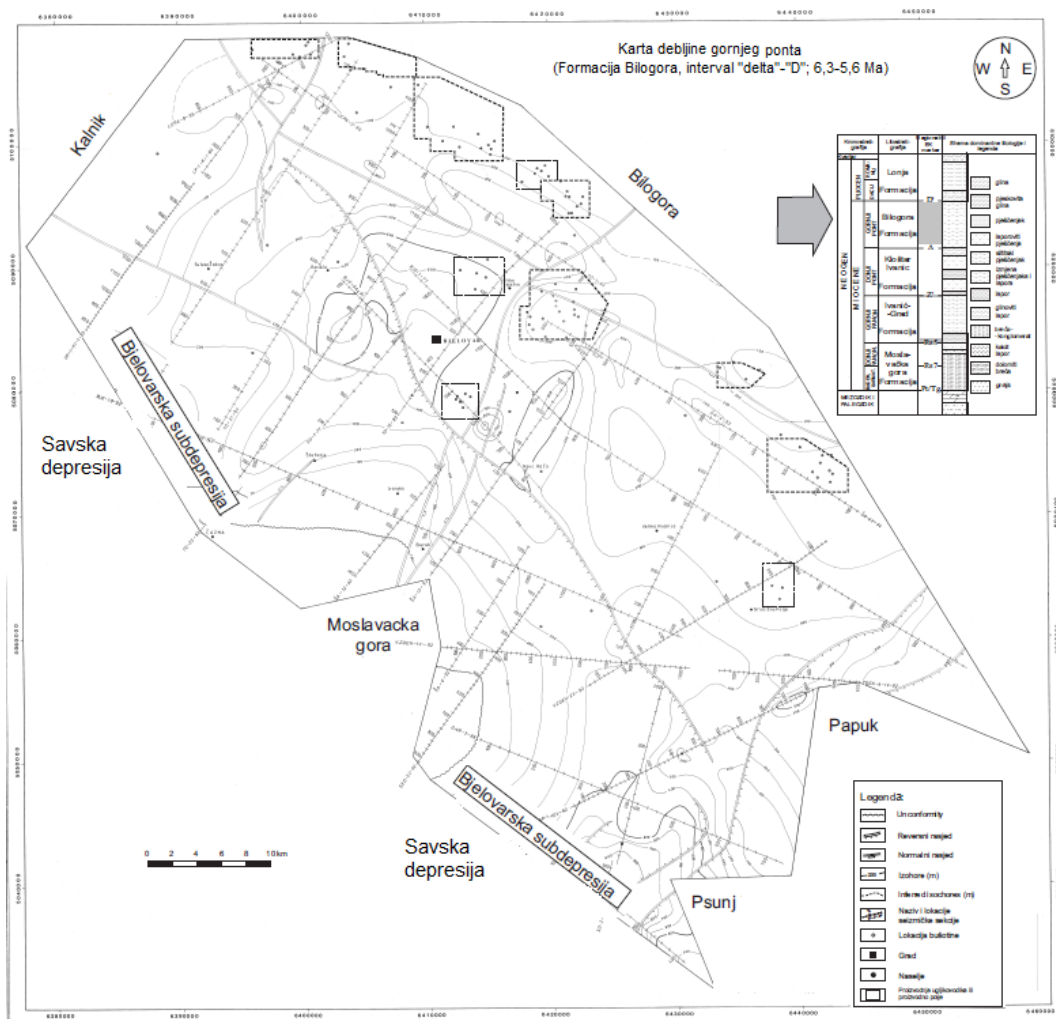


Slika 2-5. Karta debljine formacije Kloštar-Ivanić (Malvić, 2011)

2.5. TALOŽNE STIJENE GORNJEG PONTA

Naslagama formacije Bilogora (slika 2-6), starost je definirana kao približno gornjopontska, a taložine formacije nazivaju se još i Rhomboidea-naslagama prema fosilnom školjkašu *Congerina rhomboidea* (Malvić, 2003). Kako u formaciji Bilogora postoji znatno manja mogućnost otkrivanja ležišta ugljikovodika, nije dalje podijeljena u litostratigrafske jedinice nižeg ranga kao što je slučaj u starijim formacijama. Granicu sa


sedimentima formacije Kloštar-Ivanić predstavlja elektrokarotažni marker „Δ“ u podini, a u krovini je odijeljena od formacije Lonja EK markerom „D“. U najvećem dijelu depresije stariji sedimenti su predstavljeni glinovitim laporom, a u manjoj mjeri i slabovezanim pješčenjakom. Mlađi sedimenti formacije su predstavljeni laporovitom glinom i glinom te pješčenjakom i pijeskom uz dominaciju nepropusnih taložina. Dominiraju nepropusni sedimenti. U središnjem dijelu, kod Narte i Korenova cijela formacija razvijena je u nepropusnom facijesu glinovitog lapora, laporovite gline i gline (Malvić, 2003).



Slika 2-6. Karta debljina formacije Bilogora (Malvić, 2011)

2.6. TALOŽNE STIJENE I TALOŽINE PLIOCENA

Najmlađe naslage razrađene su u litostratigrafsku jedinicu, ranga formacije, Lonja (slika 2-7). Starost formacije Lonja definirana je kao približno pliocenska (dacij i romanij) te kvartarna. U vrijeme pliocena prostor Bjelovarske subdepresije već je podijeljen na niz slatkovodnih jezera (Vrbanac, 1996; Rögl, 1996, 1998) koja se uglavnom u potpunosti zapunjavaju. U pleistocenu taloženje se nastavlja samo u fluvijatilnim sredinama (Malvić & Cvetković, 2013). Taloži se pijesak i glina, a unutar dubljih jezera i silit, lapor i karbonat. Općenito, radi se o jezerskom klastičnom okolišu s taloženjem u deltama Gilbertovog tipa (Malvić, 2003). Najdublji dijelovi kod Velike Ciglene i Patkovca, su određeni kao laporovite gline, a kod Ciglenice kao pjeskoviti lapori. Ostatak depresije zapunjen je glinom, mjestimično pjeskovitom ili s proslojcima pijeska. Jedino u središnjem dijelu istaloženi su u izmjeni šljunak, pijesak i glina s proslojcima lignita (Malvić, 2003). Generalno je moguće naići na centimetarske do metarske proslojke slabokarboniziranog, crnog lignita. Stupanj konsolidacije raste s dubinom, dakle u mlađim dijelovima se nalaze nekonsolidirani sedimenti, a uz površinu su istaloženi holocenski prapor, ilovača, humus, šljunak, pijesak, a dominira glina. Formacija Lonja je u podini ograničena EK markerom „D“, a u krovini granica je određena današnjom površinom terena.



Slika 2-7. Karta debljina formacije Lonja (Malvić, 2003)

3. PREGLED REZULTATA DOSADAŠNJIH ISTRAŽIVANJA I RADOVA UPORABE NEURONSKIH MREŽA U ISTRAŽIVANJU I RAZRADBI LEŽIŠTA UGLJIKOVODIKA

Metoda umjetnih neuronskih mreža je zadnjih nekoliko desetljeća našla primjenu u mnogim područjima prirodnih, tehničkih i društvenih znanosti. U geologiji se uporaba te metode ističe unutar istraživanja ugljikovodika. Dokazana je vrijednost i u drugim područjima geologije u kojima se primjenjuju statističke metode analize podataka. U Republici Hrvatskoj su istraživanja ovom metodom postala učestala tek od 2006. godine kroz djelovanje Geomatematičkog odsjeka Hrvatskog geološkog društva. Jedan od prvih radova kojim je uvedena metoda u primjenu unutar geologije u Republici Hrvatskoj je imao primjenu u predviđanju klastičnih facijesa u polju Okoli (Malvić, 2006). Neuronski alati su još korišteni i za predviđanje šupljikavosti u polju Beničanci (Malvić & Prskalo, 2007), predviđanje ležišnih svojstava unutar naftnog polja Kloštar, poput litološkog sastava iz karotažnih dijagrama (Cvetković et al., 2008), za predviđanje litološkog saastava ležišta i zasićenja ugljikovodicima (Cvetković et al., 2009). Jedan od radova velikog značaja za popularizaciju ovog područja istraživanja svakako je „Hrvatsko-hrvatski rječnik iz primjene neuronskih mreža u geologiji“ (Malvić & Cvetković, 2008), čija je terminologija primijenjena i u ovomu radu.

Primjena umjetnih neuronskih mreža se pokazala kao učinkovitom u analizi podataka karotažnih dijagrama, primjerice za kartiranje litofacijesa pliocenskih, pleistocenskih i holocenskih sedimenata u Savskoj depresiji (Cvetković et al., 2012), te za predviđanje litologije jedne bušotine koristeći karotažne podatke druge bušotine u polju Kloštar u sedimentima gornjeg miocena (Cvetković & Velić, 2013). Uspješnost korištenja umjetnih neuronskih mreža za nadopunjavanje nedostajućih karotažnih podataka u određenim intervalima je prikazano u radu Cvetković & Bošnjak (2009) gdje su i odabrani najbolji algoritmi za takva istraživanja.

3.1. PRIMJENA UMJETNIH NEURONSKIH MREŽA U NAFTNOM INŽENJERSTVU

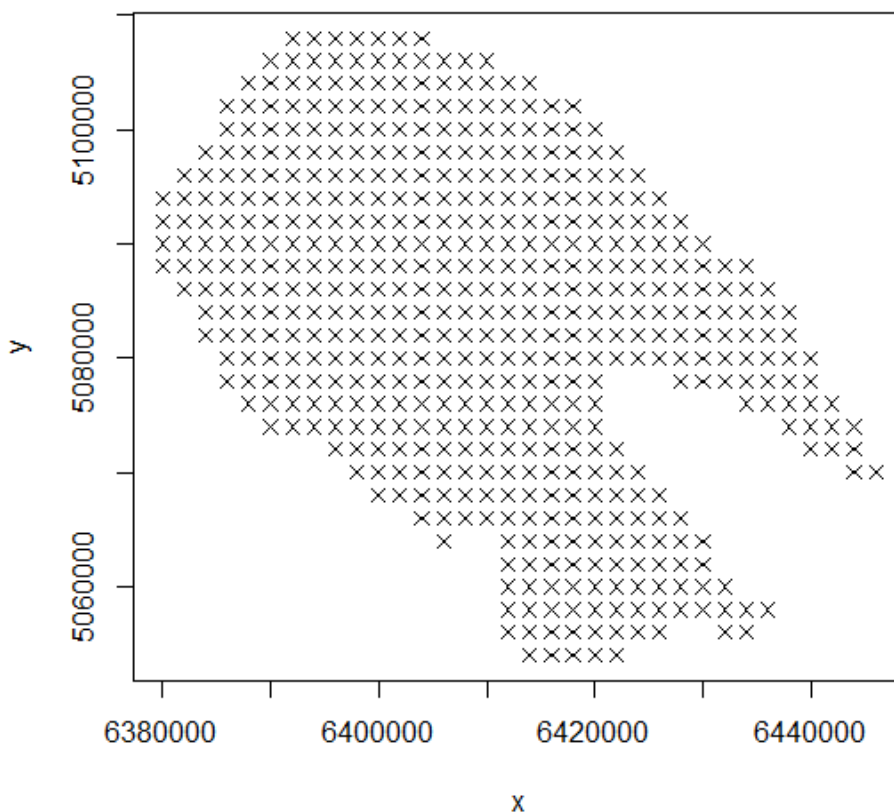
Primjena neuronskih mreža u naftnom inženjerstvu može biti značajna u situacijama kada inženjerski podatci korišteni za modeliranje i interpretaciju nisu u potpunosti adekvatni. Taj slučaj je često moguć u ležištima i geološkim sustavima koji pridobivaju ugljikovodike duže vrijeme. Također se može javiti i manjak podataka zbog visoke cijene dodatnog istraživanja i prikupljanja podataka, jezgrovanja i karotažnih podataka.

Neuronske mreže su našle primjenu u predviđanju, odnosno određivanju, propusnosti (Mohaghegh et al., 1995) u heterogenim formacijama gdje je mala korelacija između šupljikavosti i propusnosti, a poznavanje prostorne distribucije je od velikog značaja za izradbu geološkog modela. Također je moguća primjena neuronskih mreža u predviđanju pridobivih količina nafte tijekom procesa utiskivanja CO₂ (Mohammadi et al., 2014) te simulacija utiskivanja CO₂ i pridobivanja metana iz ležišta ugljena te predviđanja utiskivanja skladišnog kapaciteta za CO₂ u nepridobivim ležištima ugljena (He et al., 2013).

Iznimno je značajna primjena umjetnih neuronskih mreža u području hidrauličkog frakturiranja, i za dizajn i za monitoring, odnosno praćenje. Kulga (2010) koristi model neuronske mreže koji predviđa mjesečno pridobivanje ugljikovodika iz hidraulički frakturiranih horizontalnih bušotina u slabopropusnim pješčenjacima s pogrješkom manjom od 10 %. U primjeni neuronskih mreža u predviđanju vodljivosti pukotine nastale hidrauličkim frakturiranjem (Prabuharnogo, 2011) pokazano je da se uz znatne uštede korištenjem starih podataka o ležištu i pukotinama dobiju podatci o vodljivosti pukotine s prosječnom pogrješkom u iznosu 7 %.

4. METODOLOGIJA

Rad se temelji na kartiranju dubine EK-markera „Rs5“ metodom umjetnih neuronskih mreža. Budući da postupak izradbe algoritma umjetne neuronske mreže i njegovo korištenje zahtijeva „uvježbavanje“ mreže postojećim podacima, podatci dubina EK-markera „Rs5“ za „uvježbavanje“ mreže su preuzeti iz doktorske disertacije „Naftnogeološki odnosi i vjerojatnost pronalaska novih zaliha ugljikovodika u bjelovarskoj uleknini“ (Malvić, 2003) te rada „Geological maps of Neogene sediments in the Bjelovar Subdepression (northern Croatia)“ (Malvić, 2011) i dani su u prilogu u obliku ASCII datoteke. Podatci su u pravilnoj mreži, a sastoje se od koordinata „x“ i „y“ te podataka dubine. Na slici 4-1 prikazana je karta s prikazom položaja svih točaka kojima su pridružene vrijednosti dubina na temelju kojih je načinjena karta. U nastavku je opisana sama metoda umjetnih neuronskih mreža te programsko okruženje „R“.

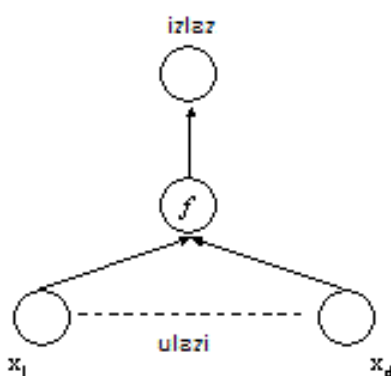


Slika 4-1. Karta s položajem ulaznih, odnosno, mjerenih vrijednosti

4.1. UMJETNE NEURONSKE MREŽE

Umjetne neuronske mreže imaju dodirnih točaka s ljudskom moždanom strukturom. Zajedničko im je da obje vrste mreža prenose samo dvije informacije, je li veza aktivna ili nije, a te informacije su izražene određenim električnim potencijalom, u mozgu ili računalu.

Neuronske mreže su se razvile unutar istraživanja umjetne inteligencije, uglavnom inspirirani pokušajima imitiranja tolerancije pogrješke i sposobnosti učenja bioloških neuronskih sustava (Patterson, 1996). U sastavu mozga se nalazi izuzetno velik broj neurona (10^{11}) koji su međusobno povezani brojnim vezama. Svaki neuron je posebna stanica koja može stvoriti, proslijediti te primiti elektrokemijski signal. Kao i biološka stanica, neuron ima tijelo, dendrite koji primaju signale iz ostalih neurona i aksona preko kojih se šalje električni impuls do krajeva sinapse. Akson jedne stanice je spojen s dendritima druge stanice preko sinapse. Kada je neuron aktiviran, šalje elektrokemijski signal preko aksona. Signal prelazi sinapsu i dolazi do tisuća drugih neurona koji mogu slati signal po cijelom neuronskom sustavu (tj. mozgu). Neuron šalje signal samo ako je razina signala koji dopiše u tijelo stanice preko dendrita veća od određene razine „praga“. Iako jedan neuron sam ne napravi značajan posao, kombinirani rezultat velikog broja neurona postaje toliko značajan da se mogu obavljati iznimno složeni kognitivni zadatci poput učenja ili svijesti. Stoga je zanimljivo da umjetne neuronske mreže mogu ostvariti zapanjujuće rezultate koristeći jedan jednostavan model.



Slika 4-2. Shema neuronske mreže s više ulaza i jednim izlazom

U praksi se neuronska mreža sastoji od više neurona, no zbog jednostavnosti će se opisati umjetna neuronska mreža s jednim neuronom s određenim brojem ulaza i jednim izlazom. Dakle, neuron prima signale iz mnogih izvora. Ti izvori obično su podatci i definirani su kao ulazne varijable x , ili samo ulazi (engl. *inputs*). Ulazi dolaze iz spojeva koji imaju određenu snagu, koja se naziva „težina“ (engl. *weight*). Vrijednost težine je predstavljena brojem, koji što je veći ukazuje na jači dolazni signal, i to ima veći utjecaj na izlaz (engl. *output*). Nakon što je signal primljen, odredi se suma ponderirana težinskim koeficijentima i odredi se aktivacijska funkcija (engl. *activation function*) neurona. Aktivacijska funkcija neurona je matematička funkcija koja pretvara sumu ponderiranu težinskim koeficijentima u izlaz. To je prikazano formulom 4-1:

$$\text{izlaz} = f(w_1 * x_1 + \dots + w_i * x_i) \quad (4-1)$$

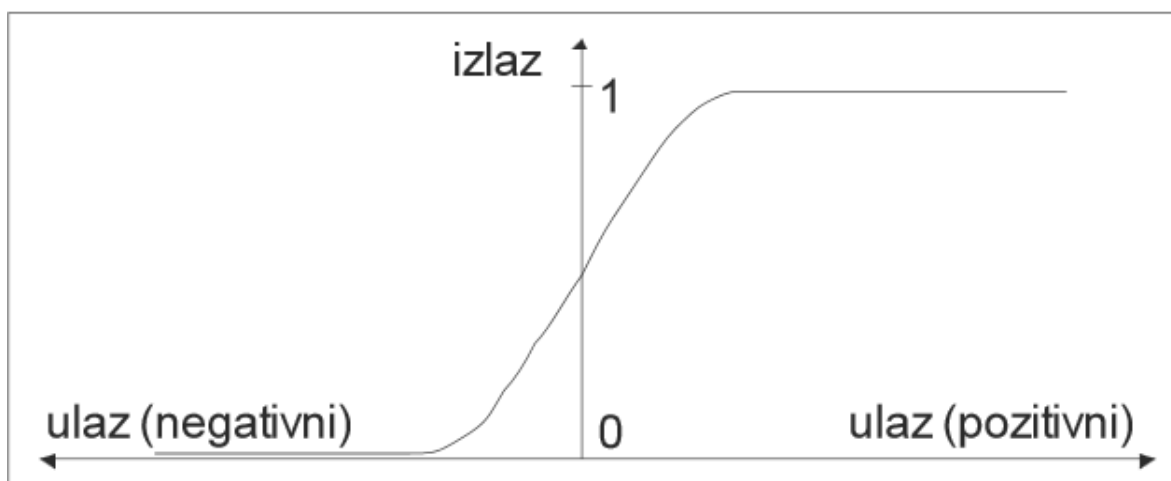
Gdje su:

f - aktivacijska funkcija;

w_i - težinski koeficijent i -tog ulaza;

x_i - vrijednost i -tog ulaza.


Aktivacijska funkcija obično je sigmoidnog oblika (slika 4-2), ali može biti i tangens hiperbolička, linearna i dr.



Slika 4-3. Sigmoidna aktivacijska funkcija (npr. Malvić, 2013)

Da bi neuronska mreža oponašala rad ljudskog mozga, potrebno je simulirati proces učenja. To se u sustavima neuronskih mreža naziva „uvježbavanje“ (engl. training). Uvježbavanje ili postupak učenja je iterativni postupak predočavanja ulaznih primjera (uzoraka, iskustva) i eventualno očekivana izlaza (Dalbello-Bašić et al., 2008). Uvježbavanje je potrebno da bi se kasnija mreža mogla koristiti i davati odgovarajući izlaz. Postoje dva načina uvježbavanja, odnosno učenja, a definirana su s obzirom na to je li poznat izlaz iz mreže. Prvi je učenje s učiteljem (engl. *supervised learning*) koje predstavlja učenje uz primjere u obliku para (ulaz, izlaz), a drugi je učenje bez učitelja (engl. *unsupervised learning*) gdje mreža uči bez poznavanja izlaza. Tijekom postupka uvježbavanja, vrijednost pogreške između stvarnog i željenog izlaza se vraća natrag u mrežu da bi se bolje uvježbala (slika 4-3). Takav postupak se naziva „mreža s postupkom povratne informacije“ (engl. *backpropagation network*). Ponavlja se toliko puta dok se vrijednost pogreške ne spusti ispod određene granice. Nakon uvježbavanja, potrebno je provesti provjeru (engl. *validation*) mreže jednim dijelom ulaznog skupa podataka. Kod testnog skupa podataka već su poznati izlazi pa je lako kontrolirati kvalitetu uvježbavanja. Nakon završetka ovog postupka, mreža je spremna za obradbu novog skupa podataka čiji izlazi nisu poznati. Sada se računaju nove vrijednosti iz uspostavljenih odnosa.

Postoji više vrsta neuronskih mreža, a u ovome radu je korišten model višeslojnih perceptrona.



Slika 4-4. Prilagođavanje težinskih koeficijenata i smanjivanje pogreške (Malvić, 2013)

4.1.1. Višeslojne neuronske mreže

Kako se umjetne neuronske mreže mogu sastojati od više neurona i više slojeva, njihova organiziranost i povezanost u mreži određuju njezinu arhitekturu. Postoje četiri osnovne vrste arhitekture (Dalbello-Bašić et al., 2008):

- a) Aciklička mreža (engl. feedforward net);
- b) Mreža s povratnom vezom (engl. recurrent net);
- c) Bočno povezana mreža (rešetkasta);
- d) Hibridna mreža.

Karakteristika acikličke mreže je da nema povratnih veza između neurona, što znači da signali iz ulaznih neurona nakon određenog broja prijelaza dolaze do izlaza mreže. Ovakva mreža se sastoji od ulaznog sloja, izlaznog i skrivenog sloja.

Višeslojne neuronske mreže s arhitekturom mreže s povratnom vezom sadržava u svojoj strukturi barem jednu povratnu vezu. To znači da postoji minimalno jedan takav čvor da ako se prati njegov izlaz kroz sve moguće putove, nakon konačnog broja koraka čvor će se ponovno obići. U ovom tipu mreže, postoje vidljivi čvorovi i skriveni čvorovi, za razliku od prethodne mreže gdje je bila riječ o ulaznom i izlaznom sloju.

4.2. PROGRAM ZA STATISTIČKU OBRADU PODATAKA „R“

„R“ predstavlja programski jezik i okruženje za statistiku, upravljanje podacima, računanje i grafiku. Kako je „R“ dobro planiran i konzistentan sustav, u njemu je moguće učinkovito programiranje, upravljanje podacima i njihovo pohranjivanje. Posjeduje niz operatora za računanje s poljima podataka, a posebno matricama te ustupa brojne grafičke mogućnosti za analizu podataka te za njihovo prikazivanje direktno na zaslonu računala ili na papiru. Brojne statističke tehnike su ugrađene u osnovu „R“ okruženja, a mnoge su dostupne u obliku paketa. „R“ je u potpunosti besplatan program, čime je omogućeno njegovo konstantno unaprjeđivanje i neometano dobavljanje već spomenutih paketa sa službene internetske stranice. Umjetne neuronske mreže su omogućene unutar paketa, a najpopularniji su „neuralnet“, „nnet“ i „AMORE“. U ovome radu je korišten „neuralnet“

prvenstveno zbog mogućnosti upravljanja velikom većinom parametara, poput aktivacijske funkcije, funkcije pogreške, broja skrivenih slojeva, broja neurona u skrivenim slojevima, stope učenja itd. Paket „neuralnet“ je izrađen za uvježbavanje višeslojnih perceptrona u kontekstu regresijske analize, tj. za aproksimaciju veze između ulaznih i izlaznih varijabli.

4.3. DIJAGRAM TOKA ALGORITMA UMJETNIH NEURONSKIH MREŽA

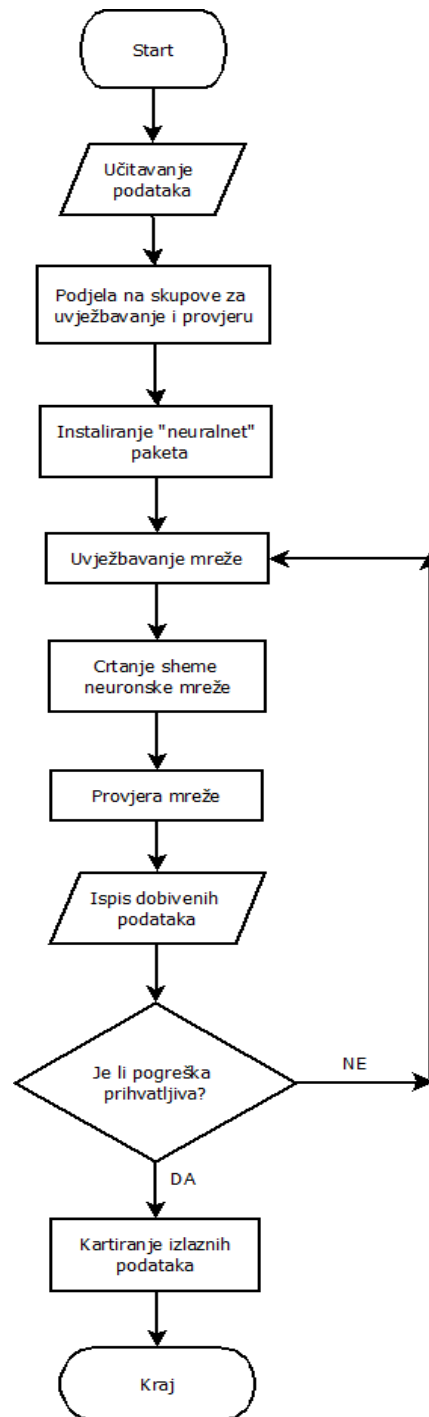
Na slici 4-5 prikazan je dijagram toka algoritma za izradbu umjetnih neuronskih mreža po komu je kasnije napisan programski kod. Primjer grafičkih prikaza rezultata u obliku karti dat je u nastavku, gdje su također detaljno objašnjeni i dijelovi koda.

Dakle, prvi korak uspješnog kartiranja algoritmom umjetne neuronske mreže je prikupljanje i priprema ulaznih podataka. U ovom radu su korišteni podatci o koordinatama smjesta te pripadajuća dubina. Budući da je bila nužna obradba podataka za što bolji izlaz, odnosno smanjenje pogreške, početne Gauss-Krügerove koordinate su pretvorene u *relativne* koordinate, čime se nije promijenio prostorni odnos, ali jest numerička vrijednost, dok su vrijednosti dubina logaritmiranjem po bazi 10 numerički umanjene, ali su odnosi ostali isti.

Nakon uređivanja ulaznog skupa, podijeljen je na skup za uvježbavanje i skupa za provjeru. Skup za uvježbavanje se sastoji od 75 % slučajno odabranih podataka iz ulaznog skupa. Sljedeći korak uključuje optimiziranje parametara neuronske mreže, a parametri u sklopu paketa „neuralnet“ koji su podložni optimiranju su broj skrivenih slojeva i broja neurona u njima, vrijednost praga (zadana vrijednost 0,01), maksimalan broj koraka kod uvježbavanja nakon kojeg se zaustavlja postupak uvježbavanja (zadana vrijednost 1×10^5), broj ponavljanja uvježbavanja mreže, početne vrijednosti težinskih koeficijenata (zadana je slučajna vrijednost), stopa učenja, vrsta algoritma (zadan je algoritam s povratnim postupkom učenja), funkcija pogreške (zadana je suma kvadrata pogreške), aktivacijska funkcija (zadana je sigmoidalna) i još nekoliko drugih parametara.

Zatim program ispisuje izlaz neuronske mreže i crta shemu pripadajuće mreže uz prikaz pripadajućih težinskih koeficijenata i pogreške. Ukoliko je optimiranjem parametara pogreška smanjena na minimalnu vrijednost, slijedi korištenje uvježbane mreže na novim podacima koji će biti ukomponirani u ulazni skup. To je umjetni skup

koji se sastoji od x i y koordinata iz ulaznog skupa uvećanih za 1 (x_i+1 , y_i+1) da bi se dobio veći broj podataka na karti i bolja razlučivost. Kad su predviđene dubine za koordinate dodatnog skupa, izlaz prvog i drugog skupa se ujedinjuje i slijedi postupak kartiranja, odnosno grafičkog prikaza prostornog razmještaja. Kartiranje se obavilo pomoću paketa „ggplot2“.



Slika 4-5. Dijagram toka algoritma neuronske mreže

5. ALGORITAM NEURONSKE MREŽE


Algoritam umjetne neuronske mreže temelji se na podacima o koordinatama x i y te podacima o dubini. Nakon učitavanja skupa podataka, dijeli se na skup za uvježbavanje koji iznosi 75 % ukupnog broja podataka i skup za provjeru. Podatci dubine su logaritmiranjem s bazom 10 pretvoreni u manje brojeve (logaritamska transformacija), čime se dobije bolji izlaz neuronske mreže (manja pogriješka). Zatim, s obzirom na varijable x i y , predviđa se dubina. Odabrana je mreža s dva skrivena sloja, u kojima prvi sloj sadrži 10 neurona, a drugi 6 neurona. Shematski je to prikazano na slici 5-1. Nakon provjere algoritma drugim skupom podataka, ispisan je izlaz. Paketom „ggplot2“ su podatci kartirani.

```
#Učitavanje podataka
podatci<-read.csv("rs5_t.csv", sep=";", header=T)
#Podjela podataka na podatke za uvježbavanje i provjeru
vel_pod <- floor(0.75 * nrow(podatci))
vjezba_ind <- sample(seq_len(nrow(podatci)), size = vel_pod)
vjezba <- podatci[vjezba_ind, ]
#Uvježbavanje mreže
install.packages('neuralnet')
library("neuralnet")
mreza_tr <- neuralnet(dubina_log~x+y,data=vjezba,hidden=c(10,6),linear.output=T)
plot(mreza_tr)
#Provjera mreže
mreza_pr<-compute(mreza_tr, podatci[,1:2])
print(mreza_pr$net.result)
#Ispis izlaza
cisti_izlaz <- cbind(podatci, as.data.frame(mreza_pr$net.result))
colnames(cisti_izlaz) <- c("x","y","dubina","dubina_log","Izlaz_neuronske_mreze")
print(cisti_izlaz)
#Izlaz dubine u metrima
dubina_1<-podatci[3]
dubina_logg<-cisti_izlaz[5]
dubina_m<-10^(dubina_logg)
izlaz<-cbind(dubina_1, dubina_m)
```

```

izlaz
#Predviđanje dodatnih podataka
dodatnipodatci<-read.csv("rs5_dodatnibr2.csv", sep=";", header=T)
vjezba2<-data.frame(podatci$x, podatci$y, dubina_logg)
mreza_tr2<-neuralnet(Izlaz_neuronske_mreze~podatci.x+podatci.y,
data=vjezba2,hidden=c(10,6),linear.output=T)
plot(mreza_tr2)
mreza_tr2$net.result[[1]]
mreza_pr2<-compute(mreza_tr2, dodatnipodatci[,1:2])
print(mreza_pr2$net.result)
#Ispis
cisti_izlaz2 <- cbind(dodatnipodatci, as.data.frame(mreza_pr2$net.result))
colnames(cisti_izlaz2) <- c("x","y","Izlaz_neuronske_mreze")
print(cisti_izlaz2)
#Izlaz dubine u metrima
dubina_logg2<-cisti_izlaz2[3]
dubina_m2<-10^(dubina_logg2)
izlaz2<-cbind(dubina_m2)
izlaz2
#Spajanje osnovnih i dodatnih podataka
kartiranje1<-data.frame(cisti_izlaz[1], cisti_izlaz[2], dubina_m)
kartiranje2<-data.frame(cisti_izlaz2[1], cisti_izlaz2[2], dubina_m2)
kartiranjespoj<-rbind(kartiranje1,kartiranje2)
n <- nrow(podatci)
kartiranjespoj[kronecker(1:n, c(0, n), "+"), ]
#Kartiranje
dubina<-kartiranjespoj[3]
x<-(kartiranjespoj$x)*2000+6379993
y<-(kartiranjespoj$y)*2000+5053986
kartiranjespoj2<-data.frame(x,y,dubina)
colnames(kartiranjespoj2)<-c("x","y","dubina")
install.packages("ggplot2")
library(ggplot2)
breaks <- c(0, 500, 1000, 1500, 2000, 2500,3000)
ggplot(aes(x = x, y = y, fill = dubina), data = kartiranjespoj2) + geom_tile()+scale_fill_gradientn(colours =
rainbow(7), breaks = breaks)

```



Slika 5-1. Shematski prikaz neuronske mreže

5.1. REZULTATI I ODABIR NAJBOLJE MREŽE

Izlaz algoritma daje ukupnu pogrešku predviđanja u iznosu od 0,238 u oko 35000 ponavljanja (iteracija). Takva pogreška je rezultat računanja s relativnim iznosima vrijednosti podataka, odnosno s logaritmiranim podacima. Izlaz algoritma u postupku predviđanja dubina drugog (umjetnog) skupa daje pogrešku u iznosu 0,03178 u oko 40000 ponavljanja. Primjenjujući isti algoritam na skup podataka koji nije prethodno logaritmiran dobije se pogreška u iznosu 84854148,760 u 1616 ponavljanja, te je izlaz konstantna vrijednost za svaki par ulaznih varijabli, što onemogućava interpretaciju. Funkcija pogreške koja se koristi u algoritmu je suma kvadrata pogreške (engl. sum of squared errors) i njena jednadžba glasi :

$$E = \frac{1}{2} \sum_{l=1}^L \sum_{h=1}^H (o_{lh} - y_{lh})^2 \quad (5-1)$$

Gdje su:

E – funkcija pogreške;

$l=1,\dots,L$ – promatrani, tj. ulazni podatci;


$h=1,\dots,H$ – izlazni podatci;

o_{lh} – predviđeni izlaz;

y_{lh} – promatrani izlaz.

Ova funkcija mjeri razliku između predviđene i promatrane vrijednosti izlaza, a proces se zaustavlja kad je vrijednost svih parcijalnih derivacija funkcija pogreške po težinskim koeficijentima ($\partial E/\partial w$) manja od zadanog praga (Günther & Fritsch, 2010).

Na slici 5-2 se nalazi karta dubina dobivena izlazom neuronske mreže.



Slika 5-2. Karta dubina EK markera „Rs5“ dobivena algoritmom neuronskih mreža

Najbolja mreža je odabrana s obzirom na najmanju pogrešku koju daje, a to je dobiveno u slučaju mreže s dva skrivena sloja gdje se u prvom sloju nalazi 10, a u drugom 6 neurona. U tablici 5-1 se nalaze nasumično izabrani rezultati mreže u usporedbi s izvornim podacima.

Tablica 5-1. Nasumično izabrani ulazni i izlazni podatci neuronske mreže

Relativne koordinate x	Relativne koordinate y	Dubina (m)	Izlaz neuronske mreže (m)
25	19	960	935,0805
24	20	850	804,0181
11	20	920	1023,6280
0	17	395	388,9871
1	20	520	521,9115
13	26	480	526,1691
2	14	290	289,4170
5	15	510	495,0765

6. STATISTIČKA ANALIZA

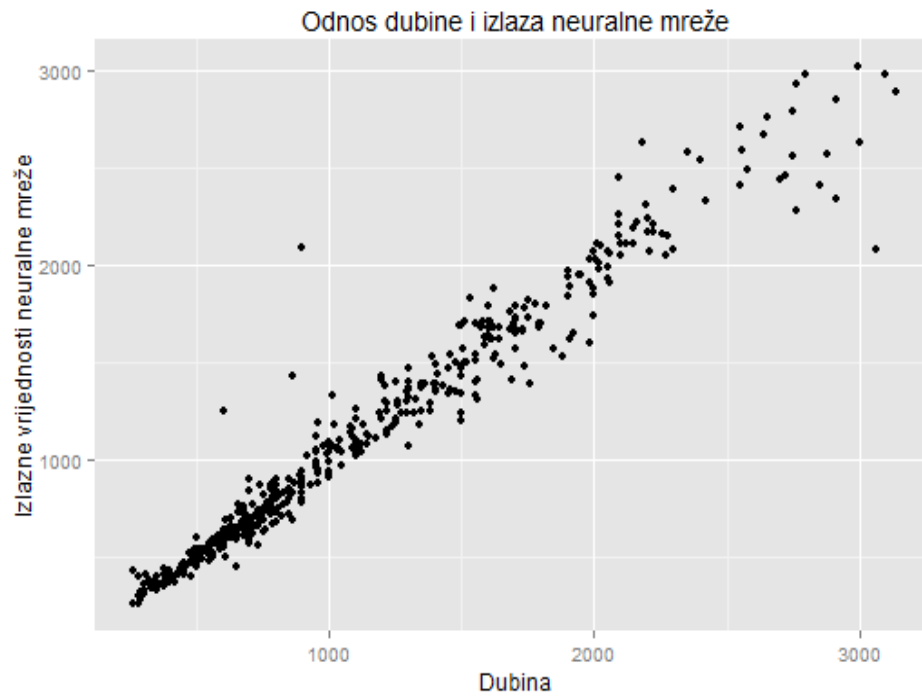
Tablica 6-1 sadrži prikaz rezultata analize pouzdanosti i korelacijske analize. Na temelju načinjene analize pouzdanosti u kojoj su uspoređivani izlazni podatci s ulaznim, vidljivo je kako algoritam postavljene neuronske mreže ima izrazito visok koeficijent pouzdanosti u iznosu 0,99 s 99 %-tnim intervalom pouzdanosti u rasponu od 0,988 do 0,991 ($p < 0,001$). Korelacijskom analizom pronađena je statistički značajna ($p < 0,001$) pozitivna korelacija velike snage s koeficijentom korelacije od 0,91 s 99 postotnim intervalom pouzdanosti od 0,895 do 0,92.

Tablica 6-1. Rezultati analize pouzdanosti i korelacijske analize

		99%-I.P.		p
α^*	0,99	0,988	0,991	<0,001
τ^\dagger	0,91	0,895	0,92	<0,001

*Cronbachov alfa, \dagger Kendallov tau

Dijagram na slici 6-1 prikazuje odnos ulaznih i izlaznih podataka. Vidljivo je kako postoji izraženija konzistentnost na području nižih vrijednosti, dok pri visokim dolazi do raspršenja. Pojedini ekstremi (engl. *outliers*) su vidljivi, ali dubljom analizom podataka ustanovljeno je kako su oni posljedica ekstremnih promjena u ulaznim podacima, zbog kojih se izlazni podaci algoritma neuronske mreže nisu prilagodili. Visoka pouzdanost i visoka korelacija su pokazatelj izvrsnosti postojećeg algoritma i potencijalne primjene neuronskih mreža u analizu ležišta ugljikovodika.



Slika 6-1. Dijagram odnosa ulaznih i izlaznih podataka

7. INTERPOLACIJA DUBINA EK-MARKERA „Rs5“ OBIČNIM KRIGIRANJEM

U ovom radu kao interpolacijska metoda koristit će se metoda krigiranja pa je u nastavku ukratko objašnjena. Kriging predstavlja jednu od najznačajnijih geostatističkih metoda, a prethodi joj određivanje prostorne zavisnosti, odnosno variogramska analiza. Kriging se smatra naprednom metodom za procjenu vrijednosti regionalizirane varijable u odabranim točkama mreže. Procjena krigingom može se opisati jednostavnim linearnim izrazom (jednadžba 7-1), koji se kasnije raspisuje u obliku matričnih jednadžbi (jednadžba 7-2). Vrijednosti varijable na odabranoj lokaciji (Z_k) procjenjuju se na temelju postojećih podataka (z_i). Svakom podatku pridružen je i odgovarajući težinski koeficijent (λ) kojim se opisuje utjecaj tog mjenenog podatka na vrijednost varijable koja se procjenjuje:

$$Z_k = \sum_{i=1}^n \lambda_i \times z_i \quad (7-1)$$

Težinski koeficijenti kriginga računaju se sustavom linearnih jednadžbi, a ovise o udaljenosti podataka od točke koja se procjenjuje te njihovoj grupiranosti. Postoje različite tehnike kriginga, a neki od njih su jednostavni kriging (engl. Simple Kriging), obični kriging (engl. Ordinary Kriging), indikatorski kriging (engl. Indicator Kriging), univerzalni kriging (engl. Universal Kriging) i disjunktivni kriging (engl. Disjunctive Kriging). Kod jednostavnog kriginga, kao osnovne tehnike, matrična jednadžba napisana u punome obliku glasi:

$$\begin{pmatrix} \gamma(Z_1 - Z_1) & \gamma(Z_1 - Z_2) \cdots & \gamma(Z_1 - Z_n) \\ \gamma(Z_2 - Z_1) & \gamma(Z_2 - Z_2) \cdots & \gamma(Z_2 - Z_n) \\ \gamma(Z_n - Z_1) & \gamma(Z_n - Z_2) \cdots & \gamma(Z_n - Z_n) \end{pmatrix} \times \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_n \end{pmatrix} = \begin{pmatrix} \gamma(X_1 - X) \\ \gamma(X_2 - X) \\ \gamma(X_n - X) \end{pmatrix} \quad (7-2)$$

gdje su:

γ - vrijednost semivariograma na udaljenosti dviju točaka;

λ - težinski koeficijent za lokaciju 'i';

$Z_1 \dots Z_n$ - mjerene vrijednosti u točkama.

Sve ostale tehnike kriginga imaju dodane „faktore ograničenja” (engl. constraint). Time je u potpunosti zadovoljen uvjet da ih se može nazvati najboljim linearnim

nepristranim procjeniteljima (engl. Best Linear Unbiased Estimator). Kod jednostavnog kriginga nije ispunjen uvjet da je procjena nepristrana (engl. „unbiased”).

7.1. VARIOGRAMSKA ANALIZA

Variogram je temeljni geostatistički alat. Njime se određuje prostorna zavisnost, a služi i za bolje definiranje međusobne povezanosti točkastih podataka koji se žele zajednički kartirati. Rezultat izrade variograma je eksperimentalni variogram, koji se dalje aproksimira teoretskim modelom (sferični, eksponencijalni, Gaussov). Takav model ulaz je za daljnju metodu kartiranja. Variogramsku jednadžbu moguće je pojednostavniti tako da se iz nazivnika eliminira broj 2 pa se dobivena funkcija 2γ naziva semivariogramom (jednadžba 7-3):

$$2\gamma(h) = \frac{1}{N(h)} \times \sum_{n=1}^{N(h)} [z_n - z_{n+h}]^2 \quad (7-3)$$

gdje su:


$2\gamma(h)$ - vrijednost variograma;

$N(h)$ - broj parova podataka uspoređenih na udaljenosti 'h';

z_n - vrijednost varijable na lokaciji 'n';


z_{n+h} - vrijednost varijable na lokaciji udaljenoj za 'h' od promatrane lokacije 'n'.

Variogram koji će se dalje koristiti u kartiranju izrađen je u programu Variowin. Prvi korak je definiranje parametara s obzirom na ulazni skup, te nakon toga slijedi izrada eksperimentalnog variograma. Eksperimentalni variogram prikazan je na slici (7-1).



Slika 7-1. Eksperimentalni variogram s pripadajućom krivuljom

Sljedeći korak je aproksimacija eksperimentalnog variograma jednim od teorijskih modela (sferični, eksponencijalni, Gaussov). Variogram je aproksimiran sferičnim modelom (slika 7-2) s vrijednošću varijance, odnosno praga, 425 514, a dosega 24 684.




Slika 7-2. Aproksimacija variograma teorijskim modelom

7. 2. INTERPOLACIJA OBIČNIM KRIGIRANJEM

Karta je izrađena u programu SURFER 9, a kao ulazne vrijednosti uzete su koordinate EK markera RS5 (x i y) te podatci o dubini. Vrijednost variograma je također jedan od bitnih podataka za izradbu karte metodom krigiranja. Kao relevantna metoda izabrana je metoda običnog krigiranja. Načinjena karta je prikazana na slici 7-3, a metodom krosvalidacije dobivene su vrijednosti kvadratne pogreške procjene te najprecjenjeniji i najpodcjenjeniji podatci.

Vrijednost kvadratne pogreške procjene iznosi 14638,35. Najprecizniji podatak je dubina s vrijednošću 900 m, koja je procijenjena na 2161,50 m, a nalazi se na koordinatama $X=6431993$ te $Y=5059986$. Najpodcjenjeniji podatak je podatak na $X=6429993$ i $Y=5081986$. Umjesto 3060 m predviđeno je 2271,39 m.

Za usporedbu, kvadratna pogreška procjene kod kartiranja metodom umjetnih neuronskih mreža iznosi 16742,5. Ova usporedba pokazuje ipak nešto točniju procjenu i točniji prikaz karte dobivene običnim krigiranjem.



Slika 7-3. Karta EK markera „Rs5“ dobivena metodom običnog krigiranja

Ovi dobiveni rezultati ukazuju na iznimno malu međusobnu razliku u postupku procjene podataka te moguće korištenje obje metode (krigiranja i neuronske mreže) u kartiranju.

8. DISKUSIJA I ZAKLJUČAK

Tijekom kartiranja prikupljeni podatci mogu biti u nelinearnom odnosu, a u tom slučaju primjenu nalazi metoda umjetnih neuronskih mreža u kojoj se podatci ujedninjuju u jedan složeni ulazni skup. Također u takvom slučaju linearne metode kartiranja poput krigiranja uopće nisu primijenjive, odnosno rezultati bi bili pogrešni, iako bi izlaze bilo moguće generirati. Takva prednost neuronske mreže proizlazi iz njezine karakteristika da simulira postupak ljudskog učenja uvježbavanjem i optimiranjem parametara nizom ponavljanja. U geologiji ležišta fluida i naftnom inženjerstvu je metoda umjetnih neuronskih mreža relativno zahvalna metoda.

U ovomu radu je potvrđena postavljena hipoteza o uspješnom kartiranju izvornim algoritmom umjetne neuronske mreže izrađenom u programu za statističku obradbu podataka „R“ na primjeru kartiranja dubine EK markera (elektrokarotaznog markera) Rs5. Sama arhitektura mreže koja je dala najbolji izlaz je bila takva da se sastoji od dva skrivena sloja kod kojih prvi sadrži 10 neurona, a drugi sloj 6. Koristio se algoritam mreže s povratnim postupkom učenja (engl. backpropagation algorithm). Ulazni podatci bile su koordinate koje su iz Gauss-Krügerovog koordinatnog sustava pretvorene u relativne koordinate kako bi se dobio bolji izlaz i manja pogreška mreže, te podatci o dubini, koje su pak logaritmiranjem pretvorene u manje vrijednosti s istim ciljem smanjenja pogreške. S obzirom na koordinate, predviđana je dubina. Ovaj algoritam može biti korisno sredstvo u kartiranju u slučaju poznavanja većeg broja podataka ili podataka koji su u nelinearnom odnosu te se jednostavnim postupkom određuju međusobni odnosi i omogućava se uspješno kartiranje.

U slučaju uporabe kod podataka obilježenih linearnom međuzavisnošću neuronske mreže mogu se i trebaju usporediti s drugim često uspješnim linearnim metodama kartiranja. Najpoznatija među njima je krigiranje. Tada u odnosu na klasične geostatističke interpolacijske metode, primjerice tehniku običnog kriginga, metoda umjetnih neuronskih mreža daje iznimno dobre i kvalitetne rezultate koji su potkrijepljeni analizom pouzdanosti i korelacijskom analizom. Algoritam postavljene neuronske mreže ima izrazito visok koeficijent korelacije u iznosu 0,99 s 99 %-tnim intervalom pouzdanosti u rasponu od 0,988 do 0,991 ($p < 0,001$). Korelacijskom analizom pronađena je statistički značajna

($p < 0,001$) pozitivna korelacija velike snage s koeficijentom korelacije od 0,91 s 99 %-tnim intervalom pouzdanosti od 0,895 do 0,92.

U analizi odnosa izlaznih i ulaznih podataka vidljiva su određena odstupanja koja se mogu opisati naglom promjenom predviđane varijable, odnosno dubine, na bliskim udaljenostima čemu se mreža nije uspjela prilagoditi zbog stope učenja ili drugih parametara.

Kako neuronska mreža raspolaže relativno malim brojem podataka u usporedbi s onim kod običnog krigiranja, gdje se dodatni dobivaju interpolacijom, pogriješka kod neuronske mreže je nešto veća i karta je „zrnatija“. Ta zrnatost je posljedica načina kartiranja, gdje se metodom neuronskih mreža karta dobiva procjenjivanjem dubine u samoj ćeliji. Ova dva problema se mogu riješiti povećanjem broja ćelija u neuronskim mrežama. U tom slučaju bi se javio veći broj podataka na manjim udaljenostima čime bi se smanjila razlika u vrijednostima te javio trend kojeg bi neuronska mreža „naučila“ i unatoč povećanju ukupne vrijednosti kvadratne pogriješke, ona bi bila manja u odnosu na onu kod običnog krigiranja.

Običnim krigiranjem dobivena je karta s vrijednosti kvadratne pogriješke procjene 14638,35. Najprecijenjeniji podatak je dubina s vrijednošću 900 m, koja je procijenjena na 2161,50 m, a nalazi se na koordinatama $X=6431993$ te $Y=5059986$. Najpodcjenjeniji podatak je podatak na $X=6429993$ i $Y=5081986$. Umjesto 3060 m predviđeno je 2271,39 m. Vrijednost najprecijenjenijeg podatka dobivenog algoritmom neuronske mreže iznosi 2089,336 m, umjesto 900 m na lokaciji $X=6431993$, $Y=5059986$. Najpodcjenjeniji podatak je na lokaciji $X=6429993$, $Y=5081986$ sa vrijednosti 2086,28 m umjesto 3060 m.

Algoritam neuronske mreže će dati valjani izlazni skup pri kartiranju bilo kojeg geološkog parametra (šupljikavosti, propusnosti, zasićenja, debljine) ukoliko je uvježban na valjanim podacima i u tomu slučaju postoji očekivanje malih pogriješaka po točkama ili ćelijama. Glavni problem kod izradbe uspješnih mreža je uređivanje ulaznog skupa i optimiranje parametara koje može biti dugotrajno.

9. LITERATURA

1. CVETKOVIĆ, M., VELIĆ, J., MALVIĆ, T., 2008. Neural network prediction of the reservoir properties on the Klostar oil field. XII. Congress of hungarian geomathematics and the first congress of croatian and hungarian geomathematics. Morahalom, Mađarska, 29-31.05.2008.
2. CVETKOVIĆ, M., VELIĆ, J., MALVIĆ, T., 2009. Application of neural networks in petroleum reservoir lithology and saturation prediction. *Geologia Croatica: journal of the Croatian Geological Survey and the Croatian Geological Society*. 62(2), str. 115-121.
3. CVETKOVIĆ, M., BOŠNJAK, M., 2009. Successfulness of different neural network algorithms for missing well log data prediction – Example from the Sava Depression. XIII. Congress of Hungarian geomathematics and the II. Congress of Croatian and Hungarian geomathematics, Morahalom.
4. CVETKOVIĆ, M., VELIĆ, J., 2012. Successfulness of inter well lithology prediction on Upper Miocene sediments with artificial neural networks. 4th Croatian-Hungarian and 15th Hungarian geomathematical congress, Opatija, Hrvatska, 23-25.5.2012. Zagreb: Geomathematics as geoscience, Hrvatsko geološko društvo, str. 13-20.
5. CVETKOVIĆ, M., VELIĆ, J., MALVIĆ, T., 2012. Application of Artificial Neural Networks on Well Log Data for Lithofacies Mapping of Pliocene, Pleistocene and Holocene Sediments in Sava Depression, Pannonian Basin, Croatia. XI th International Conference on Geoinformatics – Theoretical and Applied Aspects, Kiev, Ukraine 14-17. 5. 2012. Kiev, Ukraine – Geoinformatics 2012 Kyiv : EAGE, 2012, str. 1-5.
6. CVETKOVIĆ, M., VELIĆ, J., 2013. Lithology prediction by artificial neural networks and preparation of input data on Upper Miocene sediments. Theories and applications in geomathematics. *GeoLitera*, Institute of Geosciences, University of Szeged, 2013, str. 9-14.
7. DALBELO-BAŠIĆ, B., ČUPIĆ, M., ŠNAJDER, J., 2008. Umjetne neuronske mreže. Nastavni materijali za kolegij Umjetna inteligencija, Fakultet elektrotehnike i računalstva Zagreb, 2008.

URL: www.fer.hr/predmet/umjint/materijali. (29.2.2016.)

8. GÜNTHER, F., FRITSCH, S., 2010. Neuralnet: Training of neural networks. *The R Journal*. 2(1), str. 30-38.
9. HE, Q., MOHAGHEGH S. D., GHOLAMI, V., 2013. A Field Study on Simulation of CO₂ Injection and ECBM Production and Prediction of CO₂ Storage Capacity in Unmineable Coal Seam. *Journal of Petroleum Engineering*, vol. 2013, Article ID 803706, 8 str., 2013. doi:10.1155/2013/803706.
10. KULGA, I.B., ERTEKIN, T., 2010. Development of an artificial neural network for hydraulically fractured horizontal wells in tight gas sands. Pennsylvania State University, 2010. Dissertation.
11. MALVIĆ, T., 2003. Naftnogeološki odnosi i vjerojatnost pronalaska ugljikovodika u Bjelovarskoj uleknini (Doktorska disertacija), Zagreb, 156 str.
12. MALVIĆ, T., 2006. Predviđanje klastičnih facijesa neuronskom mrežom (primjer polja Okoli). *Nafta*, 57(10), str. 415-431.
13. MALVIĆ, T., PRSKALO, S., 2007. Using of neural network in porosity prediction (Beničanci field). XI. Congress of Hungarian Geomathematics, Geiger, Janos (ur.). Szeged: Hungarian Geological Society, Geomathematical Section of the Hungarian Geological Society.
14. MALVIĆ, T., CVETKOVIĆ, M., 2008. Hrvatsko-hrvatski rječnik iz primjene neuronskih mreža u geologiji. (Croatian-Croatian dictionary from application of neural network in geology). *Vijesti Hrvatskoga geološkog društva (1330-1357)*, 45 (1), str. 43-46.
15. MALVIĆ, T., 2011. Geological maps of Neogene sediments in the Bjelovar Subdepression (northern Croatia). *Journal of Maps*, 2011, str. 304-317.
16. MALVIĆ, T., CVETKOVIĆ, M., 2013. Korelacija litostratigrafskih jedinica u Dravskoj depresiji (hrvatski i mađarski dio). *Nafta*. 64(1), str. 27-33.
17. MALVIĆ, T., CVETKOVIĆ, M., 2013. Neuronski alati u geologiji ležišta ugljikovodika, II. izdanje. Hrvatsko geološko društvo (Geomat. odsjek), Sveučilište u Zagrebu (RGN fakultet), sveučilišni priručnik, Zagreb, 89 str.
18. MOHAGHEGH, S., AMERI, S., 1995. Artificial Neural Network As A Valuable Tool For Petroleum Engineers, Society of Petroleum Engineers. Paper No. 29220 (1995).

19. MOHAMMADI M., KOUHI, M., MOHEBBI, A., 2014. Prediction of Oil Recovery Factor in CO₂ Injection Process, *Petroleum Science and Technology*, 32(17), str. 2093-2101.
20. PATTERSON, D.W., 1996. *Artificial Neural Networks: Theory and Applications*. Prentice Hall, 477 str..
21. PRABUHARNOGO, RACHMAT, S., 2011. The Application of Artificial Neural Network to Predict Fracture Conductivity of Hydraulic Fracturing. Institute of Technology Bandung.
22. RÖGL, F., 1996. Stratigraphic correlation of the Paratethys Oligocene and Miocene. *Mitt. Ges. Geol. Bergbaust Wien*, 41, str. 65-73, Wien.
23. RÖGL, F., 1998. Palaeogeographic consideration for Mediterranean and Paratethys Sea ways (Oligocene to Miocene). *Ann. Naturhist. Mus. Wien (Serie A)*, 99, str. 279-310.
24. ŠIMON, J., 1968. Informativne litostratigrafske jedinice tercijarnog kompleksa u profilima dubokih bušotina na području Dravske potline, Zagreb: INA- Industrija nafte d.d.
25. VRBANAC, B., 1996. Paleostrukturalne i sedimentološke analize gornjopanonskih sedimenata Ivanić Grad formacije u Savskoj depresiji (s engleskim sažetkom). Disertacija, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, 303 str., Zagreb.