

*Tomislav Malvić, Marko Cvetković*

NEURONSKI ALATI U GEOLOGIJI LEŽIŠTA UGLJIKOVODIKA

*NEURONSKI ALATI  
U GEOLOGIJI  
LEŽIŠTA UGLJIKOVODIKA*

Tomislav Malvić, Marko Cvetković



Hrvatsko geološko društvo  
Geomatematički odsjek



Tomislav MALVIĆ, Marko CVETKOVIĆ

# **NEURONSKI ALATI U GEOLOGIJI LEŽIŠTA UGLJIKOVODIKA**

Hrvatsko geološko društvo  
Geomatematički odsjek

Zagreb, 2009.

Nakladnik:

Hrvatsko geološko društvo (HGD), Sachsova 2, 10000 Zagreb  
[www.geologija.hr](http://www.geologija.hr)

Za nakladnika:

Mr. sc. Niko Dalić, dipl. ing. geologije, predsjednik Društva

Autori:

Dr. sc. Tomislav Malvić, docent, dipl. ing. geologije  
Marko Cvetković, dipl. ing. geologije

Recenzenti:

Prof. dr. sc. Josipa Velić, redoviti profesor, dipl. ing. geologije  
(*Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet*)  
Dr. sc. Zoran Peh, viši znanstveni suradnik, dipl. ing. geologije  
(*Hrvatski geološki institut*)

Lektorica:

Dr. sc. Ivana Matas Ivanković, prof.

Grafičko oblikovanje i tisak:  
Denona d.o.o., Zagreb

Naklada:

150 primjeraka

CIP zapis dostupan u računalnom katalogu Nacionalne i sveučilišne knjižnice  
u Zagrebu pod brojem 715556.

ISBN 978-953-95130-5-2

*Sva prava pridržana, HGD, 2009.*

*Djelomično pretiskivanje i umnažanje dopušteno je samo uz naznaku izvora,  
a tiskanje i distribucija više od jednoga primjerka samo uz pisano  
odobrenje nakladnika.*

# ***SADRŽAJ***

<b>PREDGOVOR</b>	7
<b>1. OSNOVNA IDEJA I NAČIN RADA UMJETNE NEURONSKE MREŽE</b>	9
1.1. LJUDSKI NEURONI	10
1.2. STRUKTURA NEURONSKE MREŽE	12
1.3. OSNOVNI MATEMATIČKI IZRAZI NEURONSKE MREŽE	14
1.4. UČENJE MREŽE	16
1.5. MREŽA S POV RATNIM POSTUPKOM	20
1.6. MREŽA S RADIJALNOM FUNKCIJOM	23
1.7. MREŽA S POSTUPKOM POOPĆENE REGRESIJE	25
1.8. LITERATURA	27
<b>2. PREDVIĐANJE KLASTIČNIH FACIJESA NEURONSKOM MREŽOM, PRIMJER POLJA OKOLI</b>	29
2.1. OSNOVNI GEOLOŠKI ODNOSSI U POLJU OKOLI	29
2.2. PROGRAM cVision	32
2.3. VRSTA UPOTRIJEBLJENE MREŽE I REZULTATI	33
2.3.1. Uvježbavanje mreže i njezini izlazi	33
2.3.2. Rezultati analize facijesa u polju Okoli (ležište „c <sub>2</sub> “)	34
2.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU FACIJESA	40
2.5. LITERATURA	41
<b>3. PREDVIĐANJE LITOLOŠKOGA SASTAVA I INTERVALA ZASIĆENIH UGLJKOVODICIMA, PRIMJER POLJA KLOŠTAR</b>	43
3.1. OSNOVNI GEOLOŠKI ODNOSSI U POLJU KLOŠTAR	43

3.2. ANALIZE NEURONSKIM MREŽAMA U POLJU KLOŠTAR	44
3.2.1. Predviđanje litološkoga sastava	45
3.2.2. Predviđanje zona zasićenih ugljikovodicima	49
3.3. MOGUĆI PROBLEMI PRILIKOM ANALIZA NEURONSKIM MREŽAMA ZAPAŽENI U PRIMJERU POLJA KLOŠTAR	52
3.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU LITOLOŠKOGA SASTAVA I ZASIĆENJA UGLJKOVODICIMA	54
3.5. LITERATURA	55
 <b>4. PROCJENA POROZNOSTI NEURONSKOM MREŽOM, PRIMJER POLJA BENIČANCI</b>	
4.1. OSNOVNI GEOLOŠKI ODNOSSI U POLJU BENIČANCI	59
4.2. ULAZNE VARIJABLE ZA NEURONSKU MREŽU	60
4.3. VRSTA I PARAMETRI UVJEŽBAVANJA NEURONSKE MREŽE	61
4.3.1. Vrijednosti robusnih parametara mreže	61
4.3.2. Vrijednosti osjetljivih parametara mreže	62
4.4. REZULTATI NEURONSKE MREŽE	63
4.5. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU POROZNOSTI	65
4.6. LITERATURA	67
 <b>5. REKONSTRUKCIJA DIJELOVA KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA, PRIMJER IZ HRVATSKOGA DIJELA PANONSKOGA BAZENA</b>	
5.1. OSNOVNI GEOLOŠKI ODNOSSI U POLJU ĐELETOVCI	69
5.2. OSNOVNI GEOLOŠKI ODNOSSI U POLJU STARI GRADAC–BARCS NYUGAT	70
5.3. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA U POLJU KLOŠTAR	71
	72

5.3.1. Rezultati analiza višeslojne neuronske mreže	73
5.3.2. Rezultati analiza neuronske mreže s radijalnom funkcijom	76
5.3.3. Rezultati analiza neuronske mreže s postupkom poopćene regresije	78
5.4. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA	
U POLJU STARI GRADAC–BARCS NYUGAT	80
5.4.1. Rezultati analize podataka iz intervala „miocenski klastiti“	81
5.4.2. Rezultati analize podataka iz intervala „metavulkaniti“	83
5.5. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA	
U POLJU ĐELETOVCI	85
5.6. ZAKLJUČAK O REKONSTRUKCIJI KAROTAŽNIH KRIVULJA	
POMOĆU NEURONSKIH MREŽA	88
5.7. LITERATURA	89
<b>POGOVOR</b>	91
<b>KAZALO</b>	95

---

---

---

---

---

---

---

---

## **PREDGOVOR**

Neuronski alati danas su uobičajeni u analizi različitih podataka, a pozornost privlače i svojim nazivom koji ih povezuje s ljudskim poступcima, odnosno mehanizmima kojima razmišljamo i odlučujemo. Već nekoliko desetljeća neuronski se alati razvijaju i teorijski i praktičnom primjenom u mnogim znanostima poput geologije, brojnih prirodnih znanosti, informatike, lingvistike, ekonomije i drugih.

Njihova je glavna primjena pri traženju zavisnosti između podataka koji nisu u isključivo linearnoj vezi, a opet mogu se ujediniti u jedan složeni ulazni skup. Ujedinjavanje takvih podataka zadatak je stručnjaka u području u kojem se neuronske mreže primjenjuju, a njihova analiza kasnije je u domeni vrste neuronske mreže koja je odabrana. Danas postoji nekoliko glavnih vrsta mreža, a o njima će više riječi biti u tekstu knjige. No, temeljno je obilježje svih mreža da se odlikuju svojstvom „učenja“, tj. uvježbavanja kroz niz ponavljajućih postupaka analize. Od cijelog skupa podataka veći dio upotrijebljen je za učenje, a manji za ponovno predviđanje poznatih vrijednosti. Na taj način lako je izračunati pogrešku predviđanja, koja bi većim brojem pokušaja trebala biti što manja. Taj postupak „učenja“ nalik je na ljudsko učenje iz iskustva pa odatle i naziv „neuronske mreže“.

Primjena takvih alata u geologiji prilično je raširena, a posebno u onim disciplinama u kojima se raspolaze velikim brojem podataka te se kod većine analiza upotrebljavaju namjenski računalni programi.

Geologija ležišta ugljikovodika jedno je od takvih disciplina unutar polja geologije, u kojem autori imaju prilično iskustvo, pa se primjeri upotrebe neuronskih alata odnose upravo na analize podataka iz ležišta nafte i plina.

No, svi su primjeri vrlo razumljivi te je, uz malo truda, gotovo jednake neuronske modele moguće preslikati u sva druga područja geologije, odnosno prikupljene stratigrafske, tektonske, hidrogeološke, inženjersko geološke i druge podatke analizirati neuronskim alatima.

Nadamo se da će čitateljima knjiga koja je pred njima biti zanimljiva, laka za snalaženje te im pružiti dovoljno znanja da samostalno načine različita predviđanja, rekonsstrukcije i procjene na temelju svojih podataka upotrebom neuronskih alata.

*Autori*

# 1.

## OSNOVNA IDEJA I NAČIN RADA UMJETNE NEURONSKE MREŽE

Umjetna neuronska mreža ima dosta dodirnih točaka sa strukturu ljudskog mozga. Ta sličnost nije izražena u gradivnim elementima tih mreža, jer je, naravno, ljudska neuronska struktura biološka, sastavljena od stanica, u kojima se informacije prenose kemijskim i električkim putom. Za razliku od toga, umjetna (računalna) neuronska mreža temelji se na poluvodičkoj tehnologiji u kojoj se promjene stanja unutar mikroprocesora prenose isključivo električki. Zajedničko im je da obje vrste mreža prenose samo dvije informacije, tj. je li veza aktivna (1) ili nije (0), koje su izražene određenim električnim potencijalom, bilo u mozgu, bilo u računalu.

Sličnost je tih dviju mreža u načinu kako ta dva stanja upotrebljavaju da bi konačan rezultat predstavljaо suvislu obradbu podataka. Obje arhitekture na kraju se temelje na postupcima koji se ponavljaju, iteracijama ili učenju, odnosno uvježbavanju (npr. **Rosenblatt, 1957, 1958**). Ovisno o malim promjenama u rezultatima kod svake iteracije dolazi do korekcije konačnoga rezultata koji se na kraju procesa učenja sprema kao završni. Dobiveni uzorak (pod uzorkom se misli na konačnu arhitekturu mreže i završni matematički izraz za daljnju projekciju) upotrebljava se za kasniju analizu istovrsnih ili sličnih podataka (situacija) te se kod čovjeka naziva *iskustvom*, a kod računala *uv-*

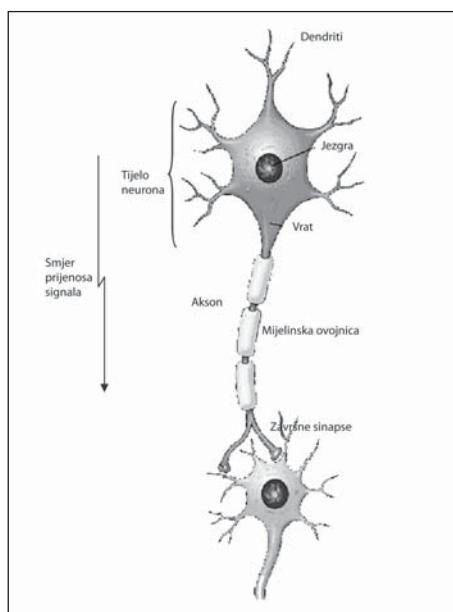
*ježbanom mrežom.* Osnovne računalne arhitekture neuronskih računalnih mreža dane su u sljedećim potpoglavlјima s naglaskom da su te temeljne postavke nadograđene kroz niz posebnih postupaka, odnosno posebnih vrsta neuronskih mreža nastalih prilagođavanjem obradba za određene skupove podataka, a nakon što je prikupljeno znatno iskušto o ponašanju osnovnih tipova mreža (npr. **Anderson & Rosenfeld, 1989; McCormack, 1991; Riedmiller & Braun, 1993**).

## 1.1. LJUDSKI NEURONI

U ljudskome mozgu neuroni služe kao prijenosnici informacija međusobno komunicirajući sinapsama. Ovisno o vrsti poslanoga signala susjedni će se neuron aktivirati ili će ostati neaktivan. Skup mnoštva takvih međudjelovanja čini ono što se naziva „mišljenje”. Takav mehanizam izgleda vrlo jednostavno dok se ne uzme u obzir podatak da u mozgu ima oko  $10^{11}$  neurona. Svaki od njih povezan je s gotovo tisuću susjednih neurona. Tijelo neurona (**slika 1.1**) naziva se *soma*. Okruženo je *dendritima* koji primaju signale iz ostalih neurona. Ti signali mogu potaknuti ili spriječiti daljnju neuronsku aktivnost. Ako je neuron aktiviran, stvara se električni impuls koji polazi od baze izlaza neurona (engl. „hillock“), kreće se preko nastavaka nazvanih *aksonima* (engl. „axon“) i završava na krajevima sinapse (engl. „boutons“).

Ako je ljudski neuron aktiviran, znači da je nastao električni impuls koji se prenosi elektrokemijskim putom preko sinapsa. Gledano fizikalno, „neaktivni“ neuroni imaju električni potencijal 40–60 mV.

„Aktivnim“ neuronima potencijal se mijenja na 90–100 mV. Brzina putovanja impulsa iznosi 0,5–100 m/s i obično traje oko 1 ms (znači da signal u prosjeku prelazi put od 5 do 10 cm). Nakon aktiviranja neurona treba proteći nekoliko milisekunda da bi se mogao ponovno aktivirati. Općenito, prosječni neuron može se aktivirati oko 100 puta u sekundi ili jedanput u 10 ms.



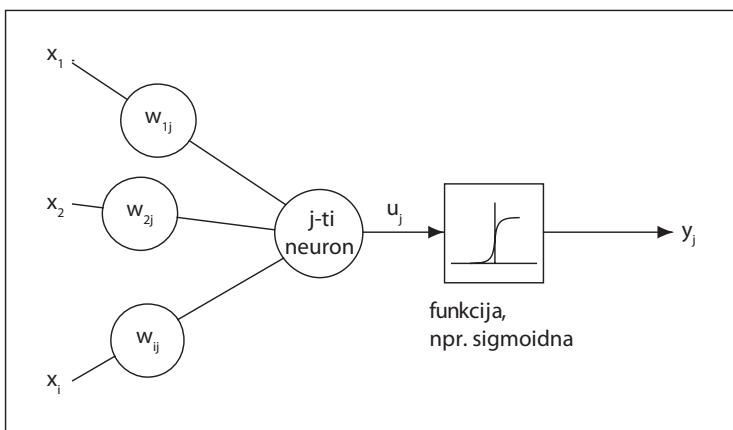
**Slika 1.1:** Model ljudskoga neurona

Kod električnog računala brzina signala iznosi oko  $3 \times 10^8$  m/s, trajanje je električnoga impulsa  $10^{-5}$  ms. Vidljivo je da računala oko  $3 \times 10^{11}$  puta brže prenose električni signal. Uz to, njihovo je vrijeme „oporavka“ oko milijun puta kraće od ljudskih neurona ili oko 10 ns.

Brzina prijenosa podataka očito je za nekoliko redova veličine na strani računala, no to nije jedini kriterij ocjene sustava, jer bi u tome slučaju elektroničko računalo već sada bilo nedostižno ljudskom mozgu. Budući da to nije tako očito je trebalo pronaći i definirati način kojim čovjek dominira u odnosu na svoje elektroničko djelo. I ta je prednost izražena u iznimnoj sposobnosti prepoznavanja uzoraka (pravilnosti) u svojem okruženju te donošenju zaključaka iz samo dijela podataka koji su ranije obrađeni. Drugim riječima, ljudski um ima sposobnost učenja i pamćenja, ali i mogućnost korekcije svojih zaključaka na temelju iskustva. Cilj je neuronskih mreža stvoriti uzorak što sličniji ljudskomu pamćenju, učenju i iskustvu unutar računalnoga sustava.

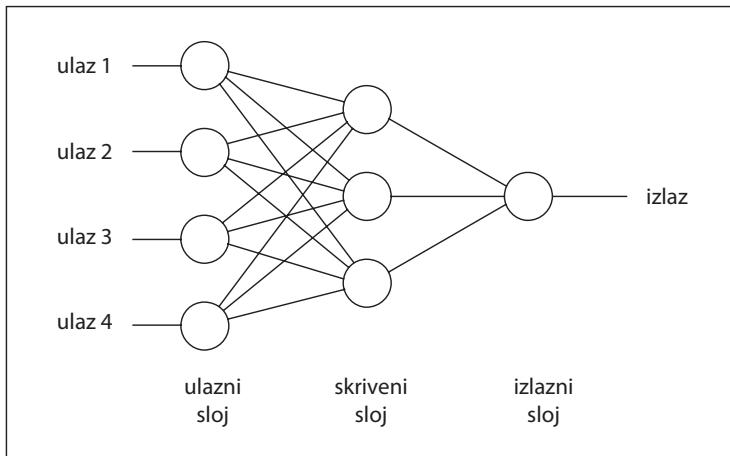
## 1.2. STRUKTURA NEURONSKE MREŽE

Struktura neuronske mreže temelji se na modelu umjetnoga neurona (**slika 1.2**). Takav neuron sastavljen je od nekoliko ulaza i jednoga izlaza. Svakomu ulazu dodijeljena je odgovarajuća težina kojom se opterećuje ulazna vrijednost. Ovisno o rezultatu neuron će ostati neaktiviran ili će se aktivirati. O vrijednostima i uvjetima aktivacije odlučuje tzv. aktivacijska funkcija. Neuronska mreža ima još jedno obilježje kojim oponaša rad ljudskog mozga, a to je povrat informacije te se na taj način se ostvaruje nešto što nalikuje na učenje. Taj postupak opisuje jedan od najčešćih modela neuronskih mreža, tj. mrežu s povratnim postupkom (engl. „backpropagation network“).



*Slika 1.2: Model umjetnoga neurona*

Način na koji određeni broj neurona čini mrežu mogao bi se opisati pomoću nekoliko vrsta slojeva (**slika 1.3**). Prvo se odabrani broj neurona poreda u niz čineći ulazni sloj. Ti neuroni svoje signale šalju prema međuslojevima koji nemaju vezu s okolinom (ni ulaznu, ni izlaznu) te su nazvani i skriveni slojevi. Način veze između ulaznoga i tih slojeva određuje vrstu mreže, a mreža je obično potpuno povezana unatrag, što znači da je svaki neuron povezan sa svakim izlazom iz prethodnoga sloja. Rezultat je, nakon obradbe, uvjek izražen kroz jedan izlazni sloj koji je veza prema vanjskome svijetu.



*Slika 1.3: Shema organizacije neuronske mreže preko slojeva*

Općenito, ulazni sloj prosljeđuje signal iz okолнога svijeta. Skriveni slojevi obrađuju primljeni signal. Izlazni sloj prikuplja rezultate i stvara izlaz.

### 1.3. OSNOVNI MATEMATIČKI IZRAZI NEURONSKE MREŽE

Izlaz svakoga neurona predstavlja ulazni signal modificiran odgovarajućom funkcijom. Primjerice, izlaz neurona „j“ opisan je dvjema jednadžbama:

$$U_j = \sum X_i \cdot w_{ij} \quad (1.1)$$

$$Y_j = F_{th}(U_j + t_j) \quad (1.2)$$

gdje su:

$j$  – broj neurona

$i$  – broj ulaza

$X_i$  – vrijednost „ $i$ ”-tog ulaza

$w_{ij}$  – prije utvrđeni težinski koeficijent za ulaz „ $i$ ”

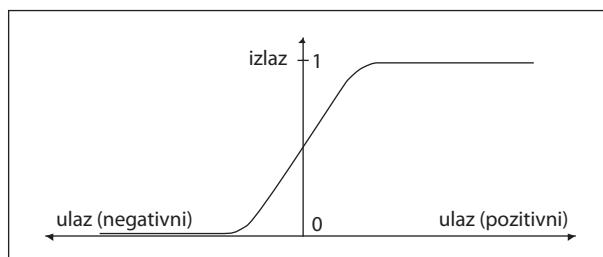
$U_j$  – zajednička vrijednost izlaza svih ulaza neurona „ $j$ ”

$F_{th}$  – aktivacijska funkcija

$Y_j$  – izlaz promatranoj sloja ili ukupni izlaz mreže

Kada se izračuna zajednička vrijednost  $U_j$ , ona se uspoređuje s vrijednošću odbacivanja hipoteze (engl. „threshold value“, „cutoff“), tj. testira se pokretanje aktivacijske funkcije  $F_{th}$ . Ukratko, prvi izraz (1.1) predstavlja skup operacija na neuronu, a drugi (1.2) ispituje aktivira li se taj isti neuron.

Aktivacijska funkcija obično je sigmoidnoga oblika (**slika 1.4**). Izlaz  $Y_j$  ulaz je za sljedeći sloj ili izlaz neuronske mreže ako se radi o posljednjemu sloju. Osim sigmoidne funkcije mogu se upotrijebiti i drugi oblici aktivacijskih funkcija.



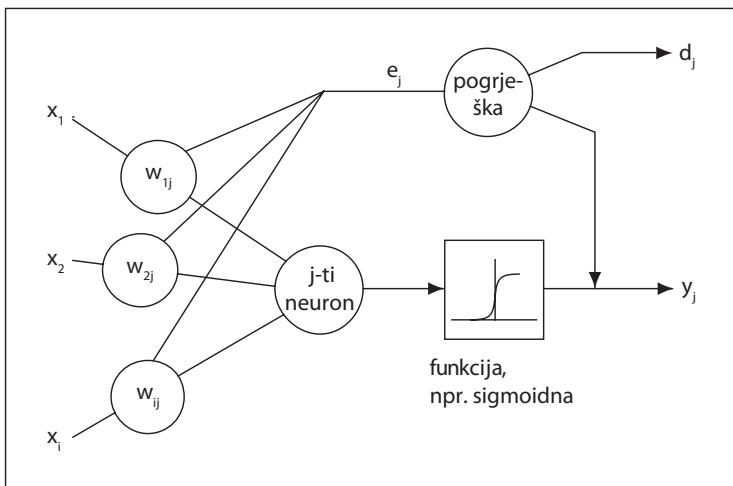
**Slika 1.4:** Sigmoidna aktivacijska funkcija

U jednadžbi (1.1) podrazumijeva se da postoje prethodno utvrđeni težinski koeficijenti, definirana vrijednost odbacivanja hipoteze i određen broj slojeva i neurona u svakome od tih slojeva. Tek kada su utvrđeni ti elementi, moguće je dobiti odgovor neuronske mreže za neki skup ulaznih podataka. Prve dvije spomenute vrijednosti (težinski koeficijenti i vrijednost odbacivanja) mogu se mijenjati i prilagođavati u prvome razdoblju rada mreže ili u vremenu dok mreža još „uči”.

#### 1.4. UČENJE MREŽE

Da bi neuronska mreža zaista oponašala rad ljudskoga mozga, potrebno je unutar nje simulirati proces učenja. To se u sustavima neuronskih mreža naziva uvježbavanjem (engl. „training“). Uvježbavanje treba biti planirano tako da kasnija upotreba mreže daje odgovarajući izlaz.

Ako se pritom može odrediti razlika između stvarnoga i željenoga odgovora mreže, dobije se iznos pogreške koji se može vratiti natrag u mrežu kako bi se ona bolje uvježbala (**slika 1.5**). Pogrješka određena na svakome neuronu služi za prilagođavanje postojećih težinskih koeficijenata i vrijednosti njihove aktivacije.



**Slika 1.5:** Prilagođavanje težinskih koeficijenata i smanjivanje pogreške

Takva korektivna procedura nazvana je mrežom s postupkom povratne informacije (engl. „backpropagation network“). Ponavlja se toliko puta dok se pojedinačna ili ukupna pogreška ne spusti ispod željene vrijednosti. Nakon toga je proces uvježbavanja neuronske mreže završen i ona se može upotrijebiti za obradbu novih ulaznih podataka.

Nekoliko je osnovnih matematičkih izraza koji opisuju učenje neuronske mreže.

Postupak vraćanja informacije unutar mreže kreće unatrag počevši od izlaznog sloja i definiran je sljedećim jednadžbama:

$$w_{ij} = w_{ij}^* + LR \cdot e_j \cdot X_i \quad (1.3)$$

$$e_j = Y_j \cdot (1 - Y_j) \cdot (d_j - Y_j) \quad (1.4)$$

gdje su:

$i$  – broj ulaza  $j$ -toga neurona u izlaznom sloju

$w_{ij}$  – broj neurona

$w_{ij}^*$  – korekcija težine određena u postupku učenja

$LR$  – iznos učenja (engl. „Learning Rate“)

$e_j$  – iznos pogreške

$X_i$  – vrijednost  $i$ -toga ulaza

$Y_j$  – stvarni izlaz

$d_j$  – željeni izlaz

Izraz (1.4) može se modificirati ovako (1.5):

$$e_j = Y_j \cdot (1 - Y_j) \cdot \sum (e_k \cdot w_{jk}^*) \quad (1.5)$$

gdje su:

$e_j$  – iznos pogreške u promatranom neuronu „ $k$ “

$w_{jk}^*$  – korekcija težina u promatranim parovima neurona „ $j$ “ i „ $k$ “

U tome slučaju razlika između željenoga i stvarnoga izlaza zamije- njena je zbrojem pogrešaka na svakome neuronu „ $k$ “ u sloju koji slijedi odmah nakon sloja koji se obrađuje, a ovisno o prethodno pri- lagođenim težinama.

Iznos učenja (skr. „LR“) utječe na prethodno određene težinske koe- ficiente i računa nove. Također njezin iznos utječe na brzinu procesa

učenja. Obično se počinje nižom vrijednošću, a ako je proces uvježbavanja spor, vrijednost se povećava. Najčešće se prilagođavanje težinskih koeficijenata radi kroz nešto proširenu **jednadžbu (1.6)**:

$$w_{ij} = w_{ij}^* + (1 - M) \cdot LR \cdot e_j \cdot X_j + M \cdot (w_{ij}^* - w_{ij}^{**}) \quad (1.6)$$

gdje su:

$M$  – momentni faktor

$w^*, **$  – težinski koeficijenti određeni u prethodna dva koraka

U tu jednadžbu uveden je momentni faktor ‘M’ te se upotrebljavaju težinski koeficijenti iz prethodnih dvaju koraka. Ako je ‘M = 0’ jednadžba se vraća na **izraz (1.3)**, koji je jednostavnija procjena težinskih koeficijenata. Većom vrijednošću ‘M’ pojačan je utjecaj prethodnih vrijednosti težina u njihovoј novoj procjeni. To u nekim slučajevima može poboljšati iznos učenja.

Jedan dio skupa ulaznih podataka najčešće se ostavlja po strani za provjeru (engl. „validation“) neuronske mreže, koja slijedi nakon uvježbavanja. Kod testnoga skupa podataka već je poznato kakvi se izlazi trebaju dobiti pa je tako moguće kontrolirati kvalitetu uvježbavanja.

Na kraju opisanoga postupka mreža je spremna obraditi skupove podataka kod kojih izlazna vrijednost nije poznata. Tada se više ne primjenjuje povratni postupak, tj. mreža više ne uči i ne proširuje svoje mogućnosti, već se računaju samo nove vrijednosti iz uspostavljenih

odnosa. Svako novo proširivanje mogućnosti mreže zahtijeva pripremu i analizu novoga skupa podataka za uvježbavanje.

## 1.5. MREŽA S POVRATNIM POSTUPKOM

U ranim danima razvoja umjetne inteligencije **Rosenblatt (1957, 1958)** je radeći u aeronautičkome laboratoriju „Cornell“ razvio mehanizam zvan *perceptron*, koji se temelji na pohrani podataka onako kako se to odvija u ljudskome umu. Takav postupak imao je svojstva učenja. Osnova je te neuronske strukture, naravno, umjetni neuron čija aktivacija ovisi o rezultatu obradbe aktivacijske funkcije. Vraćajući se ponovno na definiciju mreže preko ulaznih, skrivenih i izlaznoga sloja, naglašava se važnost *težinskih koeficijenata* (**1.7**):

$$U_j = \left( X_i \cdot w_{ij} \right) \quad (1.7)$$

gdje su (primijenjeno na pojedinačni neuron):

$U_j$  – vrijednost izlaza neurona „ $j$ “

$X_i$  – vrijednost ulaza „ $i$ “

$w_{ij}$  – prethodno određeni težinski koeficijenti za ulaz „ $i$ “ i neuron „ $j$ “

Težinski koeficijenti se primjenjuju u svakome skrivenome sloju upotrebom aktivacijske funkcije (**1.8**):

$$Y_j = F(U_j + t_j) \quad (1.8)$$

gdje su (primjenjeno na cijelu mrežu):

$Y_j$  – izlaz sloja „ $j$ “ (može biti i ukupni izlaz mreže)

$F$  – aktivacijska funkcija

$U_j$  – izlaz neurona „ $j$ “

$t_j$  – ciljna vrijednost za neuron „ $j$ “

**Jednadžba (1.7)** podrazumijeva da su prethodno određeni težinski koeficijenti za svaki neuron, a **jednadžba (1.8)** da su određene i vrijednosti prihvaćanja hipoteze aktivacijskom funkcijom, broj slojeva te broj neurona u svakome sloju. Vrijednosti težinskih koeficijenata i prihvaćanja hipoteze mijenjaju se kroz razdoblje uvježbavanja mreže, tražeći najmanju ukupnu pogrešku mreže.

Kako je opisano, najjednostavnija arhitektura mreže temelji se samo na perceptronima. Njezino je ograničenje prepoznavanje veza u podatcima koje su predstavljene isključivo linearnim matricama. To ograničenje prevladano je uvođenjem nove paradigmе ili algoritma (spomenutoga u potpoglavlju 1.4.) nazvanoga *povratnim postupkom* (engl. „back error propagation“ ili skr. „backprop“). Time je unaprijeđena arhitektura pojedinačnoga perceptrona, ponajprije uvođenjem većega broja skrivenih slojeva (odakle potječe naziv *višeslojna mreža*; engl. „Multiple Layer Perceptron“ ili skr. „MLP“), a zatim i vraćanjem rezultata unatrag i ponavljanjem iteracija veliki broj puta.

Algoritam povratnoga postupka podrazumijeva da učenje mreže uključuje određivanje razlike između stvarnoga i želenoga odgovora,

tj. izračun pogreške vraća se natrag u mrežu s ciljem postizanja najuspješnijega učenja. Takva pogreška izračunata je za svaki neuron te je upotrijebljena za prilagodbu težinskih koeficijenata i vrijednosti aktivacijske funkcije. Na temelju takva korektivnoga postupka mreža je nazvana *mrežom s povratnim postupkom* tijekom učenja i provjere mreže. On se ponavlja toliko puta dok pojedinačna ili ukupna pogreška nije niža od postavljene granične vrijednosti. Nakon dosezanja te granice učenje je mreže završeno i ona može biti primijenjena za predviđanje na temelju novih podataka. Jednadžba algoritma povratnoga postupka prikazana je **izrazom 1.9**:

$$[w_i]_{novi} = [w_{i-1}]_{stari} + LR \cdot TF \cdot CT + MC \cdot \Delta w \quad (1.9)$$

gdje su:

$[w_i]_{novi}$  – težinski koeficijent ulaza u „i-toj“ iteraciji

$[w_{i-1}]_{stari}$  – težinski koeficijent ulaza u prethodnoj iteraciji

$LR$  – iznos učenja (engl. „Learning Rate“) koji upućuje na razinu upotrebe aktivacijske funkcije i koeficijenta momenta (engl. „Momentum Coefficient“) u svakoj iteraciji. Ako je  $LR = 0$ , aktivacijska funkcija nije upotrijebljena, a rad cijele mreže temelji se isključivo na upotrebi koeficijenta momenta;

$TF$  – aktivacijska funkcija, ovdje prevedena i kao prijenosna funkcija (engl. „Transfer Function“). Postoji nekoliko oblika takvih funkcija, a ovdje je upotrijebljena sigmoidna, tj.:

$$f(x) = \frac{1}{1+e^x}$$

- $CT$  – korekcijski izraz (engl. „Correction Term“). Vrijednost korekcijskoga izraza ovisi o razlici između stvarne (mjerene) i mrežom uvježbane vrijednosti;
- $MC$  – koeficijent momenta (engl. „Momentum Coefficient“) određuje koliki je utjecaj prethodne iteracije u trenutnoj kalkulaciji
- $\Delta w$  – razlika spomenutih težinskih koeficijenata

Takav postupak danas je još uvijek najpopularnija temeljna paradigma koja se primjenjuje u neuronskim mrežama. Ipak, upotreba povratnoga postupka može znatno produžiti vrijeme uvježbavanja mreže pa postoji nekoliko metoda nadogradnje kojima se smanjuje taj problem, ali i poboljšavaju neki drugi elementi mreže. Na primjer, znatno smanjenje vremena učenja postupno je postignuto uvođenjem metode *postupnoga opadanja* (engl. „gradient descent“), kojom je poboljšan algoritam povratnoga postupka.

## 1.6. MREŽA S RADIJALNOM FUNKCIJOM

Mrežu s radijalnom funkcijom (engl. „Radial Basis Function“, skr. „RBF“) predložio je M. J. D. Powel (opisano u: **Karatalopoulos, 1996**). Može se upotrebljavati u istim situacijama kao i mreža s postupkom povratne informacije. Ta mreža upotrebljava radijalno simetričnu i radijalno ograničenu aktivacijsku funkciju u svojemu skrivenoj sloju.

Mreža s radijalnom funkcijom nema neke nedostatke mreže s postupkom povratne informacije kao što su problem lokalnoga minimuma i dugotrajan proces učenja, no zahtijeva više računanja u fazi prekida rada mreže prije negoli sama kroz zadani broj iteracija dosegne zadani minimum.

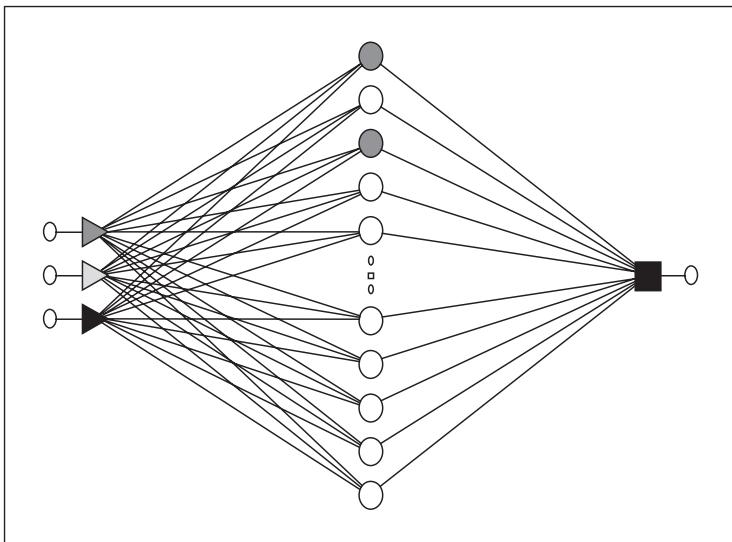
Mreža se sastoji samo od triju slojeva, tj. od ulaznoga, skrivenoga i izlaznoga sloja (**slika 1.6**). Takva arhitektura, uz veliki broj neurona u skrivenom sloju, karakteristika je RBF mreže. Broj neurona u ulaznom sloju odgovara broju ulaznih varijabli te, primjereno tomu, broj neurona u izlaznom sloju odgovara broju izlaznih varijabli.

Algoritam učenja u mreži s radijalnom funkcijom može se, kroz slojeve, opisati na sljedeći način:

1. Učenje počinje u skrivenome sloju s nenadgledanim algoritmom kako bi se odredilo središte.
2. Učenje se nastavlja u izlaznom sloju s nadgledanim algoritmom kako bi se izračunala pogrješka.
3. Istodobno se primjenjuje nadgledani algoritam u skrivenome i izlaznom sloju kako bi se prilagodile težine u mreži.

Iako mreža s radijalnom funkcijom ima brzi algoritam za učenje, po nekad se može dogoditi da je potrebno više vremena za učenje nego kod mreže s postupkom povratne informacije.

Početna faza učenja kod mreže s radijalnom funkcijom temelji se na nenadgledanoj fazi pridodavanja podataka pojedinim skupinama te

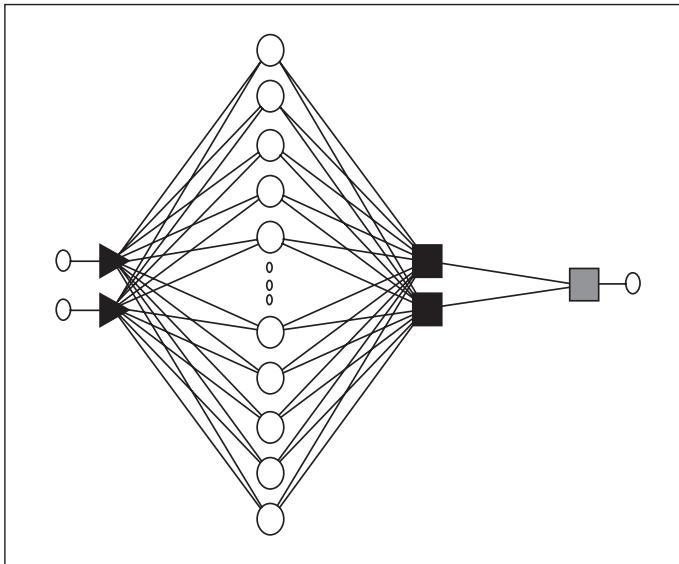


**Slika 1.6:** Jednostavan prikaz mreže s radikalnom funkcijom s velikim brojem neurona u skrivenome sloju (izvor: *Statistica, 2007*)

bi se stoga moglo dogoditi da se u toj fazi izgube neke važne informacije.

## 1.7. MREŽA S POSTUPKOM POOPĆENE REGRESIJE

Neuronska mreža s postupkom poopćene regresije (engl. „Generalized Regression Neural Network“, skr. „GRNN“) predstavlja unaprijedenu verziju RBF mreže jer u svojoj gradi obvezno sadržava dva skrivena sloja, uz uobičajeni ulazni i izlazni sloj. Broj je neurona u prvoj skrivenome sloju velik i ovisi o veličini ulaznoga skupa podataka, dok broj neurona u drugome skrivenome sloju mora biti dva (**slika 1.7**).



**Slika 1.7:** Jednostavan prikaz mreže s poopćenom regresijom s velikim brojem neurona u skrivenome sloju (*Statistica, 2007*)

Postupak obradbe informacija u ovoj neuronskoj mreži može se kroz slojeve opisati na sljedeći način:

1. Podatci proslijeđeni iz ulaznoga sloja obrađuju se u prvome skrivenome sloju. Prvi skriveni sloj mora sadržavati onoliko neurona koliko ima slučajeva koji se koriste u obradbi podataka. Ovdje se određuju težinski koeficijenti za pojedini neuron, a on ovdje predstavlja koliko će okolnih slučajeva (neurona) imati utjecaj na vrijednost u promatranome neuronu.
2. Drugi skriveni sloj obvezno se sastoji od dvaju neurona. Jedan neuron predstavlja sumu (tzv. „neuron nazivnik“, engl. „denominator unit“) svih težinskih koeficijenata i primjenjivat će se

kao nazivnik u jednadžbi konačnoga izračuna predviđene vrijednosti. Vrijednost izlaza drugoga neurona (tzv. „neuron brojnik“, engl. „numerator unit“) predstavlja sumu težinskih koeficijenata pomnoženih sa zadanim izlaznom vrijednosti.

3. U izlaznome sloju predviđena se vrijednost izračunava kao kvocijent dviju izlaznih vrijednosti neurona iz drugoga skrivenoga sloja.

Mreža s postupkom poopćene regresije djelomično nasljeđuje svojstva od RBF mreže od koje je uspješnija u slučaju kada je manji ulazni skup podataka (sadržava veći broj neurona u skrivenome sloju uz drugačiji način izračuna vrijednosti). Zbog svojega načina izračunavanja vrijednosti mreža ima tendenciju „zaglađivanja“ rezultata ovisno o postavi težinskoga koeficijenta.

## 1.8. LITERATURA

1. Anderson, J. A. & Rosenfeld, E. (1989): Neurocomputing: Foundations of Research. Cambridge, MA: MIT Press.
2. Karatalopoulos, S. V. (1996): Understanding neural networks and fuzzy logic, basic concepts and application. IEEE Press.
3. McCormack, M. D. (1991): Neural Computing in Geophysics. The Leading Edge, 10/1, Society of Exploration Geophysicists.
4. Riedmiller, M. & Braun, H. (1993): A direct adaptive method for faster backpropagation learning: The RProp algorithm. Proc. of the IEEE Intl. Conf. on Neural Networks, San Francisco, 586–591.

5. Rosenblatt, F. (1957): The perceptron: A perceiving and recognizing automaton. Technical report 85-460-1, Project PARA, Cornell Aeronautical Lab.
6. Rosenblatt, F. (1958): The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, 386–408.

## **2.**

# **PREDVIĐANJE KLASTIČNIH FACIJESA NEURONSKOM MREŽOM, PRIMJER POLJA OKOLI**

Primjer u ovome poglavlju predstavlja izvadak iz jednoga od prvih radova objavljenih u nas s tematikom primjene neuronskih mreža u analizi ležišta ugljikovodika (**Malvić, 2006**).

### **2.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU OKOLI**

Polje Okoli sadržava nekoliko pješčenjačkih ležišnih „serija“, od kojih se svaka dijeli na nekoliko pojedinačnih ležišta. No, pojam „serija“ ovdje je napisan unutar navodnika kako bi se razlikovao od formalno definirane kronostratigrafske jedinice (veće od doba, a manje od sistema). Pisana pod navodnicima predstavlja neformalnu jedinicu koja obuhvaća nekoliko ležišta iz kojih se proizvode ugljikovodici.

Struktura Okoli predstavljena je brahiantiklinalom izduženom pravcem SZ–JI, u dubljim dijelovima rasjednutom. Ležišne su stijene gornjopontske („serije“ „b“ i „c“) te pliocenske („serije“ „p“, „A“, „B“, „a“) starosti. Ukupno je otvoreno 11 ležišta unutar „serije“ „c“ ( $c_1 - c_{11}$ ). „Serija“ „a“ (ležišta  $a_1, a_2, a_3$ ) iskorištava se za utiskivanje i sklađištenje plina, dok se danas kao eksplotacijski objekti za plin vode „serije“ „b“ i poglavito „serija“ „c“. Pješčenjačka šupljikavost varira

između 14 i 37%, a propusnost između 1,3 i  $24,8 \times 10^{-3} \mu\text{m}^2$  (**Jüttner et al., 2001; Saftić et al., 2001**). Debljina pješčenjačkih ležišta varira približno između 1 metra i 20 metara.

Strukturni podatci preuzeti su iz baze tvrtke INA d. d. (**Atlas polja, 2005**) te su razlučeni intervali ležišta  $c_2$ . „Serija“ „c“ razvijena je u najvećemu dijelu strukture Okoli, a pojedinačna ležišta uglavnom su međusobno konkordantna, s lokalno korelativnim laporima u krovini i podini.

Ležište	Bušotina B-1 (aps. dubine u metrima)	Bušotina B-2 (aps. dubine u metrima)
$c_1$	2 088,5 – 2 098,5	2 123,0 – 2 125,5
Lapor	2 098,5 – 2 108,5	2 125,5 – 2 135,0
$c_2$	2 108,5 – 2 132,5	2 135,0 – 2 164,0
Lapor	2 132,5 – 2 147,5	2 164,0 – nedostaje
$c_3$	2 147,5 – 2 152,0	nedostaje – nedostaje
Lapor	2 152,0 – 2 159,5	nedostaje – 2 184,0
$c_4$	2 159,5 – 2 177,5	2 184,0 – 2 192,0

**Tablica 2.1:** Smještaj ležišta  $c_i - c_4$  u analiziranim bušotinama

U bušotini B-1 lapor u krovini i podini ležišta  $c_2$  omedjen je ležištim  $c_1$  i  $c_3$  (normalan konkordantni slijed, **tablica 2.1**). U bušotini B-2 takve granice predstavljaju ležišta  $c_1$  i  $c_4$  (ležište  $c_3$  je zalapreno, **tablica 2.1**). Bušotina B-1 smještena je približno na tjemenu, a B-2 na sjeverozapadnome krilu strukture.

Upotrijebljene karotažne krivulje za bušotinu B-1 su GR (krivulja prirodne radioaktivnosti),  $R_{16}$  (krivulja otpornosti – „mala normala“) i  $R_{64}$  (krivulja otpornosti – „velika normala“).

Ulagne krivulje u bušotini B-2 bile su GR, PORE (krivulja efektivne poroznosti), PORT (krivulja ukupne/totalne poroznosti), PORW (krivulja poroznosti u dijelu stijene zasićene 100% vodom),  $R_{16}$ , SANDSTONE (krivulja udjela pješčenjaka) i SHALE (krivulja udjela lapor).

Izlazna krivulja u obama slučajevima nazvana je „ležište“. Ta krivulja predstavlja „kategoriziranu“ varijablu, definiranu brojčano s 0 i 1. Broj 0 predstavlja lapor, a 1 pješčenjak. Te vrijednosti poredane su po dubini zahvaćenoga intervala te na taj način opisuju facijes odabranoga ležišta, krovinskoga i podinskoga lapor. Cilj analize programom cVision bilo je predviđanje točnoga poretku brojeva 0 i 1, tj. položaj lapor i pješčenjaka, odnosno što točnija rekonstrukcija vrijednosti varijable nazvane „ležište“, kojom su predstavljeni facijesi.

Za polje Okoli napravljena su brojna geološka istraživanja. Facijesna analiza pokazala je homogenost i razlučivost koja se može opisati matematički (**Hernitz et al., 2001**) te su izračunati eksperimentalni semivariogrami poroznosti i propusnosti prema podatcima iz ležišta a<sub>1</sub>. Interpretacija krivulja temeljila se na utvrđivanju semivariogramskih trendova u različitim klastičnim rezervoarima (**Kupfersberger & Deutsch, 1999**). Dokazano je kako su ležišta serije „a“ podijeljena u zone s obzirom na varijaciju petrofizikalnih podataka. Nadalje, nekoliko tih zona može se povezati u veću cjelinu 2. reda, a tada se opaža i ciklični trend postupnoga porasta vrijednosti s dubinom. Variogramski doseg poroznosti u ležištu a<sub>1</sub> iznosi 3,2 – 5,3 metara i na toj udaljenosti postoji međusobna zavisnost uzoraka poroznosti. Ka-

ko je to ležište reprezentativno za cijelu seriju „a“ tim dosezima mogu se ekstrapolirati petrofizikalne vrijednosti u neuzorkovane dijelove serije „a“. Kod propusnosti doseg iznosi 2,2 metra. Autori su tako dokazali kako je petrofizikalne parametre, a time i facijese u polju Okoli, moguće opisati geomatematičkim alatima, u koje se ubrajaju i neuronske mreže.

## 2.2. PROGRAM cVision

Za facijesnu analizu ležišta u polju Okoli upotrijebljen je cVision (po-kusna licenca) proizvođača *Neuro Genetic Solution* (NGS) koji se bavi razvojem programa i analizom podataka iz ležišta ugljikovodika (**Fruhwirth, 2005**). Program je dodatak (engl. „AddIn“) unutar MsExcel™ okruženja, pa se podaci učitavaju iz jedne ili više tablica oblika „.xls“. Posebni dio programskoga algoritma nazvan je *lokalno prilagodiva pravila učenja* (engl. „local adaptive learning rules“). Time je korisniku omogućeno da pojmom *iznos učenja mreže* (engl. „learning rate“) poznaje samo elementarno. Uz to, svaka sinaptička veza između neurona u različitim slojevima ima svoju vlastitu vrijednost iznosa učenja, prilagođenu tijekom uvježbavanja.

Automatiziran je i proces određivanja veličine mreže, čime je one-mogućeno zagušenje prilikom modeliranja, odnosno predimenziranje zbog memoriranja privremenih podataka ili analiziranja nekarakterističnih, redundantnih podataka. Svi skriveni slojevi spojeni su prema naprijed kroz sve moguće kombinacije, čime je dobivena arhi-

tekturna *potpuno povezanih perceptron* (engl. „completely connected perceptrons“).

Ulagni podatci podijeljeni su u skupine namijenjene uvježbavanju (engl. „Learning“, skr. „L“), provjeri (engl. „Validation“, skr. „V“) i predviđanju (engl. „Testing“, skr. „T“), otprilike u omjeru 80 : 10 : 10%.

### 2.3. VRSTA UPOTRIJEBLJENE MREŽE I REZULTATI

Za analizu je odabrana vrsta mreže *potpuno povezanih perceptron*. Najbolja mreža odabrana je prema iznosu domene pogreške. Pogreška je određena prema kriteriju provjere (engl. „validation error“). Određen je broj mrežnih modula u mreži (engl. „experts in cluster“) uz različite početne uvjete, a odabrana je vrijednost od 10 modula. Vrijednost prema kojoj se inicira prvi modul naziva se *slučajan broj* (engl. „random seed value“), a početno je postavljen na 0,01. Sljedeći modul inicira se s prethodnom vrijednošću uvećanom za 1 itd. Razvoj mreže podrazumijeva njezinu nadogradnju povećanjem broja skrivenih slojeva za 1 do maksimalne dopuštene vrijednosti.

#### 2.3.1. Uvježbavanje mreže i njegini izlazi

Preko opcija opisanih u prethodnome poglavljju određuju se pravila te inicijalni iznos učenja. U analizi je odabran lokalno prilagodivo pravilo nazvano unaprijeđeni RProp algoritam (**Riedmiller & Braun, 1993**), tj. IRprop+ (iz engl. „Improved Resilient propagation plus“).

Kao početni iznos odabrana je vrijednost 0,01, koja se samostalno prilagođava tijekom učenja. U okvirima mreže definiraju se kriteriji prema kojima se zaustavlja njezin rad, tj. analiza.

Prvi je takav kriterij pogreška. Kada njezina vrijednost padne ispod graničnoga kriterija, analiza se prekida. Drugi je kriterij izražen najvećim brojem ciklusa uvježbavanja, nakon kojega se rad mreže zaustavlja bez obzira na prvi kriterij.

Rezultati analize facijesa u polju Okoli bili su predstavljeni tablicama i grafikonima, posebno izraženim za tri vrste izlaznih mreža nazvanih *najbolja mreža, trenutno najbolja mreža i niz karakterističnih mreža*.

*Najbolja mreža* (engl. „face machine“) sadržava rezultate o najboljoj mreži tijekom uvježbavanja i oni su završno mjerilo uspješnosti mreže.

*Trenutno najbolja mreža* (engl. „best machine“) sadržava podatke o trenutno najboljoj iteraciji.

*Niz karakterističnih mreža* (engl. „trip machine“) ujedinjuje niz najboljih rezultata dobivenih tijekom uvježbavanja (tj. rezultate u prvim dvjema vrstama mreža).

### **2.3.2. Rezultati analize facijesa u polju Okoli (ležište „ $c_2$ “)**

Rezultati su prvo prikazani odvojeno za bušotine B-1 i B-2, a zatim zajednički u zaključku. Iz bušotine B-1 upotrijebljene su krivulje GR,  $R_{16}$  i  $R_{64}$ . Za učenje mreže (engl. „learning or L“) ukupno su upotrije-

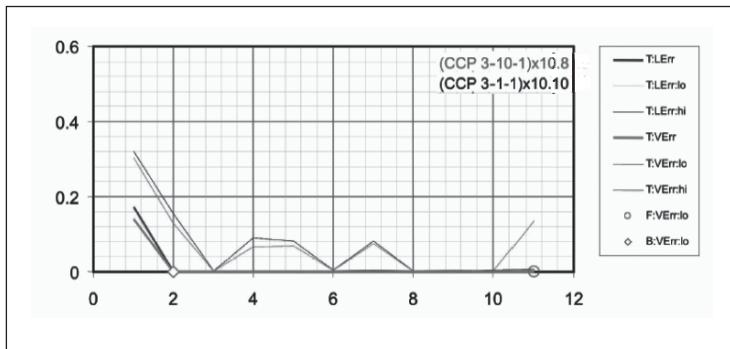
bljena 153 podatka s vrijednošću 0 te 142 podatka s vrijednošću 1. Za provjeru (engl. „validation or V“) 48 podataka imalo je vrijednost 0, a 50 podataka vrijednost 1.

LEGENDA (za skupinu od po tri stupca): 1 - Tip podataka; 2 – Kategorička varijabla „ležište“; 3 – Vjerojatnost uspješnoga predviđanja								
L	0	78,3	V	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	V	0	82,1
L	0	78,3	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	L	0	78,3
V	0	82,1	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	V	0	82,1
V	0	82,1	L	1	78,3	V	0	82,1
L	0	78,3	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	L	0	78,3
V	1	82,1	L	1	78,3	L	0	78,3
L	1	78,3	L	1	78,3	L	0	78,3
L	1	78,3	L	1	78,3	V	0	82,1
V	1	82,1	L	0	78,3			
L	1	82,1	L	0	82,1			

**Tablica 2.2:** Vjerojatnosti uspješnosti učenja mreže za buštinu B-1

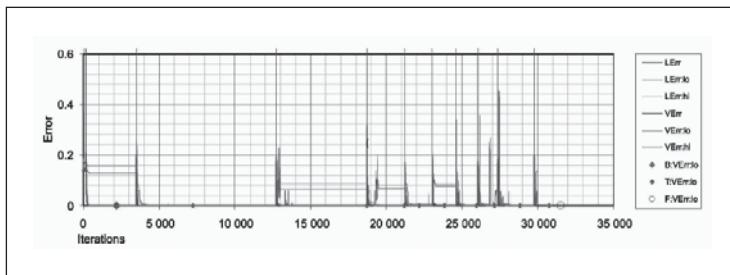
Najbolja mreža obilježena je s ukupno 31 515 iteracija, s vremenom učenja od 5,40 minuta te s prosječnom pogreškom učenja 0,00173. U buštoni B-1 je obrađeno ukupno 393 podatka.

Očitani podatak, kategorička vrijednost te uspješnost učenja i provjere mreže iskazani su u **tablici 2.2** i na **slici 2.1**. Rezultat uspješnosti postupka nigdje nije bio manji od 78,3% (oznaka L znači učenje, a V provjeru).



**Slika 2.1:** Odnos pogrješaka tijekom učenja ( $L$ ), provjere ( $V$ ) i predviđanja ( $T$ ) mreže te položaj ukupno (B) i trenutno (F) mreže u bušotini B-1  
(iz Malvić, 2006)

Vrlo je zanimljivo tijekom uvježbavanja mreže u bušotini B-1 pratiti varijaciju pogrješke te položaj ukupno i trenutno najbolje mreže u odnosu na 30 000 načinjenih iteracija (slika 2.2).



**Slika 2.2:** Varijacija pogrješke tijekom iteracija te položaj trenutno (F) i ukupno (B) najbolje mreže u bušotini B-1 (iz Malvić, 2006)

Istovrsno uvježbavanje i predviđanje napravljeno je u bušotini B-2. Ponovno bi u slučaju idealno uvježbane mreže stvarne vrijednosti tre-

bale u potpunosti odgovarati kategoričkoj varijabli „ležište“. Rezultati predviđanja u procesima uvježbavanja i provjere prikazani su u **tablici 2.3**. Ipak, vjerojatnost ispravnoga uvježbavanja i predviđanja (0 ili 1) procijenjena je na preko 80% za cijelo ležište.

U toj bušotini upotrijebljen je nešto veći broj krivulja koje prikazuju prirodnu radioaktivnost (GR), posredno izračunate poroznosti (efektivnu – PORE, ukupnu – PORT, te dijela prostora zasićenoga vodom – PORW), zatim otpornost ( $R_{16}$  i  $R_{64}$ ) te ponovno krivulje dobivene posredno koje označavaju facijese (SANDSTONE i SHALE).

Za učenje mreže (engl. „L – Learning“) ukupno je upotrijebljeno 225 podataka s vrijednošću 0 te 215 podataka s vrijednošću 1. Za provjeru (engl. „V – Validation“) 71 podatak imao je vrijednost 0, a 75 podataka vrijednost 1. Ukupno je to bilo 586 podataka, od kojih je svaki deseti prikazan u **tablici 2.3**.

Mreža je programirana na 28 599 iteracija, a dobivena je prosječna pogreška učenja 0,002681. Slične su vrijednosti dobivene i za mrežu u bušotini B-1.

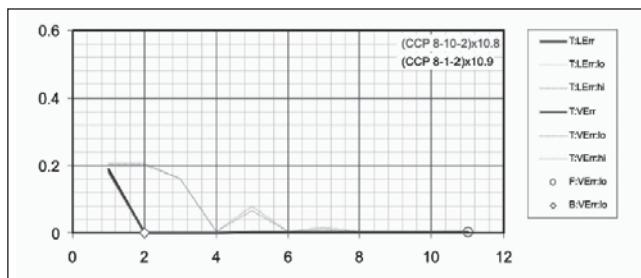
Ipak, zbog većega broja upotrijebljenih krivulja ukupno je vrijeme uvježbavanja mreže bilo duže oko 3 puta te je iznosilo 16,13 minuta.

LEGENDA (za skupinu od po tri stupca): 1 - Tip podataka; 2 – Kategorička varijabla „ležište“; 3 – Vjerojatnost uspješnoga predviđanja							
L	0	82,1	L	1	82,1	L	0
L	0	82,1	L	1	82,1	L	0
L	0	82,1	L	1	82,1	L	0
L	0	82,1	L	1	82,1	V	0
V	0	88,1	L	1	82,1	L	0
L	0	82,1	L	1	82,1	V	0
V	0	88,1	L	1	82,1	V	0
L	0	82,1	L	1	82,1	L	0
L	0	82,1	V	1	88,1	L	0
V	0	88,1	L	1	82,1	L	0
L	1	82,1	L	1	82,1	L	0
L	1	82,1	L	1	82,1	L	0
V	1	88,1	V	1	88,1	L	0
L	1	82,1	V	1	88,1	L	0
V	1	88,1	L	1	82,1	V	0
L	1	82,1	L	1	82,1	L	0
L	1	82,1	L	1	82,1	L	0
L	1	82,1	L	1	82,1	–	–
L	1	82,1	V	0	88,1	–	–
L	1	82,1	L	0	82,1	–	–
L	1	82,1	V	0	88,1	–	–

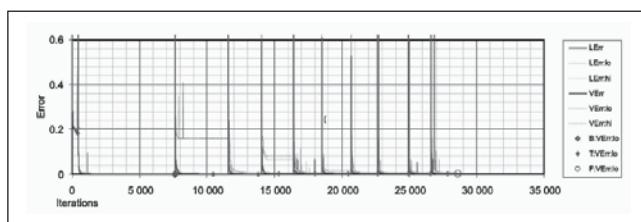
**Tablica 2.3:** Vjerojatnosti uspješnosti učenja mreže za buštinu B-2

Ipak, pregledom **tablice 2.3** vidljivo je kako predviđene i stvarne vrijednosti imaju znatno manji stupanj podudarnosti. Prema facijesima, predviđanje vrijednosti 1 (odnosno pješčenjačkoga facijesa) 100% su podudarne. No, kod krovinskoga i podinskoga laporanog (0) te se vrijednosti znatno razlikuju te je tu u samo 7,8% slučajeva ispravno predviđen lapor. Brojčano, od 296 ulaznih celija opisanih kao lapor, vrijednost 0 ispravno je predviđena u 23, a zamijenjena brojem 1 u 273 slučaja.

Ista je pojava zabilježena i u bušotini B-1 (**tablica 2.2** i **slike 2.3 i 2.4**) pa se postavlja pitanje uzroka zamjene tako velikoga broja laporovitih intervala pješčenjakom. Odgovor je u vrsti i broju upotrijebljenih karotažnih krivulja. Od njih jedna prikazuje prirodnu radioaktivnost (GR), a druge dvije otpornosti ( $R_{16}$  i  $R_{64}$ ). Razumno je pretpostaviti da bi analiza temeljena na krivuljama spontanoga potencijala, odnosno na krivuljama karotaže poroznosti (zvučna karotaža, karotaža gustoće, neutronska karotaža), znatno olakšala razlikovanje laporanja od pješčenjaka upotreboom neuronskoga algoritma.



**Slika 2.3:** Odnos pogrješaka tijekom učenja (L), provjere (V) i predviđanja (T) mreže te položaj ukupno (B) i trenutno (F) najbolje mreže u bušotini B-1 (iz **Malvić, 2006**)



**Slika 2.4:** Varijacija pogrješke tijekom iteracija te položaj trenutno (F) i ukupno (B) najbolje mreže u bušotini B-1 (iz **Malvić, 2006**)

## **2.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU FACIJESA**

Prikazana analiza jedan je od prvih objavljenih pokušaja da se u Hrvatskoj upotrebom neuronskih alata obrade mjerni podatci u naftno-me ležištu. Stoga rezultate treba promatrati u obliku smjernica koje su pomogle u kasnijim, ponešto drugačijim, neuronskim analizama ležišta ugljikovodika (drugačijim i po vrsti mreže i po tipu ulaznih podataka).

Ipak, postoji i dio konkretnih postignuća koja se odnose na upotrebu neuronskoga alata u predviđanju klastičnih facijesa u donjopontskim sedimentnim stijenana Savske depresije. Tako je opaženo kako je:

1. Postignuto izvrsno podudaranje predviđenoga i stvarnoga položaja pješčenjačkih intervala unutar ležišta.
2. Nasuprot tomu, loše je podudaranje predviđenoga i stvarnoga položaja krovinskoga i podinskoga laporanja.
3. Programska vjerojatnost točnoga predviđanja facijesa, odnosno litološkoga sastava, vrlo je velika u bušotini B-1 (na temelju 3 karotažne krivulje), gdje iznosi minimalno 78,3%, a u bušotini B-2 (na temelju 7 karotažnih krivulja) minimalno je 82,1%.
4. Položaj *najbolje mreže* javlja se u relativno ranoj fazi rada mreže. Za bušotinu B-1 takva mreža zabilježena je u 2 186. iteraciji, a za bušotinu B-2 u 7 626. iteraciji. To pokazuje kako u analizi facijesa, kod izmjene pješčenjaka i laporanja, nije potreban toliki broj iteracija (oko 30 000) za uvježbavanje mreže, već da se znatno veći

dobitak postiže povećanjem broja karakterističnih karotažnih krivulja.

5. Prema tome, mreža u polju Okoli preuvježbana je te ne sadržava dovoljno podataka za prepoznavanje laporovitih intervala.
6. U eventualnim dalnjim sličnim facijesnim analizama bilo bi dobro ulazne podatke proširiti dodatnim karotažnim krivuljama koje dobro karakteriziraju litologiju, poroznost i zasićenje.
7. To su krivulje spontanoga potencijala (engl. „Spontaneous Potential“, skr. SP), kompenzirane karotaže neutrona (engl. „Compensated Neutron log“, skr. „CN“), karotaže gustoće (engl. „DENsity log“, skr. „DEN“) te zvučne karotaže (engl. „ACoustic log“, skr. „AC“, upotrebljava se i engleski izraz „Sonic“ bez kratice).
8. Tada bi *najbolja mreža* vjerojatno bila konfigurirana s vjerojatnošću ispravnoga predviđanja većom od 90%.

## 2.5. LITERATURA

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond struč. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Hernitz, Z., Bokor, N. & Malvić, T. (2001): Geostatistical Modeling of Petrophysical Data of Oil Fields in the Northern Croatia. Proceedings, 63rd EAGE Conference & Technical Exhibition, P611, Amsterdam.
3. Jüttner, I., Saftić, B. & Velić, J. (2001): Distribution of Porosity and Permeability within the Pontian Sandstones in the Western

Part of Sava Depression in Relation to their Stratigraphic Architecture and Palaeotectonic Relations. *Nafta*, Special Issue Dedicated to 2nd International Symposium on Petroleum Geology, April 22–24, 1999, Eds. Hernitz, Z. & Sečen, J., Sept. 2001, 139–144, Zagreb.

4. Kupfersberger, H. & Deutsch, C. V. (1999): Methodology for Integrating Analog Geologic Data in 3D Variogram Modeling. *AAPG Bulletin*, 83, 8, 1262–1278, Tulsa.
5. Malvić, T. (2006): Clastic facies prediction using neural network (case study from Okoli field) [Predviđanje klastičnih facijesa neuronском мрежом (примјер поља Околи)]. *Nafta*, 57, 10, 415–431.
6. Riedmiller, M. & Braun, H. (1993): A direct adaptive method for faster backpropagation learning: The RProp algorithm. Proc. of the IEEE Intl. Conf. on Neural Networks, San Francisco, 586–591.
7. Saftić, B., Peh, Z., Velić, J. & Jüttner, I. (2001): Interdependence of Petrophysical Properties and Depth: Some Implications of Multivariate Solution on Distinction Between the Lower Pontian Hydrocarbon-bearing Sandstone Units in the Western Part of the Sava Depression. *Geol. Croatica*, 54, 2, 259–277, Zagreb.
8. Frühwirth, R. K. (2005): cVision Users Guide Version-2. Neuro Genetic Solutions GmbH, Centre for Applied Technology, 31 str., Leoben.

### 3.

## PREDVIĐANJE LITOLOŠKOGA SASTAVA I INTERVALA ZASIĆENIH UGLJKIKOVODICIMA, PRIMJER POLJA KLOŠTAR

Sadržaj ovoga poglavlja većinom je objavljen u radu **Cvetković et al. (2009)**.

### 3.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU KLOŠTAR

Regionalno-geološki, polje Kloštar nalazi se na prostoru Savske depresije unutar Panonskoga bazena. Ležišta ugljikovodika otkrivena su u litostratigrafskim jedinicama miocena te u stijenama podine miocena. Prema **Brod (1945)** slojevitoga su i masivnoga tipa. Dosad je otkriveno ukupno 20 ležišta koja su svrstana u 5 neformalnih litostratigrafskih jedinica:

- I. pješčenjačka „serija“
- II. pješčenjačka „serija“
- „prevalencijenezijske naslage“
- „miocen“
- „temeljno gorje“.

Prosječna je šupljikavost pješčenjačkih ležišta 25%, a prosječna efektivna debljina iznosi 5 metara. Propusnost rezervoarskih stijena

kreće se u rasponu od 2,4 do  $179,9 \times 10^{-3} \mu\text{m}^2$ . Proizvodnja je 2005. godine bila  $79,6 \text{ m}^3/\text{dan}$ , odnosno oko  $29\ 000 \text{ m}^3/\text{god}$ . Gustoća nafte je  $843 \text{ kg/m}^3$ . Do danas je na polju izrađeno ukupno 196 bušotina, od kojih su 64 mjerne, 59 proizvodnih, 68 je tehnički likvidirano, a 5 se iskorištava za utiskivanje slojne vode (izvor podataka: **Atlas polja, 2005**).

### **3.2. ANALIZE NEURONSKIM MREŽAMA U POLJU KLOŠTAR**

U ovome poglavlju prikazat će se način i rezultati predviđanja neuronskom mrežom. Sve analize i dijagrami napravljeni su u programskome paketu StatSoft STATISTICA 7.0.

Istraživanje je načinjeno uvježbavanjem neuronske mreže na određenome dubinskome intervalu bušotine (nadgledano učenje) te je tako uvježbana neuronska mreža korištena u svrhu predviđanja vrijednosti željenih parametara u njoj dosad nepoznatim intervalima.

Kao ulazne vrijednosti koristit će se elektrokardioški podatci bušotina Klo-44 i Klo-71.

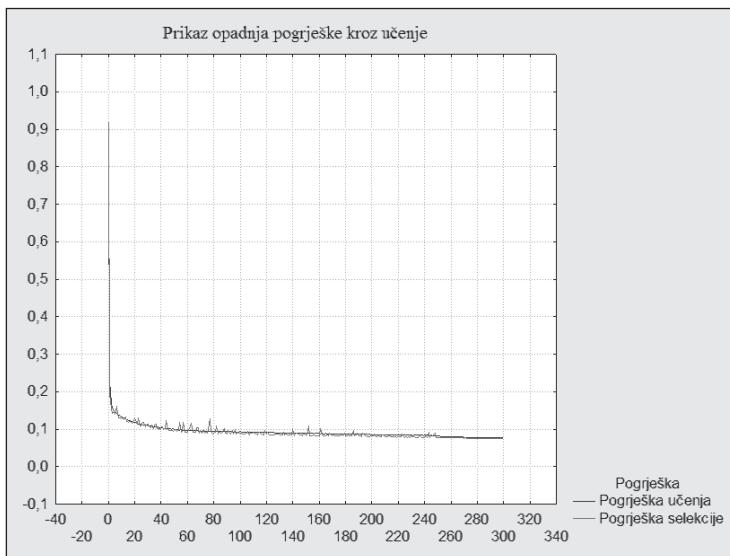
Rezultati upotrebe neuronskih mreža bit će prikazani pomoću dijagrama i tablica. Dijagrami se sastoje od linije koja predstavlja stvarne (zadane vrijednosti) i linije predviđenih vrijednosti označenih različitim tonovima koji su naznačeni u legendi. Predviđene vrijednosti u nazivlju imaju dodatak SNN (engl. „Statistica Neural Networks“).

### **3.2.1. Predviđanje litološkoga sastava**

Za predviđanje litološkoga sastava ručno su izdvojeni slojevi pješčenjaka i lapora na karotažnim dijagramima bušotine Klo-44.

Kao ulazni podatak za uvježbavanje neuronske mreže koristit će se vrijednosti spontanoga potencijala (SP) i otpornosti ( $R_{16}$  i  $R_{64}$ ) te litološki sastav. Litološki sastav definiran je varijabljom čija je vrijednost predviđena. Interval koji će se koristiti za uvježbavanje približno će odgovarati intervalu I. pješčenjačke „serije“ uključujući nekoliko metara iznad i ispod toga intervala kako bi se analizom obuhvatila određena debljina nepropusnih naslaga. Koristit će se neuronska mreža s radijalnom funkcijom i mreža s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno MLP mreža. Predviđanje će se provoditi za interval koji približno odgovara II. pješčanoj „seriji“.

Ulagani skup za uvježbavanje u programu STATISTICA 7.0 automatski se dijeli tako da se jedna polovina skupa koristi za uvježbavanje, a druga polovina za određivanje uspješnosti mreže koja je izražena iznosom pogreške selekcije i pogreške uvježbavanja. Pogreška selekcije predstavlja pogrešku u predviđanju na skupu izdvojenome za provjeru uspješnosti mreže, a pogreška uvježbavanja onu utvrđenu na skupu za uvježbavanje mreže. Prilikom uvježbavanja neuronske mreže program automatski zaustavlja uvježbavanje kada se dostigne unaprijed zadani iznos pogreške. Ako to nije postignuto, program se vraća na iteraciju u kojoj je postignuta najniža pogreška selekcije (slika 3.1).



**Slika 3.1:** Na ordinati su dane vrijednosti pogreške.  
Vrijednosti na apscisi predstavljaju broj iteracija.

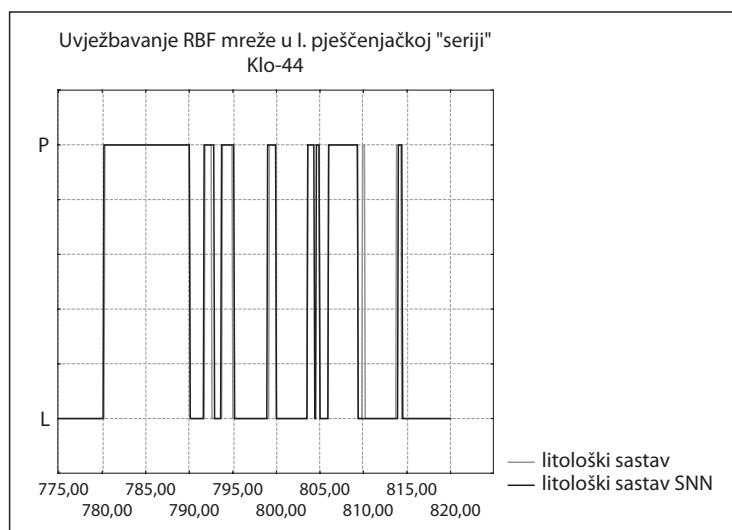
Uspješnost uvježbavanja i predviđanja RBF i MLP neuronske mreže prikazana je u **tablici 3.1** i **slikama 3.2, 3.3, 3.4 i 3.5**.

Tip neuronske mreže i svojstva <sup>a</sup>	Pogreška uvježbavanja <sup>b</sup>	Pogreška selekcije <sup>b</sup>
RBF 3:3-31-1:1	0,152942	0,172753
MLP 3:3-4-6-3-1:1	0,314380	0,133478

**Tablica 3.1:** Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-44 za predviđanje litološkoga sastava (iz **Cvetković et al., 2009**)

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

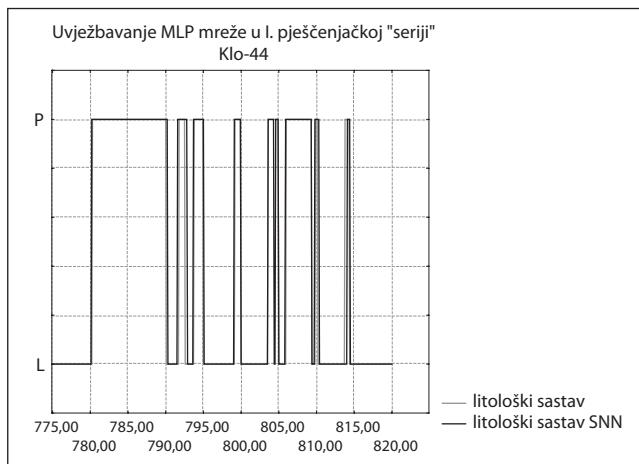
<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.



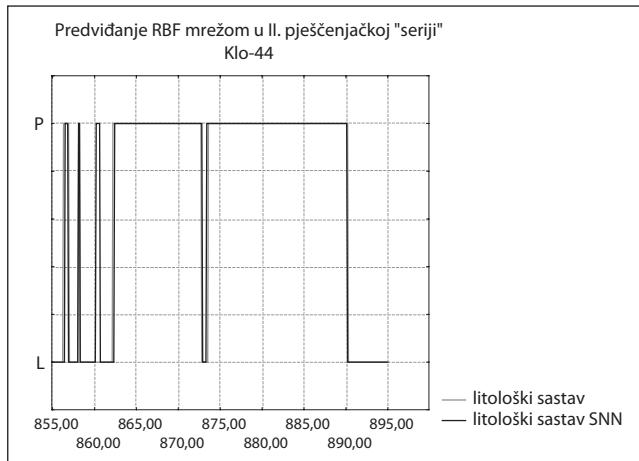
*Slika 3.2: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).*

Prema **slikama 3.2 i 3.3** može se vidjeti da su obje mreže uspješno uvježbane u intervalu I. pješčenjačke „serije“ iako bi se po vrijednostima pogreške kod MLP mreže moglo očekivati da će rezultati biti loši.

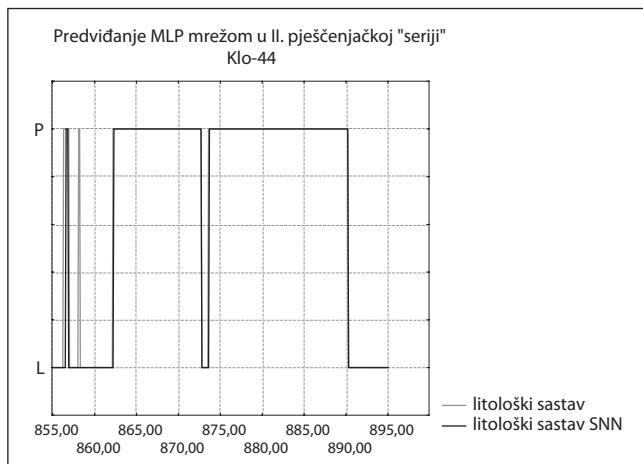
To dokazuje da je pogreška selekcije vrlo važan parametar u krajnjoj učinkovitosti neuronske mreže.



*Slika 3.3: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).*



*Slika 3.4: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).*



**Slika 3.5:** Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).

Na **slikama 3.4 i 3.5** dani su rezultati predviđanja litološkoga sastava u intervalu II. pješčenjačke „serije“. Obje mreže dale su vrlo dobre rezultate. Male pogreške prisutne su u predviđanju intervala iznad II. pješčenjačke „serije“.

Iako obje mreže pokazuju približne rezultate, može se zaključiti da MLP mreža daje bolje rezultate kod predviđanja nego RBF mreža.

### 3.2.2. Predviđanje zona zasićenih ugljikovodicima

Za razliku od predviđanja litološkoga sastava, neuronska mreža uvežbavana je na jednoj bušotini, a predviđanje je obavljeno na drugoj bušotini.

Zone zasićene ugljikovodicima određene su prema otklonu krivulje  $R_{64}$  kao varijabla ležišta s vrijednostima 0 i 1 (0 predstavlja nezasićeni, a 1 zasićeni dio).

Takve kategoričke vrijednosti (0 i 1) korištene su za uvježbavanje i provjeru uspješnosti neuronske mreže. Osim vrijednosti zasićenja korištene su krivulje SP-a,  $R_{16}$ ,  $R_{64}$ , dubine (m) i atributivna varijabla litološkoga sastava.

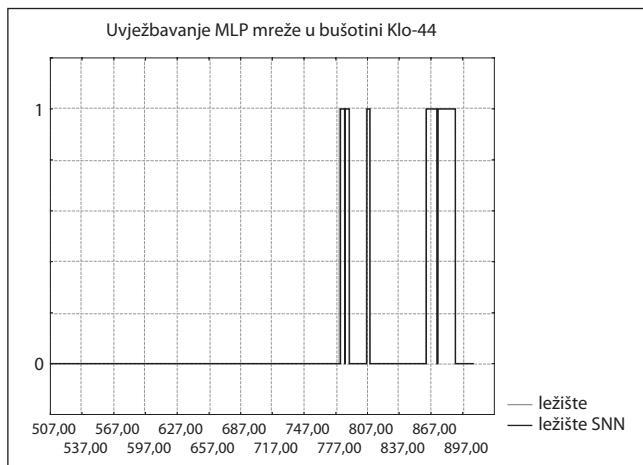
Za predviđanje varijabli ležišta korištena je MLP mreža sa šest neurona u prvoj te osam neurona u drugome skrivenome sloju. Uspješnost uvježbavanja i predviđanja varijabli ležišta dana je u **tablici 3.2** te na **slikama 3.6 i 3.7**.

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
MLP 5:5-6-8-1:1	0,056897	0,091173

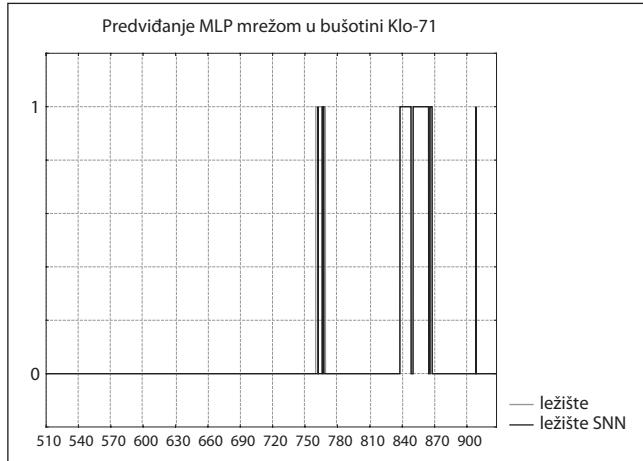
**Tablica 3.2:** Prikaz parametara uvježbane neuronske mreže u bušotini Klo-44 u svrhu predviđanja varijabli ležišta (preuzeto iz Cvetković et al., 2009)

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.



**Slika 3.6:** Na ordinati su dane vrijednosti varijable ležišta: 0 – nezasićeni dio, 1 – zasićeni dio. Vrijednosti na apscisi predstavljaju dubinu nasлага u metrima (preuzeto iz Cvetković et al., 2009).



**Slika 3.7:** Na ordinati su dane vrijednosti varijabli ležišta: 0 – nezasićeni dio, 1 – zasićeni dio. Vrijednosti na apscisi predstavljaju dubinu nasлага u metrima (preuzeto iz Cvetković et al., 2009).

Na **slici 3.6**, gdje je prikazana uspješnost uvježbavanja neuronske mreže, može se vidjeti da je neuronska mreža točno predvidjela varijablu ležišta u intervalima I. i II. pješčenjačke „serije“.

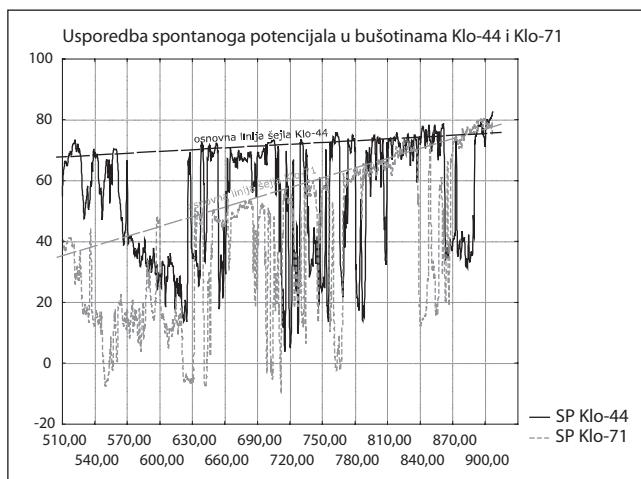
Uspješnost predviđanja ugljikovodicima zasićenih zona u bušotini Klo-71 prikazana je **slikom 3.7**. Može se vidjeti da je neuronska mreža s velikom točnošću odredila granice II. pješčenjačke „serije“, dok su granice I. pješčenjačke „serije“ također određene, no uz nešto manju točnost.

### **3.3. MOGUĆI PROBLEMI PRILIKOM ANALIZA NEURONSKIM MREŽAMA ZAPAŽENI U PRIMJERU POLJA KLOŠTAR**

Općenito, za analize neuronskim mrežama vrijedi: što je veći broj ulaznih varijabli i broj slučajeva, rezultati će biti pouzdaniji i mreža će uspješnije učiti, uz bolje predviđanje.

Predviđanje litološkoga sastava pokazalo se uspješnim, no samo ukoliko je skup podataka za uvježbavanje i predviđanje dolazio iz intervala unutar iste bušotine, tj. tu se govori o jednodimenzionalnoj ekstrapolaciji. Ukoliko bi se umjesto krivulja SP-a upotrijebile krivulje GR-a (prirodne radioaktivnosti), promjera bušotine, kompenzirane gustoće neutrona (CN), karotaže gustoće (DEN) i drugih koje karakteriziraju litološki sastav i zasićenje ugljikovodicima, dobili bi se bolji rezultati.

Problem koji se javlja kod uvježbavanja neuronske mreže za predviđanje litološkoga sastava jest pomak osnovne linije nepropusnih stijena koji je vidljiv kod krivulje SP-a u bušotini Klo-71, dok kod bušotine Klo-44 pomak nije izražen (**slika 3.8**). Uz uvrštavanje dubine kao varijable, kod uvježbavanja neuronske mreže nisu postignuti zadovoljavajući rezultati zbog toga što se osnovna linija nepropusnih stijena ne ponaša jednakom u objema bušotinama.



**Slika 3.8:** Na ordinati su dane vrijednosti spontanoga potencijala u mV.  
Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Kod analize neuronskom mrežom za predviđanje zasićenja ugljikovodicima kao važan parametar koristila se varijabla kojom je opisan litološki sastav. Ona je bila definirana na temelju odvajanja intervala pješčenjaka od intervala laporanog prema položaju točaka infleksije na krivulji SP-a. Kada se atributivna varijabla ne bi koristila kao ulazna

vrijednost u analizi neuronском mrežom, uz vrijednosti karotažnih krivulja SP-a,  $R_{16}$  i  $R_{64}$ , mreža ne bi pokazala zadovoljavajuću vrijednost predviđanja zbog nemogućnosti preciznoga definiranja relacije da varijabla ležišta ima pozitivnu vrijednost samo u pješčenjačkim slojevima. Varijabla ležišta vjerojatno se ne bi morala uvoditi kao ulazna vrijednost ako bi se koristile vrijednosti krivulja GR-a, promjera bušotina i druge.

### **3.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU LITOLOŠKOGA SASTAVA I ZASIĆENJA UGLJIKOVODICIMA**

Prikazano je nekoliko neuronских mreža koje su imale zadatak odrediti litološki sastav sedimenata gornjega panona (II. pješčenjačka „serija“) i donjega ponta (I. pješčenjačka „serija“) te zasićenost ugljikovodicima u njima. Uspješnost uvježbavanja i predviđanja neuronским mrežama prikazane su grafički i tablično. Pješčenjački facijesi, gornjopanonske i donjopontske starosti, predstavljaju najprikladniji tip sedimenta za neuronske i statističke obradbe te su na analizirani takvim alatima. Na osnovi rezultata neuronских analiza može se zaključiti:

- prilikom određivanja litološkoga sastava u bušotini Klo-44 pomoću neuronske mreže s radijalnom funkcijom i višeslojnom mrežom dobiveno je izvrsno poklapanje predviđenoga i stvarnoga litološkoga sastava,

- određivanje zasićenosti ugljikovodicima u bušotini Klo-71 pomoću višeslojne mreže, uvježbane na bušotini Klo-44, daje izvrsno poklapanje između predviđenih i stvarnih vrijednosti.

### **3.5. LITERATURA**

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond str. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
3. Cvetković, M., Velić, J., Malvić, T. (2009): Application of neural networks in petroleum reservoir lithology and saturation prediction. Geologia Croatica, 62/2, 115–121.

---

---

---

---

---

---

---

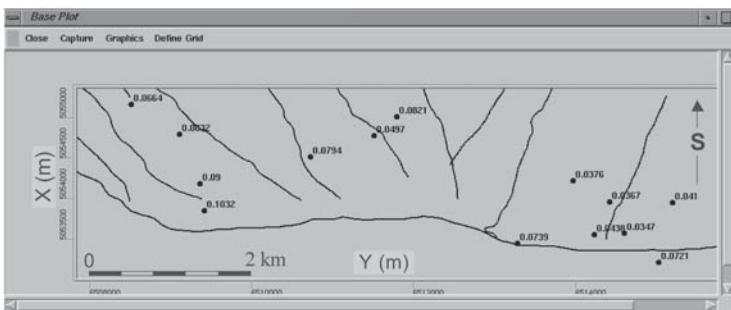
---

## 4.

# PROCJENA POROZNOSTI NEURONSKOM MREŽOM, PRIMJER POLJA BENIČANCI

U ovome poglavlju prikazano je istraživanje objavljeno izvorno u radu **Malvić & Prskalo (2007)** te prilagođeno sadržaju ove knjige. Naglasak je stavljen na vrstu upotrijebljene mreže te vrijednosti ulaznih podataka i njihovih linearnih veza koje su omogućile predviđanje poroznosti unutar cijelog ležišta nafte polja Beničanci neuronskim algoritmom.

Naftno polje Beničanci smješteno je u istočnome dijelu Dravske depresije i svrstava se među pet najvećih ležišta ugljikovodika u Hrvatskoj. Zato primjena novijih analitičkih alata u izradbi geološkoga modela postaje vrlo smislenim zadatkom. Unutar ležišta badenske starosti bili su dostupni reinterpretirani bušotinski podatci na 14 lokacija (**slika 4.1**) te seizmički atributi interpretirani iz rezultata snimanja 3D seismike (amplituda, faza i frekvencija). Modelirana je razdioba poroznosti kao najvažnije ležišne variabile (radi procjene ukupnoga volumena ležišta). Kao suvremena metoda procjene poroznosti ležišta upotrijebljena je neuronska mreža s povratnim postupkom (engl. „back propagation network“), čije je učenje načinjeno kroz 10 000 iteracija. Unutar mreže postavljena je linearna veza između svih triju seizmičkih atributa i poroznosti te je tražena najviša vrijednost njihove korelacije, odnosno minimalni iznos konvergencije uvježbavanja.

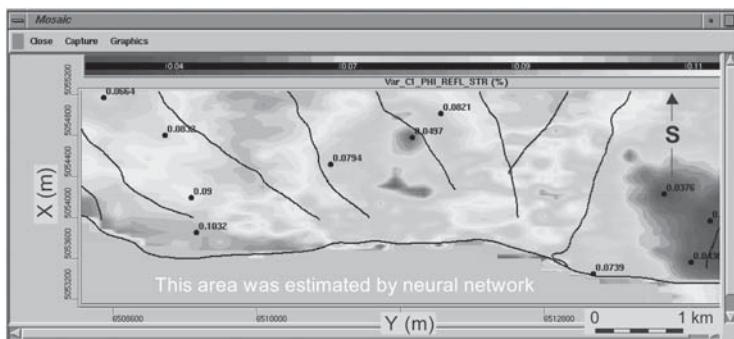


*Slika 4.1: Indeks-karta poroznosti (iz Malvić & Prskalo, 2007)*

Najbolja procjena poroznosti neuronskom mrežom postignuta je u slučaju kada su istodobno upotrijebljena sva tri seizmička atributa, što je potvrdilo pretpostavku da neuronske mreže obično postižu uspješnija predviđanja s većim brojem ulaza.

Rezultati dobiveni neuronskom mrežom za provjeru su uspoređeni s prethodno načinjenim geostatističkim kartama poroznosti (upotrebom kriginga i kokriginga). U tome slučaju najbolja interpolacija postignuta je kokrigingom upotrebom samo jednoga seizmičkoga atributa (snage refleksije kao izvedenice amplitude), koji je predstavljao sekundarnu varijablu (Malvić & Đureković, 2003).

Relativno postupni prijelaz na karti poroznosti dobivenoj neuronskom mrežom te vrijednosti celija koje rijetko dosežu minimum i maksimum ulaznoga skupa pokazali su da je neuronska procjena preciznija od onih na kartama dobivenim drugim interpolacijskim metodama.



**Slika 4.2:** Karta poroznosti dobivena kokrigingom u naftnome ležištu polja Beničanci (iz Malvić & Prskalo, 2007)

#### 4.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU BENIČANCI

Ležište naftnoga polja Beničanci masivnoga je tipa (klasifikacija iz Brod, 1945; Brod & Jeremenko, 1957; Velić, 2007), odnosno zamka je strukturno-stratigrafska (Levorsen, 1956; Velić, 2007). Sastavljeno je uglavnom od dolomitnih i vapnenačkih breča badenske starosti. Tjeme je antiklinale na dubini od 1699 metara, prosječna poroznost ležišta iznosi 7,33%, početno zasićenje vodom 28,1%, a gustoća 875 kg/m<sup>3</sup>. Proizvodnja je započela 1972. godine, a danas se crpljenje odvija iz nešto više od 20-ak bušotina od njih ukupno 106. Posebna reinterpretacija karotažnih dijagrama načinjena je početkom ovoga stoljeća u 14 bušotina, tako da su one najnoviji i najpouzdaniji skup podataka za izradbu različitih modela ležišta. Također, otprilike u isto vrijeme snimljena je i 3D seizmika na području Beničanaca pružajući mogućnost interpretacije većega broja seizmičkih atributa.

Ukupne geološke rezerve nafte u polju Beničanci iznose  $34 \times 10^6$  m<sup>3</sup> uz predviđeni iscrpak 52,5%. U plićim, miocenskim slojevima nalazi se nekoliko plinskih ležišta u pješčenjacima gdje ukupne geološke rezerve iznose  $2700 \times 10^6$  m<sup>3</sup> uz iscrpak od oko 58%. Iako je proizvodnja na polju u opadanju i dostiže najveći predviđeni iscrpak, histogram eksploracije pokazuje da su pridobive rezerve vjerojatno veće od predviđenih pa su i nove karakterizacije ležišta svakako isplativa s obzirom na nisku cijenu rada računala u odnosu na količine ostvarene mogućim, čak i jednopostotnim povećanjem iscrpka.

#### **4.2. ULAZNE VARIJABLE ZA NEURONSKU MREŽU**

Kako je spomenuto, neuronska mreža primijenjena je na skupu od dvije korelativne vrste podataka. Primarni skup sadržavao je poroznost, a sekundarni tri seizmička atributa interpretirana iz 3D seizmičke kocke. Ti seizmički atributi bili su amplituda, frekvencija i faza, koje su kao odvojene varijable osrednjene u intervalu ležišta u 14 bušotina, gdje su iz najnovijih karotažnih mjerjenja interpretirane srednje poroznosti.

Tako su na polju Beničanci razvrstana dva ulazna skupa podataka – poroznost izračunata iz karotaže (14 točkastih vrijednosti) te seizmički atributi interpretirani iz seizmičke kocke (16 384 točkastih vrijednosti po atributu).

## **4.3. VRSTA I PARAMETRI UVJEŽBAVANJA NEURONSKE MREŽE**

Za analizu je odabrana arhitektura mreže s povratnim postupkom (engl. „back propagation network“), u kojoj je tražena iteracija s najmanjom pogreškom uvježbavanja. Uvježbavanje se sastojalo od utvrđivanja linearne zavisnosti vrijednosti poroznosti i seizmičkih atributa na istim lokacijama. S tako utvrđenom zakonitošću predviđene su poroznosti i na onim mjestima gdje su izmjerene samo vrijednosti seizmičkih atributa. Na mjestima gdje su postojali poroznost i seizmička snimanja tražena je veza u svim mogućim slučajevima njihova kombiniranja, tj. korelacija poroznosti i jednoga atributa (tri mogućnosti), korelacija poroznosti i dvaju atributa (tri mogućnosti) te korelacija poroznosti i triju atributa (jedna mogućnost). Signali su transformirani upotrebom sigmoidne aktivacijske funkcije.

### **4.3.1. Vrijednosti robusnih parametara mreže**

Pod izrazom „robustni parametar“ podrazumijeva se mrežna varijabla čija se manja promjena vrijednosti ne će odmah odraziti u radikalno drugačijemu rezultatu uvježbavanja. Mreža je u početku sadržavala 5 skrivenih slojeva, a taj je broj povećavan do 25. Tu je bila dobro izražena robustnost, jer povećanje broja slojeva nije znatnije uvećalo korelaciju poroznosti i atributa (za vrijednost  $10^{-3}$  do  $10^{-2}$ ), dok je brzina uvježbavanja bila znatno manja.

Nadalje, iznos učenja (engl. „learning rate“) na kraju je postavljen na vrijednosti 0,9, a koeficijent momenta (engl. „Momentum Coefficient“) na 0,6. Povremeno su te vrijednosti varirane za vrijednost 0,1 u intervalu [0, 1], no nije bilo znatnijih promjena u pogrešci mreže.

Broj iteracija variran je između 10 000 i 30 000, no kako nije bilo većih promjena u rezultatu, konačno je namješten na 10 000 kako bi se smanjilo vrijeme uvježbavanja.

#### **4.3.2. Vrijednosti osjetljivih parametara mreže**

Pod „osjetljivim“ parametrom podrazumijeva se onaj dio mreže gdje i mala promjena vrijednosti vodi do bitne promjene rezultata mreže, čime je kod takva parametra nužan i veći oprez prilikom odabira njegove vrijednosti.

Prvi takav parametar bio je broj istodobno promatranih atributa kod uvježbavanja. Pri tome je upotreba dvaju ili triju seizmičkih atributa zahtjevala da se prvo fizikalno objasni njihova povezanost. Iako sva tri atributa (frekvencija, faza i amplituda) izvor imaju u promjenama zvučnoga vala do kojih dolazi zbog njegove refleksije od različitih litoloških granica u podzemlju, njihova je vezu često vrlo nejasna. Ipak, veće korrelacije izračunate su uključivanjem većega broja atributa.

Odabrana je log-sigmoidna aktivacijska funkcija te određena vrijednost konvergencijskoga kriterija ( $\Sigma \varepsilon^2$ ). Ako je iznos toga kriterija po-

stao manji od granične vrijednosti, rad mreže prekinut je prije dosezanja korisnički postavljenoga broja iteracija. U prikazanome modelu konvergencijski kriterij iznosio je 1, te je u jednom uvježbavanju mreža zaustavljena zbog te vrijednosti (a ne dostizanja najvećega broja iteracija).

#### 4.4. REZULTATI NEURONSKE MREŽE

Kvaliteta uvježbavanja mreže izražena je kroz vrijednost korelacije između poroznosti i atributa, dok je *kriterij konvergencije* razmatran kao minimum pogreške postignut neuronskom mrežom. S obzirom na različit broj ulaza u mrežu, postignuti su sljedeći rezultati usporedljivim različitim broja atributa:

**Tri atributa korelirana s poroznošću:**

- Amplituda + frekvencija + faza i poroznost –  $R^2 = 0,987$ ;  
 $\Sigma \varepsilon^2 = 0,329$ .

**Dva atributa korelirana s poroznošću:**

- Amplituda + frekvencija i poroznost –  $R^2 = 0,496$ ;  $\Sigma \varepsilon^2 = 1,935$ .
- Amplituda + faza i poroznost –  $R^2 = 0,603$ ;  $\Sigma \varepsilon^2 = 1,740$ .
- Faza + frekvencija i poroznost –  $R^2 = 0,820$ ;  $\Sigma \varepsilon^2 = 1,090$ .

**Jedan atribut koreliran s poroznošću:**

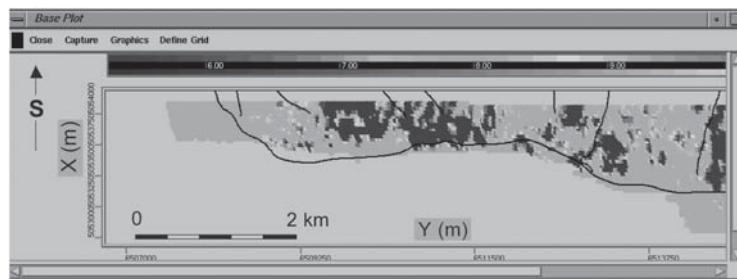
- Amplituda i poroznost –  $R^2 = 0,250$  i  $\Sigma \varepsilon^2 = 2,730$ .
- Frekvencija i faza, samostalno uspoređene s poroznošću, imale su vrlo male koeficijente determinacija.

Vidljivo je kako je najbolja korelacija ulaznih podataka te uvježbavanje neuronske mreže postignuto upotrebom svih triju atributa. Oni su korelirani s poroznošću koja se izvorno kretala u rasponu 5,3–11,1%, dok je predviđanje neuronском mrežом dalo vrijednosti koje su unutar toga intervala, ali čak u užim granicama (**slika 4.3**).

Upotreba samo jednoga atributa dovela je do precjenjivanja predviđene poroznosti. Nadalje, zajedničko promatranje amplitude i frekvencije rezultiralo je procjenom većine vrijednosti poroznosti blizu gornje granice ranije spomenutoga intervala.

Ako ponovno promatramo slučaj jednoga atributa, primjerice amplitude, kao onoga što se najbolja „očuva“ na putu do površine te može najjasnije opisati stjenski sastav kroz koji je signal prošao, stupanj postignute korelacije za par amplituda – poroznost bio je samo 0,25, odnosno mreža je slabo uvježbana ( $S_e^2 = 2,73$ ).

Fizikalno, niže amplitude odgovarale su nižim poroznostima, no nije očuvan relativni odnos između tih varijabli. Na primjer, amplitudi od 1200 odgovara poroznost od 5,27%, a zatim  $1472 = 7,3\%$ ,  $1669 = 8,15\%$ ,  $1990 = 8,17\%$ ,  $2107 = 8,16\%$ . Vidljivo je kako promjena nije linearна, tj. pravilo izvedeno iz nje naglašava procjenu poroznosti općenito bliže donjoj granici (tj. vrijednosti od 5,3%).



*Slika 4.3: Karta poroznosti dobivena neuronskom mrežom u naftnome ležištu na južnome dijelu polja Beničanci (iz Malvić & Prskalo, 2007)*

#### 4.5. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU POROZNOSTI

Dokazano je kako seizmički atributi mogu predstavljati dodatni vrijedan ulaz koji se može upotrijebiti u predviđanju poroznosti. Kvaliteta prikazane mreže s povratnim postupkom može se procijeniti iz vrijednosti dvaju parametara. Jedan je *koeficijent determinacije* ( $R^2$ ), koji je računat za parove seizmički attribut(i) i poroznost. Drugi izlazni parametar jest *kriterij konvergencije*, tj. *postignuti minimum* ( $\Sigma \varepsilon^2$ ). Najuspješnije uvježbana mreža imala je najveći koeficijent determinacije ( $R^2 = 0,99$ ) te najmanji postignuti minimum ( $\Sigma \varepsilon^2 = 0,329$ ). Te vrijednosti mogu se u svakoj iteraciji promijeniti za nekoliko postotaka, odražavajući tako stohastički element (tj. interval nesigurnosti koji pripada procjeni) u radu neuronskih veza i aktivacijskih funkcija.

Najbolje uvježbavanje postignuto je istodobnom upotrebom svih triju dostupnih atributa, iako se u praksi interpretacije ležišta kvantitativ-

nom metodom najčešće upotrebljava isključivo amplituda za procjenu poroznosti i općenito litološkoga sastava ležišta. Razlog je u samoj dubini ležišta te prilično heterogenom klastičnom sadržaju, čija je posljedica osciliranje kvalitete reflektiranoga signala (uz dodatnu okolnost da je teško dobro kalibrirati geofone na malim udaljenostima) te će se amplituda zaista bitno mijenjati u vremenu i prostoru. Nasuprot tomu, promjene kod frekvencije i faze signala znatno su manje. Uz to, u plićim, miocenskim pješčenjacima iznad naftnoga ležišta nalaze se tanja ležišta zasićena plinom (s oko 30% ukupnih količina plina dokazanih u polju). Taj fluid prigušuje izvorni seizmički signal reflektiran iz dubljih slojeva, a ponekad čak potpuno prikrije izvornu amplitudu karakterističnu za naftno ležište. Naravno, rezultat je velika varijacija u amplitudi iz istoga stratigrafskoga horizonta, a to je razlog zašto uvođenjem drugih dvaju atributa ipak dobivamo zbirni atribut koji je bolje kvalitete (s manjim varijacijama vrijednosti) negoli sama amplituda.

Upotrijebljena neuronska mreža pomogla je u određivanju poroznosti u ležištu nafte obilježenome priličnom heterogenošću, a time i nesigurnostima u predviđanju poroznosti bilo kojom metodom. Nadalje, zbog iznimno velikoga broja podataka i mogućnosti obradbe programom predviđanje je načinjeno na južnome dijelu polja. Neke promjene poroznosti mogu se uočiti i bez detaljnoga kartiranja, tj. poznavanjem samo točkastih, mjerenih vrijednosti te vrste taložnoga okoliša koji je postojao u vrijeme nastanka ležišnih stijena. Prvi podatci bili su poznati kao ulaz u neuronsku mrežu. Radi se o aluvijalnoj le-

pezi koja se pružala smjerom (od svoga proksimalnoga do distalnoga dijela) od zapada na istok, ali i obrončanim brečama istaloženim u prostoru strukture Beničanci (**Tišljar, 1993**). Sličan aluvijalni taložni model opisan je i na drugim poljima kod nas koja imaju slične litofacije (npr. **Malvić, 2006**). U tome je smjeru zbog promjene veličine čestica (granulometrije) dolazilo i do postupnoga smanjivanja poroznosti, što je dodatni pristrani parametar na koji neuronska mreža nije mogla biti uvježbana.

#### 4.6. LITERATURA

1. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
2. Brod, I. O. & Jeremenko, N. A. (1957): Osnovi geologii nefeti i gasa. Izdanie tretie, Gostoptehizdat, Moskva.
3. Levorsen, A. I. (1956): Geology of petroleum. Freeman, 703 str., San Francisco.
4. Malvić, T. (2006): Middle Miocene Depositional Model in the Drava Depression Described by Geostatistical Porosity and Thickness Maps (Case study: Stari Gradac-Barcs Nyugat Field). Rudarsko-geološko-naftni zbornik, 18, 63–70.
5. Malvić, T. & Đureković, M. (2003): Application of methods: Inverse distance weighting, ordinary kriging and collocated cokriging in porosity evaluation, and comparison of results on the Beničanci and Stari Gradac fields in Croatia. Nafta, 54, 9, 331–340.

6. Malvić, T. & Prskalo, S. (2007): Some benefits of the neural approach in porosity prediction (Case study from Beničanci field) [Koristi upotrebe neuronske mreže u procjeni poroznosti (na primjeru polja Beničanci)]. *Nafta*, 58, 9, 455–467.
7. Tišljar, J. (1993): Sedimentary bodies and depositional models for the Miocene oil-producing areas Ladislavci, Beničanci and Obod (Croatia). *Nafta*, 44, 10, 531-542.
8. Velić, J. (2007): Geologija ležišta nafte i plina. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, 342 str., Zagreb.

## 5.

# REKONSTRUKCIJA DIJELOVA KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA, PRIMJER IZ HRVATSKOGA DIJELA PANONSKOGA BAZENA

U ovome poglavlju prikazani su rezultati rekonstrukcija intervala karotažnih krivulja pomoću neuronskih mreža. Slična analiza prikazana je na XIII. mađarskome geomatematičkome kongresu i II. hrvatsko-mađarskome geomatematičkome kongresu (**Cvetković & Bošnjak, 2009**). Analize su napravljene na osnovi podataka o ležištima iz polja Kloštar, Stari Gradac-Barcs Nyugat i Đeletovci kako bi se prikazala uspješnost neuronskih mreža u rekonstrukciji karotažnih vrijednosti u stijenama različitoga litološkoga sastava.

Princip rada programa StatSoft STATISTICA 7.0, kao i opća geološka obilježja polja Kloštar, prikazana su u poglavlju 3. ove knjige.

Analize neuronskim mrežama prikazat će se posebno za svako polje. Rezultati uspješnosti analiza bit će prikazani tablično, dijagramima razlika vrijednosti (engl. „Residual plot“) i troosnim dijagramima.

Pojedine analize ograničene su samo na jednu bušotinu (1D ekstrapolacija). Unutar jedne bušotine odabran je kontinuirani interval relativ-

no homogenoga sastava kako se ne bi dogodilo da je uvježbavanje i predviđanje neuronske mreže otežano zbog lošega odabira ulaznih podataka.

U analizama su korištene krivulje zvučne karotaže (engl. „ACoustic log“, skr. „AC“), neutronske karotaže (engl. „Compensated Neutron log“, skr. „CN“), karotaže gustoće (engl. „DENsity log“, skr. „DEN“) i karotaže prirodne radioaktivnosti (engl. „Gamma Ray log“, skr. „GR“).

Za prikaz rezultata odabrane su tri najuspješnije neuronske mreže, i to jedna od svake vrste (MLP, RBF i GRNN).

## **5.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU ĐELETOVCI**

Polje Đeletovci smješteno je približno 20 kilometara jugoistočno od Vinkovaca te pripada Slavonsko-srijemskoj depresiji. Uz Đeletovce, koje je najveće, u toj depresiji nalaze se još samo tri polja – Tovarnik, Ilača i Privilaka. Polje je otkriveno 1982. godine bušotinom Đe-1, a proizvodnja je započela 1984. godine.

Sva četiri polja nalaze se unutar izdignute strukture „Vinkovci“ koja se proteže od Vinkovaca na sjeverozapadu do Tovarnika na jugoistoku. Oblik strukture uvjetovan je oblikom paleozojskoga paleoreljefa, koji se neformalno naziva i „temeljno gorje“.

Ležišne stijene pretežno su paleozojske starosti, a predstavljene su raspucanim i trošnim granitima, gnajsevima, dijabazima i različitim

škriljavcima. Mlađi dio iznad erozijsko-transgresivne granice predstavljen je badenskim brečama i pješčenjacima. Zamke su strukturno-stratigrafskoga tipa (prema **Levorsen, 1957**), tj. ležište je masivnoga tipa (prema **Brod, 1945** te **Brod & Jeremenko, 1957**).

Načinjeno je ukupno 60 bušotina, od kojih je 35 proizvodnih, 11 mjernih, 4 utisne za otpadne vode, a deset ih je tehnički likvidirano (**Atlas polja, 2005**).

## **5.2. OSNOVNI GEOLOŠKI ODNOSI U POLJU STARI GRADAC-BARCS NYUGAT**

Stari Gradac-Barcs Nyugat jest plinsko-kondenzatno polje. Struktura se prostire s obiju strana hrvatsko-mađarske granice. Bušotina Bny-1 pokazala je 1979. godine mogućnost postojanja ležišta ugljikovodiča, a polje je otkriveno buštinom StG-1 1980. godine. Do 2003. godine izrađeno je 16 bušotina, od toga 7 na hrvatskoj (StG-1, 1Z, 2, 3, 4, 5, 6) i 9 na mađarskoj (Bny-1, 2, 3, 4, 5, 6, 7, 8, 9) strani. Administrativno hrvatski dio polja nalazi se na područjima četiriju općina (Pitomača, Špišić Bukovica, Kloštar Podravski i Lukač), u Virovitičko-podravskoj i Koprivničko-križevačkoj županiji.

U regionalnome geološkome pogledu struktura Stari Gradac-Barcs Nyugat pripada sjeverozapadnomu dijelu Dravske depresije, tj. području dubokoga dijela Dravske depresije (s obzirom na ukupnu debjinu neogensko-kvartarnih sedimenata). Struktura čini jedinstvenu

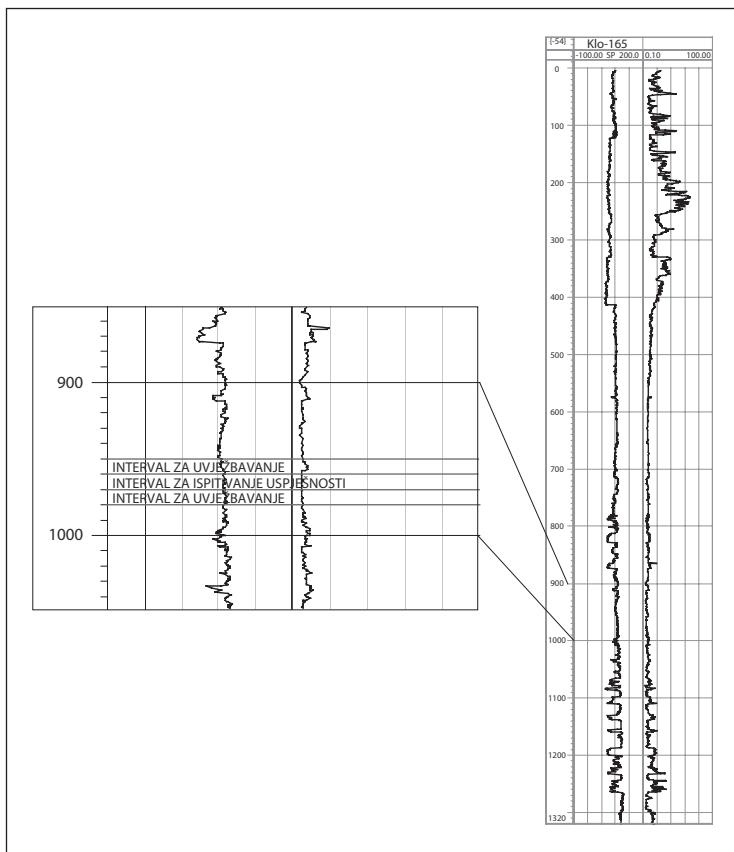
zonus s drugim dvjema bliskim strukturama – Molvama i Kalinovcem. Sve tri brahiantiklinale povezane su pravcem pružanja Z/SZ–I/JI, a u istome smjeru raste i njihova dubina (Molve – Kalinovac – Stari Gradac). Polje Stari Gradac ima strukturno-stratigrafski tip zamke (**Le-vorsen, 1956**), odnosno predstavlja masivno ležište ograničeno nepropusnim stijenama (**Brod, 1945 te Brod & Jeremenko, 1957**). Definirana su četiri proizvodna litofacijesa: *miocenski klastiti, klastiti srednjega trijasa, donjotrijaski kvarciti i dolomiti te permski metavulkaniti*.

### 5.3. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA U POLJU KLOŠTAR

Za analizu je odabrana bušotina Klo-165 s dostupnim krivuljama karotaže zvuka (AC), neutronske poroznosti (CN) i gustoće (DEN). Odabrani interval od –950 do –980 metara približno odgovara I. pješčenjačkoj „seriji“ (**slika 5.1**).

Prvih i zadnjih deset metara (od –950 do –960 m i od –970 do –980 m) intervala koristilo se za uvježbavanje neuronskih mreža, dok se interval od –960 do –970 metara koristio za ispitivanje uspješnosti uvježbane neuronske mreže. Prema tome, neuronska mreža uvježbana je na 200 slučajeva, a ispitivanje uspješnosti na 100 slučajeva.

Ulagne varijable bile su vrijednosti karotažnih krivulja AC-a i DEN-a pomoću kojih je predviđena vrijednost karotažne krivulje CN-a.



*Slika 5.1: Prikaz bušotine Klo-165 s naznačenim dijelovima korištenima za analizu neuronskim mrežama*

### 5.3.1. Rezultati analiza višeslojne neuronske mreže

Najuspješnija mreža sadržavala je dva skrivena sloja s po devet i šest neurona (**tablica 5.1**).

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
MLP 2-9-6-1	0,187415	0,175165

**Tablica 5.1:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

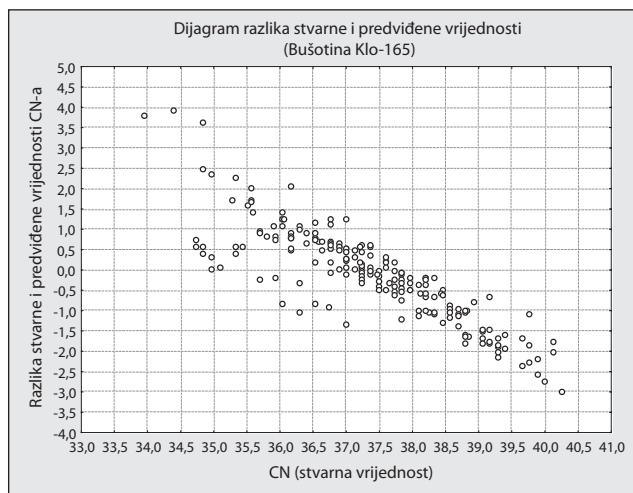
<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.

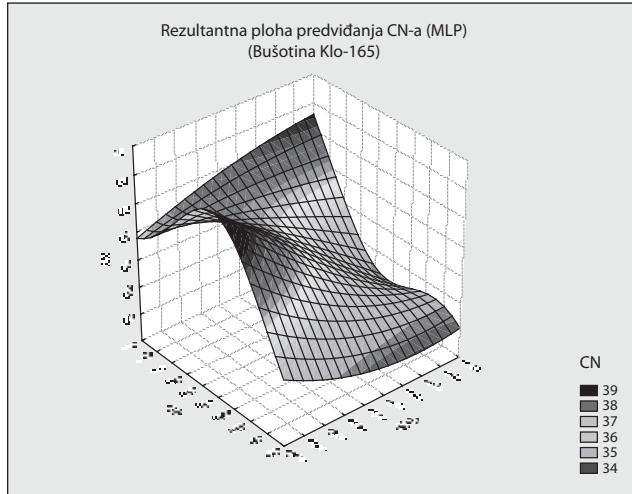
Uspješnost MLP neuronske mreže za predviđanje vrijednosti iz intervala od –960 do –970 metara prikazana je na dijagramu razlika vrijednosti (**slika 5.2**), troosnomo dijagramu (**slika 5.3**) i na zbirnome prikazu karotažne krivulje usporedbama uspješnosti predviđanja istoga intervala za sve korištene neuronske mreže (**slika 5.4**).

Vrijednosti za koje je najuspješnije predviđanje višeslojnom mrežom bile su iz intervala od 35,5 do 38,5%, dok su vrijednosti s većim odstupanjima imale i veću pogrešku (**slika 5.3**).

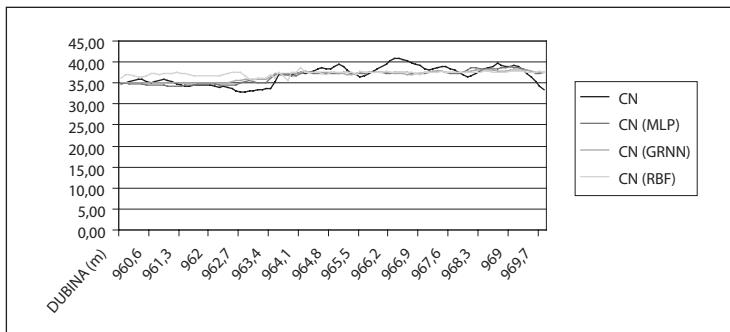
Na troosnomo dijagramu prikazana je rezultantna ploha iz koje se može vidjeti da neuronska mreža ima mogućnost predviđanja maksimalnih, minimalnih i srednjih vrijednosti CN-a (**slika 5.3**).



**Slika 5.2:** Prikaz razlike vrijednosti predviđene MLP mrežom (na ordinatni) za pojedinu stvarnu vrijednost (prikazanu na apscisi)



**Slika 5.3:** Prikaz rezultantne plohe vrijednosti karotaže CN-a za MLP mrežu



**Slika 5.4:** Odnos vrijednosti CN-a predviđenih raznim neuronskim mrežama i stvarnih za interval od -960 do -970 m (buš. Klo-165)

### 5.3.2. Rezultati analiza neuronske mreže s radijalnom funkcijom

Parametri najuspješnije RBF mreže prikazani su u **tablici 5.2.**

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
RBF 2-18-1	0,291071	0,299214

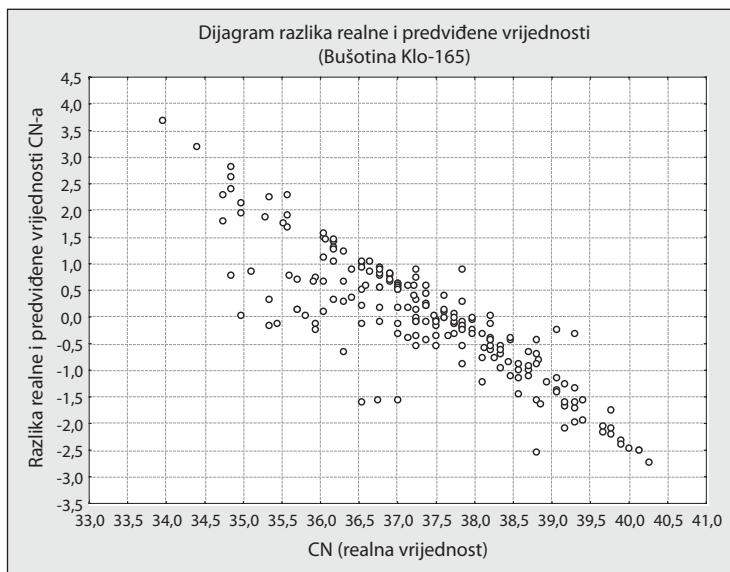
**Tablica 5.2:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti poroznosti iz karotažne krivulje CN-a

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

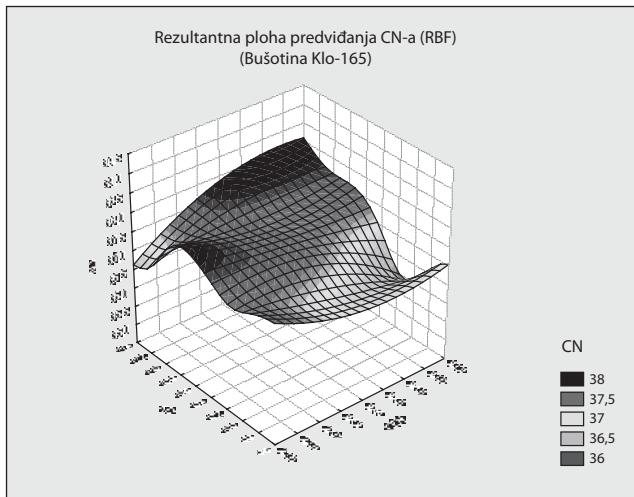
<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.

Iz iznosa pogreške prikazane u **tablici 5.2** može se vidjeti da je RBF mreža manje uspješna u predviđanju od MLP mreže.

To također potvrđuju vrijednosti na dijagramu razlika (**slika 5.5**), izgled resultantne plohe na troosnome dijagramu (iako je složene geometrije, nema mogućnost predviđanja maksimuma i minimuma vrijednosti – **slika 5.6**) i izgled same karotažne krivulje u odnosu na realnu i onu predviđenu MLP mrežom (**slika 5.4**).



**Slika 5.5:** Prikaz iznosa razlike vrijednosti predviđene RBF mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazana na apscisi)



**Slika 5.6:** Prikaz rezultantne plohe vrijednosti karotaže CN-a za RBF mrežu

### 5.3.3. Rezultati analiza neuronske mreže s postupkom poopćene regresije

Najuspješnija GRNN neuronska mreža imala je, kao i RBF mreža, relativno visoke iznose pogreške (**tablica 5.3**).

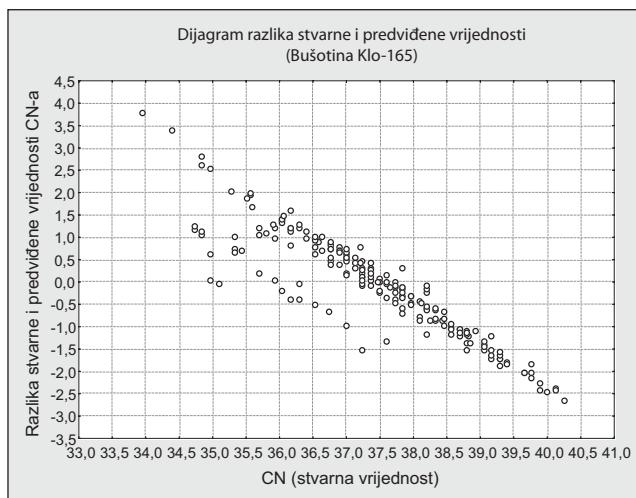
Unatoč manjoj uspješnosti uvježbavanja izdvojena GRNN mreža imala je prilično dobre vrijednosti predviđanja u odnosu na stvarne vrijednosti (**slika 5.4 i 5.7**), što je rezultat konstrukcije mreže kojom je moguće predviđati maksimume i minimume. Sposobnost predviđanja minimuma i maksimuma jasno se može vidjeti iz troosnoga dijagrama (**slika 5.8**).

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
GRNN 2-100-2-1	0,271277	0,288517

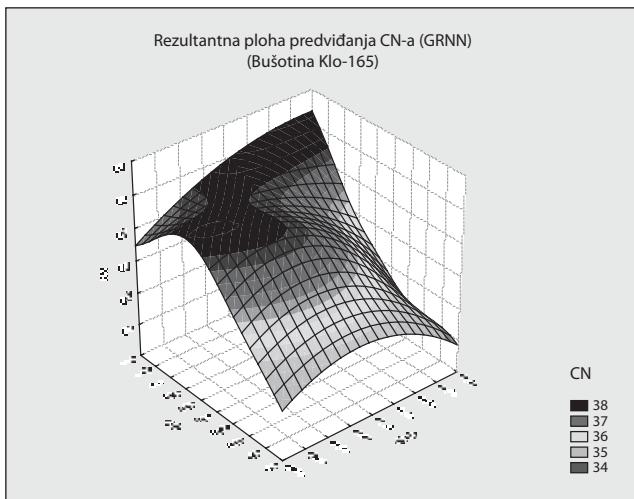
**Tablica 5.3:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznome i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.



**Slika 5.7:** Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)



**Slika 5.8:** Prikaz rezultantne plohe vrijednosti karotaže CN-a za GRNN mrežu

#### 5.4. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA U POLJU STARI GRADAC-BARCS NYUGAT

Analize neuronskim mrežama u polju Stari Gradac-Barcs Nyugat prikazane su u dvama potpoglavlјima. Prvi dio obuhvaća analize u bušotini Stg-3 intervala označenih kao „miocenski klastiti“, a drugi analize intervala „metavulkaniti“.

U obama poglavlјima za analize su izdvojeni intervali od trideset metara za uvježbavanje (prvih i zadnjih deset metara) te provjeru uspješnosti neuronskih mreža (srednji interval). Neuronska mreža uvježbana je trima varijablama, no rezultantna ploha ipak nije prikazana troosnim dijagramima zbog preglednosti.

Kao ulazne varijable korištene su karotažne krivulje AC-a, DEN-a i GR-a, a predviđena je vrijednost karotažne krivulje CN-a.

#### 5.4.1. Rezultati analize podataka iz intervala „miocenski klastiti“

Odabrani interval pružao se u rasponu od –3530 do –3560 metara dubine. Uvježbano je nekoliko neuronskih mreža od kojih su za prikaz rezultata izabrane samo one najuspješnije (**tablica 5.4**).

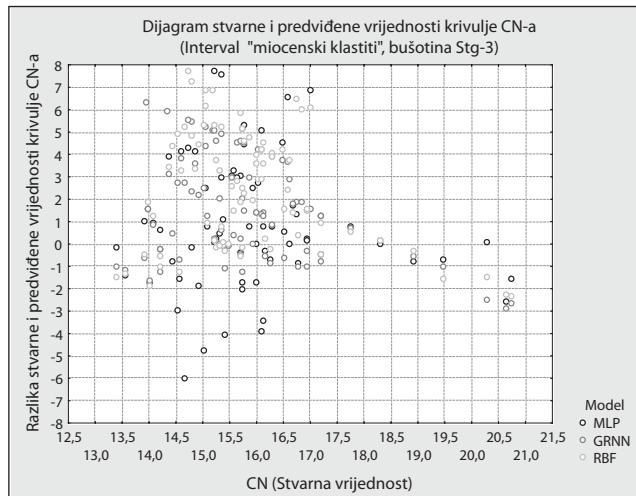
Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
MLP 3:3-4-6-4-1:1	0,064183	0,076466
GRNN 3:3-81-2-1:1	0,136259	0,207764
RBF 3:3-30-1:1	0,142624	0,151374

**Tablica 5.4:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

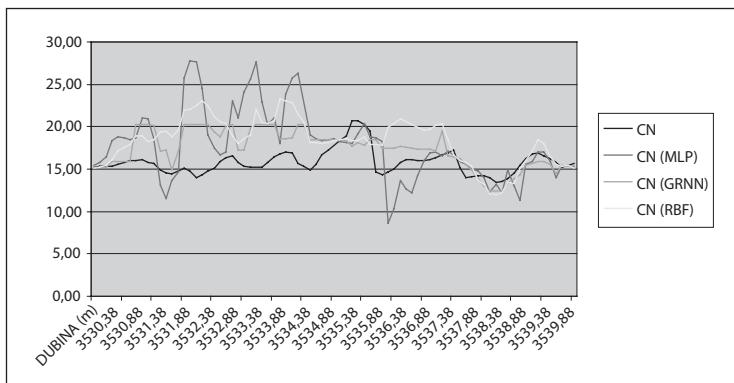
<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.

MLP mreža još se jednom pokazala kao najuspješnije uvježbana zbog najmanjih iznosa pogreške uvježbavanja i selekcije. Također, na zbirnome dijagramu razlika za sve mreže može se vidjeti da MLP ima najmanje razlike za većinu vrijednosti, no i najveća negativna i pozitivna odstupanja (**slika 5.9**).



**Slika 5.9:** Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)

Iako je prema vrijednostima pogrješaka selekcije i uvježbavanja MLP mreža bila najuspješnija, u intervalu predviđenome za provjeru uspješnosti neuronskih mreža imala je najveća odstupanja u intervalu od –3530 do –3535 metara (**slika 5.10**). U intervalu od –3535 do –3540 metara dobro odražava vrijednosti i trend stvarne krivulje. Prema **slici 5.10** najuspješnija neuronska mreža za predviđanje vrijednosti u intervalu „miocenskih klastita“ bila je GRNN neuronska mreža. Ona u prvome djelu intervala (od –3530 do –3535 metara) najbolje odražava vrijednosti stvarne krivulje kao i njezin trend. U drugome dijelu intervala „miocenskih klastita“ vrijednosti predviđene GRNN neuronskom mrežom također imaju najmanji odmak od one stvarne.



**Slika 5.10:** Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od -3530 do -3540 metara (bušotina Stg-3)

#### 5.4.2. Rezultati analize podataka iz intervala „metavulkaniti“

Odabrani interval bio je od -3810 do -3840 metara dubine. Prikaz najuspješnije uvježbanih neuronskih mreža dan je u **tablici 5.5**.

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
MLP 3:3-4-5-8-1:1	0,123758	0,184956
GRNN 3:3-80-2-1:1	0,220790	0,345607
RBF 3:3-13-1:1	0,416945	0,394645

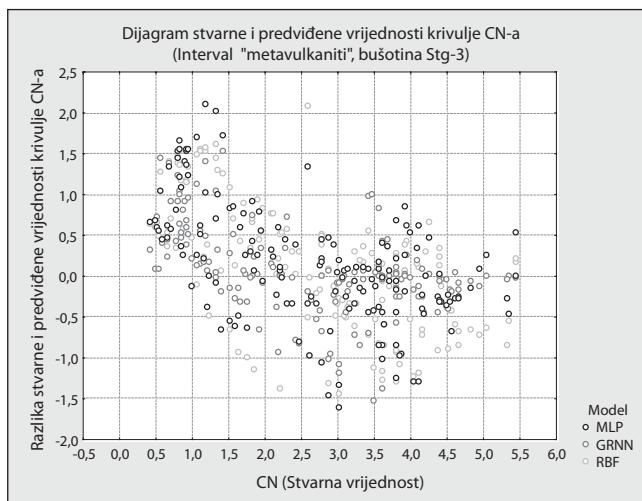
**Tablica 5.5:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.

Najuspješnije uvježbana mreža jest MLP mreža s trima skrivenim slojima, dok GRNN, a posebice RBF mreža, imaju visoku pogrešku uvježbavanja i selekcije.

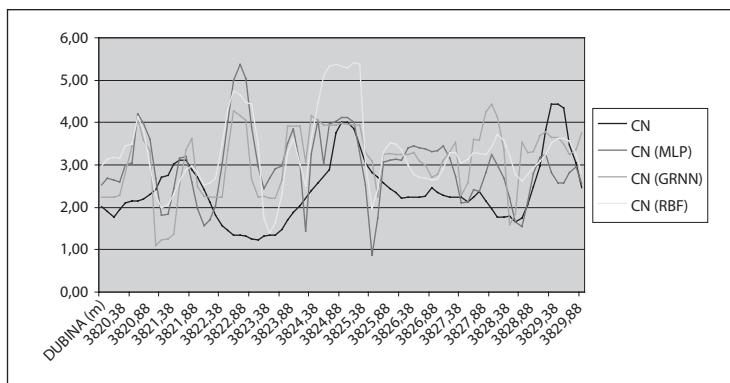
Na dijagramu razlika (**slika 5.11**) također se može vidjeti kako vrijednosti predviđene MLP mrežom imaju manja odstupanja od onih predviđenih GRNN i RBF mrežom.



**Slika 5.11:** Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)

Uspješnost predviđanja neuronskim mrežama intervala od –3820 do –3830 metara dubine prikazana je na **slici 5.12**. Već iz vrijednosti

pogrješke uvježbavanja i selekcije, koje su prilično velike, moglo se zaključiti kako će predviđanje u tome intervalu za sve mreže biti manje uspješno nego u prošlima. Najboljom se ipak pokazala MLP mreža koja je u većini slučajeva uspjela pratiti trend karotažne krivulje CN-a uz iznimku prisutnu kod svih neuronskih mreža na vrijednostima iz intervala od –3822 do –3823 metra dubine.



*Slika 5.12: Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od –3530 do –3540 metara (bušotina Stg-3)*

## 5.5. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA U POLJU ĐELETOVCI

Rezultati analiza prikazani su zbirno za sve korištene vrste neuronskih mreža. Kao i kod analiza u polju Stari Gradac-Barcs Nyugat za prikaz uspješnosti koristili su se samo dijagrami i tablice s iznosima pogrešaka neuronskih mreža.

Izabrani interval bio je od  $-1000$  do  $-1030$  metara dubine bušotine Dt-42 koji obuhvaća ugljikovodicima nezasićen dio stijena „temeljnoga gorja“. Uvježbano je više neuronskih mreža od kojih su odabранe samo one najuspješnije. Varijable korištene za uvježbavanje bile su karotažne krivulje AC-a, DEN-a i GR-a, a predviđena varijabla bila je vrijednost karotažne krivulje CN-a.

Najuspješnije mreže, kao i njihovi parametri, prikazani su u **tablici 5.6**. Najuspješnije uvježbana neuronska mreža u ovome slučaju bila je RBF neuronska mreža, dok je MLP mreža imala najveće pogreške uvježbavanja u odnosu na ostale dvije. Posebno treba istaknuti da su uvježbane mreže imale najmanju pogrešku dotad u odnosu na analize u polju Kloštar i Stari Gradac-Barcs Nyugat.

Tip neuronske mreže i svojstva <sup>a</sup>	Pogrješka uvježbavanja <sup>b</sup>	Pogrješka selekcije <sup>b</sup>
MLP 3:3-8-6-1:1	0,051508	0,062663
GRNN 3:3-80-2-1:1	0,043126	0,044439
RBF 3:3-26-1:1	0,039061	0,038555

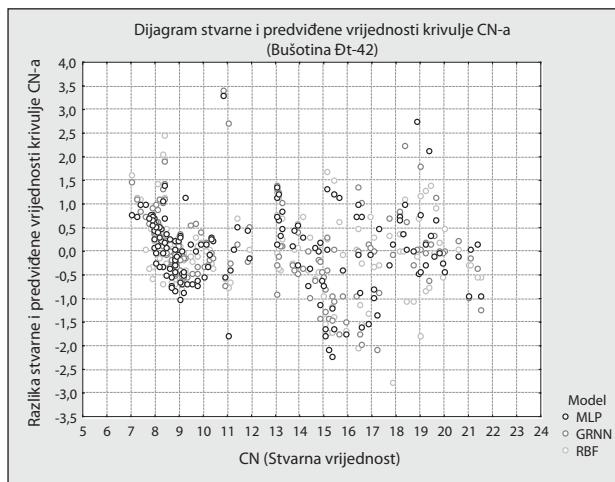
**Tablica 5.6:** Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

<sup>a</sup> Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

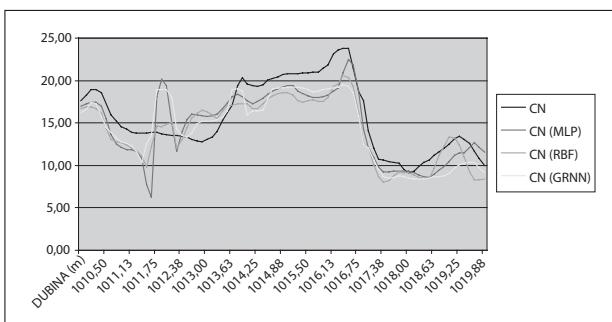
<sup>b</sup> Iznos pogreške prikazan je tako da 0 predstavlja 0% pogreške, tj. 100% uspješnosti, a iznos pogreške od 1 predstavlja 100% pogreške, odnosno 0% uspješnosti.

Uspješnost uvježbavanja također je prikazana na dijagramu razlika, gdje se vidi da neuronske mreže imaju male razlike stvarnih i pred-

viđenih vrijednosti, no minimumi i maksimumi vrijednosti CN-a izvrsno su predviđeni (**slika 5.13**).



**Slika 5.13:** Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)



**Slika 5.14:** Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od –1010 do –1020 metara (bušotina Dt-42)

Uspješnost predviđanja neuronskim mrežama prikazana je na intervalu od –1010 do –1020 metara dubine bušotine Đt-42 (**slika 5.14**). Gotovo sve predviđene vrijednosti izvrsno prate stvarnu vrijednost krivulje CN-a, a najuspješnija mreža za predviđanje jest MLP neuronska mreža.

## **5.6. ZAKLJUČAK O REKONSTRUKCIJI KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA**

Ukupno je odabранo devet neuronskih mreža, tri od svake vrste, kojima su pomoću vrijednosti karotaže zvuka (AC), karotaže gustoće (DEN) i eventualno karotaže prirodne radioaktivnosti (GR) predviđene vrijednosti karotaže neutronske poroznosti (CN) iz istoga intervala.

Rezultati dobiveni analizama neuronskim mrežama na pojedinim lokacijama i litološkim sastavima jesu sljedeći:

- Sve vrste neuronske mreže uspješne su u predviđanju neutronske poroznosti, a najuspješnija je višeslojna mreža s povratnom informacijom (MLP).
- Najuspješnije predviđanje vrijednosti karotaže neutronske poroznosti bilo je na odabranome intervalu iz polja Đeletovci.
- Najmanje uspješno bilo je predviđanje vrijednosti krivulje neutronske poroznosti u intervalu „metavulkaniti“ u polju Stari Gradac-Barcs Nyugat.
- Rezultati predviđanja klastičnoga intervala I. pješčenjačke „serije“ bili su zadovoljavajući iako u ulaznome skupu nije korištena vrijednost krivulje prirodne radioaktivnosti (GR).

Ovim je istraživanjem još jednom prikazana primjenjivost neuron-skih mreža u istraživanju ležišta ugljikovodika, u ovome slučaju u rekonstrukciji karotažnih krivulja, kao brzoga i jeftinoga alata koji s određenom pouzdanošću može uspješno rekonstruirati dijelove pojedinih krivulja koje nedostaju.

## 5.7. LITERATURA

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond struč. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
3. Brod, I. O. & Jeremenko, N. A. (1957): Osnovi geologii niefti i gasa. Izdanie tretie, Gostoptehizdat, Moskva.
4. 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.
5. Levorsen, A. I. (1956): Geology of petroleum. Freeman, 703 str., San Francisco.

---

---

---

---

---

---

---

---

## ***POGOVOR***

Nakon što je prikazano nekoliko različitih primjera uporabe neuronskih mreža na različitim vrstama podataka iz ležišta ugljikovodika u poljima Okoli, Kloštar i Beničanci, može se donijeti nekoliko općih zaključaka:

1. Gotovo svi podatci mogu se upotrijebiti kao ulaz u neuronske mreže.
2. Karotažne krivulje posebno su pogodne za analizu neuronskim mrežama zbog velikoga broja dostupnih podataka i visoke rezolucije.
3. Sve karte koje su interpolirane drugim metodama, a na njima su prikazane varijable ležišta nafte i plina, moguće je procijeniti i neuronskim algoritmima.
4. Postoji nekoliko neuronskih algoritama, počevši od najpopularnije paradigmе povratnoga postupka do naprednijih i specijaliziranih inačica poput radijalne funkcije, naprednoga povratnoga algoritma i drugih. Svaka upotreba zahtjeva određivanje najprimjerije metode za obradbu odabranih podataka.

Prvi postupak u stvaranju primjenjive neuronske mreže predstavlja oblikovanje njezine arhitekture. Njime se utvrđuje broj slojeva unutar mreže (posebno broj skrivenih slojeva), određivanje veza unutar svakoga sloja i između slojeva, odabir aktivacijske funkcije postavljene uz svaku vezu te početnih težinskih koeficijenata pridruženih poje-

dinačnomu neuronu. Nadalje, svako uvježbavanje neuronskih mreža predstavlja postupak kojim se traga za najprimjerenijim težinskim koeficijentima koji su, već u prvoj koraku, pridijeljeni pojedinačnim neuronima u slojevima. Aktivirajući veze između neurona unutar i između slojeva, vrijednosti tih koeficijenata prilagođavaju se tijekom učenja. Vidljivo je kako veze između neurona i slojeva igraju vrlo važnu ulogu u radu mreže. Sve mreže opisane u ovoj knjizi bile su vrsta *potpuno povezanih mreža* (engl. „completely connected perceptrons“), što znači da je svaki neuron u prethodnome sloju povezan sa svakim neuronom u sljedećemu sloju. No, arhitektura mreža može biti i malo drugačije posložena, pa tako kod *djelomično povezanih mreža* svaki neuron u prethodnome sloju nije povezan sa svim neuronima u sljedećem sloju. Kod *jednosmjernih mreža* veze (bilo potpune, bilo djelomične) su postavljene tako da informacije idu samo iz prethodnoga u sljedeći sloj (nema povratnoga postupka unutar jedne iteracije). Između tih slučajeva postoje razni varijeteti dvosmjernih i jednosmjernih veza, ovisno o tome događa li se učenje već unutar jedne iteracije, postoje li preferirane veze itd.

Možda je najvažniji mehanizam unutar neuronske mreže *aktivacijska funkcija* kojom se na kraju određuje hoće li izlaz nekoga neurona ili sloja postojati ili će signal biti „ugašen“. U svojoj biti, aktivacijska funkcija predstavlja pravilo učenja neuronskoga algoritma. Ako se vratimo na arhitekturu mreže preko slojeva, ulaz svakoga sljedećega sloja (osim ulaznoga) zapravo je izlaz prethodnoga pomnožen s težinskim koeficijentom pridodanim izlazu sloja ili neurona. Ako je takvih

veza između slojeva više, kod svake od njih (obično svaka objedinjuje više „lokalno povezanih“ neurona) računa se takav umnožak.

Tada je moguće kod svake veze odrediti i prikladnu aktivacijsku funkciju, koja ovisno o vrijednosti izlaza određuje hoće li on biti ulaz za sljedeći sloj (neuron će biti aktiviran) ili ne (bit će neaktiviran, tj. imat će vrijednost 0). Nekoliko je vrsta takvih funkcija kojima se donose odluke unutar umjetne mreže, a najčešća je *sigmoidna* funkcija koja je upotrijebljena u primjerima u ovoj knjizi. Sigmoidna funkcija još se naziva i *logistička*, a njezin čest varijetet jest *log-sigmoidna* funkcija. Zatim su tu još jednostavna *funkcija koraka*, pa složenije *signum funkcija*, *hiperboličko-tangentna*, *linearna*, *linearna funkcija s pragom* uz druge rjeđe upotrebljavane aktivacijske funkcije.

Ovisno o načinu učenja neuronske mreže, tj. o načinu na koji će previdjeti vrijednosti, postoje dvije glavne vrste – neuronske mreže s nadgledanim učenjem i nenadgledanim učenjem. U radovima opisanim u ovoj knjizi korištene su samo mreže s nadgledanim tipom učenja koji podrazumijeva da se u postupku učenja neuronskoj mreži dodjeljuje određeni skup ulaznih podataka i odgovarajuće izlazne vrijednosti. Na temelju izlaza neuronske mreže proces učenja u novim je iteracijama poboljšavan korekcijom težinskih faktora pojedinačnih neurona. Način korekcije ovisi o upotrijebljenom pravilu učenja. Cilj je postupka da predviđena vrijednost bude što sličnija vrijednosti onoj iz ulaznoga skupa. Pravila nadgledanoga učenja koja se najčešće koriste jesu *delta pravilo*, *poopćeno delta pravilo* i *delta-bar-delta*.

*pravilo*. Kod neuronskih mreža s nenadgledanim učenjem poznat je samo ulazni skup podataka, za razliku od onih s nadgledanim gdje je ulaznom skupu prirodan i skup izlaznih vrijednosti za potrebe uvježbavanja. Mreže s nenadgledanim tipom učenja koriste se uglavnom za prepoznavanje uzoraka u ulaznom skupu podataka, a najuspješnije pravilo učenja koje se primjenjuje je *Kohonenovo pravilo*.

U prikazanim analizama jasno je vidljiv potencijal analiza neuronskim mrežama u geologiji, a posebice u geologiji ležišta ugljikovodika. One su matematički alat koji vrlo brzo daje dovoljno dobre aproksimacije, tj. primjenjiva rješenja, kada ne postoji mogućnost linearne aproksimacije. To posebno vrijedi kod dovoljno velikih skupova ulaznih podataka kakvi su često dostupni u analizama ležišta nafte i plina.

# **KAZALO**

## **Aktivacijska funkcija**

*(Activation function)* 12, 15, 21, 22, 62, 92

## **Algoritam postupnoga opadanja**

*(Gradient descent algorithm)* 23

## **Algoritam s povratnim postupkom**

*(Backpropagation algorithm)* 12, 17, 19, 20-24, 45, 57, 61, 65

## **Arhitektura potpuno povezanih perceptronova**

*(Completely connected perceptrons)* 33, 92

## **Brzina učenja (v. iznos učenja)**

### **Delta pravilo**

*(Delta rule)* 93

### **Delta-bar-delta pravilo**

*(Delta-bar-delta rule)* 93

### **Elastični unaprijedeni povratni algoritam**

*(Improved resilient propagation algorithm plus)* 33

## **Iteracija**

*(Iteration)* 9, 21-24, 34-37, 39, 40, 45, 46, 57, 61-63, 65, 92, 93

## **Izlazni sloj**

*(Output layer)* 13, 14, 17, 18, 20, 24, 25, 27

## **Iznos učenja**

*(Learning rate)* 18, 19, 22, 32, 33, 62

## **Koeficijent momenta (v. i momentni faktor)**

*(Momentum coefficient)* 22, 23, 62

**Kohonenovo pravilo**

(*Kohonen's rule*) 94

**Korekcijski izraz**

(*Correction term*) 23

**Log-sigmoidna funkcija**

(*Log-sigmoid function*) 62, 93

**Lokalno prilagodljiva pravila učenja**

(*Local adaptive learning rules*) 32

**Momentni faktor**

(*Momentum factor*) 19

**Mreža s postupkom poopćene regresije**

(*Generalized regression neural network*) 25

**Mreža s povratnim postupkom**

(*Backpropagation network*) 12, 17, 20, 57

**Mreža s radijalnom funkcijom**

(*Radial basis function network*) 23-25, 45, 54, 76

**Nadgledane mreže**

(*Supervised networks*) 24, 44, 93, 94

**Nenadgledane mreže**

(*Non-supervised networks*) 24, 93, 94

**Neuron, ljudski neuron**

(*Neuron, human*) 10, 11

**Neuron, umjetni neuron**

(*Neuron, artificial*) 12, 13, 20

**Perceptron**

(*Perceptron*) 20, 21, 33, 92

**Povratni postupak (v. algoritam s povratnim postupkom)**

(*Backpropagation procedure*) 12,21

**Pravilo učenja**

(*Learning rule*) 32

**Radijalna funkcija**

(*Radial basis function*) 23-25

**Sigmoidna funkcija**

(*Sigmoid function*) 15, 22, 61, 62, 93

**Skriveni slojevi**

(*Hidden layers*) 13, 14, 20-26, 45, 46, 50, 61, 73, 84, 91

**Težinski koeficijent**

(*Weighting coefficient*) 15-20, 23, 26, 27, 91-93

**Transformacijska funkcija (v. aktivacijska funkcija)**

(*Transfer function*)

**Učinak preuvježbavanja neuronske mreže**

(*Overtraining effect*) 41

**Ulazni sloj**

(*Input layer*) 13, 14

**Višeslojna mreža**

(*Multiple layer perceptron*) 21, 54, 55, 73, 74, 88

## ***BILJEŠKE***

---



---

---

---

---

---

---

---

---