

SVEUCILIŠTE U ZAGREBU  
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Studij geologije

**NAFTNOGEOLOŠKA PRIMJENA NEURONSKIH MREŽA NA  
PRIMJERU LEŽIŠTA U POLJU KLOŠTAR**

Diplomski rad

Marko Cvetkovic

G1312

Zagreb, 2007.

*Zahvaljujem mentoru prof.dr.sc. Josipi Velic na predloženoj temi, ukazanom povjerenju te pomoci pri izradi ovog diplomskog rada.*

*Veliku strpljivost i vjeru u moj rad ukazao mi je suvoditelj dr.sc. Tomislav Malvic iz INA-e d.d., Sektora za razradu.*

*Takoder zahvaljujem doc.dr.sc. Slavki Pfaff i prof.dr.sc. Bruni Safticu na strucnim primjedbama i korisnim savjetima.*

NAFTNOGEOLOŠKA PRIMJENA NEURONSKIH MREŽA NA PRIMJERU LEŽIŠTA U POLJU  
KLOŠTAR

MARKO CVETKOVIC

Diplomski rad izraden: Sveučilište u Zagrebu  
Rudarsko-geološko-naftni fakultet  
Zavod za geologiju i geološko inženjerstvo  
Pierottijeva 6, 10000 Zagreb

Sažetak

Naftno polje Kloštar nalazi se na sjevernom rubu Savske depresije unutar hrvatskog dijela Panonskog bazena. Najveći dio ležišta ovoga polja je u gornjomiocenskim sitnozrnatim pješčenjacima grupiranim u dvije operativne jedinice – «I. i II. pješcanu seriju». Nakon opisa temeljnih postavki neuronskih mreža i povijesti njihovog razvoja, dani su osnovni modeli i strukture dviju vrsta neuronskih mreža kao i opis elektrokarotažnih metoda čiji su rezultati korišteni kao ulazni podaci za njihovo uvježbavanje. Neuronske mreže uvježbavane su u intervalima «I. i II. pješcane serije» u bušotinama Klo-44 i Klo-71. Na tim mjestima kao ulazni podaci izdvojene su vrijednosti spontanog potencijala (SP) i električne otpornosti ( $R_{16}$ ,  $R_{64}$ ). Iz takvih ulaza predviđan je litološki sastav. U drugom zadatku neuronska mreža upotrijebljena je za predviđanje zasićenja ugljikovodicima. Ista je ponovno uvježbavana na bušotini Klo-44, a predviđanje je načinjeno na bušotini Klo-71. Ulazni podaci bili su istovrsni onima u prethodnom zadatku, uz upotrebu dviju dodatnih varijabli, a to su bili dubina (m) te litološki sastav kao atributivna varijabla. Relativno mali iznosi pogreške kod predviđanja, odnosno velika podudarnost predviđenih i stvarnih vrijednosti analiziranih varijabli ukazuje na velike mogućnosti primjene neuronskih mreža u naftnogeološkim istraživanjima. Točnost predviđanja mogla bi se znatno povećati koristeći veći broj ulaznih podataka, prvenstveno karotažnih krivulja koje dobro opisuju litološki sastav i zasićenje u stijeni. Takve krivulje su: krivulja prirodne radioaktivnosti (GR), karotaža kompenziranih neutrona (CN) te karotaža gustoće (DEN).

Ključne riječi: neuronske mreže, polje Kloštar, predviđanje, litološki sastav, zasićenje.

Diplomski rad sadrži: 49 stranica, 6 tablica, 24 slike i 14 referenci.

Jezik izvornika: hrvatski

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

Mentor: Dr. sc. Josipa Velic, redoviti profesor RGNF

Ocjenjivaci: Dr. sc. Josipa Velic, redoviti profesor RGNF  
Dr. sc. Slavka Pfaff, docent RGNF  
Dr. sc. Bruno Saftic, izvanredni profesor RGNF  
Dr. sc. T. Malvic, ekspert INA d.d.

Datum obrane: 15. lipanj 2007.

University of Zagreb  
Faculty of Mining, Geology  
and Petroleum Engineering

Graduate Engineer of Geology Thesis

PETROLEUM GEOLOGY USE OF NEURAL NETWORKS ON THE EXAMPLE OF RESERVOIR  
IN KLOŠTAR FIELD

MARKO CVETKOVIC

Thesis completed in: University of Zagreb

Faculty of Mining, Geology and Petroleum engineering  
Institute of Mineralogy, Petrology and Mineral deposits,  
Pierottijeva 6, 10 000 Zagreb

Abstract

Oil field Kloštar is situated in the northern part of the Sava depression within the Croatian part of the Panonian basin. Main part of the field is in upper Miocene sandstones which are grouped in two operative units – “I. and II. sandstone series”. After the description of the basic principles of neural networks, with a detailed description of two types that were used in this diploma thesis, geophysical borehole measurements that were used as input data for the neural network analysis were also described. Neural networks were trained in the intervals of the “I and II sandstone series” in the wells Klo-44 and Klo-71. From the parts of the data logs that correspond to the previous mentioned intervals, data was used in the neural network analysis. In the first analysis input data were log data (curves SP,  $R_{16}$  and  $R_{64}$ ) and the predicted value was lithological composition (described as sandstone or marl). Secondly, the neural network was used to predict saturation with hydrocarbons. Neural network was trained in the well Klo-44 and prediction was done in the well Klo-71. Input data were the same with the addition of depth (m) and lithological composition. Relatively small prediction error values and very good correspondence between predicted and real values was achieved. This points out to great possibilities in neural network application on petroleum geology problems and in exploration. Accuracy of prediction can additionally be heightened by adding more input data, primarily more data logs that are good at defining lithological composition and hydrocarbon saturation such as gamma ray (GR), compensated neutron (CN) and density (DEN) logs.

Keywords: neural networks, Kloštar field, prediction, lithological composition, hydrocarbon saturation

Thesis contains: 49 pages, 6 tables, 24 figures and 14 references.

Original in: Croatian

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

Supervisor: PhD Josipa Velic, Full Professor

Reviewers: PhD Josipa Velic, Full Professor  
PhD Slavka Pfaff, Assistant Professor  
PhD Bruno Saftic, Full Professor  
PhD Tomislav Malvic, Expert

Date of defense: June 15, 2007.

## SADRŽAJ:

<b>1. UVOD</b>	<b>1</b>
<b>2. GEOGRAFSKI POLOŽAJ POLJA KLOŠTAR</b>	<b>2</b>
<b>3. POVIJEST ISTRAŽIVANJA ŠIRE OKOLICE POLJA KLOŠTAR</b>	<b>3</b>
<b>4. OSNOVNI PODATCI O LEŽIŠTIMA POLJA KLOŠTAR</b>	<b>4</b>
<b>5. NAFTNOGEOLOŠKI ODNOSI</b>	<b>6</b>
<b>5.1. Stratigrafski odnosi</b>	<b>6</b>
<b>5.2. Strukturno-tektonski odnosi u polju Kloštar</b>	<b>8</b>
<b>5.3. Geološki opis ležišta nafte i plina</b>	<b>9</b>
<b>5.4. Pregled kolektorskih parametara po eksploatacijskim objektima</b>	<b>13</b>
<b>6. NEURONSKE MREŽE</b>	<b>15</b>
<b>6.1. Modeli neuronskih mreža</b>	<b>15</b>
<i>6.1.1. Povijest razvoja neuronskih mreža</i>	<b>15</b>
<i>6.1.2. Biološka neuronska mreža</i>	<b>16</b>
<i>6.1.3. Umjetna neuronska mreža</i>	<b>17</b>
<b>6.2. Osnovna načela učenja u neuronskim mrežama</b>	<b>19</b>
<i>6.2.1. Tipovi veza među neuronima</i>	<b>20</b>
<i>6.2.2. Ulazne i aktivacijske funkcije</i>	<b>21</b>
<i>6.2.3. Tipovi učenja</i>	<b>23</b>
<i>6.2.4. Pravila učenja</i>	<b>24</b>
<b>6.3. Neuronske mreže za probleme predviđanja</b>	<b>25</b>
<i>6.3.1. «Back propagation» mreža</i>	<b>25</b>
<i>6.3.2. Mreža sa radijalnom funkcijom</i>	<b>27</b>
<b>7. ELEKTROKAROTAŽNE METODE</b>	<b>30</b>
<b>7.1. Karotaža spontanog potencijala (SP)</b>	<b>30</b>
<b>7.2. Karotaža prividne električne otpornosti (<math>R_{16}</math>, <math>R_{64}</math>)</b>	<b>32</b>
<b>8. ANALIZE NEURONSKOM MREŽOM</b>	<b>35</b>
<b>8.1. Predviđanje litološkog sastava</b>	<b>35</b>
<i>8.1.1. Analiza za bušotinu Klo-44</i>	<b>35</b>

8.1.2. <i>Analiza za bušotinu Klo-71</i>	40
8.2. Predvidanje zona zasćenih ugljikovodicima	44
8.3. Moguci problemi prilikom analiza neuronskim mrežama	46
9. ZAKLJUCAK	48
10. LITERATURA	

## POPIS SLIKA

Slika 2-1. Geografski položaj polja Kloštar (\*\*\*)

Slika 4-1. Shematski prikaz raspored bušotinske mreže na polju Kloštar (izdvojene 62 bušotine) (\*\*\*)

Slika 5-1. Shematski geološki profil «I. pješcane serije» (\*\*\*)

Slika 5-2. Strukturna karta po krovini ležišta T (\*\*\*)

Slika 6-1. Biološki model neurona

Slika 6-2. Prikaz modela umjetnog neurona

Slika 6-3. Graf sigmoidne aktivacijske funkcije (za  $g > 0$ )

Slika 6-4. Graf hiperbolicko tangentne aktivacijske funkcije

Slika 6-5. Jednostavan prikaz višeslojne mreže s povratnom informacijom s dva skrivena sloja (engl. «*multi layer perceptron, MLP*») (STATISTICA, 2004)

Slika 6-6. Jednostavan prikaz mreže s radijalnom funkcijom s velikom brojem neurona u skrivenom sloju (STATISTICA, 2004)

Slika 7-1. Izgled krivulje SP-a s pripadajućim osnovnim linijama te probušena litologija (BALIC, 1993)

Slika 7-2. Prikaz krivulje otpornosti za  $R_6$  i  $R_{64}$  te krivulje SP-a u slučaju zasićenja pješčenjaka ugljikovodicima (BALIC, 1993)

Slika 8-1. Prikaz opadanja pogrješke kroz učenje

Slika 8-2. Uvježbavanje RBF mreže u «II. pješcanoj seriji», Klo-44, litološki sastav

Slika 8-3. Uvježbavanje MLP mreže u «II. pješcanoj seriji», Klo-44, litološki sastav

Slika 8-4. Predviđanje RBF mrežom u «I. pješcanoj seriji», Klo-44, litološki sastav

Slika 8-5. Predviđanje MLP mrežom u «I. pješcanoj seriji», Klo-44, litološki sastav

Slika 8-6. Uvježbavanje RBF mreže u «I. pješcanoj seriji», Klo-71, litološki sastav

Slika 8-7. Uvježbavanje MLP mreže u «I. pješcanoj seriji», Klo-71, litološki sastav

Slika 8-8. Predviđanje RBF mrežom u «II. pješcanoj seriji», Klo-71, litološki sastav

Slika 8-9. Predviđanje MLP mrežom u «II. pješcanoj seriji», Klo-71, litološki sastav

Slika 8-10. Uvježbavanje MLP mreže u bušotini Klo-44, ležište

Slika 8-11. Predviđanje MLP mrežom u bušotini Klo-71, ležište

Slika 8-12. Usporedba spontanog potencijala u bušotinama Klo-44 i Klo-71

*POPIS TABLICA*

Tablica 5-1. Prikaz pripadnosti eksploatacijskih objekata i ležišta stratigrafskim jedinicama

Tablica 5-2. Pregled kolektorskih parametara u polju Kloštar (\*\*\*)

Tablica 5-3. Pregled hidrodinamickih jedinica «I. pješcane serije» (\*\*\*)

Tablica 8-1. Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-44 za predviđanje litološkog sastava

Tablica 8-2. Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-71 za predviđanje litološkog sastava

Tablica 8-3. Prikaz parametara uvježbane neuronske mreže na bušotini Klo-44 u svrhu predviđanja varijable ležište



## 1. UVOD

Za područje analize rezultata primjene neuronskih mreža odabrano je područje polja Kloštar zapadnom dijelu Savske depresije. Upotrebom neuronske mreže predviđani su raspored pješčenjaka i lapora u intervalima koji odgovaraju «I. i II. pješcanoj seriji» te raspored zasićenja ugljikovodicima prema podacima iz bušotina Klo-44 i Klo-71. Ležišta «I. i II. pješcana serija» odabrana su zbog relativno velike homogenosti pješčenjaka te ujedno kao i tipske klastične sekvence koje se pojavljuju unutar naslaga gornjeg panona i donjeg pontu u cijelom hrvatskom dijelu Panonskog bazena.

Analize neuronskim mrežama detaljno su opisane i prikazane grafički te tablicama. Nacinjene su pomoću programskog paketa StatSoft STATISTICA.

## 2. GEOGRAFSKI POLOŽAJ POLJA KLOŠTAR

Naftno-plinsko polje Kloštar smješteno je na širem području sela Kloštar Ivanic, Gornji Šarampov, Šcapovec, Sobocani, Predave, Lipovec i Prkos. Nalazi se otprilike 35 km istočno od Zagreba (**slika 2-1.**) uz državnu auto-cestu A3 Zagreb-Kutina. U neposrednoj blizini polja Kloštar nalaze se naftna polja Križ, Bunjani i Ivanic. Topografski polje je smješteno na blago brežuljkastom području na zapadnim obroncima Moslavacke gore gdje nadmorska visina varira u rasponu od 110 i 180 metara. Područje polja zauzima površinu od oko 30 km<sup>2</sup> i pripada Zagrebackoj županiji.



Slika 2-1. Geografski položaj polja Kloštar (\*\*\*)

### 3. POVIJEST ISTRAŽIVANJA ŠIRE OKOLICE POLJA KLOŠTAR

Interes za istraživanjem na širem području polja Kloštar javlja se na samom početku 20-tog stoljeća. Razlog tome bile su pojava plina u bunarima Kloštar Ivanica i okolnih naselja. Prva bušenja bila su 1904./1905. godine pri čemu je postignuta dubina od otprilike 650 metara bez otkrica nafte. Kasnije, regionalnim gravimetrijskim mjerenjima sjeverozapadne Hrvatske u razdoblju do 1940. do 1942. godine otkrivena je gravimetrijska struktura Križ dinarskog pravca pružanja (SZ-II), u kojoj su izdvojena naftna ležišta, tj. polja Šumecani 1948. godine i Bunjani 1952. godine.

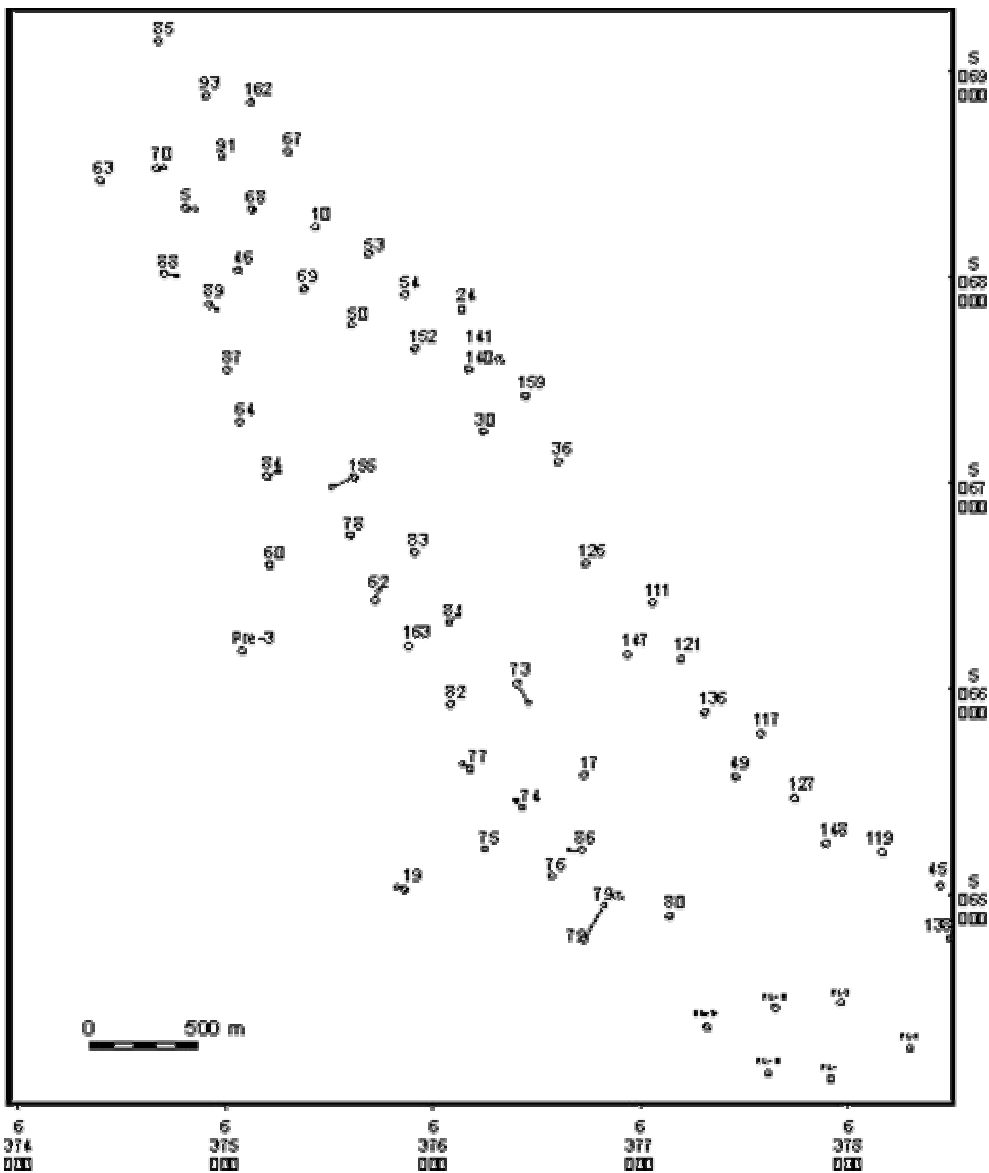
Na sjeverozapadnom dijelu strukture Križ, na području Kloštra, već se 1952. godine pristupilo novoj geofizickoj metodi istraživanja. Radilo se o seizmickim istraživanjima. Na temelju gravimetrijskih i seizmickih mjerenja i rezultata interpretacije smještena je prva bušotina Kloštar-1 (Klo-1). Postignuta dubina bušotine iznosila je 1272 metara. Bušotinom su probušena ležišta O (853-865 m), P (875-873 m), R (914-915m), Y (987-990m) te su dobivene ekonomski značajne količine nafte. Time je bilo potvrđeno postojanje novog polja unutar strukture Križ, naftnog polja Kloštar. Proizvodnja nafte na polju započeta je 1954. godine. Naknadno su obavljena dodatna geofizicka istraživanja, tj. snimanja novih seizmickih profila, posebno na rubnim dijelovima polja. Istraživanja su provedena u svrhu okonturenja ležišta i objašnjenja naftnogeoloških odnosa. Intenzivna razradba polja odvijala se od 1953. do 1961. godine.

#### 4. OSNOVNI PODATCI O LEŽIŠTIMA POLJA KLOŠTAR

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

- I. pješcana serija
- II. pješcana serija
- Prevalenc ijenezijske naslage
- Miocen
- Temeljno gorje

Prosječna šupljikavost pješčenjackih ležišta je 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 2005. godine bila je 79,6 m<sup>3</sup>/dan što iznosi oko 29000 m<sup>3</sup>/godina. Gustoća nafte je 843 kg/m<sup>3</sup>. Do danas na polju je ukupno izradeno 196 bušotina, od kojih su 64 mjerne, 59 proizvodne, 68 je tehnički likvidirano, a 5 se koristi za utiskivanje slojne vode. Shematski prikaz bušotinske mreže na polju Kloštar nalazi se na slici 4-1.



Slika 4-1. Shematski prikaz rasporeda bušotinske mreže na polju Kloštar (izdvojene 62 bušotine)(\*\*\*)

## 5. NAFTNOGEOLOŠKI ODNOSI

U ovom poglavlju bit će prikazane najvažnije cjeline vezane za naftnogeološke odnose, a one uključuju stratigrafiju, najvažnije strukturne-tektonske odnose u ležištu te geološki opis naftnih i plinskih ležišta uz opis kolektorskih parametara.

### 5.1. Stratigrafski odnosi

Gravimetrijska struktura Križ nalazi se na krajnjem sjeverozapadnom dijelu Moslavacke gore. Pružanje strukture je dinarskog pravca od rijeke Lonje na sjeverozapadu preko polja Kloštra, Šumecana i Bunjana prema rijeci Cesmi na jugoistoku. Jezgru same strukture čine paleozojski magmatiti i metamorfiti. Moslavacka gora je u vrijeme miocena, kada je bila formirana Savska depresija, predstavljala kopno. Paralelno s južnim rubom strukture Križ proteže se sustav glavnih rasjeda koji su bili aktivni za vrijeme glavne ekstenzijske faze (rani i srednji miocen). Pomicanjem tektonskih blokova po tim rasjedima uzrokovalo je otvaranje lokalnih i regionalnih ekstenzijskih zona među kojima je bila i Savska depresija.

Granice stratigrafskih jedinica nisu jednoznačno određene unatoc velikom broju raspoloživih bušotina i podataka. Stratigrafske jedinice određene su na temelju podataka pridobivenih iz jezgara, krhotina iz isplake i elektrokarotažnih krivulja. U najvećem broju uzoraka nisu pronađeni fosili, djelomice zbog toga što detaljna paleontološka istraživanja nisu bila primarni cilj jezgrovanja. Na temelju svih dostupnih bušotinskih podataka, koji uključuju jezgre, krhotine iz isplake te elektrokarotažne krivulje, izdvojene su jedinice:

«*Temeljno gorje*» (Tg)- Obuhvaća magmatske i metamorfne stijene paleozojske starosti. Kontakt temeljnog gorja i mladih stijena predstavlja paleoreljef. Stijene su trošne i raspucane zbog predtercijarne i miocenske tektonike i dugog izlaganja (gotovo 200 milijuna godina) uvjetima površinskog trošenja u doba paleogena i mezozika. Na strukturno povoljnim mjestima unutar ovih stijena nalaze se i ležišta.

*Miocen* ( $M_{4,5}$ ) - Naslage su predstavljene serijom stijena koje diskordantno leže na stijenama «temeljnog gorja». Stratigrafski nisu jednoznacno određene. Serija zapocinje konglomeratima, konglomeraticnim pijescima te pijescima s proslojcima pjeskovitih glina. Prema krovini u slijedu sedimenata dolaze sivi do tamnosivi tvrdi lapori i pješčenjaci s litotamnijским algama badenske starosti. Nakon njih slijede sarmatski tamnosmedi, pjeskoviti, bituminozni lapori uz proslojke sitnozrnastih pješčenjaka. Pocetak serije je teško uocljiv tj. teško je razluciti granicu temeljnog gorja i bazalnih konglomerata. Na južnom i istocnom dijelu polja miocenske naslage nosioci su ekonomski znacajnih kolicina ugljikovodika.

*Donji panon* ( $M_6^1$ ) - Sedimenti donjeg panona konkordantno slijede na sarmatske bituminozne lapore. Izgradeni su od bijelih, tvrdih kalcitnih lapora koji se po litološkim i geofizickim svojstvima vidljivo razlikuju od sarmatskih lapora. Unutar ovoga podkata nalaze se proslojci sitnozrnastih pješčenjaka svijetle boje s ekonomskim kolicinama nafte u južnom dijelu ležišta.

*Gornji panon* ( $M_6^2$ ) – Sedimenti gornjeg panona rasprostranjeni su po cijeloj površini polja. Uglavnom se radi o sredim do tamnosivim tvrdim vapnenim laporima. Na jugozapadnom dijelu polja nalaze se tri «serije» pješčenjaka:  $\alpha$ ,  $\beta$  i  $\gamma$ . U operativnom smislu ove naslage se zajedno nazivaju «II. pješcana serija». Pješčenjaci su djelomicno zasaceni ugljikovodicima, a najvece zalihe nalaze se u seriji  $\beta$ .

*Donji pont* ( $M_7^1$ ) – Naslage sadrže cak 17 pješčenjackih ležišta. Podina je jasno definirana elektrokarotaznim (EK) reperom Z', a krovina je približno određena EK reperom W. Predstavljene su sivim laporima koji se nalaze pretežno u južnom i istocnom dijelu polja dok su u sjevernom i zapadnom dijelu polja dominantni pješčenjaci. Pješčenjaci su pretežno sitnozrnasti, sivi do svijetlosivi. Dolaze u intervalima koji su medusobno odvojeni proslojcima lapora. Od krovine prema podini imamo intervale G, H, I, K, L, M i N koji su pretežno zasaceni slojnom vodom uz izuzetak pojava plina u intervalima G i H te pojava nafte u intervalima I i K. Nakon njih slijede intervali O, P, Q, R, S, T, U, V, Y i Z koji predstavljaju

glavne nosioce nafte na polju Kloštar. Najznacajniji intervali su T, U i V. Operativno ime intervala od O do Z je «I. pješcana serija».

*Gornji pont* ( $M_7^2$ ) - Naslage se rasprostiru po cijelom polju i konkordantno se nastavljaju na naslage donjeg ponta. Sastavljene su od mekih pjeskovito-glinovitih sedimentata s trendom povećavanja pjeskovite komponente u smjeru mladih naslaga.

*Dacij i romanij (Pl)* – Granice su determinirane usporedbom elektrokarotažnih dijagrama i litologije iz bušotina s polja Kloštar i iz bušotina s polja Križ i Bunjani. Uglavnom se sastoje od gline razne boje u izmjeni sa slojevima krupno do srednje zrnatih pijesaka.

*Kvartar (Q)* - Predstavljen je sedimentima koji se sastoje od pjeskovite gline žuckaste boje uz cesto pojavljivanje vapnenackih konkreција. Debljina kvartarnih naslaga iznosi od 10 do 15 metara.

## **5.2. Strukturno -tektonski odnosi u polju Kloštar**

U donjem i srednjem miocenu, za vrijeme otnanga, karpata i posebice badena, dolazi do transgresije mora na predmiocenski paleoreljef izgrađen od magmatskih i metamorfnih stijena. Paleoreljef temeljnog gorja i ekstenzijska tektonika za vrijeme miocena imali su bitan utjecaj na oblikovanje strukture polja Kloštar. Struktura Kloštar je antiklinala, djelomicno naslijedena od paleoreljefa, dinarskog smjera pružanja. Antiklinala je presjecena uzdužnim, normalnim, rasjedom koji presijeca strukturu nešto sjevernije od tjemena antiklinale (**slika 5-1. i 5-2.**). Paraklaza mu je nagnuta prema sjeveroistoku. Aktivnost rasjeda bila je najveća u vrijeme neogena. Sjeverno krilo antiklinale granica je zapadnog dela strukture Križ, koja je također intenzivno rasjednuta. Rasjedi manjeg skoka normalnog su karaktera, poprecno su orijentirani na pružanje glavne strukture i glavni uzdužni rasjed. Na području ležišta «I. pješcane serije» struktura je razlomljena na 17 tektonskih blokova.



### 5.3. Geološki opis ležišta nafte i plina

Ležišta nafte i plina u polju Kloštar nalaze se unutar:

- «temeljnog gorja»
- stijena srednjeg miocena (ležišta «miocen» – I, II, III, IV, V i VI)
- stijena donjeg panona (prevalencijenezijske naslage)
- stijena gornjeg panona (ležišta «II. pješćane serije»-alfa, beta i gama)
- stijena donjeg pontona (ležišta «I. pješćane serije»-Z, Y, V, U, T, S, R, Q, P, O i K)

S obzirom na prostorni raspored, ležišta u polju podijeljena su na tri proizvodna ili eksploatacijska objekta (**Tablica 5-1.**). To su:

- «I. pješćana serija» – cilj istraživanja diplomskog rada
- «II. pješćana serija» – cilj istraživanja diplomskog rada
- «prevalencijenezijske naslage», «miocen» i «temeljno gorje»

Ležište «temeljno gorje» nalazi se u raspucanim, izdignutim dijelovima granita i gnajseva te predstavlja «*burried hill*» tip ležišta. Gnajsevi na području ležišta su trošnji od granita kod kojih su pukotine djelomično ili potpuno zapunjene kalcitom. Ležište je prostorno ograničeno glavnim rasjedom koji se nalazi na sjeveroistocnom dijelu ležišta. Prema klasifikaciji BROD (1945) ovo ležište svrstava se u masivna.

Ležišta «miocen» izgrađuju konglomeratni, pjeskoviti i pješćani prosljoci u izmjeni s pjeskovitim laporima. Ležišta se nalaze južno od glavnog rasjeda. Debljina ležišta «miocen» kreće se između 150 i 400 metara. Površina je približno definirana linijom koja razdvaja pozitivne od negativnih bušotina. Najvjerojatnije se radi o bocnoj promjeni facijesa. Prema klasifikaciji BROD (1945) ležišta «miocen» pripadaju litološki ekraniziranom tipu slojnih ležišta.

Ležišta «prevalencijenezijske naslage» smještena su u stijenama donjeg panona, južno od glavnog rasjeda te sjeverno na području Sobocana. Kolektorske stijene predstavljaju pješćenjaci koji se nalaze unutar debelog kompleksa lapora. Pješćenjaci se pojavljuju u obliku leca, a na području Prkosa imaju najveću debljinu i rasprostranjenost. Prema gore navedenoj klasifikaciji ležišta pripadaju litološki ekraniziranom tipu slojnih ležišta.

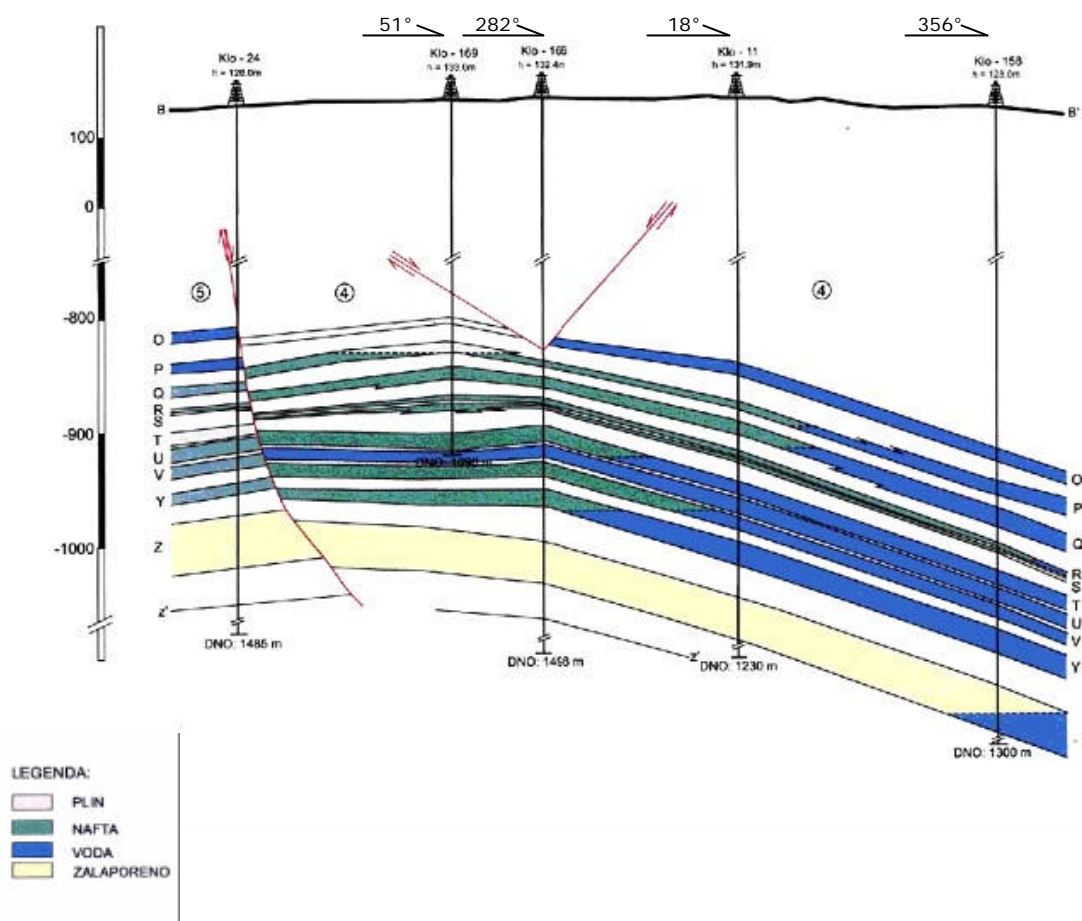
Ležišta «II. pješćane serije» leže unutar naslaga gornjeg panona u zapadnom dijelu polja, na području bušotina Klo-159, Klo-141 i Klo 152. Kolektorske stijene su pijesci i slabo

vezani pješčenjaci. Debljina pješćanih slojeva kreće se u rasponu od 1 do 10 metara, a debljine lapora ne prelaze 5 metara. Ležišta pripadaju skupini slojevitih ležišta, tektonski i litološki ekraniziranih.



Ležišta «I. pješćane serije» leže unutar naslaga donjeg ponta. Utvrđena su dva sustava rasjeda kojima je struktura podijeljena na 17 blokova. Područje zasićeno ugljikovodicima nalazi se na sjeveroistocnom dijelu polja Kloštar. Struktura pokazuje blago tonjenje prema sjeverozapadu, a kolektorske stijene na istocnom dijelu polja prelaze u lapore tj. vidljiva je bocna promjena facijesa. Prema BROD (1945) ležišta pripadaju skupini slojevitih ležišta, tektonski i litološki ekraniziranih.

**Tablica 5-1.** Prikaz pripadnosti eksploatacijskih objekata i ležišta stratigrafskim jedinicama

stratigrafska jedinica	eksploatacijski objekt	ležište
donji pont ( $M_7^1$ )	«I. pješćana serija»	IK
		O
		P
		Q
		R
		S
		T
		U
		V
		Y
		Z
gornji panon ( $M_6^2$ )	«II. pješćana serija»	alfa ( $\alpha$ )
		beta ( $\beta$ )
		gama ( $\gamma$ )
donji panon ( $M_6^1$ )	«prevalencijenezijske naslage» «miocen» «temeljno gorje»	
srednji miocen ( $M_{4,5}$ )		
temeljno gorje ( $Tg$ )		



Slika 5-1. Shematski geološki profil "I pješčane serije" (\*\*\*)



0 500 m

Slika 5-2. Strukturna karta po krovini ležišta T (\*\*\*)

#### 5.4. Pregled kolektorskih parametara po eksploatacijskim objektima

Na polju Kloštar izradeno je 197 bušotina koje nose oznake Klo (Kloštar) i Pk (Prkos). Procjena petrofizikalnih svojstava načinjena je iz relativno malog broja uzoraka iz mehanickih jezgara, kao posljedica malog broja jezgrovanih intervala. Svojstva kolektorskih stijena temeljena su na podacima dobivenim iz karotažnih dijagrama, tj. njihovom interpretacijom.

Podatci o šupljikavosti dobiveni su analizom EK dijagrama 53 bušotine. Laboratorijski podatci o šupljikavosti dobiveni su analizom uzoraka iz 9 bušotina. Ukupan broj uzoraka bio je 51 što je vrlo malo. Važeće vrijednosti za ležište određene su aritmetickom sredinom. Za izracun rezervi ugljikovodika koristio se podatak o šupljikavosti dobiven iz EK dijagrama. Na taj način smanjio se utjecaj pojedinih nerealnih podataka dobivenih laboratorijskom analizom šupljikavosti.

**Tablica 5-2.** Pregled raspona kolektorskih parametara u polju Kloštar (\*\*\*)

Ležište	? (%)	S <sub>o</sub> (%)	k 10 <sup>-3</sup> μ m <sup>3</sup>
Temeljno gorje	0,200-0,225	0,650-0,701	6,7
Miocen	0,220-0,240	0,562-0,659	2,62-9,4
Prevalencijenezijske n.	0,229-0,265	0,665-0,707	-
II. pješcana serija	0,233-0,261	0,600-0,810	26-50
I. pješcana serija	0,192-0,266	0,511-0,740	3-179

Eksploatacijski objekt «prevalencijenezijske naslage», «miocen» i «temeljno gorje» tvore hidrodinamicke jedinice XXII, XXIII, XXIV, XXV, XXVI koje se međusobno razlikuju u kolektorskim svojstvima, ležišnim režimima i postignutim iscrpkom. Iscrpak nafte ovog objekta iznosi 23,8 %, zavodnjenje 54 %, a ležišni tlakovi krecu se od 45 do 150 bara. Danas je u proizvodnji još 12 bušotina, a proizvodnja u hidrodinamickej jedinici XXV potpuno je obustavljena zbog zavodnjenosti.

Eksploatacijski objekt «II. pješcana serija» podijeljen je u dvije hidrodinamicke jedinice: XX i XXI. Rezerve ugljikovodika nalaze se u ležištima alfa, beta i gama od kojih je ležište beta najznacajnije s obzirom na proizvodnju ugljikovodika. Postignuti iscrpak ovog

eksploatacijskog objekta iznosi 27.2 %, zavodnjenje 64,7 %. Ležišni tlakovi krecu se od 111 do 128 bara na dubini od oko -1303 metara. Danas su u proizvodnji cetiri bušotine u XXI. hidrodinamickoj jedinici. Ta jedinica sadrži 89 % rezervi ugljikovodika u «II. pješcanoj seriji». Proizvodnja u XX. hidrodinamickoj sredini zaustavljena je zbog zavodnjenja.

Eksploatacijski objekt «I. pješcana serija» obuhvaca 11 ležišta podjeljenih u 20 hidrodinamickih jedinica.

**Tablica 5-3.** Pregled hidrodinamickih jedinica «I. pješcane serije» (\*\*\*)

Ležište	Hidrodinamicka jedinica
IK	XIX
O	XII, XVIII
P	II, XII
Q	I, II, IV, V, X, XII, XIV, XV
R	I, II, IV, V, IX, X, XII, X, XV
S	I, II, V, IX, X
T	III, VI, X, XVI, XVII, XVIII
U	X, XIII, XVI, XVII
V	IIA, IX, X, XIII, XVI, XVII
Y	I, IIA, VII, IX, X, XI, XII
Z	I, II, VIII, IX, X, XI, XII

Zbog izražene tektonike, heterogenosti kolektorskih parametara i mnoštva blokova vodonaporni režim varira od vrlo jakog do sasvim neznatnog u pojedinim hidrodinamickim sredinama. Postignuti iscrpak ovog eksploatacijskog objekta iznosi 40,8 %, zavodnjenje 72 %. Ležišni tlakovi krecu se od 50 do 75 bara na dubini od oko -850 metara što je posljedica dugotrajnog crpljenja. Proizvodno su aktivne 22 bušotine.

## 6. NEURONSKE MREŽE

U posljednjih nekoliko godina neuronske mreže postale su predmet zanimanja mnogih znanstvenika. Našle su svoju primjenu u širokom rasponu temeljno različitih područja istraživanja poput ekonomije, medicine, fizike, inženjerstva i geologije. Neuronske mreže koriste se svugdje gdje se pojavljuju problemi klasifikacije i predviđanja. Velika popularnost i uspješnost neuronskih mreža rezultat su njihove značajke da pomažu u rješavanju kompleksnih zadataka visokom točnošću i da se lako upotrebljavaju.

Primjena neuronskih mreža vrlo je jednostavna. Neuronska mreža uvježbava se na temelju poznatog skupa podataka algoritmima preko kojih se analizira struktura podataka. Uspješno se primjenjuju u slučajevima koji se ne mogu riješiti linearnim aproksimacijama, a od korisnika se ne traži visoka razina teoretskog znanja, za razliku od slučaja kada bi se problem rješavao klasičnim nelinearnim statističkim metodama.

### 6.1. Modeli neuronskih mreža

Nadahnuce za arhitekturu umjetnih neuronskih mreža bila je struktura biološke neuronske mreže. Svojim razvojem od 40-tih godina prošloga stoljeca sve do danas postaju jednostavnije za korištenje i efikasnije u rješavanju problema, tj. predviđanja nepoznatih vrijednosti.

#### *6.1.1. Povijest razvoja neuronskih mreža*

Prvi model umjetnog neurona bio je predstavljen 1943. godine (McCULLOH i PITTS, 1943). Frank Rosenblatt kasnije razvija arhitekturu neuronske mreže nazvanu «perceptron» (ROSENEBLATT, 1958). Funkcija perceptrona temeljila se na postavkama memoriranja kakve koristi ljudski um. Nakon Rosenblatta, Bernard Widrow je sa svojim suradnicima razvio novi tip «neurona» - ADALINE (engl. «ADAPtive LINear Element») s prijenosnom funkcijom  $f(x)=x$  i odgovarajućim zakonom učenja.

U razdoblju 1967. - 1982. godine pojavljuju se istraživači koji daju znatan doprinos razvoju neuronskih mreža kao Teuvo Kohonen, Kunihiko Fukushima i Stephen Grossberg. Najistaknutiji od te trojice je Teuvo Kohonen. Razvio je nekoliko tipova neuronskih mreža od kojih su neke dobile naziv po njemu. U ovom razdoblju pojavila se i mreža s postupkom povratne informacije (engl. «*back propagation*»). Sredinom 80-tih godina neuronske mreže su se počele brže razvijati, najviše zbog financiranja DARPA-e (Agencija za obrambene istraživačke projekte). John Hopfield dao je veliki doprinos popularizaciji neuronskih mreža objavivši rad koji je postavio paralelu između neuronskih mreža i određenih sustava u fizici.

RUMELHART, D.E. et al.(1986) dokazali su veliku primjenjivost i potencijal algoritma za uvježbavanje mreže postupkom povratne informacije. Krajem 80-ih i početkom 90-ih godina neuronske mreže uvode se kao predmet na nekoliko elitnih sveučilišta u SAD. Danas se neuronske mreže podučavaju na većini sveučilišta.


### **6.1.2. Biološka neuronska mreža**

Biološki neuron je temeljna jedinica središnjeg živčanog sustava. Ukupni broj neurona u živčanom sustavu čovjeka iznosi oko  $10^{11}$ . Neuroni su svrstani tako da je svaka pojedina skupina zadužena za određene funkcije. Unutar same skupine neuroni su čvrsto povezani tako da na ulaze jednih neurona dolaze izlazi drugih neurona. Veze mogu biti i povratne.

Sam neuron sastoji se od tijela neurona, dendrita i aksona (**slika 6-1.**). Funkcija dendrita je prihvaćanje signala iz drugih neurona. Tijelo neurona također može prihvatiti signale, no više od 90 % signala prenosi se preko dendrita. Signali iz neurona se dalje prenose na druge neurone preko aksona gdje su aksoni jednog neurona direktno povezani s dendritima drugog neurona. Spojevi između dendrita jednog neurona i aksona drugog nazivaju se sinapse. Bitnu ulogu u prijenosu signala imaju neurotransmiteri koji u tisućinki sekunde reguliraju vezu između dendrita i aksona. Proces učenja i pamćenja sastoji se u upravljanju tokova neurotransmitera kojima se pojedine veze pojačavaju, smanjuju ili potpuno prekidaju. Svaka neuronska mreža posjeduje unutrašnji, membranski, potencijal koji iznosi oko -70 mV. Potencijal se konstantno mijenja i kada dođe do postizanja granicne vrijednosti dolazi do



pobudivanja drugih neurona preko aksona. Aktiviranje jedne sinapse obično nije dovoljno da dođe do aktiviranja susjednog neurona. Uzastopnim aktiviranjem jedne sinapse u kratkom vremenskom intervalu ili istovremeno aktiviranje više sinapsi može dovesti do izlazne aktivnosti neurona.




**Slika 6-1.** *Biološki model neurona*

Obrada informacija u središnjem živčanom sustavu izvodi se jednostavnim jedinicama, neuronima, koji imaju mogućnost obradivanja više informacija istovremeno za razliku od konvencionalnih računala koji obrađuju jednu po jednu informaciju.

### **6.1.3. Umjetna neuronska mreža**

Umjetna neuronska mreža predstavlja sustav od velikog broja jedinica (neurona) koji imaju svojstvo pamćenja podataka koje obrađuju preko vlastite lokalne memorije. Sustavi umjetnih neuronskih mreža sposobni su za prikupljanje, pamćenje i korištenje eksperimentalnog znanja. Ne postoji jedinstvena definicija umjetne neuronske mreže, no može se prihvatiti ona koju je dao KOHONEN, T. (1988): «Umjetna neuronska mreža je skup

medusobno povezanih, jednostavnih elemenata (najčešće elemenata koji se mogu prilagodavati), koji rade paralelno i koji su organizirani na način da je odnos te neuronske mreže, prema objektima u stvarnom svijetu, isti kao odnos biološkog neuronskog sustava.»



**Slika 6-2.** Prikaz modela umjetnog neurona

Oznake uz sliku 6-2.

- $ulaz_j$  –  $j$ -ti ulazni podatak
- $w_{1ji}$  – težinski koeficijent  $j$ -tog ulaza za  $i$ -ti neuron
- $izlaz_i$  – izlazni podatak iz  $i$ -tog neurona

Matematički model neurona prikazan je kao točka u prostoru do koje se prenose signali iz okolnih neurona. Velicina utjecaja pojedinog signala na aktivnost neurona određena je težinskim koeficijentom  $w$  (engl. «weight factor»). Ukupni ulazni signal matematičkog neurona određen je sumom svih umnožaka težinskih koeficijenata s pripadajućim ulaznim signalom. Ako je ukupni ulazni signal veći od praga osjetljivosti neurona, on je aktivan i izlazni signal ima maksimalnu vrijednost. U suprotnom slučaju, kada je ukupni signal znatno manji od praga osjetljivosti, neuron je u neaktivnom stanju i izlazni signal ima minimalnu vrijednost. Prijelaz između aktivnog i neaktivnog stanja naziva se aktivacijskom funkcijom.

Model umjetne neuronske mreže (matematičke) sastoji se od velikog broja neurona koji su organizirani u slojeve. Osnovna organizacije sastoji se od tri sloja: ulazni, izlazni i skriveni sloj. Ulazni sloj prima signale iz okoline. U našem slučaju signali su parametri koje

želimo obraditi neuronskom mrežom. Signali se prenose iz ulaznog u skriveni sloj gdje se obrađuju.

Informacije koje se smatraju važnima prenose se izlaznom sloju. Na izlaznom sloju, koji je ujedno i zadnji sloj neuronske mreže, dobivaju se konacni rezultati obradbe ulaznih parametara.

## 6.2. Osnovna nacela ucenja u neuronskim mrežama

Učenje (uvježbavanje) neuronskih mreža zapravo je proces kojim sustav dolazi do vrijednosti težinskih koeficijenata među neuronima. Težinski koeficijent je snaga veze između dva neurona. Ako je neuron  $j$  povezan s neuronom  $i$ ,  $w_{ji}$  označava težinski koeficijent od neurona  $j$  prema neuronu  $i$ . Neuron ima određeni broj ulaznih veza, te proizvodi jedan izlaz.

Proces dizajniranja neuronske mreže sastoji se od četiri faze (ZAHEDI, 1993):

1. Raspoređivanje neurona u različite slojeve,
2. Određivanje tipa veze između neurona (inter-slojne i intra-slojne veze),
3. Određivanje načina na koji neuroni primaju ulazne i proizvode izlaze vrijednosti,
4. Određivanje pravila ucenja za prilagodavanje težinskih koeficijenata.

Krajnji rezultat dizajniranja neuronske mreže je njezina arhitektura. Prema gore navedenom procesu dizajniranja, kriteriji za razlikovanje arhitektura neuronskih mreža su:

- broj slojeva,
- tip veze između neurona,
- veza između ulaznih i izlaznih vrijednosti,
- ulazne i prijenosne funkcije,
- tip ucenja,
- sigurnost ispaljivanja,
- vremenske karakteristike,
- vrijeme ucenja.

### 6.2.1. Tipovi veza među neuronima

Veze u mreži mogu se ostvariti između dva sloja (inter-slojna veza) i između neurona u jednom sloju (intra-slojna veza). Postoje različiti tipovi inter-slojnih veza (ZAHEDI, 1993):

- potpuno povezane - svaki neuron u prvom sloju povezan je sa svakim neuronom u drugom sloju,
- djelomično povezane - svaki neuron u prvom sloju nužno ne mora biti povezan sa svakim neuronom u drugom sloju,
- jednosmjerne (engl. «*feed forward*») - veze između neurona su jednosmjerne i to na način da neuroni prvog sloja šalju svoje izlaze neuronima u drugom sloju,
- dvosmjerne - postoji povratna veza kada neuroni drugog sloja šalju svoj izlaz nazad neuronima u prvom sloju,
- hijerarhijske - neuroni prvog sloja povezani su samo s neuronima drugog sloja,
- rezonantna - dvosmjerna veza gdje neuroni nastavljaju slati informacije između slojeva sve dok određeni uvjet nije zadovoljen.

Veze neurona u jednom sloju (inter-slojne) mogu biti:

- ponavljajuće - neuroni u jednom sloju potpuno su ili djelomično povezani. Veza je uspostavljena na način da neuroni svoje izlazne vrijednosti šalju drugim neuronima u sloju nakon što prime ulaze iz prethodnog sloja. Komunikacija među neuronima unutar sloja održava se sve dok ne postignu stabilni uvjeti. Kad je stabilan uvjet postignut, neuronima je dopušteno poslati izlaze u idući sloj.
- usmjerene na blisko okruženje (engl. «*on-center/off-surround*») - u ovoj vezi jedan neuron u sloju ima pobudujuću vezu prema susjednim neuronima, ali smirujuću vezu prema ostalim neuronima u sloju.

Neuronske mreže se mogu razlikovati s obzirom na veze između ulaznih i izlaznih vrijednosti. One mogu biti:

- autoasocijativne - ulazni vektor je istog sastava kao i izlazni. Ovaj tip veza čest je u problemima prepoznavanja uzoraka,
- heteroasocijativne - izlazni vektor razlikuje se od ulaznog vektora.

## 6.2.2. Ulazne i aktivacijske funkcije

Da bi se mogli razumjeti glavni tipovi arhitektura neuronskih mreža koji će se koristiti u ovom diplomskom radu, osnovno načelo funkcioniranja neuronskih mreža bit će opisano kroz ulazne i izlazne jednadžbe, prijenosne funkcije i pravila učenja.

### Ulazne funkcije

Kada neki neuron prima ulaz iz prethodnog sloja, vrijednost njegova ulaza računa se prema ulaznoj funkciji koja se obično naziva «sumacijska funkcija». Najjednostavnija takva funkcija za neuron  $i$  određena je množenjem izlaza poslanog od strane neurona  $j$  prema neuronu  $i$  s težinom veze između ta dva neurona, zatim sumiranjem tog umnoška za sve neurone  $j$  povezane s neuronom  $i$ .

$$ulaz_i = \sum_{j=1}^n (w_{ji} \cdot izlaz_j) \quad (6-1)$$

U izrazu  $n$  predstavlja broj neurona u sloju koji šalje svoj izlaz primljen od strane neurona  $i$ .

### Izlazne funkcije

Nakon primanja ulaza prema gore navedenoj sumacijskoj funkciji, neuron šalje izlaz drugim neuronima s kojima je povezan-obično se radi o neuronima u slijedećem sloju. Izlaz neurona računa se prema aktivacijskoj funkciji (engl. «*activation function*»). Najčešće korištene aktivacijske funkcije su:

- **Funkcija koraka** - izlaz u funkciji s korakom računa se prema formuli:

$$izlaz_i = \begin{cases} 0, ulaz_i \leq T \\ 1, ulaz_i > T \end{cases} \quad (6-2)$$

gdje se  $T$  naziva prag funkcije,  $T \in R$

- **Signum funkcija** - upotrebljavala se u prvoj neuronskoj mreži tipa «perceptrona». «Perceptron» predstavlja poseban oblik funkcije koraka. Danas se rijetko koristi.

$$izlaz_i = \begin{cases} 1, ulaz_i > 0 \\ 0, ulaz_i = 0 \\ -1, ulaz_i < 0 \end{cases} \quad (6-3)$$


- **Sigmoidna ili logistička funkcija** - jedna od najčešće korištenih prijenosnih funkcija u neuronskim mrežama. Formula po kojoj se računa je:

$$izlaz_i = \frac{1}{1 + e^{-g \cdot ulaz_i}} \quad (6-4)$$

gdje je


$$g = \frac{1}{T} \quad (6-5)$$

$i$  naziva se doprinos funkcije. Doprinos određuje zaobljenost funkcije oko nule. Vrijednosti funkcije su realni brojevi iz intervala  $\langle 0,1 \rangle$ . Upotrebljava se u mreži s postupkom povratne informacije i u Hopfieldovoj mreži. Zajedno s hiperbolicko-tangentnom funkcijom je najčešće korištena prijenosna funkcija u radu s neuronskim mrežama.



**Slika 6-3.** Graf sigmoidne aktivacijske funkcije (za  $g < 0$ )

- **Hiperbolicko-tangentna funkcija** - poseban oblik sigmoidne funkcije. Graf hiperbolicko-tangentne funkcije sličan je grafu sigmoidne funkcije samo što je interval vrijednosti funkcije u ovom slučaju  $\langle -1,1 \rangle$ .



**Slika 6-4.** Graf hiperbolicko tangentne aktivacijske funkcije

- **Linearna funkcija** - formula linearne funkcije:

$$izlaz_i = g \cdot ulaz_i \quad (6-6)$$

- **Linearna funkcija s pragom** - poseban oblik linearne funkcije gdje neuron ima razlicitu vrijednost od nule samo ako njegov ulaz dostigne vrijednost praga  $T$ .

$$izlaz_i = \begin{cases} 0, ulaz_i \leq T \\ ulaz_i - T, ulaz_i > T \end{cases} \quad (6-7)$$

Izbor odgovarajuće aktivacijske funkcije radi se u fazi dizajniranja neuronske mreže s time da je moguće naknadno promijeniti vrijednosti praga  $T$  odnosno doprinosa  $g$ . Najbolja prijenosna funkcija za određeni problem obično se dobiva eksperimentiranjem.

Ulazne i aktivacijske funkcije su prijenosne funkcije.

#### 6.2.4. Tipovi ucenja

«Učenje» je proces racunanja težinskih koeficijenata između neurona u mreži (ZAHEDI, 1993). Težinski koeficijenti su važan parametar koji određuje vrijednost ulaza nekog neurona, a indirektno utječe na njegov izlaz. Postoje dva glavna tipa ucenja:

- nadgledano i
- nenadgledano.

Razlika između navedena dva tipa ucenja je u raspoloživosti poznatih izlaza u uzorku za uvježbavanje. Kod nadgledanog ucenja skup podataka za uvježbavanje sastoji se od prethodnih slučajeva s poznatim ulaznim i izlaznim vrijednostima. Sustav neuronske mreže prima stvarni izlaz, racuna pogrešku i prilagodava težine u donosu na pogrešku. Kod nenadgledanog ucenja stvarni izlazi nisu poznati i težine se ne prilagodavaju na osnovi

stvarnih vrijednosti izlaza. Takav tip ucenja obicno se upotrebljava za prepoznavanje uzoraka i klasteriranje.

Svaka neuronska mreža prolazi kroz tri operativne faze:

- Faza ucenja (uvježbavanja) - mreža uči na uzorku pripremljenom za treniranje. Težinski koeficijenti se kroz iteracije prilagodavaju u cilju minimiziranja ciljne funkcije, npr. korijena srednje pogreške.
- Faza testiranja - mreža se testira na uzorku za testiranja dok su težine fiksirane.
- Operativne faze - faza u kojoj se neuronska mreža upotrebljava na novim podacima za koje nisu poznati rezultati.

### 6.2.5. Pravila ucenja

Pravilo ucenja predstavlja formulu koja se koristi za prilagodavanje težina veza među neuronima. Između različitih, do sada razvijenih pravila ucenja, najčešće se koriste ova:

- **Delta pravilo** - poznato je kao i Widrow/Hoff-ovo pravilo ili pravilo najmanjih srednjih kvadrata. Cilj ovog pravila je minimizirati sumu kvadrata pogrešaka, gdje je pogreška definirana kao razlika između izračunatog i stvarnog (zadanog) izlaza neke neuronske mreže za dane ulazne podatke. Jednadžba delta pravila je:

$$\Delta w_{ji} = \mathbf{h} \cdot izlaz_{cj} \cdot \mathbf{e}_i \quad (6-8)$$

gdje je  $\Delta w_{ji}$  vrijednost prilagodavanja težine veze od neurona  $j$  prema neuronu  $i$  izračunatom prema:

$$\Delta w_{ji} = w_{ji}^{nova} - w_{ji}^{stara} \quad (6-9)$$

$izlaz_{cj}$  je vrijednost izlaza izračunatog u neuronu  $j$ ,  $\mathbf{e}_i$  je tzv. sirova pogreška izračunata prema:

$$\mathbf{e}_i = izlaz_{ci} - izlaz_{di} \quad (6-10)$$

$\eta$  je koeficijent ucenja, a  $izlaz_{di}$  je zadani (stvarni) izlaz. Sirova pogreška u prethodnoj formuli rijetko se širi unatrag kroz mrežu. Češće se koriste neki drugi oblici izračuna pogreške.

- **Poopceno delta pravilo** - pravilo je dobiveno dodavanjem derivacije ulazne funkcije u delta pravilo tako da se prilagodavanje težina računa po formuli:



$$\Delta w_{ji} = \mathbf{h} \cdot y_{cj} \cdot \mathbf{e}_i \cdot f'(I_i) \quad (6-11)$$

gdje je  $I_i$  ulaz u neuron  $i$ . Ovo pravilo može se koristiti kod nelinearnih aktivacijskih funkcija.

- **Delta-bar-delta i prošireno delta-bar-delta pravilo** - pravilo je razvio JACOBS (1988) s ciljem povećanja brzine konvergencije postupka kod klasičnog delta pravila. To je heuristički pristup prostorne raspodjele koeficijenata učenja  $\eta$  na način da svaka veza u mreži ima svoju stopu učenja i mijenja te stope kontinuirano kako učenje napreduje. Ovo pravilo učenja koristi zadani (stvarni) izlaz za računanje pogreške. Samim tim mreže koje primjenjuju ovo pravilo su nadgledane.
- **Kohonen-ovo pravilo** - mreža ne uči na poznatim izlazima, a težine u mreži se prilagode koristeći ulaz u neuron  $i$ .

### 6.3. Neuronske mreže za probleme predviđanja

Postoji više vrsta neuronskih mreža koje se mogu koristiti u rješavanju problema predviđanja. Najčešće su mreža s postupkom povratne informacije i mreža sa radijalnom funkcijom koje se ujedno koriste u ovom diplomskom radu.

#### 6.3.1. Mreža s postupkom povratne informacije

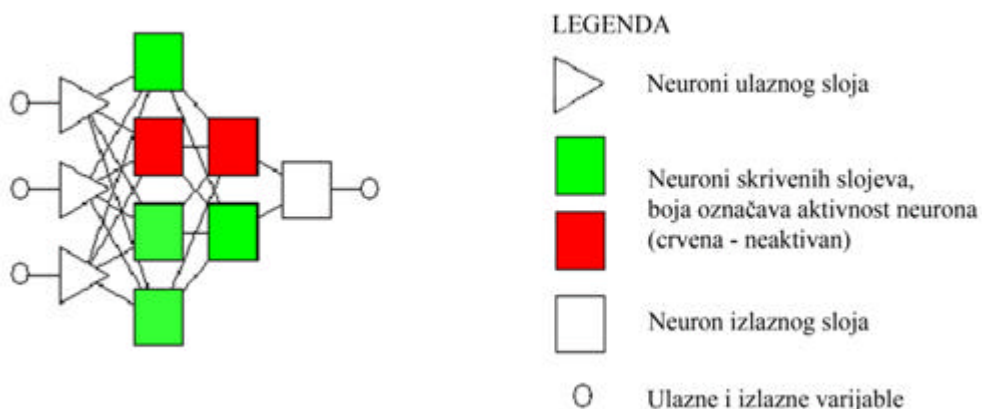
Algoritam mreže s postupkom povratne informacije (engl. «*back propagation algorithm*») bio je prvi algoritam koji je počeo nalaziti široku primjenu. Prvi kreator mreže bio WERBOS P. J. (1974). To je bila prva mreža koja je sadržavala jedan ili više skrivenih slojeva.

Klasičan algoritam mreže s postupkom povratne informacije uključuje optimizaciju pogreške koristeći deterministički algoritam gradijentnog opadanja. U posljednje vrijeme osim algoritma gradijentnog opadanja pojavili su se i novi algoritmi koji poboljšavaju

rezultate. Algoritam koji će se koristiti u ovome radu, osim algoritma gradijentnog opadanja, je algoritam konjugiranog gradijentnog opadanja (engl. «*conjugate gradient descent*»).

### Arhitektura mreže

Mreža se sastoji od ulaznog sloja, izlaznog sloja i najmanje jednog skrivenog sloja. Arhitektura klasične mreže s postupkom povratne informacije prikazana je na slici 6-5.



**Slika 6-5.** Jednostavan prikaz višeslojne mreže s povratnom informacijom s dva skrivena sloja (engl. «*multi layer perceptron, MLP*») (STATISTICA, 2004)

Tok podataka u mreži može se opisati sljedećim koracima:

1. Od ulaznog prema skrivenom sloju - ulazni sloj učitava podatke iz ulaznog skupa podataka i šalje ih u prvi skriveni sloj.
2. U skrivenom sloju - jedinice u sloju primaju ulaz korigiran za težinski koeficijent i prenose ga u naredni skriveni sloj, ukoliko ga ima, ili u izlazni sloj koristeći aktivacijsku funkciju.
3. Kako informacije putuju kroz mrežu, zbrajaju se ulazi i izlazi za svaku jedinicu obradbe.
4. U izlaznom sloju - za svaku jedinicu obradbe racuna se sirova lokalna pogreška koja se dalje koristi u određivanju težina.
5. Širenje unazad od izlaznog sloja do skrivenih slojeva - daljnja obradba sirove pogreške i prilagodavanje težina.

### *Nedostatci i primjena mreže*

Dva najveća problema u mreži s postupkom povratne informacije su lokalni minimum i preuvježbavanje (engl. «*overtrainig*»). Prvi problem nastaje zbog nacina na koji se pogreška širi kroz mrežu. Može se dogoditi da uvježbavanje minimalizira pogrešku samo lokalno. Problem preuvježbavanja je univerzalni problem svih algoritama neuronskih mreža. Pojavljuje se kada mreža savršeno nauči uzorak za uvježbavanje te više nije u mogućnosti generalizirati na nepoznatom (testnom) uzorku.

Mreža s postupkom povratne informacije namijenjena je problemima s kontinuiranim vrijednostima ulaza i izlaza, tj. više se koristi za predviđanje nego za klasifikacijske probleme.

### **6.3.2. Mreža s radijalnom funkcijom**


Mrežu s radijalnom funkcijom (engl. «*radial basis function*», RBF), predložio je M.J.D. Powel (KARATALOPOULOS, 1996). Može se upotrebljavati u istim situacijama kao i mreža s postupkom povratne informacije. Ova mreža upotrebljava radijalno simetričnu i radijalno ograničenu aktivacijsku funkciju u svom skrivenom sloju. Mreža s radijalnom funkcijom nema neke nedostatke mreže s postupkom povratne informacije kao što su problem lokalnog minimuma i dugotrajan proces učenja, no zahtijeva više računanja u fazi prekida rada mreže prije nego li sama kroz zadani broj iteracija dosegne zadani minimum.

### *Arhitektura mreže*

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

1. Učenje počinje u skrivenom sloju s nenadgledanim algoritmom kako bi se odredilo središte.
2. Učenje se nastavlja u izlaznom sloju s nadgledanim algoritmom kako bi se izračunala pogreška.

3. Istovremeno se primjenjuje nadgledani algoritam u skrivenom i izlaznom sloju kako bi se podesile težine u mreži.



**Slika 6-6.** Jednostavan prikaz mreže s radijalnom funkcijom s velikim brojem neurona u skrivenom sloju (STATISTICA, 2004)

## Nedostatci i primjena mreže

Iako mreža s radijalnom funkcijom ima brzi algoritam za učenje, ponekada 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 bi se stoga moglo dogoditi da se u toj fazi izgube neke važne informacije.

Mreža s radijalnom funkcijom može se uspješno koristiti za probleme predviđanja i probleme klasifikacije. U ovom diplomskom radu mreža je uspješno korištena za predviđanje klasičnih facijesa.


## **7. ELEKTROKAROTAŽNE METODE**

U ovom poglavlju prikazat će se elektrokarotažne metode i krivulje nastale snimanjem kao ulazni podatci za uvježbavanje i predviđanje neuronskim mrežama. Kako su karotažna mjerenja u promatranim bušotinama izvođena 1956. godine (bušotina Klo-41) i 1957. godine (bušotina Klo-71), radi se o najosnovnijim metodama geofizickih mjerenja u bušotinama. Tu su uključena snimanja vrijednosti spontanog potencijala (SP) i električne otpornosti sondama manjeg i većeg dubinskog zahvata. Sonda manjeg dubinskog zahvata ima razmak između strujnih i potencijalnih elektroda 16" i naziva se kratka normala ( $R_{16}$ ), a kod sonde većeg dubinskog zahvata razmak elektroda iznosi 64" i naziva se duga normala ( $R_{64}$ ).

### **7.1. Karotaža spontanog potencijala (SP)**

Mjerenjem spontanog potencijala utvrđuju se propusne i nepropusne stijene, te što se u njima nalazi. Određuju se svojstva fluida, a ne količina.

Prema dogovoru otkloni ulijevo nazivaju se negativnima, a udesno pozitivnima. Na krivulji SP-a može se povući pravac koji tangira otklone udesno, a ne mora biti paralelan s mrežom. Taj pravac naziva se osnovna linija nepropusnih stijena (naslaga), osnovna linija lapora (ili šejla) ili osnovna linija SP-a.



**Slika 7-1.** Izgled krivulje SP-a s pripadajucim osnovnim linijama te probušena litologija (BALIC, 1993)

Pojam statickog SP-a (SSP) povezan je s pojmom ciste formacije (stijene). Predstavlja teoretski slucaj najveceg otklona ulijevo na krivulji SP-a u potpuno cistim pijescima/pješčenjacima bez primjesa lapora. Za njih možemo pretpostaviti ista elektrofizikalna svojstva, isti mineralni i granulometrijski sastav, isto zasícenje fluidima, te istu temperaturu duž cijelog obuhvacenog intervala. No, cesto dolazi do prigušenja te linije zbog premale debljine sloja ili glinovitih i laporovitih primjesa. Tada se najveći otklon krivulje SP ulijevo naziva pseudostaticki SP (PSP). Linija koja tangira takve otklone krivulje SP-a naziva se: osnovna linija propusnih stijena (naslaga), osnovna linija pijesaka/pješčenjaka ili osnovna linija SSP-a (ili PSP-a).

Sve vrijednosti na krivulji SP-a očitavaju se od osnovne linije, a ne od pocetka dijagrama. Ranije je spomenuto kako je u propusnim stijenama otklon ulijevo dogovorno negativan, a u nepropusnim udesno dogovorno pozitivan. Ovo pravilo vrijedi kad su slojne vode slane (visokomineralizirane), a isplaka slatka, tj. kad je salinitet slojne vode veci od saliniteta isplake. Takav slucaj je u naftnogeološkoj praksi najčešći. Ako je salinitet isplake veci od saliniteta slojne vode otkloni u propusnim slojevima bit ce udesno, a u nepropusnim ulijevo te dolazi do inverzije pri interpretaciji. Kod podjednakih saliniteta otkloni krivulje SP-a bit ce slabo izraženi, tj. krivulja može biti neupotrebljiva.

Prema krivulji SP-a moguće je:

- otkriti propusne slojeve,
- odrediti granice propusnih i nepropusnih slojeva,
- korelirati izdvojeće propusne i nepropusne slojeve,
- odrediti specifične otpornosti slojne vode  $R_w$ ,
- kvalitativno i kvantitativno odrediti zaglinjenja pješćanih slojeva.


Granica odvajanja propusnih od nepropusnih slojeva povlači se na mjestima tocaka infleksije, tj. tamo gdje krivulja mijenja oblik iz konveksnog u konkavni (**slika 7-1.**).

## **7.2. Karotaža prividne električne otpornosti ( $R_{16}$ , $R_{64}$ )**

Gline i lapori su nepropusne stijene, zasićene konatnom ili singenetskom slojnom vodom koja je visokomineralizirana. Zato su otpori u takvim sedimentima mali, tj. često najmanji duž krivulje otpora. Suhe i kompaktne stijene poput karbonata odlikuju se visokim vrijednostima otpora. Kod klastičnih sedimenata, npr. pješćenjaka, breca ili konglomerata, povišeni otpori posljedica su njihova zasićenja ugljikovodicima ili slatkim slojnom vodom. Zbog nedostatka slobodnih iona ti fluidi imaju izolatorska svojstva. Dakle, ukoliko su takve naslage zasićene slatkim slojnom vodom, na krivulji otpora snimljenoj kroz njih očitavat će se visoki otpor kao i u karbonatima.

Prema krivulji prividne električne otpornosti mogu se izračunati približne vrijednosti otpornosti slojne vode ( $R_w$ ), a zatim i vrijednosti zasićenja naftom i vodom u sloju ( $S_o$  i  $S_w$ ).





**Slika 7-2.** Prikaz krivulje otpornosti za  $R_{16}$  i  $R_{64}$  te krivulje SP-a u slučaju zasicenja pješčenjaka ugljikovodicima (BALIC, 1993)

U intervalu kolektorskog sloja zasicenog ugljikovodicima i slanom slojnom vodom razlikuju se dva dijela krivulje SP-a:

- malo niži otkloni krivulje SP-a, nego u dijelu zasicenom slanom slojnom vodom,
- cesto se uz sam kontakt nafte i vode nalazi pik maksimalnog otklona SP-a i
- nešto više vrijednosti na krivulji SP-a u dijelu sa slanom slojnom vodom.

U sloju zasicenom CH i slanom slojnom vodom cesto se razlikuju dvije zone otpornosti:

- veca otpornost u dijelu zasicenom CH i
- niža otpornost u dijelu sa slanom slojnom vodom.

Prema obliku kontakta mogu se izdvojiti dva slucaja:

- izravan kontakt koji se iskazuje naglim padom prividne elektricne otpornosti kad se iz zone s naftom prijede u zonu sa slojnom vodom i
- slucaj kada postoji kontaktna (dodirna, prijelazna) zona, što je u prirodi češći slucaj. Ona se na krivulji prividne elektricne otpornosti ocrta postupnim opadanjem vrijednosti otpora iduci iz zone 100 % zasícene naftom u zonu 100 % zasícenom slojnom vodom. Širina kontaktne zone je u funkciji propusnosti, tj. razvucenija zona ukazuje na manju propusnost.

U prstenastom prostoru bušotine može se razlikovati:

- isprana zona u kojoj je filtrat isplake potisnuo slojne fluide,
- prijelazna zona gdje filtrat isplake potiskuje dio slojnog fluida sve do netaknute stijene. Ovaj proces naziva se invazijom, a zamjena slojnog fluida filtratom isplake uključuje i promjenu prividne elektricne otpornosti porne vode iz  $R_w$  u  $R_{mf}$ . Isplaka je obicno na bazi svježe vode, suprotno od slane slojne vode, pa je i veće otpornosti i
- neporemecena zona gdje nema utjecaja filtrata isplake

Sonde pomocu kojih je mjerena prividna elektricna otpornost u bušotinama Klo-41 i Klo-71 pripadaju skupini normalnih sondi, a razlikuju se medusobno po razmaku između elektroda. Zbog razlicite velicine razmaka među elektrodama ove sonde imaju razlicit dubinski zahvat. Nazivaju se:

- kratka normala ( $R_{16}$ ) od 16" koja se koristi za odredivanja granica među slojevima i procjenu tankih slojeva. Doseg mjerenja je mali što znaci da ova sonda mjeri prividnu elektricnu otpornost isprane zone prstenastog prostora bušotine i
- duga normala ( $R_{64}$ ) od 64" koja se koristi za odredivanje prividne elektricne otpornosti u netaknutoj zoni prstenastog prostora bušotine zbog velikog dubinskog dosega sonde (oko 3,5 metra).

## 8. ANALIZE NEURONSKOM MREŽOM

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

Istraživanje će se provoditi na način da će se neuronske mreže uvježbavati na određenom dubinskom intervalu bušotine (nadgledano učenje) te će se tako uvježbana neuronska mreža koristiti u svrhu predviđanja vrijednosti željenih parametara na, njoj dosad, nepoznatim intervalima.

Kao ulazne vrijednosti koristit će se elektrokarotazni podaci bušotina Klo-41 i Klo-71.

Rezultati upotrebe neuronskih mreža biti će prikazani pomoću dijagrama i tablica. Dijagrami se sastoje od linije koja predstavlja stvarne (zadane vrijednosti) i linije predviđenih vrijednosti označenih različitim bojama koje su naznačene u legendi. Predviđene vrijednosti u nazivlju imaju dodatak SNN («*Statistica neural networks*»). Iznos pogreške u tablicnim prikazima može varirati od 0 do 1 s tim da je mreža uspješnija što je pogreška iznosom bliže nuli.

Do sada je na području hrvatskog dijela Panonskog bazena izvedeno samo jedno istraživanje u kojem su se koristile neuronske mreže u svrhu predviđanja litološkog sastava na polju Okoli (MALVIC, 2006).

### 8.1. Predviđanje litološkog sastava

U svrhu predviđanja litološkog sastava prvo su ručno izdvojeni slojevi pješčenjaka i lapora na karotaznim dijagramima bušotina Klo-41 i Klo-71. Analize su napravljene odvojeno za svaku bušotinu što znači da se skup podataka za uvježbavanje i predviđanje nalazi unutar iste bušotine, no na različitom dubinskom intervalu.


#### 8.1.1 Analiza za bušotinu Klo-44

Kao ulazni podatak za uvježbavanje neuronske mreže koristit će se vrijednosti spontanog potencijala (SP) i otpornosti ( $R_{16}$  i  $R_{64}$ ) te litološki sastav. Litološki sastav

definiran je kao atributivna varijabla. Interval koji će se koristiti za uvježbavanje približno će odgovarati intervalu «II. pješčane serije» uključujući nekoliko metara iznad i ispod tog 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 «I. pješčanoj seriji».

Ulazni skup za uvježbavanje u programu STATISTICA 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. Prilikom uvježbavanja neuronske mreže program automatski zaustavlja uvježbavanje ukoliko se dostigne unaprijed zadani iznos pogreške. Ukoliko to nije postignuto program se vraća na iteraciju i kojoj je postignuta najniža pogreška selekcije (**slika 8-1.**).

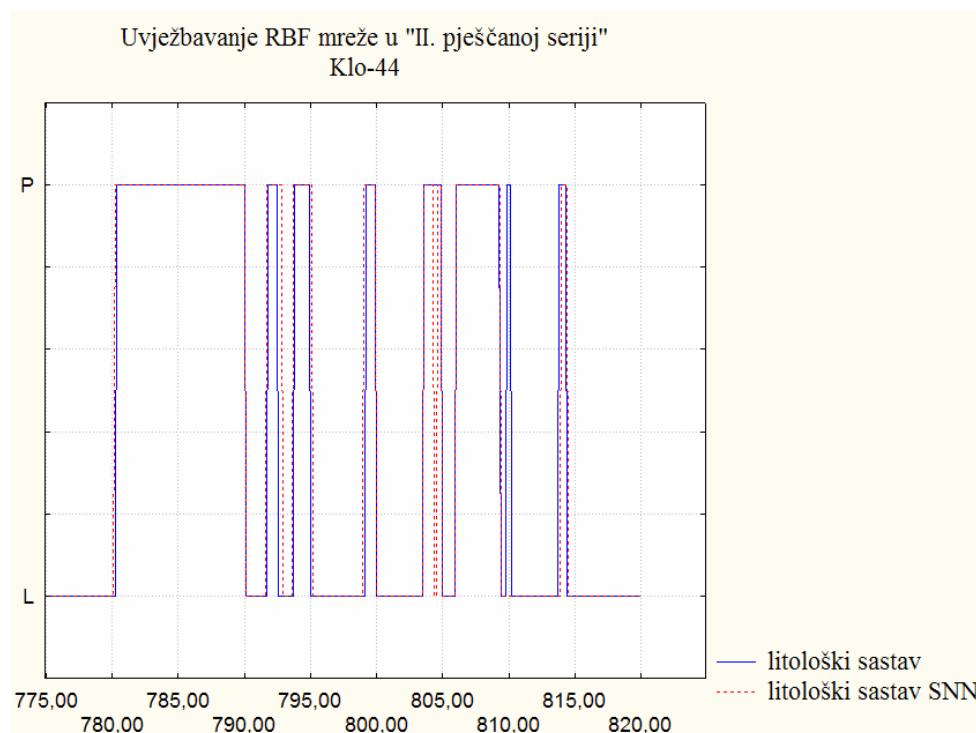
Mreže koje su se pokazale uspješnima kod uvježbavanja i predviđanja litološkog sastava bile su mreža s radijalnom funkcijom (RBF) koja sadrži 31 neuron u skrivenom sloju te mreža s postupkom povratne informacije (MLP) s četiri neurona u prvom skrivenom sloju, šest u drugom i tri u trećem skrivenom sloju. Uspješnost uvježbavanja i predviđanja RBF i MLP neuronske mreže prikazani su u tablici 8-1 i slikama 8-2, 8-3, 8-4, 8-5.



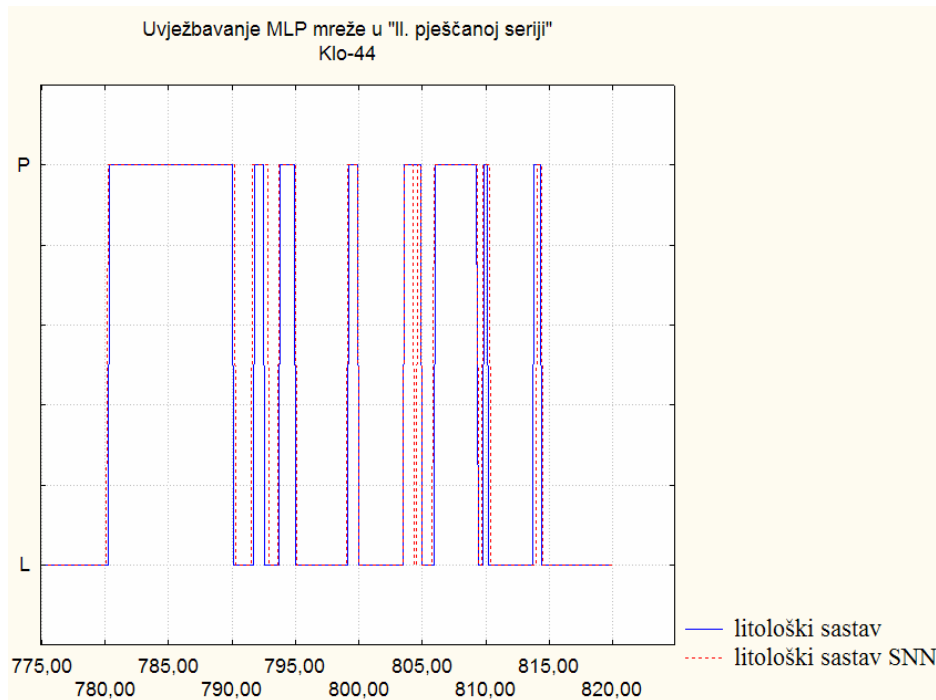
**Slika 8-1.** Na ordinati su dane vrijednosti pogreške. Vrijednosti na apscisi predstavljaju broj iteracija.

**Tablica 81.** Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-44 za predviđanje litološkog sastava

Tip neuronske mreže	pogrješka kod uvježbavanja	pogrješka kod selekcije	pogrješka kod predviđanja
RBF 3:3-31-1:1	0,152942	0,172753	0,174165
MLP 3:3-4-6-3-1:1	0,314380	0,133478	0,436107




**Slika 8-2.** Na ordinati su dane vrijednosti litologije P-pješčenjaka, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.




**Slika 8-3.** Na ordinati su dane vrijednosti litologije P-pješčenjak, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Prema slikama 8-2 i 8-3 može se vidjeti da su obje mreže uspješno uvježbane u intervalu «II. pješčane serije» iako bi se po vrijednostima pogreške kod MLP mreže moglo misliti da će rezultati biti loši što dokazuje da je pogreška selekcije vrlo važan parametar u krajnjoj učinkovitosti neuronske mreže.



**Slika 8-4.** Na ordinati su dane vrijednosti litologije P-pješčenjaka, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.



**Slika 8-5.** Na ordinati su dane vrijednosti litologije P-pješčenjaka, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Na slikama 8-4 i 8-5 dani su rezultati predviđanja litološkog sastava na intervalu «I. pješcane serije». Obadvije mreže su dale vrlo dobre rezultate. Male pogreške prisutne su kod obadvije mreže u predviđanju u intervalu iznad «I. pješcane serije».

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

### **8.1.2. Analiza za bušotinu Klo-71**


Kao ulazni podatci za uvježbavanje neuronske mreže koja će imati mogućnost predviđanja litološkog sastava koristit će se vrijednosti spontanog potencijala (SP), otpornosti ( $R_{16}$ ,  $R_{64}$ ) te litološkog sastava. Za razliku od analize na bušotini Klo-44 ovdje će neuronske mreže biti uvježbavane za dublji intervalu tj. u intervalu «I. pješcane serije», a predviđanje u plićem intervalu koji približno odgovara «II. pješcanej seriji».

Mreže koje su se pokazale uspješnima kod uvježbavanja i predviđanja litološkog sastava bile su mreža s radijalnom funkcijom (RBF) koja sadrži 13 neurona u skrivenom sloju, te mreža s postupkom povratne informacije (MLP) sa šest neurona u prvom skrivenom sloju, četiri u drugom i dva u trećem skrivenom sloju. Uspješnost uvježbavanja i predviđanja neuronskih mreža dani su u tablici 8.2 i slikama 8-6, 8-7, 8-8, 8-9.

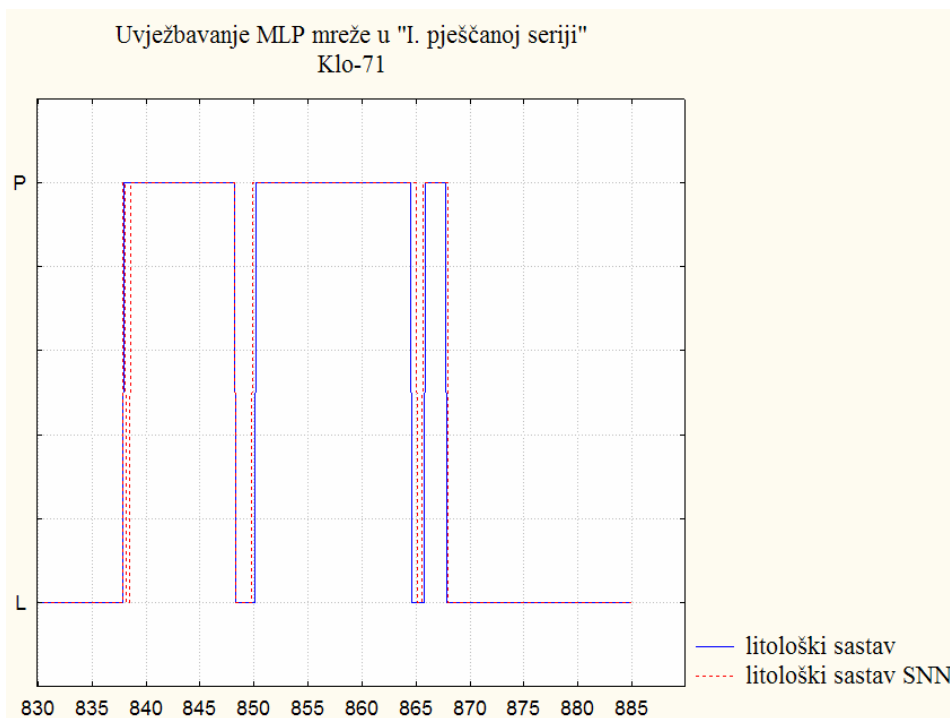
**Tablica 82.** Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-71 za predviđanje litološkog sastava

Tip neuronske mreže	pogreška kod uvježbavanja	pogreška kod selekcije	pogreška kod predviđanja
RBF 3:3-13-1:1	0,156621	0,149185	0,117858
MLP 3:3-6-4-2-1:1	0,255012	0,214935	0,427695



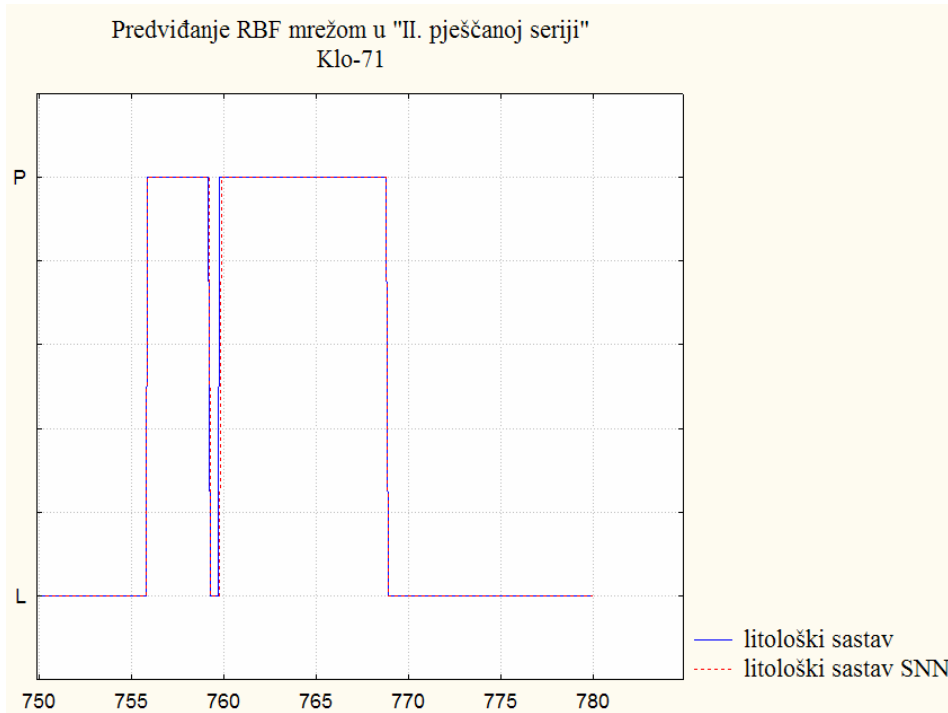


**Slika 8-6.** Na ordinati su dane vrijednosti litologije *P*-pješčenjaka, *L*-lapora. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

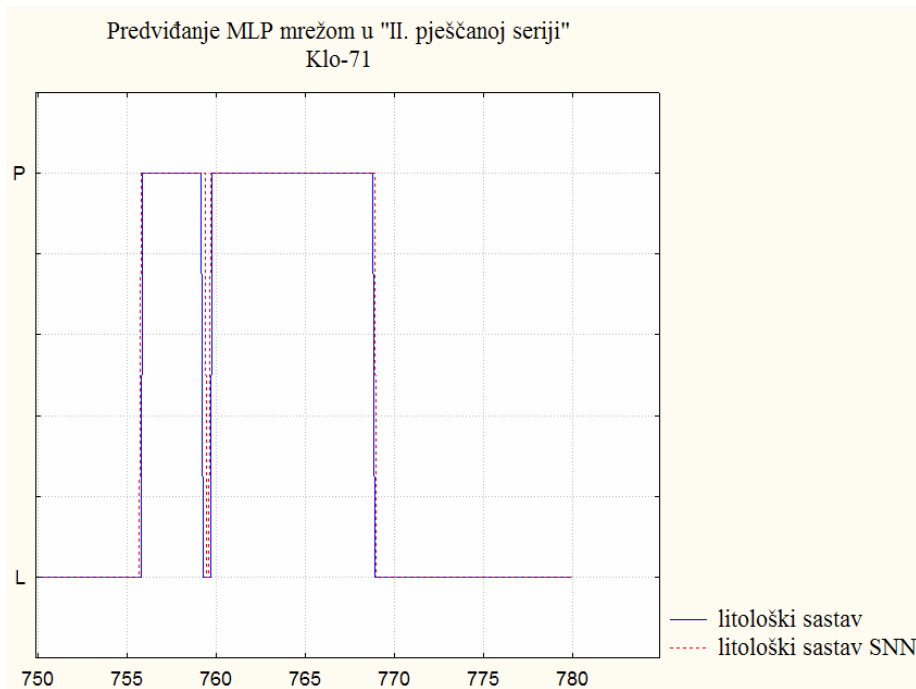


**Slika 8-7.** Na ordinati su dane vrijednosti litologije *P*-pješčenjaka, *L*-lapora. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Prema slikama 86. i 87. može se vidjeti da su fadviije neuronske mreže uspješno uvježbale interval «I. pješcane serije» gdje se mogu vidjeti male pogrješke kod pocetka intervala te na dubini od oko 865 m.



**Slika 8-8.** Na ordinati su dane vrijednosti litologije P-pješčenjak, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.



**Slika 8-9.** Na ordinati su dane vrijednosti litologije P-pješčenjak, L-lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Prema slikama 8-8. i 8-9. neuronske mreže su uspješno predvidjele litološki sastav, pogreške su minimalne.

Za razliku od prethodne bušotine, ovdje analiza RBF mrežom daje nešto bolje rezultate nego MLP mreža.

## 8.2. Predviđanje zona zasćenih ugljikovodicima


Za razliku od predviđanja litološkog sastava, ovdje će neuronska mreža biti uvježbavana u jednoj bušotini, a predviđanje će se obavljati na drugoj bušotini.

Zone zasćene ugljikovodicima određene su prema otklonu na krivulji  $R_{64}$  kao varijabla ležišta s vrijednostima 0 i 1 (0 predstavlja nezasiceni, a 1 zasćeni dio) korištene za uvježbavanje i provjeru uspješnosti neuronske mreže. Osim vrijednosti zasćenja korištene su krivulje SP-a,  $R_{16}$ ,  $R_{64}$ , dubina (m) i atributivna varijabla litološkog sastava.


Za predviđanje varijable ležišta korištena je MLP mreža sa šest neurona u prvom skrivenom sloju te osam neurona u drugom skrivenom sloju. Uspješnost uvježbavanja i predviđanja varijable ležišta dani su u tablici 8-2. te slikama 8-10. i 8-11.

**Tablica 8-3.** Prikaz parametara uvježbane neuronske mreže na bušotini Klo 44 u svrhu predviđanja varijable ležište.

Tip neuronske mreže	pogrješka kod uvježbavanja	pogrješka kod selekcije	pogrješka kod predviđanja
MLP 5:5-6-8-1:1	0,056897	0,091173	0,057473



**Slika 8-10.** Na ordinati su dane vrijednosti varijable ležište: 0-nezasiceni dio, 1-zasćeni dio. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.



**Slika 8-11.** Na ordinati su dane vrijednosti varijable ležište: 0-nezasiceni dio, 1-zasiceni dio. Vrijednosti na apscisi predstavljaju dubinu naslaga u me trima.

Na slici 8-10., gdje je prikazana uspješnost uvježbavanja neuronske mreže, može se vidjeti da je neuronska mreža točno predvidjela varijablu ležišta u intervalu «I. pješčane serije». U području «II. pješčane serije» neuronska mreža također ima točno predviđanje.


Uspješnost predviđanja ugljikovodicima zasicenih zona u bušotini Klo-71 dan je slikom 8-11. Može se vidjeti da je neuronska mreža s velikom točnošću odredila granice «I. pješčane serije» dok su granice «II. pješčane serije» također određene, no uz nešto manju točnost.

### 8.3. Moguci problemi prilikom analiza neuronskim mrežama

Opcenito, za analize pomocu neuronskih mreža vrijedi: što je veci broj ulaznih varijabli i što veci broj slucajeva, rezultati ce biti pouzdaniji i mreža ce uspješnije uciti, uz bolje predvidanje.

Predvidanje litološkog sastava pokazalo se uspješnim, no samo ukoliko je skup podataka za uvježbavanje i predvidanje dolazio iz intervala unutar iste bušotine tj. tu se govori o 1D ekstrapolaciji. Prema mišljenju autora, ukoliko bi se uz krivulje SP-a, koja je najvažniji parametar preko koje se neuronska mreža uvježbavala za predvidanje litologije, koristile krivulje GR-a (prirodne gama radioaktivnosti), promjera bušotine, kompenzirane gustoće neutrona (CN), karotaže gustoće (DEN) i drugih, koje karakteriziraju litološki sastav i zasícenje ugljikovodicima, dobili bi se bolji rezultati u predvidanju istih.

Problem koji se javlja kod uvježbavanja neuronske mreže za predvidanje litološkog sastava je pomak osnovne linije šejla koji je vidljiv kod krivulje SP-a u bušotini Klo-71 dok kod bušotine Klo-44 pomak nije izražen (**slika 8-12.**). Uz uvrštavanje dubine kao varijable, kod uvježbavanja neuronske mreže nisu postignuti zadovoljavajuci rezultati zbog toga što se osnovna linija šejla ne ponaša jednako u obje bušotine.



S

**Ilika 8-12.** Na ordinati su dane vrijednosti spontanog potencijala u mV. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

Kod analize neuronskom mrežom za predviđanje zasićenja ugljikovodicima, kao važan parametar koristila se atributivna varijabla litološkog sastava. Ona je bila definirana na temelju odvajanja intervala pješčenjaka od intervala lapora prema položaju točaka infleksije na krivulji SP-a. Ukoliko se atributivna varijabla ne bi koristila kao ulazna vrijednost u analizi neuronskom mrežom, uz vrijednosti karotažnih krivulja SP-a,  $R_{16}$  i  $R_{64}$ , mreža ne bi pokazala zadovoljavajuću vrijednost predviđanja zbog nemogućnosti preciznog definiranja relacije da varijabla ležišta ima pozitivnu vrijednost samo u pješčenjackim slojevima. Varijabla ležišta vjerojatno se ne bi morala uvoditi kao ulazna vrijednost ako bi se koristile vrijednosti krivulja GR-a, promjera bušotina i druge.

## 9. ZAKLJUCAK

U ovom diplomskom radu nacinjeno je nekoliko neuronskih mreža koje su imale zadatak odrediti litološki sastav sedimenata gornjeg panona («II. pješćana serija») i donjeg pontata («I. pješćana serija») te zasicenost ugljikovodicima u njima. Uspješnost uvježbavanja i predvidanja neuronskim mrežama prikazane su graficki i tablicno. Pješćenjacki facijesi i sedimenti slicnog geološkog razvoja predstavljaju najprikladniji medij za neuronske i statisticke analize te su zbog toga odabrani sedimenti gornjeg panona i donjeg pontata.

Nacinjene analize medu prvima su glede primjene neuronskih mreža u svrhu naftnogeoloških analiza podrucja Hrvatske.

Na osnovi rezultata neuronskih analiza može se zakljuciti:

- prilikom odredivanja litološkog sastava u bušotini Klo-44 pomocu neuronske mreže s radijalnom funkcijom i MLP mrežom dobiveno je izvrsno poklapanje u predvidenom i stvarnom litološkom sastavu,
- prilikom ekstrapolacije litološkog sastava u bušotini Klo-71 pomocu neuronske mreže s radijalnom funkcijom te MLP mrežom dobiveno je izvrsno poklapanje u predvidenom i stvarnom litološkom sastavu,
- odredivanje zasicenosti ugljikovodicima u bušotini Klo-71 pomocu MLP mreže, uvježbane na bušotini Klo-44, daje izvrsno poklapanje izmedu predvidenih i stvarnih vrijednosti,
- povecavanjem broja ulaznih varijabli u obliku korištenja dodatnih vrijednosti karotažnih mjerenja, poput krivulja GR (prirodne gama radioaktivnosti), CN (kompenzirane karotaže neurona), DEN (karotaže gustoce) i drugih, moglo bi u velikoj mjeri povecati tocnost predvidanja neuronskim mrežama.

Dobiveni rezultati ukazuju na veliki potencijal u korištenju neuronskih mreža pri naftnogeološkim istraživanjima gdje bi se neuronske mreže koristile za dobivanje brzih rješenja iz karotažnih dijagrama. Zbog lakoce uporabe i potencijala neuronskih mreža koji je dokazan u drugim znanostima, poput medicine i ekonomije, vrlo je vjerojatno da ce ubrzo postati alat koji ce se standardno upotrebljavati u naftnogeološkim analizama.



## 10. LITERATURA

- BALIC, D. (1993): Odabrana poglavlja iz interpretacije karotažnih dijagrama. INA – Industrija nafte NAFTAPLIN.
- BHATT, A. (2002): Reservoir properties from well logs using neural networks. Dr.Sc. thesis, Dep. Petroleum Technology and Applied Geophysics, NTNU, Trondheim.
- BROD, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, December 1945, v. 29, no. 12, p. 1738-1755.
- JACOBS, R.A. (1988): Increased rates of convergence through learning rate adaptation. Neural Networks, 1, 295-307.
- KARTALOPOULOS, S. V. (1996): Understanding neural networks and fuzzy logic, basic concepts and application. IEEE Press.
- KOHONEN, T. (1988): Self organization and associative memory. Springer, second edition.
- MALVIC, T (2006): Predviđanje klastičnih facijesa neuronskom mrežom (primjer polja Okoli). Nafta, 57, 10, 415-431.
- McCULLOH, W. & PITTS, W. (1943): A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, 5, 115-133.
- ROSENBLATT, F. (1958): The perceptron: A probabilistic model for information storage and organisation in the brain. Psychological review, 65, 386-408.
- RUMELHART, D.E., et al(1986): Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1: Foundations (eds Rumelhart, D. E. & McClelland, J. L.) 318- 362.
- StatSoft, Inc. (2004): STATISTICA (data analysis software system), version 7. [www.statsoft.com](http://www.statsoft.com).
- WERBOS, P.J. (1974): Beyond regression: New tools for prediction and analysis in the behavioural sciences. Ph.D. thesis, Harvard university
- ZAHEDI, F. (1993): Intelligent systems for business, expert systems with neural networks. Wodsworth publishing inc.
- \*\*\* Skupina autora (1987): Elaborat o rezervama polja Kloštar. INA-Industrija nafte d.d., SD Istraživanje i proizvodnja nafte i plina, Zagreb.