

Unaprijeđeni model procjene neuronskim algoritmom miocenskih litofacijesa u polju Ladislavci

Varenina, Andrija

Master's thesis / Diplomski rad

2017

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:169:942478>

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

Download date / Datum preuzimanja: **2024-04-19**



Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU

RUDARSKO – GEOLOŠKO –NAFTNI FAKULTET

Diplomski studij geologije

**UNAPRIJEĐENI MODEL PROCJENE NEURONSKIM ALGORITMOM
MIOCENSKIH LITOFACIJESA U POLJU LADISLAVCI**

Diplomski rad

Andrija Varenina

G 213

Zagreb, 2017.

UNAPRIJEĐENI MODEL PROCJENE NEURONSKIM ALGORITMOM
MIOCENSKIH LITOFACIJESA U POLJU LADISLAVCI

Andrija Varenina

Diplomski rad je izrađen na: Sveučilištu u Zagrebu

Rudarsko–geološko–naftnom fakultetu

Zavodu za geologiju i geološko inženjerstvo

Pierottijeva 6, 10 000 Zagreb

Sažetak:

Naftno-plinsko polje Ladislavci nalazi se u istočnoj Slavoniji na području sela Ladislavci koje je udaljeno desetak kilometara od Donjeg Miholjca. Na polju Ladislavci danas postoji 21 bušotina. Ležište nafte je u miocenskim naslagama vukovarske formacije, a plinsko u osječkim pješčenjacima (serija B). Ležište nafte podijeljeno je u tri ležišna sloja (El, F1a i F1b) i radi se kombiniranoj zamci strukturno-stratigrafskog tipa. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati. Nakon opisa osnovnih svojstava umjetnih neuronskih mreža i povijesti njihovog razvoja, prikazane su još i elektrokarotажne metode čiji su rezultati korišteni za interpretaciju ležišnih stijena te kao ulazni podaci za uvježbavanje neuronskih mreža. Neuronske mreže su uvježbavane na podacima iz bušotina (A i B) i to u intervalu od EK-markera Rs7 do dna bušotine. Na tim mjestima kao ulazni podaci izdvojene su vrijednosti spontanog potencijala (SP) i električne otpornosti (R_{16} i R_{64}). Iz takvih ulaza predviđan je litološki sastav uz pomoć višeslojne perceptronske mreže (skr. VPM).

Ključne riječi: Neuronske mreže, Ladislavci, srednji miocen, litologija, Hrvatska.

Diplomski rad sadrži: 46 stranica, 26 slika, 4 tablice i 22 reference

Jezik izvornika: hrvatski

Voditelj: dr. sc. Tomislav Malvić, izv. prof.

Ocjenjivači: dr. sc. Tomislav Malvić, izv. prof., RGN fakultet

dr. sc. Josipa Velić, prof. emer., RGN fakultet

dr. sc. Rajna Rajić, red. prof., RGN fakultet

Datum obrane: 27. rujan 2017.

IMPROVED NEURAL NETWORK MODEL FOR LITHOFACIES INTERPRETION IN MIOCENE LAYERS OF THE LADISLAVCI FIELD

Andrija Varenina

Thesis completed at: University of Zagreb

Faculty of Mining, Geology and Petroleum Engineering

Department of Geology and Geological Engineering

Pierottijeva 6, 10 000 Zagreb

Abstract:

The Ladislavci Oilfield is located in eastern Slavonia, in the Ladislavci village, about ten kilometers from Donji Miholjac. There are 21 boreholes in the Ladislavci Oilfield today. The oil reservoir is in the Miocene deposits of Vukovar formation and gas reservoir is in Osijek sandstones (series B). The oil reservoir is divided into three sections (E1, F1a and F1b) and it is a combined structural-stratigraphic trap. The reservoir rocks are limestone breccia's, clastic limestone and breccia conglomerates. After the description of basic properties of artificial neural networks, well logs have been presented, whose results are used for the interpretation of the bedrock and as input data for the training of neural networks. Neuronal networks are trained on the data from wells (A and B) from the interval of the EK marker Rs7 to the bottom of the well. The analysis input data where log data (curves SP, R_{16} and R_{64}) and from such data the lithological composition is foreseen with the help of multilayer perceptron network (MLP).

Keywords: Neural networks, Ladislavci, middle miocene, lithological composition, Croatia.

Master's thesis contains: 46 pages, 26 images, 4 tables and 22 references

Original in: Croatian

Supervisor: Associate Professor Tomislav Malvić, PhD

Reviewers: Associate Professor Tomislav Malvić, PhD

Professor Emerita Josipa Velić, PhD

Full Professor Rajna Rajić, PhD

Date of defense: September 27, 2017.

ZAHVALA:

Zahvaljujem mentoru izv. prof. dr. sc Tomislavu Malviću na savjetima, strpljenju i stručnoj pomoći pri izradi ovog rada. Također zahvaljujem prof. dr. sc. Josipi Velić, prof. emerita i izv. prof. dr. sc. Rajni Rajić na izdvojenom vremenu, kvalitetnim smjernicama i savjetima kako bi ovaj rad postao još bolji te autorima računalnog programa JustNN na besplatnoj licenci i detaljnim uputama za korištenje.

SADRŽAJ

POPIS SLIKA	I
POPIS TABLICA	II
1. UVOD.....	1
2. REZULTATI RANIJIH ISTRAŽIVANJA GEOLOŠKIH STRUKTURNIH I TALOŽNIH PODATAKA NEURONSKIM MREŽAMA U HRVATSKOJ.....	3
3. ZEMJOPISNI POLOŽAJ ISTRAŽIVANOG PODRUČJA	8
4. TEORIJA I PRIMJENA NEURONSKIH MREŽA	9
4.1 Umjetna inteligencija.....	10
4.2 Osnovna svojstva umjetnih neuronskih mreža	11
4.3 Podjela umjetnih neuronskih mreža	12
4.4 Osnovni matematički izrazi neuronske mreže.....	14
4.5 Princip rada umjetnih neuronskih mreža	15
4.6 Mreža s povratnim postupkom	17
4.7 Uporaba opisanih vrsta mreže na primjeru ležišta polja Okoli	19
5. OSNOVNI NAFTNOGEOLOŠKI ODNOSI U POLJU LADISLAVCI.....	23
6. TEORIJA ELEKTROKAROTAŽNIH METODA KOJE SU KORIŠTENE U ANALIZI MIOCENSKIH LITOFACIJESA.....	26
6.1 Karotaža spontanoga potencijala (SP-karotaža)	26
6.2 Karotaža prividne električne otpornosti (R_{16} , R_{64}).....	28
7. ANALIZE UMJETNIM NEURONSKIM MREŽAMA	30
7.1 Predviđanje litološkoga sastava.....	30
7.1.1 Analiza za bušotinu A.....	31
7.1.2 Analiza za bušotinu B.....	36
8. ZAKLJUČAK.....	42
9. LITERATURA	44

POPIS SLIKA

Slika 2-1. Karta šupljikavosti dobivena kokrigingom u naftnome ležištu polja Beničanci ..	4
Slika 2-2. Poroznosti procijenjene neuronskom mrežom na polju Beničanci	4
Slika 2-3. Područja u kojima su dubinski geološki podatci analizirani i interpretirani pomoću umjetnih neuronskih mreža.....	7
Slika 3-1. Geografski položaj naftno-plinskog polja Ladislavci.....	8
Slika 4-1. Model ljudskog neurona	9
Slika 4-2. Sigmoidalna aktivacijska funkcija.....	15
Slika 4-3. Mreža s postupkom povratne informacije	16
Slika 4-4. Model umjetnoga neurona	17
Slika 4-5. Položaj polja Okoli unutar hrvatskoga dijela Panonskoga bazena	19
Slika 5-1. Shematski stratigrafski stup u polju Ladislavci.....	24
Slika 5-2. Karta po krovini ležišta „F1a“	25
Slika 6-1. Izgled krivulje spontanoga potencijala s pripadajućim osnovnim linijama te probušena litologija	27
Slika 6-2. Normalna sonda.....	29
Slika 6-3. Prikaz krivulje otpornosti za R ₁₆ i R ₆₄ te krivulje SP-a u slučaju zasićenja pješčenjaka ugljikovodicima	29
Slika 7-1. Vrijednosti spontanoga potencijala za bušotinu A.	31
Slika 7-2. Arhitektura umjetne neuronske mreže korištene za procjenu miocenskih litofacijesa u bušotini A.	32
Slika 7-3. Učenje neuronske mreže u programu JustNN za bušotinu A.	33
Slika 7-4. Relativna važnost ulaznih podataka u neuronskoj mreži za procjenu miocenskih litofacijesa u bušotini A.	33
Slika 7-5. Uvježbavanje VPM mreže na podacima iz bušotine A.	34
Slika 7-6. Predviđanje VPM mrežom u bušotini A.	35
Slika 7-7. Vrijednosti spontanog potencijala za bušotinu B.	36
Slika 7-8. Arhitektura umjetne neuronske mreže korištene za procjenu miocenskih litofacijesa u bušotini B.	37
Slika 7-9. Učenje neuronske mreže u programu JustNN za bušotinu B.	38
Slika 7-10. Relativna važnost ulaznih podataka u neuronskoj mreži za procjenu miocenskih litofacijesa u bušotini B.....	38
Slika 7-11. Uvježbavanje VPM mreže na podacima iz bušotine B.	39
Slika 7-12. Predviđanje VPM mrežom u bušotini B.....	40

POPIS TABLICA

Tablica 2-1. Uspješnost uvježbavanja i predviđanja varijabli ležišta za predviđanje litološkog sastava u bušotini Klo-44	5
Tablica 2-2. Uspješnost uvježbavanja i predviđanja varijabli ležišta za predviđanje intervala zasićenosti ugljikovodicima u bušotini Klo-44	6
Tablica 4-1. Vjerojatnosti uspješnosti učenja mreže za bušotinu B-1.....	20
Tablica 4-2. Vjerojatnosti uspješnosti učenja mreže za bušotinu B-2.....	21

1. UVOD

Umjetne neuronske mreže možemo opisati kao relativno rjeđi koncept korišten u analizi podataka i mogu se primijeniti u gotovo svim područjima prirodnih, tehničkih i društvenih znanosti. U geologiji, velika uspješnost njihove primjene odražava se u području predviđanja i klasifikacije te procijeni veličine i položaja ležišta vrijednih sirovina ili stijenskih svojstava. Glavna primjena umjetnih neuronskih mreža je traženje zavisnosti između podataka koji nisu isključivo u linearnoj vezi, a opet se mogu ujediniti u jedan složeni ulazni skup. Operacije poput uočavanja i klasificiranja litofacijesa u geologiji obavljaju se intuitivno, ali računalima predstavljaju prepreku. S obzirom na to da su umjetne neuronske mreže karakterizirane visokim stupnjem tolerancije pogrešaka, čak i u slučaju analize nejasnih i manjkavih podataka, moguće je često doći do zadovoljavajućeg rješenja. Primjena umjetnih neuronskih mreža u geologiji je prilično raširena, a posebno u onim disciplinama koje raspolažu velikim brojem ulaznih podataka kao što je geologija ležišta ugljikovodika.

U radu su opisani osnovni pojmovi te metode umjetnih neuronskih mreža kao i rezultati ranijih istraživanja uz pomoć umjetnih neuronskih mreža u geologiji Hrvatske. Također, opisan je i primjer uspješnog korištenja umjetne inteligencije za predviđanje litofacijesa gornjega miocena u dvije bušotine polja Okoli.

Radovi na istraživanju ugljikovodika u ovom području počinju nakon geološke interpretacije geofizičkih podataka prikupljenih do 1959. godine. Tada je locirano nadsvodenje na donjomiholjačkom pragu i iste je godine izrađena bušotina Kučanci – 1. Seizmičkim profilima koji su izrađeni do 1973. godine dobiveni su kvalitetniji podatci na temelju kojih je izrađena geološko-ekonomska osnova projekta istraživanja strukture Ladislavci i strukture Kučanci. Ležište nafte je u miocenskim naslagama vukovarske formacije, a plinsko u osječkim pješčenjacima (serija B). Ležište nafte podijeljeno je u tri cjeline (El, F1a i F1b) (**Kosovec, 1995**). Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati. Ležišna svojstva takvih stijena s drugotnom šupljikavosti znatno variraju i na manjim razmacima. Te česte vertikalne i bočne promjene ležišnih stijena stvarale su poteškoće u razradi ležišta. Između vapnenaca i dolomita pojavljuje se limonitizirani uškrljeni glinjak koji služi kao izolatorska stijena.

U ovom radu izrađene su dvije umjetne neuronske mreže za predviđanje točnog poretka položaja slojeva ležišnih i izolatorskih stijena, odnosno što točnija rekonstrukcija intervala od EK-markera Rs7 do dna bušotine na temelju podataka iz bušotina, tj. unutar naslaga badena i sarmata. Ti podatci su litofacijsni, tj. kategoričke varijable. One su derivirane iz karotažnih krivulja s kojih se litofacijesi mogu interpretirati.

Za facijesnu analizu ležišta upotrijebljen je program „JustNN“ a ulazni podatci određeni su interpretacijom elektro-karotažnih dijagrama iz bušotina A i B. Ispitivanje se odvijalo tako da su neuronske mreže uvježbavane na određenom dubinskom intervalu bušotine (nadgledano učenje) te se tako uvježbana neuronska mreža koristila za predviđanje željenih parametara na, dosad njoj, nepoznatim intervalima.

Za analizu ulaznih podataka korištena je mreža s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno višeslojna perceptronska mreža, skraćeno VPM (engl.«*multi layer perceptron, MLP*»). Mreža koja se pokazala najuspješnijom kod uvježbavanja i predviđanja miocenskih litofacijesa u bušotini A bila je mreža s postupkom povratne informacije (VPM) sa četiri neurona u prvom skrivenom sloju, jedan u drugom i dva u trećem skrivenom sloju a obilježena je s ukupno 8 199 iteracija.


Mreža koja se pokazala najuspješnijom kod uvježbavanja i predviđanja miocenskih litofacijesa u bušotini B bila je mreža s postupkom povratne informacije (VPM) sa četiri neurona u prvom skrivenom sloju, pet u drugom i dva u trećem skrivenom sloju, a obilježena je s ukupno 15 658 iteracija.

2. REZULTATI RANIJIH ISTRAŽIVANJA GEOLOŠKIH STRUKTURNIH I TALOŽNIH PODATAKA NEURONSKIM MREŽAMA U HRVATSKOJ


Neuronski alati kao računalna pomagala u sve su većoj upotrebi zadnjih nekoliko desetljeća i pokazali su se korisnim u područjima geologije, osobito kod statističkih metoda analize podataka pri istraživanju ležišta ugljikovodika. U hrvatskoj se ova vrsta analize podataka koristi od 2006. godine, a tijekom zadnjih nekoliko godina najveći iskorak je napravljen u analizi karotažnih mjerenja i litologije kvartarnih naslaga Hrvatskog dijela Panonskog bazena. Jedan od prvih radova tiskanih u Hrvatskoj s tematikom primjene umjetnih neuronskih mreža u predviđanju klastičnih facijesa u polju Okoli (**Malvić, 2006**). U tom radu detaljno je prikazana metodologija upotrebe neuronskih mreža u predviđanju ležišnih facijesa. Uvodno su dane osnovne postavke neuronskih mreža, a zatim je opisan napredniji algoritam učenja nazvanim RProp po kojemu je načinjena prikazana analiza. Mreža je uvježbana karotažnim podacima (krivulje GR, R_{16} , R_{64} , PORE/T/W, SAND i SHALE) iz dviju bušotina (kodnih imena B-1 i B-2) koje su probušile proizvodnu seriju «seriju c» te ležište c2 (kao cilj analize) donjopontske starosti. Rezultati su dvojaki, odnosno dijelom ukazuju na pretreniranost mreže kod predviđanja pješčenjačkih intervala te je najveći broj laporovitih sekvenci u krovini i podini zamijenjen pješčenjakom. S druge strane, analiza je ukazala da bi se u daljnjim facijesnim modeliranjima neuronskim alatima u Savskoj depresiji, broj upotrijebljenih karotažnih krivulja trebao proširiti dodatnim vrstama koje također karakteriziraju litološki sastav i zasićenje fluidima (SP, CN, DEN).

Umjetne neuronske mreže još su korištene za procjenu poroznosti u polju Beničanci (**Malvić & Prskalo, 2007**). Naglasak je stavljen na vrstu upotrijebljene mreže te vrijednosti ulaznih podataka i njihovih linearnih veza koje su omogućile predviđanje šupljikavosti unutar cijeloga ležišta nafte polja Beničanci neuronskim algoritmom. Unutar ležišta badenske starosti bili su dostupni reinterpetirani bušotinski podatci na 14 lokacija te seizmički atributi interpretirani iz rezultata snimanja 3D seizmike (amplituda, faza i frekvencija). Najbolja procjena šupljikavosti dobivena je kada su upotrijebljena sva tri seizmička atributa, što je potvrdilo pretpostavku da neuronske mreže obično postižu uspješnija predviđanja s većim brojem ulaza. Relativno postupni prijelaz na karti

šupljikavosti dobivenoj neuronskom mrežom te vrijednosti ćelija koje rijetko dosežu minimum i maksimum ulaznog skupa pokazali su da je neuronska procjena preciznija od onih na kartama dobivenim drugim interpolacijskim metodama.



Slika 2-1. Karta šupljikavosti dobivena kokrigingom u naftnome ležištu polja Beničanci (preuzeto iz **Malvić & Prskalo, 2007**)



Slika 2-2. Poroznosti procijenjene neuronskom mrežom na polju Beničanci (preuzeto iz **Malvić & Prskalo, 2007**)

Jedan od radova koji je značajan za popularizaciju umjetnih neuronskih mreža u Republici Hrvatskoj je „Hrvatsko-hrvatski rječnik iz primjene neuronskih mreža u geologiji“ (**Malvić & Cvetković, 2008**) koji je rezultat rada autora u tome području i prethodnom objavljivanju nekoliko predmetnih radova. Radi se o malome hrvatskome rječniku različitih pojmova iz upotrebe neuronskih mreža koji su korišteni i u ovom radu.

Još je važno spomenuti upotrebu umjetnih neuronskih mreža za predviđanje litološkog sastava i intervala zasićenja ugljikovodicima na primjeru polja Kloštar (**Malvić et al., 2009**). Kao ulazne vrijednosti korišteni su elektrokarotazni podatci bušotina Klo-44 i Klo-71. Za predviđanje litološkog sastava ručno su izdvojeni slojevi pješčenjaka i lapora na karotaznim dijagramima bušotine Klo-44. Kao ulazni podatak za uvježbavanje neuronske mreže korištene su vrijednosti spontanog potencijala (SP) i otpornosti (R_{16} i R_{64}) te litološki sastav. Litološki sastav definiran je varijablom čija je vrijednost predviđena. Za razliku od predviđanja litološkog sastava, neuronska mreža za predviđanje zona zasićenim ugljikovodicima uvježbana 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 zasićeni, a 1 nezasićeni dio). Osim vrijednosti zasićenja korištene su krivulje SP-a, R_{16} , R_{64} , dubine (m) i atributivna varijabla litološkog sastava. Za predviđanje varijabli ležišta korištena je VPM mreža sa 6 neurona u prvom sloju te 8 neurona u drugom skrivenom sloju. Prilikom određivanja litološkog sastava u bušotini Klo-44 pomoću neuronske mreže s radijalnom funkcijom i višeslojnom mrežom dobiveno je izvrsno poklapanje predviđenog i stvarnog litološkog sastava. Za određivanje intervala zasićenosti u bušotini Klo-71 pomoću višeslojne mreže, uvježbane na bušotini Klo-44 dobiveno je izvrsno poklapanje između predviđenih i stvarnih vrijednosti.

Tablica 2-1. Uspješnost uvježbavanja i predviđanja varijabli ležišta za predviđanje litološkog sastava u bušotini Klo-44 (preuzeto iz **Malvić et al., 2009**)

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
RBF 3:3-31-1:1	0,152942	0,172753
MLP 3:3-4-6-3-1:1	0,314380	0,133478

Tablica 2-2. Uspješnost uvježbavanja i predviđanja varijabli ležišta za predviđanje intervala zasićenosti ugljikovodicima u bušotini Klo-44 (preuzeto iz **Malvić et al., 2009**)

^a 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 izlaznome sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

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

Tip neuronske mreže i svojstva ^a	Pogreška uvježbavanja ^b	Pogreška selekcije ^b
MLP 5:5-6-8-1:1	0,056897	0,091173

Umjetne neuronske mreže pokazale su se uspješnima i pri nadopunjavanju nedostajućih karotažnih podataka u određenim intervalima kao što je prikazano u radu **Cvetković & Bošnjak (2009)** u kojem su odabrani i najbolji algoritmi za takva istraživanja. 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 različitog litološkog sastava. U analizama su korištene krivulje zvučne karotaže, neutronske karotaže, karotaže gustoće i karotaže prirodne radioaktivnosti. Sve vrste neuronske mreže uspješne su u predviđanju neutronske šupljikavosti, a najuspješnija je višeslojna mreža s povratnom informacijom (VPM). Najuspješnije predviđanje vrijednosti karotaže neutronske šupljikavosti bilo je na odabranom intervalu iz polja Đeletovci, a najmanje uspješno predviđanje vrijednosti krivulje neutronske karotaže bilo je u intervalu „metavulkaniti“ u polju Stari Gradac-Barcs Nyugat. Za prikaz rezultata odabrane su tri najuspješnije neuronske mreže, i to jedna od svake vrste (VPM, RBF i GRNN).

Umjetne neuronske mreže još su korištene za predviđanje litologije u jednoj bušotini koristeći karotažne podatke druge bušotine u polju Kloštar u sedimentima gornjeg miocena (**Cvetković & Velić, 2009**). Najbolji rezultati predviđanja litofacijesa unutar jedne bušotine su dobiveni uvježbavanjem jedne umjetne neuronske mreže na cijelom intervalu bušotine.



Slika 2-3. Područja u kojima su dubinski geološki podatci analizirani i interpretirani pomoću umjetnih neuronskih mreža (preuzeto iz **Malvić, 2009**).

Svakako valja spomenuti najvažniji pregledni hrvatski rad o neuronskim mrežama u geologiji pod nazivom „Neural networks in petroleum geology as interpretation tools“ (**Malvić et al., 2010**). U njemu su prikazana tri primjera korištenja neuronskih mreža za analizu podataka iz ležišta ugljikovodika. Sve mreže su uvježbavane na podacima iz klastičnih ležišta neogenske starosti koja se nalaze u Hrvatskom dijelu Panonskog bazena. U radu je prikazana upotreba neuronskih mreža za predviđanje klastičnih facijesa u polju Okoli, procjenu poroznosti u polju Beničanci i predviđanje litološkog sastava i intervala zasićenja ugljikovodicima u polju Kloštar.

Primjena umjetnih neuronskih mreža pokazala se uspješnom pri analiziranju podataka iz karotažnih dijagrama, kao što je kartiranje litofacijesa pliocenskih, pleistocenskih i holocenskih sedimenata u Savskoj depresiji (**Cvetković et al., 2012**). Ulazni podatci su dobiveni iz karotažnih krivulja SP, R₁₆ i R₆₄. Analiza je uspješno primijenjena u ukupno 20 bušotina, a u dvije bušotine je izvršeno uvježbavanje i validacija umjetne neuronske mreže. Dobiveni litofcijesni podatci korišteni su pri izradi litofacijesnih karata koje jasno pokazuju rasprostranjenost i ukupnu debljinu pješčenjačkih slojeva kao i njihov ukupni broj. Na konstruiranim kartama mogu se uočiti smjerovi paleotransporta i intervali s većom debljinom pješčenjaka koji su pogodni za akumulaciju plina.

3. ZEMJOPIISNI POLOŽAJ ISTRAŽIVANOG PODRUČJA

Naftno-plinsko polje Ladislavci (**slika 3-1**) nalazi se u istočnoj Slavoniji na području sela Ladislavci koje je udaljeno desetak kilometara od Donjeg Miholjca. Ovo područje je pretežito nizinsko s prosječnom nadmorskom visinom od oko 100 metara.

Istočni dio Dravske depresije ograničen je gorama Papukom i Krndijom na jugu, a na sjeveru se preko rijeke Drave nastavlja u Mađarsku. Cestovne i željezničke prometnice povezuju područje Donjeg Miholjca s bilogorskom Podravinom na sjeverozapadu i osječkom regijom na istoku. Cestovne prometnice povezuju općinu Donji Miholjac s Našicama i Požeškom kotlinom. Na rijeci Dravi sjeverno od Donjeg Miholjca nalazi se most koji povezuje Hrvatsku i Mađarsku na Međunarodnom cestovnom graničnom prijelazu Donji Miholjac koji je potaknuo razvoj tranzitnih tokova iz Mađarske.




Slika 3-1. Geografski položaj naftno-plinskog polja Ladislavci (preuzeto iz **Malvić, 2009**)

4. TEORIJA I PRIMJENA NEURONSKIH MREŽA

Pojam „neuronske mreže“ ima dvostruko značenje. Tradicionalno, ovaj se pojam odnosi na biološku (prirodnu) neuronsku mrežu građenu od bioloških neurona koji su povezani u periferni ili središnji živčani sustav. Neuron (živčana stanica) osnovna je jedinica živčanog sustava, a ujedno je i najsloženija jedinica ljudskog organizma (**slika 4-1.**). Umjetne neuronske mreže imaju dodirnih točaka s ljudskom moždanom strukturom. Zajedničko im je da obje vrste mreža prenose samo dvije informacije, je li veza aktivna ili nije, a te informacije su izražene određenim električnim potencijalom, u mozgu ili računalu. Sličnost tih dviju mreža je u načinu kako se ta dva stanja upotrebljavaju da bi konačan rezultat predstavljao suvislu obradbu podataka. Obje vrste mreža temelje se na postupcima koji se ponavljaju, iteracijama odnosno uvježbavanju (npr. **Rosenblatt, 1957, 1958**).

Umjetne neuronske mreže služe za razumijevanje bioloških neuronskih mreža i za rješavanje problema na području umjetne inteligencije. Koriste se strukturom ljudskog mozga kako bi razvile primjerenu strategiju analize podataka. Neuronske mreže nalaze široku primjenu u društvenim i tehničkim znanostima. Slijedom prethodno pojašnjenog, može se zaključiti da umjetni neuron oponaša osnovne funkcije biološkog neurona. Neuronska mreža je skup međusobno povezanih jednostavnih elemenata, jedinica ili čvorova, čija se funkcionalnost temelji na biološkom neuronu. Moć analize pohranjena je u snazi veza između pojedinih neurona, tj. težinama do kojih se dolazi postupkom prilagodbe, odnosno učenjem iz skupa podataka.



Slika 4-1. Model ljudskog neurona (**Bolf & Jerbić, 2006**).

4.1 Umjetna inteligencija

Pojam umjetna inteligencija (UI) je naziv kojim se naziva svaki neživi sustav koji ima sposobnost snalaženja u novim situacijama dakle inteligenciju. Engleski naziv za umjetnu inteligenciju je „*artificial intelligence*“ skraćeno *AI*. Svaku računalnu umjetnu inteligenciju namijenjenu rješavanju problema naziva se ograničenom umjetnom inteligencijom. Svi dosadašnji oblici umjetne inteligencije spadaju u ovu grupu jer su ograničeni na rješavanje samo određenih problema i nemaju vlastitu svijest kao ni razumijevanje. Mogućnost izrade svjesne umjetne inteligencije je za sada predmet filozofskih rasprava, tj. pitanje je li inteligenciju uopće moguće reproducirati računalom.

Neke od definicija umjetne inteligencije su:

- Znanstvena disciplina koja se bavi izgradnjom računalnih sustava čije se ponašanje može tumačiti kao inteligentno (**Dalbelo-Bašić et al., 2013**),
- Znanost o tome kako postići da strojevi izvode zadatke koji bi, kada bi ih radio čovjek, iziskivali inteligenciju (**Dalbelo-Bašić et al., 2013**).

Ako se razmišlja o svim mogućim primjenama umjetne inteligencije poput detekcije neželjene e-pošte, automatskog označavanja fotografija, prepoznavanja lica, inteligencije u autonomnim vozilima ili računalnim igrama, može se zaključiti da se radi o vrlo različitim i specifičnim problemima. Iz toga proizlaze i mnoge metode umjetne inteligencije. Inteligencija potrebna za igranje šaha razlikuje se od one za autonomno vozilo. Računalo koje je pobijedilo Kasparova u šahu, temeljilo se na heuristici, odnosno izgradnji stabla igre i vrlo brzom procesiranju svih mogućih ishoda partije. Sustav koji raspoznaje neželjenu poštu u elektroničkoj pošti radi drugačije i nastoji naučiti koja su obilježja neželjene pošte kao što je zastupljenost određenih riječi ili sintagmi. Spektar metoda zaista je širok, od heuristike, probabilističkih sustava, preko neizrazite logike pa sve do strojnog učenja. Upravo je strojno učenje danas najatraktivnije i najzanimljivije.

Algoritmi strojnog učenja koji su trenutno najzanimljiviji i zapravo pobjeđuju na većini znanstveno priznatih testova upravo su umjetne neuronske mreže. To je naziv za skup algoritama inspiriranih konceptom biološkog živčanog sustava. Mnogo jednostavnih računalnih jedinica (neurona) povezano je u jednu veliku mrežu i zajedno uče rješavati problem.

4.2 Osnovna svojstva umjetnih neuronskih mreža

Najvažnija svojstva umjetnih neuronskih mreža su:

- *Paralelno raspodijeljena obradba informacija.* Za razliku od konvencionalnih računskih tehnika, neuronske mreže prihvaćaju više ulaza paralelno i dobivene informacije obrađuju na raspodijeljen način. Informacija spremljena u umjetnu neuronsku mrežu raspodijeljena je na više računskih jedinica, što je potpuno suprotno konvencionalnome spremanju informacija u memoriju gdje je svaka posebna informacija (podatak) spremljena u svoj vlastiti memorijski prostor. Svojstvo raspodijeljenoga spremanja informacija daje neuronskim mrežama više prednosti, od kojih je najvažnija redundantnost, to jest otpornost na kvar i zbog toga umjetna neuronska mreža će raditi čak ako se i uništi neki njezin dio.
- *Učenje i prilagodba.* Svojstvo učenja i prilagodbe čini neuronske mreže sposobnima obrađivati neprecizne i loše ušćuvane podatke u nestrukturiranom i neodređenom okruženju. Na odgovarajući način naučena neuronska mreža ima svojstvo poopćavanja kada se na njezinome ulazu pojave podatci koji nisu bili u uzorku na osnovi kojeg je mreža naučena.
- *Univerzalni aproksimator.* Najvažnije svojstvo neuronskih mreža sa stajališta modeliranja, identifikacije i upravljanja nelinearnim procesima je to da one aproksimiraju kontinuiranu nelinearnu funkciju do željene točnosti.
- *Viševarijabilni sustavi.* Neuronske su mreže po svojoj strukturi viševarijabilni sustavi što ih čini lako primjenjivim za modeliranje, identifikaciju i upravljanje viševarijabilnim procesima.
- *Sklopovska implementacija.* Više je proizvođača razvilo specijalizirane sklopove za implementaciju neuronskih mreža koji omogućuju paralelnu raspodijeljenu obradbu u stvarnome vremenu.
- *Neuronske su mreže računski vrlo zahtjevne.* Izlaz svakog neurona rezultat je zbrajanja više umnožaka i izračunavanja nelinearne aktivacijske funkcije.
- *Računska brzina neuronske mreže određena je brojem matematičkih operacija pojedinog sloja, a ne čitave mreže.* Nadalje, svaki sloj mreže ima paralelnu građu, to jest svaki se neuron u sloju može promatrati kao lokalni procesor koji radi paralelno s ostalim neuronima.

- *Neuronske mreže zahtijevaju veliki memorijski prostor.* Svaki pojedini neuron ima više sinaptičkih veza, a svakoj je od njih pridružen težinski koeficijent koji mora biti spremljen u memoriju. Povećanjem broja neurona u mreži memorijski zahtjevi rastu s kvadratom broja neurona.

4.3 Podjela umjetnih neuronskih mreža

Građu, odnosno arhitekturu ili topologiju neuronske mreže, može se razlikovati s obzirom na način povezivanja neurona u mrežu. Postoji velik broj kriterija za razlikovanje arhitektura neuronskih mreža. Ovdje su opisani samo osnovni čimbenici podjele: broj slojeva, tip učenja, smjer kretanja signala kroz mrežu, tip veze između neurona, ulazne i prijenosne (aktivacijske) funkcije. Neuroni povezani u mrežu organizirani su u slojeve. Svaka mreža ima neurone koji služe za prihvatanje ulaznih vrijednosti i čine ulazni sloj neurona, te neurone koji daju odgovor mreže i čine izlazni sloj neurona. Svi ostali neuroni koji se nalaze između tih dvaju slojeva čine skriveni sloj neurona (npr. **Dalbelo-Bašić et al., 2008**). Neuronske mreže mogu biti jednoslojne i višeslojne. Jednoslojna mreža sastoji se od jednoga sloja neurona (izlaznog sloja), dok se ulazni sloj ne broji, jer u njemu nema obradbe podataka odnosno procesiranja. Višeslojne mreže osim ulaznog i izlaznog sloja imaju i jedan ili više skrivenih slojeva neurona (npr. **Lončarić, 2016**).

Glavni zadatak mreže je da nauči model okoline u kojoj će raditi i da održava model dovoljno točnim da bi se mogli postići željeni ciljevi danog sustava. Neuronska mreža uči o okolini kroz iterativni proces podešavanja sinaptičkih težina i pragova. Učenje je proces kojim se slobodni parametri neuronske mreže adaptiraju kroz kontinuirani proces stimulacije od okoline u kojoj se mreža nalazi (npr. **Lončarić, 2016**).

Skup pravila za rješavanje problema učenja zove se algoritam učenja kao npr. učenje korekcijom pogreške. Algoritam učenja određuje način izračunavanja promjena sinaptičke težine u trenutku n , dok paradigme učenja (učenje pod nadzorom, učenje podrškom, učenje bez nadzora) određuju odnos neuronske mreže prema okolini (npr. **Lončarić, 2016**). Kod nadziranog učenja (engl. *supervised learning*) podatci za uvježbavanje sastoje se od primjera s poznatim ulaznim i izlaznim vrijednostima. Mreža stvara izlaz, računa pogrešku (razliku između željene i dobivene vrijednosti) i prilagođava sinaptičke težine s obzirom na pogrešku. Proces se iterativno ponavlja sve dok mreža ne nauči oponašati

dokazano točan model. Dakle, učenje pod nadzorom pretpostavlja postojanje ciljne vrijednosti za svaku ulaznu vrijednost. U nekim situacijama nije moguće osigurati takvu informaciju, već samo informaciju koja govori je li izlazna vrijednost poželjna ili nije. Ovaj tip učenja naziva se podržano učenje (engl. *reinforcement*). Kod ovog učenja ne postoji validacijski skup podataka iz kojeg se određuje kolika je pogreška za određene ulazne i izlazne vrijednosti, nego je poznato koliko je određeni korak u učenju dobar, što daje ocjenu ili podršku. Učenje podrškom rješava problem učenja pod nadzorom, tj. da bez validacijskog skupa podataka mreža ne može naučiti nove strategije, koje nisu pokrivene primjerima koji su korišteni za učenje. Kod nenadziranog učenja (engl. *unsupervised learning*) nisu poznate izlazne vrijednosti. Ulazi su raspoloživi mreži, a težine se ne prilagođavaju na osnovi stvarnih vrijednosti izlaza. Ovdje se umjetna neuronska mreža sama organizira, pa se mreže učene ovom metodom nazivaju samoorganizirajuće neuronske mreže. Ako su slojevi neurona povezani tako da signali putuju u jednom smjeru od ulaza prema izlazu mreže, takav tip mreže se naziva aciklička neuronska mreža. Ako postoji bar jedna povratna veza mreža se naziva mreža s povratnom vezom.

Prema tipu, veze između neurona mogu se ostvarivati između dva sloja (međuslojna) i između neurona u jednom sloju (unutar-slojna). Kada neki neuron prima ulaz iz prethodnog sloja, vrijednost njegovog ulaza računa se prema ulaznoj funkciji, obično zvanoj „sumacijska” funkcija. Aktivacijske funkcije koriste se za smanjivanje broja iteracija. Slijedom navedenog, neuronske mreže mogu se podijeliti u četiri glavne vrste (Dalbello-Bašić et al., 2008):

- Aciklička mreža;
- Mreža s povratnom vezom;
- Bočno povezana mreža;
- Hibridna mreža.

4.4 Osnovni matematički izrazi neuronske mreže

Izlaz svakog neurona predstavlja ulazni signal modificiran odgovarajućom funkcijom. Izlaz neurona „j“ opisan je sljedećim jednažbama (npr. **Malvić, 2009**)

$$U_j = \sum X_i w_{ij} \quad (4.1)$$

$$Y_j = F_{th}(U_j + t_j) \quad (4.2)$$

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 „j“

F_{th} – aktivacijska funkcija


Y_j – izlaz promatranog 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} . **Izraz (4.1)** predstavlja skup operacija u neuronu, a drugi **(4.2)** ispituje aktivira li se taj isti neuron.

Najčešći oblik aktivacijske funkcije je sigmoidalna (logistička) funkcija. Osim sigmoidalne aktivacijske funkcije (**slika 4-2**) mogu se upotrijebiti i drugi oblici aktivacijskih funkcija. Sigmoidalna funkcija definirana je **izrazom 4.3** (npr. **Malvić, 2009**):

$$f(x) = \frac{1}{1 + e^{-ax}} \quad (4.3)$$

Gdje parametar «a» određuje nagib funkcije.



Slika 4-2. Sigmoidalna aktivacijska funkcija

4.5 Princip rada umjetnih neuronskih mreža


Rad umjetnih neuronskih mreža moguće je podijeliti na:

- Stupanj učenja (uvježbavanja);
- Stupanj odabira (kros validacije);
- Stupanj provjeravanja;
- Operativni stupanj (stupanj opoziva).

Kao dva temeljna stupnja u rada umjetnih neuronskih mreža najčešće se navode stupanj uvježbavanja i stupanj provjeravanja. U stupnju odabira mreža nastoji optimizirati duljinu uvježbavanja te broj skrivenih neurona, nakon čega se dobivena mreža pohranjuje i testira. Operativni stupanj odnosi se na primjenu neuronske mreže na novim slučajevima s nepoznatim rezultatima i fiksiranim težinama

Učenje predstavlja proces mijenjanja težina u mreži. Prije samog učenja potrebno je pripremiti ulazne podatke na kojima će se primijeniti mreža te definirati model umjetne neuronske mreže. Podatci se obično dijele u dva skupa, jedan se koristi za uvježbavanje mreže dok se drugi koristi za testiranje. Preporučeno je da skup podataka koji se koriste za uvježbavanje mreže bude 80 % ulaznih podataka a preostalih 20 % podataka koristi se za provjeru (**Malvić, 2006**). Učenje je proces podešavanja sinaptičkih težina u mreži koji se odvija u više ponavljanja (iteracija). Broj ponavljanja obično iznosi nekoliko tisuća te ako se pri tom može odrediti razlika između stvarnog i željenog odgovora mreže dobije se iznos pogreške koja se može vratiti natrag u mrežu kako bi se ona bolje uvježbala. Takav postupak naziva se „mreža s postupkom povratne informacije (engl. *backpropagation*)

network)“ (slika 4-3) i ponavlja se toliko puta, dok se pojedinačna ili ukupna pogreška ne spusti ispod željene vrijednosti.



Slika 4-3. Mreža s postupkom povratne informacije

Drugi stupanj rada umjetne neuronske mreže je testiranje mreže koje se provodi tako da se mreži predstave nove ulazne vrijednosti koje nisu sudjelovale u procesu učenja mreže a od mreže se očekuje da za predstavljenu ulaznu vrijednost proizvede pripadajuću izlaznu vrijednost. Ocjenjivanje mreže obavlja se na način da se izlazna vrijednost mreže uspoređuje sa stvarnom izlaznom vrijednošću na temelju čega se izračuna pogreška mreže. U ovom stupnju više se ne primjenjuje povratni postupak tj. mreža više ne uči i ne proširuje svoje mogućnosti nego se samo računaju nove vrijednosti iz uspostavljenih iznosa.


Sam proces dizajniranja umjetnih neuronskih mreža sastoji se od više koraka:

- definiranje modela (određivanje ulaznih i izlaznih varijabli);
- Odabir najprikladnijeg algoritma;
- Raspoređivanje neurona u slojeve;
- Određivanje tipa veze među neuronima;
- Određivanje funkcija među slojevima;
- Odabir pravila uvježbavanja;

- Odabir mjerila za ocjenjivanje mreže;
- Provođenje postupka uvježbavanja.

4.6 Mreža s povratnim postupkom

Višeslojni perceptron (engl. *multilayer perceptron*) jedna je arhitektura umjetnih neuronskih mreža koja se najviše primjenjuje a učenje se odvija pomoću algoritma „širenje unatrag“. Mreža se sastoji od ulaznog sloja, izlaznog sloja i najmanje jednog skrivenog sloja. Osnova te neuronske strukture je umjetni neuron (**slika 4-4.**), čija aktivacija ovisi o rezultatu obradbe aktivacijske funkcije.



Slika 4-4. Model umjetnoga neurona

Vraćajući se ponovno na definiciju mreže preko ulaznih, skrivenih i izlaznog sloja, naglašava se važnost težinskih koeficijenata (npr. **Malvić, 2009**).

$$U_j = (X_i w_{ij}) \quad (4.4)$$

gdje su (primijenjeno na pojedinačni neuron):

U_j – vrijednost izlaza neurona „j“

X_i – vrijednost ulaza „i“

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

Težinski koeficijenti se primjenjuju u svakom skrivenom sloju upotrebom aktivacijske funkcije (npr. **Malvić, 2009**):

$$Y_j = F(U_j + t_j) \quad (4.5)$$

gdje su (primijenjeno na čitavu mrežu):

Y_i – izlaz sloja „j“ (može biti i ukupan izlaz mreže)

F – aktivacijska funkcija

U_j – izlaz neurona „j“

t_j – ciljana vrijednost za neuron „j“

Jednadžba (4.4) podrazumijeva da su prethodno određeni težinski koeficijenti za svaki neuron, a **jednadžba (4.5)** da su određene vrijednosti prihvatanja hipoteze aktivacijskom funkcijom, broj slojeva te broj neurona u svakom sloju.

Tijek podataka kroz mrežu može se ukratko opisati u nekoliko koraka:

- podatci se šire od ulaznog sloja prema skrivenom sloju (ulazni sloj učitava podatke i šalje ih u prvi skriveni sloj);
- jedinice u skrivenom sloju primaju ulaz korigiran za težinski koeficijent i prenose ga u naredni skriveni (ili u izlazni) sloj pomoću aktivacijske funkcije;
- prilikom prolaska informacija kroz mrežu računaju se ukupne (sumirane) ulazne i izlazne vrijednosti za svaku jedinicu obradbe;
- u izlaznom se sloju za svaku jedinicu obradbe računa lokalna pogreška (u svrhu određivanja povećanja ili smanjenja težina);
- podatci se šire unatrag od izlaznog sloja do skrivenih slojeva.

Dva najveća problema u mreži s povratnim postupkom su lokalni minimum i preuvježbavanje (**Malvić, 2006**). Prvi problem nastaje zbog načina na koji se pogreška širi kroz mrežu dok se problem preuvježbavanja javlja u svim algoritmima neuronskih mreža, a pojavljuje se kada mreža savršeno „nauči“ uzorak za uvježbavanje te više nije u mogućnosti dati dobar izlaz na nepoznatom uzorku.

Mreža „s povratnim postupkom“ primjenjuje se za predviđanje vrijednosti jedne ili više izlaznih varijabli, no koristi se i za probleme klasifikacije.

4.7 Uporaba opisanih vrsta mreže na primjeru ležišta polja Okoli

Ovaj rad se temelji na predviđanju miocenskih litofacijesa u dvije bušotine polja Ladislavci koje se nalazi u Dravskoj depresiji. Budući da postupak izrade algoritma umjetne neuronske mreže i njegovo korištenje sličan onom iz rada „Predviđanje klastičnih facijesa neuronskom mrežom (primjer polja Okoli)“ (Malvić, 2006) ovdje su prikazani rezultati analize dobivene upotrebom neuronskih mreža u polju Okoli (slika 4-5). Taj rad je od posebnog značaja zbog toga jer je u njemu opisana uspješna primjena neuronskih mreža za predviđanje klastičnih facijesa a ujedno predstavlja i jedan od prvih radova tiskanih kod nas s tematikom primjene neuronskih mreža u analizi ležišta ugljikovodika te zbog toga zasluhuje biti spomenut i detaljnije opisan.



Slika 4-5. Položaj polja Okoli unutar hrvatskoga dijela Panonskoga bazena (preuzeto iz Malvić, 2009).

Mreža je uvježbana na podacima koji su dobiveni interpretacijom karotažnih dijagrama (krivulje GR, R_{16} , R_{64} , PORE/T/W, SAND i SHALE) iz dviju bušotina (kodnih imena B-1 i B-2) kojima je probušene proizvodna serija „c“ te ležište c2 (kao cilj analize) donjopontske starosti.

Iz bušotine B-1 upotrijebljene su krivulje GR (krivulja prirodne radioaktivnosti), R_{16} (krivulja otpornosti – „mala normala“) i R_{64} (krivulja otpornosti – „velika normala“). Ulazne krivulje u bušotini B-2 su GR, PORE (krivulja efektivne šupljikavosti), PORT (krivulja ukupne šupljikavosti), PORW (krivulja šupljikavosti u dijelu stijene zasićene 100% vodom), R_{16} , SANDSTONE (krivulja udjela pješčenjaka) i SHALE (krivulja udjela lapora). Izlazna krivulja nazvana je „ležište“ a ona predstavlja „kategoriziranu“ varijablu, definiranu brojačno s 0 i 1. Broj 0 predstavlja lapor a 1 pješčenjak.

Za učenje mreže (engl. *learning or L*) ukupno su upotrijebljena 153 podatka s vrijednošću 0 te 142 podatka s vrijednošću 1 iz bušotine B-1. Za provjeru (engl. *validation or V*) upotrijebljeno je 48 podataka s vrijednošću 0 te 50 podataka s vrijednošću 1 a vrijednosti uspješnosti učenja mreže dane su u **tablici 4-1**.

Tablica 4-1. Vjerojatnosti uspješnosti učenja mreže za bušotinu B-1 (preuzeto iz **Malvić, 2013**).

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			

Najbolja mreža obilježena je s ukupno 31 515 iteracija i vremenom učenja od 5,40 minuta te s prosječnom pogreškom učenja koja iznosi 0,00173 (**Malvić, 2006**).

Istovrsno uvježbavanje i predviđanje napravljeno je u bušotini B-2. 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 dakle, ukupno 586 podataka od kojih je svaki deseti prikazan u **tablici 4-2**.

Tablica 4-2. Vjerojatnosti uspješnosti učenja mreže za bušotinu B-2 (preuzeto iz **Malvić, 2013**).

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	82,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	V	0	88,1
V	0	88,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	V	0	88,1
V	0	88,1	L	1	82,1	V	0	88,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	V	1	88,1	L	0	82,1
V	0	88,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	L	0	82,1
V	1	88,1	V	1	88,1	L	0	82,1
L	1	82,1	V	1	88,1	L	0	82,1
V	1	88,1	L	1	82,1	V	0	88,1
L	1	82,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	L	0	82,1
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	-	-	-

Mreža je programirana na 28 599 iteracija, te je dobivena prosječna pogreška uvježbavanja mreže koja iznosi 0,002681. Dobivene vrijednosti slične su onima koje su

dobivene za bušotinu B-1 ali zbog većega broja upotrijebljenih krivulja ukupno je vrijeme uvježbavanja mreže bilo duže za oko 3 puta te je iznosilo 16,13 minuta (**Malvić, 2006**).

Pregledom dobivenih rezultata iz podatka iz bušotine B-2 vidljivo je kako predviđene i stvarne vrijednosti imaju znatno manji stupanj podudarnosti. Prema facijesima, predviđanje vrijednosti 1 (odnosno pješčenjačkoga facijesa) 100% su podudarne. Kod krovinskog i podinskog lapora (vrijednosti 0) te se vrijednosti znatno razlikuju te je tu u samo 7,8% slučajeva ispravno predviđen lapor. Brojčano, od 296 ulaznih ćelija opisanih kao lapor, vrijednost 0 ispravno je predviđena u 23, a zamijenjena brojem 1 u 273 slučaja. Ako se promatraju rezultati dobiveni iz bušotine B-1 može se primijetiti slična pojava zamjene laporovitog sloja pješčenjakom. Odgovor leži u vrsti i broju upotrijebljenih karotažnih krivulja. Od njih jedna prikazuje prirodnu radioaktivnost (GR), a druge dvije otpornosti (R_{16} i R_{64}). Može se pretpostaviti da bi analiza koja bi se temeljila na krivuljama spontanoga potencijala, odnosno na krivuljama karotaže šupljikavosti (zvučna karotaža, karotaža gustoće i neutronska karotaža), znatno olakšala razlikovanje lapora od pješčenjaka upotrebom umjetnih neuronskih mreža (**Malvić, 2006**).

5. OSNOVNI NAFTNOGEOLOŠKI ODNOSI U POLJU LADISLAVCI


Radovi na istraživanju ugljikovodika u ovom području započeli su nakon geološke interpretacije geofizičkih podataka prikupljenih do 1959. godine. Tada je locirano nadsvodenje na donjomiholjčkom pragu i iste je godine izrađena bušotina Kučanci – 1. Seizmičkim profilima koji su izrađeni do 1973. godine dobiveni su kvalitetniji podatci na temelju kojih je izrađena geološko-ekonomska osnova projekta istraživanja strukture Ladislavci i strukture Kučanci. Na temelju tog strukturnog rješenja, rezultata istražne bušotine KU-1 i općenitog poznavanja Vilanjsko-mećečke zone na strukturi Ladislavci izdvojena su perspektivna ležišta u vukovarskoj formaciji i izrađena je prva istražna bušotina La-1 (**Kosovec, 1995**). Na polju Ladislavci danas postoji 21 bušotina.

Ležište nafte je u miocenskim naslagama vukovarske formacije, a plinsko u osječkim pješčenjacima (serija B). Ležište nafte podijeljeno je u tri cjeline (El, F1a i F1b), a radi se kombiniranoj zamci strukturno-stratigrafskoga tipa. Prema klasifikaciji **Broda (1957)** ležište je masivnog tipa i može se klasificirati kao podtip masivno ležište u erozijskim uzdignućima. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati. Ležišna svojstva takvih stijena s drugotnom šupljikavosti znatno variraju i na manjim razmacima. Zanimljivo je da od 6 bušotina koje su probušile ležišne stijene približno na istoj strukturnoj visini, samo su 3 probušile ležište u „pozitivnom zasićenju“, dok su ostale tri probušile ležište u zasićenju vodom, što se može objasniti lokalnom prisutnošću nepropusnih zona unutar ležišnih stijena koje su prilikom migracije poslužile kao barijere. Te česte vertikalne i bočne promjene ležišnih stijena stvarale su poteškoće u razradbi ležišta.

Između vapnenaca i dolomita pojavljuje se limonitizirani uškriljeni glinjak koji služi kao izolatorska stijena. Kod tektonskih pokreta te su stijene došle u različite visinske odnose, pa je to vjerojatno razlog što je u pojedinim bušotinama kontakt nafta/voda na različitim dubinama. To se naročito očituje u bušotini B, u kojoj je kontakt nafta/voda 60-ak metara dublji nego u bušotini A. Najdublji kontakt ustanovljen je na bušotini B u dolomitnim naslagama na apsolutnoj dubini -2180 m. U sjevernom bloku kontakti variraju između -2115 i -2130 m što je uvjetovano tektonskim pokretima koji su doveli nepropusne stijene (uškriljeni glinjak) u današnji položaj.

Q	KVARTAR		LEŽIŠTA		
Pl ₃	PLIOCEN	GORNJI	PJESKOVITO- GLINOVITA SERIJA		
Pl ₂		SREDNJI			
Pl ₁ ²		DONJI	PJESKOVITO- GLINOVITO LAPOROVITA SERIJA		
Pl ₁ ¹			PJEŠČANO- LAPOROVITA SERIJA		
			PJEŠČANO- LAPOROVITA SERIJA	B	
M ₃ ²	MIOCEN	GORNJI	LAPOROVITO- SILTNA SERIJA		
M ₃ ¹					
M ₂ ²		SREDNJI		E ₁	
M ₂ ¹					
M ₁ ²					
M ₁ ¹					
		OLIGOCEN	GORNJI		
K		KREDA		VAPNENAČKA SERIJA	F _{1A}
J	JURA				
T	TRIJAS		DOLOMITNA SERIJA	F _{1B}	
Pz	PALEOZOIK				
P _R	PROTEROZOIK				

Slika 5-1. Shematski stratigrafski stup u polju Ladislavci.



Slika 5-2. Karta po krovini ležišta „F1a“ (preuzeto iz Atlas proizvodnih plinskih polja u Republici Hrvatskoj, 2005).


6. TEORIJA ELEKTROKAROTAŽNIH METODA KOJE SU KORIŠTENE U ANALIZI MIOCENSKIH LITOFACIJESA

Važna skupina geofizičkih metoda ispitivanja u bušotinama uključuju mjerenja električne otpornosti stijena i spontanog potencijala u nezacijevljenim bušotinama (elektrokarotažne metode) u svrhu određivanja njihove šupljikavosti odnosno zasićenja fluidima. Ležišne stijene sastoje se od minerala koji (osim nekih minerala glina) u suhom stanju ne vode električnu struju. Od ležišnih fluida, smjese ugljikovodika (plin, kondenzat, nafta) također su izolatori. Karotažna mjerenja korištena u ovom radu izvedena su krajem 70-ih godina i 80-ih godina prošloga stoljeća, radi se o osnovnim metodama geofizičkih mjerenja u bušotinama. Tu su uključena snimanja vrijednosti spontanog potencijala (SP) i električne otpornosti sondama manjeg i većeg dubinskog zahvata. Sonda manjega dubinskog zahvata ima razmak između strujnih i potencijalnih elektroda 16“ i naziva se mala normala (R_{16}) dok sonda većeg dubinskog zahvata ima razmak između strujnih i potencijalnih elektroda 64“ i naziva se velika normala (R_{64}).

6.1 Karotaža spontanoga potencijala (SP-karotaža)

Spontani potencijal (SP) u bušotini je otkriven 1928. godine, a pojavio se kao potencijal koji je prouzrokovao smetnje pri mjerenjima prvim električnim karotažnim uređajima. Spontani potencijal (SP) predstavlja razliku prirodnog potencijala između površinske elektrode i elektrode u bušotini. Osnovna svrha mjerenja spontanog potencijala je prikupljanje informacija o mineralizaciji podzemne vode u poroznim stijenama, dakle određuju se svojstva fluida a ne količina. Spontani potencijal (SP) ne predstavlja parametar stijene, već pojavu koja se prvenstveno javlja u bušotini kao rezultat međusobnog djelovanja filtrata isplake, porne vode i glina odnosno šejla. Prema dogovoru, vrijednosti SP-a smatraju se negativnima ako je otklon ulijevo, a ako je otklon u desno tada se smatraju pozitivnima. Na krivulji SP-a (**slika 6-1**) 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. U

nekim slučajevima, može se odrediti i „linija pijeska”, čija vrijednost odgovara vrijednosti SP-a u „čistim” (nezaglinjenim) slojevima pijeska.



Slika 6-1. Izgled krivulje spontanoga potencijala s pripadajućim osnovnim linijama te probušena litologija (preuzeto iz **Balić, 1993**)

Na rezultate mjerenja spontanoga potencijala u bušotini utječu brojni faktori, kao što su promjer bušotine, električna otpornost isplake i slojne vode, gustoća i sastav isplake, prodiranje isplake u okolne stijene, debljina isplaćng kolača, prisutnost ugljikovodika, temperatura u bušotini, debljina slojeva, mjerne pogriješke, itd. Sve ove varijacije moraju se uzeti u obzir pri interpretaciji rezultata mjerenja spontanog potencijala (**Balić, 1993**).


Karotaža spontanog potencija ima široku primjenu i uvijek se koristi u kombinaciji s drugim elektrokarotažnim metodama. Osnovne primjene karotaže SP-a su:

- izdvajanje propusnih slojeva,
- određivanje granica između propusnih i nepropusnih slojeva,
- procjena mineralizacije slojne vode,
- korelacija izdvojenih propusnih i nepropusnih slojeva,
- određivanje debljine slojeva i
- procjena specifične otpornosti slojne vode.

6.2 Karotaža prividne električne otpornosti (R_{16} , R_{64})


Mjerenjem otpornosti duž kanala bušotine dobiva se prividna otpornost koja ovisi o otpornosti stijene, stijenskih fluida, isplake, geometrijskom rasporedu elektroda, te otpornosti infiltriranih zona oko bušotine. Postoji niz različitih sonda konstruiranih u okviru naftnogeoloških istraživanja, koje imaju različite dubine prodiranja i namjene : normalna sonda, inverzna sonda, sonde s usmjerenim strujama (laterolog 3 i laterolog 7), mikrosonde i indukcijska sonda. U okviru plićih istraživanja najčešće se koriste normalne sonde, inverzne sonde i induktivne sonde.

U ovom poglavlju naglasak je na normalnim sondama zato što su samo one korištene pri izradbi karotažnih dijagrama u bušotinama A i B i to velika (R_{64}) i mala (R_{16}) normala. Normalnim sondama (**slika 6-2**) mjeri se potencijal na nekoj udaljenosti od strujne elektrode, a duljina sonde određena je razmakom između strujne i potencijalne elektrode. Dubina prodiranja ovisi o razmaku elektroda, a veći razmak znači i dublje prodiranje struje u stijene i obratno. U mjerenjima se najčešće koriste usporedno dvije sonde dviju različitih dimenzija, mala i velika normala. Mala normala (R_{16}) može bolje odrediti granice slojeva, zbog malih dimenzija, dok velika normala (R_{64}) daje prividne otpornosti bliske stvarnim otpornostima za razmjerno debele slojeve.



Slika 6-2. Normalna sonda (preuzeto iz Šumanovac, 2007)

Općenito karotaža otpornosti može razlučiti vrste stijena, odrediti stanje stijena (poroznost, razlomljenost, kompaktnost, propusnost), te zasićenje vodom i njezin salinitet. U takozvanim mekim naslagama mogu se vrlo precizno razdvojiti pijesci i šljunci od glina i prahova ali se na temelju otpornosti mogu dobiti i podatci o propusnosti okolnih stijena.



Slika 6-3. Prikaz krivulje otpornosti za R_{16} i R_{64} te krivulje SP-a u slučaju zasićenja pješčenjaka ugljikovodicima (preuzeto iz Balić, 1993).

7. ANALIZE UMJETNIM NEURONSKIM MREŽAMA

U ovom radu ispitivane su mogućnosti upotrebe umjetnih neuronskih mreža za predviđanje litološkog sastava u polju Ladislavci. Za facijesnu analizu ležišta upotrijebljen je program „JustNN“ a ulazni podatci određeni su interpretacijom elektro-karotažnih dijagrama iz bušotina A i B. Program može vrlo jednostavno učitati podatke i izraditi višeslojnu neuronsku mrežu koja će učiti iz tih podataka. Iz skupa ulaznih podataka moguće je odrediti manji dio koji će služiti kao skup za provjeru izlaznih vrijednosti kako bi se pogreška svela na što manju vrijednost. Nakon procesa učenja, u programu se može vidjeti koji ulazni parametri najviše utječu na izlaznu vrijednost. Ispitivanje se odvijalo tako da su neuronske mreže uvježbavane na određenom dubinskom intervalu bušotine (nadgledano učenje) te se tako uvježbana neuronska mreža koristila za predviđanje željenih parametara na, dosad njoj, nepoznatim intervalima. Prilikom uvježbavanja neuronske mreže, program zaustavlja uvježbavanje ukoliko se dostigne unaprijed zadani iznos pogreške. Ukoliko to nije postignuto, program se vraća na iteraciju u kojoj je postignuta najniža pogreška selekcije. Prije izradbe same neuronske mreže, potrebno je odrediti skup podataka za uvježbavanje mreže i on treba sadržavati velik broj i raspon podataka kako bi mreža nakon učenja davala što točnije rezultate.

7.1 Predviđanje litološkoga sastava


U svrhu predviđanja litološkoga sastava najprije su ručno izdvojene ležišne (vapnenačke breče, klastični vapnenci i brečo-konglomerati) i izolatorske (limonitizirani uškrljeni glinjak) stijene na karotažnim dijagramima iz bušotina A i B. One su izdvojene na temelju razlikovanja intervala propusnih stijena od intervala nepropusnih stijena prema položaju točaka infleksije na krivulji SP-a. Analize su napravljene odvojeno za svaku bušotinu što znači da se skup podataka za uvježbavanje i predviđanje nalazi unutar iste bušotine.

Najuspješnije su bile one mreže u kojima se polovina ulaznih podataka koristila za uvježbavanje dok se druga polovina koristila za provjeru uspješnosti mreže. Za bušotinu A mreža je uvježbavana na podacima iz intervala od -2153 m do -2228 m, a predviđanje litologije je napravljeno na dubljem intervalu, od -2228 m do -2282 m. Za bušotinu B,

mreža je uvježbavana na podacima iz intervala od -2122 m do -2224 m dok je predviđanje litologije napravljeno u intervalu od -2224 m do -2327 m.


7.1.1 Analiza za bušotinu A

Kao ulazni podatci za uvježbavanje umjetne neuronske mreže korištene su vrijednosti spontanog potencijala (SP) i otpornosti (R_{16} i R_{64}) te litološki sastav koji je dobiven interpretacijom karotažnih dijagrama. Korišteni ulazni podatci nalaze se u intervalu od dubine EK-markera Rs7 (-2153 m) do dna bušotine (-2283m) s razmakom od 1 m. U analizi je ukupno obrađeno 130 podataka, od toga 66 s vrijednošću 1 i 64 s vrijednošću 0. Broj 0 predstavlja limonitizirane uškriljene glinjake a broj 1 predstavlja vapnenačke breče, klastične vapnence i brečo-konglomerate.




Slika 7-1. Vrijednosti spontanoga potencijala za bušotinu A. (Na apscisi su dane vrijednosti spontanog potencijala u mV a vrijednosti na ordinati predstavljaju dubinu u metrima.)

Za analizu ulaznih podataka korištena je mreža s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno VPM mreža. Mreža koja se pokazala najuspješnijom kod uvježbavanja i predviđanja miocenskih litofacijesa u bušotini A bila je mreža s postupkom povratne informacije (VPM) sa četiri neurona u prvom skrivenom sloju, jedan u drugom i dva u trećem skrivenom sloju (**slika 7-2**), a obilježena je s ukupno 8 199 iteracija i prosječnom pogriješkom koja iznosi 0,024865. Skup podataka za uvježbavanje mreže podijeljen je tako da se jedna polovina skupa koristi za uvježbavanje, a druga polovina za određivanje uspješnosti mreže.



Slika 7-2. Arhitektura umjetne neuronske mreže korištene za procjenu miocenskih litofacijesa u bušotini A.




Slika 7-3. Učenje neuronske mreže u programu JustNN za bušotinu A. (Na ordinati su dane vrijednosti pogreške a vrijednosti na apscisi predstavljaju broj iteracija. Crvena linija predstavlja najveću, zelena linija predstavlja prosječnu a plava linija predstavlja najnižu pogrešku uvježbavanja.)

Na **slici 7-3.** može se vidjeti kako se odvijao proces učenja i kako se s brojem ciklusa učenja smanjivala pogreška. Na kraju procesa procijene litologije, u programu se mogu vidjeti relativne važnosti svih ulaznih podataka na izlazne vrijednosti odnosno litološki sastav (**slika 7-4.**).

Kolona	Ime ulaza	Važnost	Relativna važnost
0	SP [mV]	69.5545	
3	R64 [ohmxm]	27.2006	
2	R16 [ohmxm]	6.9292	


Slika 7-4. Relativna važnost ulaznih podataka u neuronskoj mreži za procjenu miocenskih litofacijesa u bušotini A.

Iz **slike 7-4.** vidi se da je krivulja SP-a najvažniji parametar preko koje se neuronska mreža uvježbavala za predviđanje litologije.



Slika 7-5. Uvježbavanje VPM mreže na podacima iz bušotine A. (Na apscisi su dane vrijednosti litologije a vrijednosti na ordinati predstavljaju dubinu naslaga u metrima. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati a izolatorske su limonitizirani uškriljeni glinjaci.)

Mreža je uvježbavana na intervalu od -2153 m do -2228 m. Za uvježbavanje mreže korišteno je 65 ulaznih podataka. Prema vrijednostima pogreške može se zaključiti da je mreža poprilično loše uvježbana i nije uspješno odredila granice slojeva što se može objasniti malim brojem ulaznih podataka. Iz **slike 7-5** vidljivo je da je mreža zamijenila nepropusne slojeve propusnima u intervalu od -2183 m do -2187 m.




Slika 7-6. Predviđanje VPM mrežom u bušotini A. (Na apscisi su dane vrijednosti litologije a vrijednosti na ordinati predstavljaju dubinu naslaga u metrima. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati a izolatorske su limonitizirani uškrljeni glinjaci.)

Na **slici 7-6** prikazan je rezultat predviđanja litologije u bušotini A na dubljem intervalu, od -2228 m do -2282 m. Za određivanje uspješnosti mreže u bušotini A korišteno je 65 podataka. Iz **slike 7-6** vidljivo je da je rezultat predviđanja loš te da mreža nije uspješno odredila granice slojeva kao ni litološki sastav.


7.1.2 Analiza za bušotinu B

Kao i kod prethodne analize za bušotinu A, ulazni podatci korišteni za uvježbavanje umjetne neuronske mreže su vrijednosti spontanog potencijala (SP) i otpornosti (R_{16} i R_{64}) te litološki sastav koji su dobiveni interpretacijom EK-dijagrama. Korišteni ulazni podatci nalaze se u intervalu od dubine EK-markera Rs7 (-2122 m) do dna bušotine (-2327 m) s razmakom od 1 m. U analizi je ukupno obrađeno 205 podataka, od toga 77 s vrijednošću 1 i 128 s vrijednošću 0. Broj 0 predstavlja limonitizirane uškriljene glinjake a broj 1 predstavlja vapnenačke breče, klastične vapnence i brečo-konglomerate.




Slika 7-7. Vrijednosti spontanog potencijala za bušotinu B. (Na apscisi su dane vrijednosti spontanog potencijala u mV a vrijednosti na ordinati predstavljaju dubinu u metrima.)

Kao i u prethodnoj analizi korištena je mreža s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno VPM mreža. Mreža koja se pokazala najuspješnijom kod uvježbavanja i predviđanja miocenskih litofacijesa u bušotini B bila je mreža s postupkom povratne informacije (VPM) sa četiri neurona u prvom skrivenom sloju, pet u drugom i dva u trećem skrivenom sloju (**slika 7-8**) a obilježena je s ukupno 15 658 iteracija i prosječnom pogriješkom koja iznosi 0,016835. Skup podataka za uvježbavanje mreže podijeljen je tako da se jedna polovina skupa koristi za uvježbavanje, a druga polovina za određivanje uspješnosti mreže.



Slika 7-8. Arhitektura umjetne neuronske mreže korištene za procjenu miocenskih litofacijesa u bušotini B.




Slika 7-9. Učenje neuronske mreže u programu JustNN za bušotinu B. (Na ordinati su dane vrijednosti pogreške a vrijednosti na apscisi predstavljaju broj iteracija. Crvena linija predstavlja najveću, zelena linija predstavlja prosječnu a plava linija predstavlja najnižu pogrešku uvježbavanja.)

Na **slici 7-9.** se može vidjeti kako se odvijao proces učenja i kako se s brojem ciklusa učenja smanjivala pogreška. Na kraju procesa procijene litologije, u programu se mogu vidjeti relativne važnosti svih ulaznih podataka na izlazne vrijednosti odnosno litološki sastav (**slika 7-10.**).


Kolona	Ime ulaza	Važnost	Relativna važnost
0	SP [mV]	334.7531	
2	R16 [ohmxm]	91.9282	
3	R64 [ohmxm]	88.9420	

Slika 7-10. Relativna važnost ulaznih podataka u neuronskoj mreži za procjenu miocenskih litofacijesa u bušotini B.

Iz **slike 7-10.** vidi se da je krivulja SP-a i ovdje najvažniji parametar preko koje se neuronska mreža uvježbavala za predviđanje litologije.



Slika 7-11. Uvježbavanje VPM mreže na podacima iz bušotine B. (Na apscisi su dane vrijednosti litologije a vrijednosti na ordinati predstavljaju dubinu naslaga u metrima. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati a izolatorske su limonitizirani uškriljeni glinjaci.)



Slika 7-12. Predviđanje VPM mrežom u bušotini B. (Na apscisi su dane vrijednosti litologije a vrijednosti na ordinati predstavljaju dubinu naslaga u metrima. Ležišne stijene su vapnenačke breče, klastični vapnenci i brečo-konglomerati a izolatorske su limonitizirani uškrljeni glinjaci.)

Mreža je uvježbavana na intervalu od -2122 m do -2224 m s 103 ulazna podatka. Iako je iznos pogreške manji nego u prethodnoj analizi, iz **slike 7-11** vidljivo je da mreža nije uspješno predvidjela granice slojeva što se isto može objasniti veličinom ulaznog skupa podataka te čestim vertikalnim i bočnim promjenama ležišnih stijena u polju Ladislavci. Učenje mreže moglo bi se uvelike poboljšati kada bi se uz vrijednosti krivulja SP-a, R_{16} i R_{64} još koristile vrijednosti krivulja GR-a, promjera bušotine i druge. Na **slici 7-12**

prikazan je rezultat predviđanja litologije u bušotini B na dubljem intervalu od -2224 m do -2327 m. Za provjeru uspješnosti mreže korištena su 102 podataka iz bušotine B. Iz **slike 7-12** vidljivo je da je rezultat predviđanja loš te da mreža nije uspješno odredila granice slojeva kao ni litologiju.

8. ZAKLJUČAK

U ovom diplomskom radu načinjene su dvije umjetne neuronske mreže s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno VPM mreže koje su imale zadatak procjene miocenskih litofacijesa u polju Ladislavci. Uspješnost uvježbavanja i predviđanja umjetnim neuronskim mrežama prikazane su grafički. Za analize pomoću neuronskih mreža vrijedi: što je veći broj ulaznih varijabli i što veći broj slučajeva, rezultati će biti pouzdaniji i mreža će uspješnije učiti, uz bolje predviđanje. Skup podataka za uvježbavanje mreže podijeljen je tako da se jedna polovina skupa koristi za uvježbavanje, a druga polovina za određivanje uspješnosti mreže. Pri toj raspodijeli ulaznih podataka postignuta je niža vrijednost prosječne pogreške nego kad su ulazni podatci podijeljeni na način da se 80 % koristi za uvježbavanje, a preostalih 20 % za određivanje uspješnosti mreže. Mreža koja se pokazala najuspješnijom kod uvježbavanja i predviđanja miocenskih litofacijesa u bušotini A bila je mreža s postupkom povratne informacije (VPM) sa četiri neurona u prvom skrivenom sloju, jedan u drugom i dva u trećem skrivenom sloju a za bušotinu B najuspješnija je bila VPM mreža s četiri neurona u prvom skrivenom sloju, pet u drugom i dva u trećem skrivenom sloju.

Na osnovi rezultata neuronskih analiza može se zaključiti:

- Krivulja SP-a je najvažniji parametar preko kojeg se neuronska mreža uvježbavala za predviđanje litologije te ima oko 3 puta veću relativnu važnost u odnosu na krivulje R_{16} i R_{64} pri uvježbavanju mreže.
- Niti jedna mreža nije uspješno odredila granice slojeva što se može objasniti malim brojem ulaznih podataka i kompleksnom građom ležišta.
- Da bi se dobili bolji rezultati u predviđanju potrebno je koristiti krivulje GR-a (prirodne gama radioaktivnosti), promjera bušotine, kompenzirane gustoće neutrona (CN), karotaže gustoće (DEN) i drugih, koje karakteriziraju litološki sastav.
- Česte vertikalne i bočne promjene ležišnih stijena u polju Ladislavci stvorile su poteškoće pri uvježbavanju i predviđanju neuronskim mrežama.
- Prilikom uvježbavanja mreže u bušotini A, mreža je zamijenila nepropusne slojeve propusnima u intervalu od -2183 m do -2187 m.

- Prilikom uvježbavanja mreže u bušotini B mreža je zamijenila propusne slojeve nepropusnima u intervalu od -2197 m do -2209 m.
- Programska vjerojatnost predviđanja facijesa, odnosno litološkog sastava (na temelju 3 karotažne krivulje) u bušotini A iznosi 61,5 %, dok u bušotini B iznosi 63,1 %.
- U bušotini A postignuto je loše podudaranje predviđenoga i stvarnoga položaja limonitiziranih uškriljenih glinjaka koje iznosi 46,6 % te loše podudaranje predviđenoga i stvarnoga položaja vapnenačkih breča koje iznosi 67,3 %.
- U bušotini B postignuto je loše podudaranje predviđenoga i stvarnoga položaja limonitiziranih uškriljenih glinjaka koje iznosi 63,1 % te loše podudaranje predviđenoga i stvarnoga položaja vapnenačkih breča koje iznosi 58,18 %.

Iako dobiveni rezultati ne ukazuju na veliki potencijal u korištenju neuronskih mreža u naftnogeološkim istraživanjima gdje bi se neuronske mreže koristile za dobivanje brzih rješenja iz karotažnih dijagrama one ipak nisu beskorisne. Problem koji je uočen ovdje, a za primjenu takvih mreža, je mala debljina pojedinačnih ležišta. Posljedično, i broj ulaznih podataka bit će mali za primjenu takvih alata, pa će i pogreška procjene i selekcije biti relativno velika.

Drugi problem je što pješčenjačka ležišta u hrvatskom dijelu Panonskoga bazenskoga sustava nisu homogena, posebice u krovinskom i podinskom dijelu. Time će i krivulje imati drugačiji razvoj i ne mogu izravno predstavljati svojstva pješčenjaka u središnjem dijelu ležišta. No, kako one zbog maloga broja podataka nisu razlikovane s drugačijim težinskim vrijednostima u različitim dijelovima ležišta, i njihova pogreška kada se cijeli takav ulazni skup promatra jedinstveno, bit će kod učenja neuronske mreže veća i multiplicirana.

Prikazana analiza dokazala je da se ovakav tip mreža može koristiti u opisanim ležištima polja Ladislavci kao pomoćni alat u onim intervalima ležišta koji nisu snimljeni električnom karotažom ili jezgrovani, a želi se dobiti njihov približan litološki sastav. Takvi intervali unutar cjelokupno promatranog ležišta ne smiju prelaziti polovicu njegove ukupne debljine.

9. LITERATURA

Objavljeni radovi:

BOLF, N., JERBIĆ, I. (2006): Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa. *Kemija u industriji*. 55 (11), 457-466.

BROD, I. O. (1945): Geological terminology in classification of oil and gas accumulation. *AAPG Bulletin*, 29, 12, 1738-1755.

BROD, I. O. and JEREMENKO, N. A. (1957): *Osnovi geologii niefti i gasa*. Izdanie tretie, Gostoptehizdat, Moskva.

CVETKOVIĆ, M., VELIĆ, J., MALVIĆ, T. (2008): Neural network prediction of the reservoir properties on the Klostar oil field. XII. Congress of hungarian geomathematics and the first congress of croatian and hungarian geomathematics. Morahalom, Mađarska.

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, Mađarska.

CVETKOVIĆ, M., VELIĆ, J. (2012): Successfulness of inter well lithology prediction on Upper Miocene sediments with artificial neural networks. 4th Croatian-Hungarian and 15th Hungarian geomathematical congress, Opatija, Hrvatska. Zagreb: Geomathematics as geoscience, Hrvatsko geološko društvo, 13-20.

CVETKOVIĆ, M., VELIĆ, J., MALVIĆ, T. (2012): Application of Artificial Neural Networks on Well Log Data for Lithofacies Mapping of Pliocene, Pleistocene and Holocene Sediments in Sava Depression, Pannonian Basin, Croatia. XI th International Conference on Geoinformatics –Theoretical and Applied Aspects, Kiev, Ukraine. Kiev, Ukraine – Geoinformatics 2012 Kyiv : EAGE, 2012, 1-5.

CVETKOVIĆ, M., VELIĆ, J. (2013): Lithology prediction by artificial neural networks and preparation of input data on Upper Miocene sediments. Theories and applications in geomathematics. GeoLitera, Institute of Geosciences, University of Szeged, 2013, 9-14.

Malvić, T. (2006): Clastic facies prediction using neural network (case study from Okoli field) Predviđanje klastičnih facijesa neuronskom mrežom (primjer polja Okoli). *Nafta*, 57, 10, 415–431

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.

MALVIĆ, T., CVETKOVIĆ, M. (2008): Hrvatsko - hrvatski rječnik iz primjene neuronskih mreža u geologiji. (Croatian - Croatian dictionary from application of neural network in geology). Vijesti Hrvatskoga geološkog društva, 45, 43-46.

MALVIĆ, T., CVETKOVIĆ, M. (2009): Neuronski alati u geologiji ležišta ugljikovodika. Hrvatsko geološko društvo (Geomat. odsjek), Sveučilište u Zagrebu (RGN fakultet), priručnik, Zagreb, 100 str.

MALVIĆ, T., CVETKOVIĆ, M. (2013): Neuronski alati u geologiji ležišta ugljikovodika, II. izdanje. Hrvatsko geološko društvo (Geomat. odsjek), Sveučilište u Zagrebu (RGN fakultet), sveučilišni priručnik, Zagreb, 89 str.

ROSENBLATT, F. (1957): The perceptron: A perceiving and recognizing automaton. Technical report 85-460-1, Project PARA, Cornell Aeronautical Lab.

ROSENBLATT, F. (1958): The perceptron A probabilistic model for information storage and organization in the brain. Psychological Review, 65, 386–408.

ŠUMANOVAC, F. (2007): Geofizička istraživanja podzemnih voda, Sveučilište u Zagrebu (RGN fakultet), udžbenici Sveučilišta u Zagrebu, Zagreb, 244 str.

Neobjavljeni radovi:

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.

BALIĆ, D. (1993): Odabrana poglavlja iz interpretacije karotažnih dijagrama : (kratki tečaj za geologe na bušotini). Skripta za internu upotrebu umnožena fotokopiranjem. INA – Industrija nafte NAFTAPLIN.

KOSOVEC, Z. (1995): O produktivnom kompleksu nafte na polju Ladislavci, Sveučilište u Zagrebu (RGN fakultet), diplomski rad, Zagreb.

INTERNETSKI IZVORI

DALBELO-BAŠIĆ, B., ČUPIĆ, M., ŠNAJDER, J. (2008): Umjetne neuronske mreže. Nastavni materijali za kolegij Umjetna inteligencija, Fakultet elektrotehnike i računalstva Zagreb, 2008. URL: www.fer.hr/download/repository/UmjetneNeuronskeMreze.pdf. (18.6.2017.)

LONČARIĆ, S. (2016): Predavanja. URL : www.fer.unizg.hr/predmet/neumre_a/predavanja (18.6.2017.)

KORIŠTENI RAČUNALNI PROGRAMI :

„JustNN“ (<http://www.justnn.com/>) (8.9.2017).