

Predikcija PVT svojstava neuronskom mrežom

Pavić, Marčelo

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://um.nsk.hr/um:nbn:hr:169:299292>

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

Download date / Datum preuzimanja: **2024-04-20**



Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
Diplomski studij Naftnog rudarstva

PREDIKCIJA PVT SVOJSTAVA NEURONSKOM MREŽOM

Diplomski rad

Marčelo Pavić

N164

Zagreb, 2017

Predikcija PVT svojstava neuronskom mrežom

Marčelo Pavić

Rad je izrađen na: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za naftno inženjerstvo
Pierottijeva 6, 10 000 Zagreb

Sažetak

Umjetne neuronske mreže su nova tehnologija koja je nastala kao pokušaj oponašanja rada ljudskog mozga, a našla je primjenu u rješavanju složenih nelinearnih problema na mnogo različitih područja. U ovom radu su neuronske mreže korištene za predikciju pVT (engl. *pressure-volume-temperature*) svojstava nafte iz polja Žutica. Mreže su trenirane na tri različita seta podataka, za predikciju volumnog faktora nafte, plinskog faktora i tlaka zasićenja nafte. Napravljeno je ukupno 28 različitih modela neuronskih mreža, a razlikuju se po arhitekturi, broju iteracija, stopi učenja i broju podataka u setu za treniranje, kalibraciju i verifikaciju.

Ključne riječi: predikcija, pVT, neuronska mreža, neuroni, nepovratna mreža, aktivacijska funkcija

Završni rad sadrži: 82 stranice, 50 tablica, 56 slika, 6 priloga, i 31 referencu.

Jezik izvornika: Hrvatski

Pohrana rada: Knjižnica Rudarsko-geološko-naftnog fakulteta, Pierottijeva 6, Zagreb

Mentori: Dr.sc. Domagoj Vulin, izvanredni profesor RGNF-a

Ocjenjivači: Dr.sc. Domagoj Vulin, izvanredni profesor RGNF-a
Dr.sc. Tomislav Kurevija, izvanredni profesor RGNF-a
Dr.sc. Luka Perković, docent RGNF-a

Prediction of PVT properties with neural networks

Marčelo Pavić

Thesis completed at: University of Zagreb
Faculty of mining, Geology and Petroleum Engineering
Petroleum Engineering
Pierottijeva 6, 10 000 Zagreb

Abstract

Artificial neural networks are new technology which was developed to simulate human brain and it is used for solving difficult nonlinear problems in many different areas. In this thesis neural networks are used for predicting of PVT (pressure-volume-temperature) properties of oil from Žutica field. Three different data sets were used for training neural networks for prediction of oil formation volume factor, solution gas-oil ratio and bubble point pressure. It was produced 28 different models of neural networks, based on different architecture, number of learning cycles, learning rates or number of data in training, cross-validate or test sets.

Keywords: prediction, pVT, neural network, neuron, feedforward, activation function

Thesis contains: 82 pages, 50 tables, 56 figures, 6 appendixes, and 31 references.

Original in: Croatian

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

Supervisors: PhD Domagoj Vulin, Associate Professor

Reviewers: PhD Domagoj Vulin, Associate Professor
PhD Tomislav Kurevija, Associate Professor
PhD Luka Perković, Assistant Professor

SADRŽAJ

1. UVOD	1
2. UMJETNE NEURONSKE MREŽE	2
2.1. Umjetna inteligencija	2
2.2. Umjetne neuronske mreže	2
2.2.1. Povijest umjetnih neuronskih mreža	2
2.2.2. Model bioloških neuronskih mreža	3
2.2.3. Model umjetnih neuronskih mreža	4
2.2.4. Umjetni neuroni	5
2.2.4.1. McCulloch-Pittsov model umjetnog neurona	5
2.2.4.2. Perceptron	6
2.2.5. Težinski koeficijenti	7
2.2.6. Prednaponski koeficijent	7
2.2.7. Stopa učenja	7
2.2.8. Aktivacijske funkcije	8
2.2.8.1. Funkcije praga ili skoka	8
2.2.8.2. Parcijalno linearna funkcija	9
2.2.8.3. Sigmoidalna ili logistička funkcija	10
2.2.9. Funkcioniranje neuronske mreže	10
2.2.9.1. Setovi podataka u neuronskim mrežama	11
2.2.9.2. Pretprocesiranje ili skaliranje podataka	12
2.2.9.3. Iteracije i epohe	12
2.2.9.4. Pojedinačno i grupno učenje	13
2.2.10. Podjela neuronskih mreža	13
2.2.10.1. Podjela prema broju slojeva	13
2.2.10.2. Podjela prema načinu povezivanja neurona	14
2.2.10.3. Podjela prema načinu učenja ili treninga	15
2.2.10.4. Podjela prema smjeru kretanja informacija	15
2.2.10.5. Podjela prema vrsti podataka	16
2.2.11. Višeslojne perceptronske mreže	17
2.2.12. Radijalno temeljene funkcijske mreže	17
2.2.13. Algoritam povratnog propagiranja	17
2.3. PRIMJENE NEURONSKIH MREŽA U NAFTNOM INŽENJERSTVU	18

2.3.1.	Obrada slike te primjena u 3D seizmici	19
2.3.2.	Predviđanja propusnosti i šupljikavosti	20
2.3.3.	Optimizacija.....	21
2.3.4.	Karakterizacija ležišta.....	22
2.3.5.	Predviđanje PVT svojstava neuronskim mrežama	23
3.	PODATCI I RAČUNALNI PROGRAM KORIŠTENI PRI IZRADI OVOG RADA	27
3.1.	Podatci	27
3.1.1.	Prvi set podataka – volumni faktor nafte	27
3.1.2.	Drugi set podataka – plinski faktor	27
3.1.3.	Treći set podataka – tlak zasićenja nafte.....	28
3.1.4.	Odabir podataka	28
3.2.	Software	28
3.2.1.	Unos podataka.....	28
3.2.2.	Podešavanje neuronske mreže za učenje	29
3.2.3.	Učenje neuronske mreže	30
4.	ANALIZA I REZULTATI	32
4.1.	Predikcija volumnog faktora nafte.....	32
4.2.	Predikcija plinskog faktora	40
4.3.	Predikcija tlaka zasićenja nafte.....	47
5.	ZAKLJUČAK	56
6.	LITERATURA	57
7.	DODACI	60
7.1.	Specifične vrijednosti neurona za volumni faktor nafte (B_o)	60
7.2.	Specifične vrijednosti neurona za plinski faktor (R_s)	65
7.3.	Specifične vrijednosti neurona za tlak zasićenja nafte (p_b)	70
7.4.	Prvi set podataka – Volumni faktor nafte (B_o)	75
7.5.	Drugi set podataka – Plinski faktor (R_s)	82
7.6.	Treći set podataka – Tlak zasićenja nafte (p_b)	84

POPIS SLIKA

Slika 2-1	Shematska skica građe neurona	3
Slika 2-2	McCulloch-Pittsov model umjetnog neurona	5
Slika 2-3	Perceptron	7

Slika 2-4 Aktivacijska funkcija tipa praga	9
Slika 2-5 Parcijalno linearna aktivacijska funkcija	9
Slika 2-6 Sigmoidna aktivacijska funkcija	10
Slika 2-7 Odstupanje stvarnog izlaza kroz iteracije	11
Slika 2-8 Jednoslojna mreža (a) i višeslojna mreža (b)	13
Slika 2-9 Primjeri acikličke i cikličke mreže.....	14
Slika 2-10 Djelomično i potpuno povezane mreže.....	14
Slika 2-11. Usporedba propusnosti dobivene mjerenjima iz jezgre te predikcijom pomoću neuronske mreže za bušotinu 1110 Big Injun ležišta	23
Slika 3-1 Prozor za odabir broja skrivenih slojeva i najvećeg dopuštenog broja neurona..	29
Slika 3-2 Podešavanje kontrolnih opcija neuronske mreže	30
Slika 3-3 Shematska skica neuronske mreže u JustNN-u.....	31
Slika 3-4 Redoslijed važnosti ulaznih varijabli	31
Slika 3-5 Graf učenja.....	31
Slika 4-1 Graf koeficijenata korelacije (R).....	32
Slika 4-2 Graf najveće prosječne apsolutne greške ($E_{\max}$)	33
Slika 4-3 Graf prosječne apsolutne postotne greške (E_a)	33
Slika 4-4 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1	36
Slika 4-5 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2	37
Slika 4-6 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1.....	37
Slika 4-7 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-7	37
Slika 4-8 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-2	38
Slika 4-9 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1-1.....	38
Slika 4-10 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-3-1.....	38
Slika 4-11 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1-1-1	39

Slika 4-12 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-3-2-1	39
Slika 4-13 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-1	39
Slika 4-14 Graf usporedbe vrijednosti $E_{\max}$, E_a i R za tri iste arhitekture koje su učene 10000 i 100000 iteracija	40
Slika 4-15 Graf koeficijenata korelacije (R) za analizu predikcije plinskog faktora	41
Slika 4-16 Graf najveće postotne apsolutne greške ($E_{\max}$) za plinski faktor	41
Slika 4-17 Graf prosječne apsolutne postotne greške (E_a) za plinski faktor	41
Slika 4-18 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-1-100k.....	44
Slika 4-19 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-2-100k.....	44
Slika 4-20 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-100k.....	44
Slika 4-21 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-2-10k.....	45
Slika 4-22 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-3-100k	45
Slika 4-23 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-3-3-100k	45
Slika 4-24 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-1-10k.....	46
Slika 4-25 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-10k.....	46
Slika 4-26 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-1-10k	46
Slika 4-27 Koeficijenti korelacije (R) za p_b	47
Slika 4-28 Najveće prosječne apsolutne greške ($E_{\max}$) za p_b	48
Slika 4-29 Prosječne apsolutne postotne greške (E_a) za p_b	48
Slika 4-30 Usporedba osjetljivosti predikcije volumnog faktora nafte i tlaka zasićenja na ulazne parametre.....	49
Slika 4-31 Usporedba koeficijenata korelacije za predikciju različitih parametara na mrežama s različitim brojem iteracija	49

Slika 4-32 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-1-10k.....	52
Slika 4-33 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-10k.....	53
Slika 4-34 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-3-10k.....	53
Slika 4-35 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-10k	53
Slika 4-36 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-10k	54
Slika 4-37 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-SU	54
Slika 4-38 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-1M	54
Slika 4-39 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-TS+5	55
Slika 4-40 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-SU04.....	55

POPIS TABLICA

Tablica 2-1 Najčešće vrste neuronskih mreža	16
Tablica 2-2 Statistička analiza rezultata različitih empirijskih korelacija.....	25
Tablica 2-3 Rezultati neuronske mreže i korelacija za tlak zasićenja	26
Tablica 2-4 Rezultati neuronske mreže i korelacija za volumni faktor nafte.....	26
Tablica 3-1. Karakteristične vrijednosti prvog seta podataka	27
Tablica 3-2 Karakteristične vrijednosti drugog seta podataka	27
Tablica 3-3 Karakteristične vrijednosti drugog seta podataka	28
Tablica 4-1 Postavke za učenje mreže – volumni faktor nafte.....	33
Tablica 4-2 Pogreške na trening setu – volumni faktor nafte.....	34
Tablica 4-3 Uspješnost kalibracije – volumni faktor nafte.....	35
Tablica 4-4 Osjetljivost predikcije na ulazne varijable – volumni faktor nafte	35
Tablica 4-5 Statistički rezultati analize – volumni faktor nafte.....	35
Tablica 4-6 Postavke za učenje mreže – Plinski faktor	42

Tablica 4-7 Pogreške na trening setu – Plinski faktor	42
Tablica 4-8 Uspješnost kalibracije – Plinski faktor	42
Tablica 4-9 Osjetljivost predikcije na ulazne varijable – Plinski faktor.....	43
Tablica 4-10 Statistički rezultati analize – Plinski faktor	43
Tablica 4-11 Postavke za učenje mreže – Tlak zasićenja nafte.....	50
Tablica 4-12 Pogreške na trening setu – Tlak zasićenja nafte.....	50
Tablica 4-13 Uspješnost kalibracije – Tlak zasićenja nafte	50
Tablica 4-14 Osjetljivost predikcije na ulazne varijable – Tlak zasićenja nafte	51
Tablica 4-15 Statistički rezultati analize – Tlak zasićenja nafte	52
Tablica 7-1 B_o NN-1	60
Tablica 7-2 B_o NN-2	60
Tablica 7-3 B_o NN-1-1	61
Tablica 7-4 B_o NN-2-1	61
Tablica 7-5 B_o NN-3-1	62
Tablica 7-6 B_o NN-1-1-1	62
Tablica 7-7 B_o NN-3-1-2	63
Tablica 7-8 B_o NN-2-1-7	63
Tablica 7-9 B_o NN-2-1-2	64
Tablica 7-10 B_o NN-2-1-1	65
Tablica 7-11 R_s NN-1	65
Tablica 7-12 R_s NN-2	66
Tablica 7-13 R_s NN-3	66
Tablica 7-14 R_s NN-2-10k.....	67
Tablica 7-15 R_s NN-3-3-100k	67
Tablica 7-16 R_s NN-3-3-3-100k	68
Tablica 7-17 R_s NN-1-10k.....	68
Tablica 7-18 R_s NN-3-10k.....	69
Tablica 7-19 R_s NN-3-1-10k	69
Tablica 7-20 p_b NN-1-10k	70
Tablica 7-21 p_b NN-2-10k	70
Tablica 7-22 p_b NN-3-10k	71
Tablica 7-23 p_b NN-2-1-10k.....	71
Tablica 7-24 p_b NN-2-1-6-10k	72
Tablica 7-25 p_b NN-2-1-6-SU	73

Tablica 7-26 p_b NN-2-1-6-1M.....	73
Tablica 7-27 p_b NN-2-1-6-TS+5	74
Tablica 7-28 p_b -NN-2-1-6-SU04.....	75

POPIS KORIŠTENIH OZNAKA I JEDINICA

Oznaka	Jedinica	Opis
B_o	m^3/m^3	volumni faktor nafte
R_s	m^3/m^3	plinski faktor
p_b	bar	tlak zasićenja
γ_g	-	relativna gustoća plina
γ_o	-	relativna gustoća nafte
T	°C	temperatura
E_r	-	prosječna postotna relativna pogreška
E_a	-	prosječna postotna apsolutna relativna pogreška
E_{min}	-	najmanja prosječna apsolutna postotna relativna pogreška
E_{max}	-	najveća prosječna apsolutna relativna pogreška
E_{rms}	-	standardno odstupanje
R	-	koeficijent korelacije

1. UVOD

Korištenje umjetne neuronske mreže se sve češće razmatra kao opcija za predviđanja u istraživanju ugljikovodika, tj. općenito u analizama građe podzemlja i fluida koje sadrže. Takva razmatranja su povezana s brojem dostupnih podataka, pošto pouzdanost predikcije mrežom raste s brojem podataka za treniranje same mreže.

PVT parametri mogu biti pogodni za primjenu neuronskih mreža iz više razloga:

1. Uzorci za PVT analize se uzimaju redovito
2. Jednadžbe stanja se primjenjuju najčešće kod sofisticiranih modela podzemlja i potrebno ih je pažljivo definirati, što znači da tablično računate vrijednosti volumnih i plinskih faktora, viskoznosti i sl. još uvijek imaju veliku primjenu
3. Korelacije PVT svojstava primijenjene na stvarne uvjete često daju prevelike pogreške. Nakon toga moguće ih je korigirati, međutim takav proces je skoro jednako mukotrpan kao i izrada (tj. prilagodba parametara) jednadžbe stanja.
4. Neuronska mreža može nadvladati probleme različitosti sastava u jednom ležištu te slične nekonzistencije koje je izuzetno teško (ako ne i nemoguće) nadvladati primjenom jednadžbe stanja i korelacija.

Stoga je motivacija rada bila analizirati međusobnu ovisnost PVT parametara. Hipoteza glasi: treniranjem neuronske mreže na velikom broju podataka računatih korelacijom može se lako na kraju očitati težinske množitelje (engl. *weights*) između neurona u izrađenoj mreži, te se iz istog može jednoznačno vidjeti osjetljivost zavisnih parametara na promjenu pojedine nezavisne varijable u korelaciji.

2. UMJETNE NEURONSKE MREŽE

2.1. Umjetna inteligencija

Umjetna ili virtualna inteligencija može se definirati kao kolekcija novih analitičkih alata koji pokušavaju imitirati život te pokazuju mogućnost učenja i snalaženja u novim situacijama.

Cilj umjetne inteligencije je imitacija ljudskog mozga tj. stvaranje njegovog umjetnog oblika jer je u ljudskom mozgu sadržan maksimum inteligencije koju danas, a možda i uopće, možemo spoznati (Dalbelo-Bašić et al., 2008).

Umjetne neuronske mreže, evolucijsko programiranje te neizravna (engl. *fuzzy*) logika su tri glavna pristupa rješavanja problema umjetnom inteligencijom. Ove tehnike posjeduju jednu ili više karakteristika „razuma“, kao što su generalizacija, otkrivanje, pridruživanje te apstrakcija. U posljednjem desetljeću, umjetna inteligencija sazrela je u skup analitičkih alata koji olakšavaju rješavanje problema koji su prije bili presloženi ili nemogući za rješavanje. Trenutni trend je integracija ovih alata međusobno te s konvencionalnim alatima, kao što je statistička analiza, da bi se izgradili složeni sistemi koji mogu rješavati izazovne probleme. Ovi alati sada se koriste u mnogo različitih disciplina te su našli svoju primjenu u komercijalnim proizvodima (Mohaghegh, 2000).

2.2. Umjetne neuronske mreže

2.2.1. Povijest umjetnih neuronskih mreža

Ideja umjetnih neuronskih mreža nastala je 1943. godine kada su McCulloch i Pitts (s američkog sveučilišta MIT) objavili matematički model neuronske mreže utemeljen na funkcioniranju živčanog sustava živih bića. Međutim, zbog sporosti tadašnjih računala neuronske mreže su praktičnu primjenu dobile tek krajem pedesetih godina 20. stoljeća.

Rosenblatt je 1957. godine osmislio perceptron. Dokazao je da će dajući perceptronu linearno odvojive klase, on u konačnom broju ciklusa treninga razviti težinski faktor koji će razvrstati klase (zadatak klasifikacije uzorka). Također je pokazao da početna vrijednost težinskog faktora neće utjecati na njegovu tvrdnju.

U približno isto vrijeme, Widrow je razvio sličnu mrežu nazvanu Adeline. Rosenblatt je također proučavao strukture s više od jednog sloja (engl. *layer*), vjerujući da bi one mogle savladati ograničenja jednostavnih perceptrona. Kakogod, nije bio poznat algoritam za učenje koji bi odredio težinske faktore potrebne za izvršavanje zadanog


izračuna. Minsky i Papert su sumnjali da takav uopće može biti napravljen te su preporučivali traženje drugog pristupa umjetnoj inteligenciji. Povodeći se za ovom tvrdnjom, većina istraživača s tog područja je idućih 20 godina zapostavila paradigmu neuronskih mreža.

U ranim osamdesetim godinama 20. st. Hopfield je oživio istraživanje neuronskih mreža. Njegovo istraživanje podudarilo se s razvojem novih algoritama za učenje, kao što je metoda povratnog propagiranja. Od devedesetih godina neuronske mreže preuzimaju primat razvoja inteligentnih sustava, stvaraju se novi algoritmi te se istražuje međudnos neuronskih mreža i arhitekture računala koja je još uvijek sekvencijalna, za razliku od mozga koji podatke obrađuje paralelno, a cilj svega toga je učinkovitija implementacija umjetnih neuronskih mreža (Mohaghegh, 2000; Dalbelo-Bašić et al., 2008).

2.2.2. Model bioloških neuronskih mreža

Umjetna neuronska mreža (UNM) sustav je za obradu informacija koji ima određene karakteristike svojstvene biološkoj neuronskoj mreži. Zbog toga ćemo ukratko opisati biološku neuronsku mrežu prije nego definiramo umjetnu neuronsku mrežu.

Svi živući organizmi sastoje se od stanica. Osnovne građevne jedinice živčanog sustava su živčane stanice koje nazivamo neuronima. Tipični neuron sastoji se od tijela stanice (gdje se nalazi jezgra), dendrita te aksona (slika 2-1).



Slika 2-1 Shematska skica građe neurona (Dalbelo-Bašić et al., 2008)

Neuron prima informacije preko sinapsa koje su spojno sredstvo ili most između dva neurona, tj. njihovih dendrita, a one utječu na potencijal stanice povećavajući ga

(hiperpolarizacija) ili smanjujući ga (depolarizacija). U tijelu stanice se zbrajaju potencijali ulaznih vrijednosti susjednih neurona ako je vrijeme dolaska ulaznih vrijednosti unutar određenog vremenskog intervala, te se, ako je suma potencijala veća od određene granične vrijednosti, neuron aktivira ili uzbuđuje i stvara akcijski potencijal koji traje 1 ms. Signal se njime prenosi preko aksona do sinapsi, a one ovisno o vrijednosti potencijala stvaraju i otpuštaju neurotransmitere. Ako je napon niži od određene granice, neuron prelazi u represivno stanje te ne šalje impuls na akson. Isto se ponavlja u sljedećim neuronima iz čega se da zaključiti da je propagacija impulsa jednosmjerna (Dalbelo-Bašić et al., 2008).

Pretpostavlja se da ljudski mozak sadrži od 10 do 500 milijardi neurona. Ovi neuroni su podijeljeni u module, a svaki modul sadrži približno 500 neuronskih mreža. Svaka mreža može sadržavati približno 100000 neurona, gdje je svaki neuron spojen sa stotinama ili tisućama ostalih neurona. Ovakva arhitektura je glavna pokretačka sila složenog čovjekovog ponašanja koje ljudi uzimaju zdravo za gotovo. Jednostavni zadaci kao što je hvatanje lopte, ispijanje čaše vode ili šetanje kroz gužvu, zahtijevaju jako puno složenih i koordiniranih izračuna koje suvremena računala nisu u stanju izvesti, ali čovjek ih radi rutinski i nesvjesno. Ovo postaje još zanimljivije kad shvatimo da neuroni u ljudskom mozgu imaju vrijeme ciklusa ili odaziva od približno 10 do 100 milisekundi, dok se vrijeme ciklusa običnog stolnog računala mjeri u nanosekundama. Ljudski mozak, iako milijune puta sporiji od stolnih računala, može izvesti mnogo zadataka pri brzinama koje su nekoliko redova veličine brže od računala zbog svoje masivne paralelne arhitekture (Mohaghegh, 2000).

2.2.3. Model umjetnih neuronskih mreža

Umjetne neuronske mreže su sustavi za obradu informacija koji su zapravo gruba aproksimacija i pojednostavljenje složenog biološkog procesa te imaju učinak sličan onom bioloških neuronskih mreža, dakle sposobne su riješiti složene nesekvencijalne zadatke kao što su učenje, optimiranje ili prepoznavanje. Razvijene su kao poopćenja matematičkih modela ljudske kognitivne ili živčane biologije temeljenih na sljedećim pretpostavkama:

- Obrada informacija se događa u mnogo jednostavnih elemenata koji se zovu neuroni
- Signali se prenose između neurona preko sinapsa
- Svaka veza ima pridruženu težinu, koja, u tipičnoj neuronskoj mreži, umnožava signal koji se prenosi


- Svaki neuron primjenjuje aktivacijsku funkciju (obično nelinearnu) na svoje ulazne signale da bi odredio svoj izlazni signal (Dalbelo-Bašić et al., 2008)

2.2.4. Umjetni neuroni

Neuroni, ekvivalenti neurona u biološkim neuronskim mrežama, su općenito jednostavni sustavi koji primaju određeni broj ulaznih signala te temeljeno na ulaznim podacima ili stvaraju signal ili ne. Izlazni signal pojedinog neurona šalje se ostalim neuronima (a moguće i nazad u neuron iz kojeg je proizašao) kao ulazni signal preko veza između neurona (Ali, 1994).

2.2.4.1. McCulloch-Pittsov model umjetnog neurona

McCulloch-Pittsov model umjetnog neurona (engl. *Threshold Logic Unit* – TLU) (slika 2-2) koristi signale koji su indeksirani indeksom „i“ čija je vrijednost od 0 do n te imaju numeričke vrijednosti (x_i) koje se na ulazu u neuron množe težinskim faktorima (w_i), koji predstavljaju jakost sinapse, a daju izlazni signal (o) ako je suma umnoška signala i težinskih faktora veća od definirane granice. Pri tome tijelo neurona ima ulogu zbrajala (Σ), a na aksonu je aktivacijska funkcija (ϕ) (Dalbelo-Bašić et al., 2008).



Slika 2-2 McCulloch-Pittsov model umjetnog neurona

(https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/ 12.1.2017. / 15:06)

$$o = \phi(\sum_{i=0}^n w_i x_i) \quad (2-1)$$

gdje su:

φ	- aktivacijska funkcija
n	- broj ulaznih podataka
w_i	- vrijednost težinskog faktora
x_i	- ulazna vrijednost
o	- izlazna vrijednost

2.2.4.2. Perceptron

Perceptron (slika 2-3) je najjednostavniji oblik umjetnog neurona koji omogućava klasifikaciju samo linearno odvojivih razreda, a osmislio ga je Rosenblatt 1957. godine. Kao aktivacijsku funkciju ima funkciju praga. Učenje perceptrona odvija se na vrlo jednostavnom principu. Za svaki primjer koji se sastoji od ulazne vrijednosti (x) te željene izlazne vrijednosti (t), perceptron daje izlaz (o) čija je vrijednost 0 ako je suma umnožaka ulaznih vrijednosti i odgovarajućih težinskih faktora manja od 0 ili 1 ako je ista suma veća ili jednaka 0. Razlika između željene izlazne vrijednosti i izlaza iz perceptrona ukazuje na potrebu korigiranja težinskih koeficijenata.

(https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/

12.1.2017. / 15:06)


$$w_i \leftarrow w_i + \Delta w_i \quad (2-2)$$

$$\Delta w_i = \eta(t - o)x_i \quad (2-3)$$

gdje su:

w_i	- težinski koeficijent
Δw_i	- promjena težinskog koeficijenta
t	- željena izlazna vrijednost
o	- izlazna vrijednost
η	- stopa učenja
x_i	- ulazna vrijednost

Stopa učenja mora biti dovoljno malena da bi algoritam konvergirao u konačnom broju koraka. Osim toga, primjeri za učenje moraju biti linearno odvojivi.



Slika 2-3 Perceptron (https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/12.1.2017. / 15:06)

2.2.5. Težinski koeficijenti

Težinski koeficijenti, koji su analogija jakosti sinapse u biološkim neuronskim mrežama, su promjenjive vrijednosti čija je uloga približavanje izlaznih vrijednosti željenim vrijednostima, a kada se dosegne određena zadovoljavajuća preciznost oni se više ne mijenjaju. Vrijednost im iznosi od -1 do +1.

2.2.6. Prednaponski koeficijent

Neuroni skrivenih i izlaznih slojeva (engl. *hidden layers* i *output layers*) osim težinskih koeficijenata koriste i koeficijent prednapona u računanju mrežnih ulaznih vrijednosti, a ima konstantnu vrijednost jedan. (<http://solair.eunet.rs/~ilicv/neuro.html> 10.01.2017./ 21:39)

2.2.7. Stopa učenja

Stopa učenja (engl. *learning rate*) bitan je čimbenik brze i ispravne konvergencije algoritma, a ovisno o njezinoj vrijednosti moguća su tri ishoda:

- 1) U slučaju da je stopa učenja jako mala, mreža će sporo i monotono konvergirati prema idealnom težinskom koeficijentu.

- 2) Ako imamo veliku stopu učenja doći će do njenog alterniranja, a to znači da će mreža varirati ispod i iznad idealne vrijednosti težinskog koeficijenta, ali će joj se svakog puta sve više približavati.
- 3) Treći slučaj, kada je vrijednost stope učenja veća od njene maksimalne vrijednosti, najgori je te rezultira divergencijom algoritma, odnosno vrijednost težinskog koeficijenta se sve više udaljava od njegove idealne vrijednosti (Dalbello-Bašić et al., 2008).

2.2.8. Aktivacijske funkcije


Aktivacijske funkcije mogu biti linearne, koje se u principu ne koriste jer se kod linearnih funkcija suma umnožaka ulaznih signala i težinskih koeficijenata množi s nekom vrijednosti te se tako dobiva izlazna vrijednost neurona, i nelinearne koje omogućuju mreži da nauči nelinearne funkcije, bez koje bi neuronske mreže bile poput obične perceptronske mreže koja se sastoji samo od ulaza i izlaza. Nelinearnost čini mreže izrazito moćnima te se može koristiti skoro svaka nelinearna funkcija. Najčešće aktivacijske funkcije su funkcije praga, sigmoidne, arcus-tangens, tangens-hiperbolične, gausove funkcije te harmonične funkcije.

Neuronima izlaznog sloja pridružuju se aktivacijske funkcije koje odgovaraju raspodjeli željenih vrijednosti. (<http://solair.eunet.rs/~ilicv/neuro.html> 10.01.2017./ 21:39; http://matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf 13.01.2017 / 17:09)

2.2.8.1. Funkcije praga ili skoka

Funkcija praga je aktivacijska funkcija koja se koristi u modelu perceptrona, a funkcionira tako da sve vrijednosti funkcije iznad određene vrijednosti ili praga primaju fiksnu vrijednost 1, a sve vrijednosti manje od praga primaju vrijednost 0, što znači da funkcija praga daje Booleov izlaz iz neurona. Jednadžba i graf funkcije praga (slika 2-4) su dane ispod. (http://matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf 13.01.2017. / 17:09)

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2-4)$$




Slika 2-4 Aktivacijska funkcija tipa praga (preuređeno od Dalbelo-Bašić et al., 2008)

2.2.8.2. *Parcijalno linearna funkcija*

Postoje i parcijalno linearne funkcije (engl. *piecewise linear function*) koje se koriste u Adaline tipu neurona kad mu je izlaz ograničen na određeni interval za koji je izlaz linearan dok vrijednosti ispod i iznad intervala prelaze u minimalne ili maksimalne vrijednosti (slika 2-5). Opći oblik funkcije ima dvije granice za ulaz koje obično iznose -0,5 i +0,5 te 0 i 1 kao vrijednosti za izlaz izvan granica. (http://matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf 13.01.2017. /17:09)

$$f(x) = \begin{cases} 1, & x \geq b \\ x + b, & a < x < b \\ 0, & x \leq a \end{cases} \quad (2-5)$$




Slika 2-5 Parcijalno linearna aktivacijska funkcija (preuređeno od Dalbelo-Bašić et al., 2008)

2.2.8.3. Sigmoidalna ili logistička funkcija

Najčešći oblik prijenosne funkcije je sigmoidalna prijenosna funkcija (slika 2-6) koja je za razliku od prethodnih funkcija derivativna, a ima sljedeći oblik:

$$F(x) = \frac{1}{1+e^{-ax}} \quad (2-6)$$

Pri tome je „a“ parametar nagiba čijim se smanjenjem povećava interval linearnosti. Ova funkcija slična je funkciji praga, a razlikuje ju to što dozvoljava područje nesigurnosti unutar određenog intervala te ju zbog toga najčešće koristimo. (http://matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf 13.01.2017./ 17:09)



Slika 2-6 Sigmoidna aktivacijska funkcija (preuređeno od Dalbelo-Bašić et al., 2008)


2.2.9. Funkcioniranje neuronske mreže

Umjetna neuronska mreža skup je neurona koji su raspoređeni na poseban način, odnosno grupirani u slojeve. Višeslojna mreža obično se sastoji od ulaznog sloja, jednog ili više skrivenih slojeva, te izlaznog sloja. Broj neurona u ulaznom sloju odgovara broju parametara koji su postavljeni u mreži kao ulazni podatci, a isto vrijedi i za izlazni sloj. Svrha ulaznog sloja je da prenese podatke skrivenom sloju koji ih obrađuje i izdvaja njihove specifične osobine i sheme. Neuroni u skrivenim slojevima primarno su odgovorni za buduće izračune. Oni pružaju povećanu dimenzionalnost i prilagođavanje zadacima poput klasifikacije ili prepoznavanja uzoraka.

2.2.9.1. Setovi podataka u neuronskim mrežama

U tipičnoj proceduri procesuiranja podataka neuronskom mrežom, podatci su podijeljeni u tri odvojena seta koji su nazvani trening set, kalibracijski set te verifikacijski set. Trening set koristi se za razvoj željene mreže, odnosno za podešavanje težinskih faktora između neurona, a pitanja kada prestati s treningom te koliko puta bi mreža trebala proći kroz podatke trening seta postaju sve važnija kako trening odmiče jer se želi izbjeći pretreniranost mreže.

Pretreniranost možemo definirati kao „učenje na pamet“, tj. kao pojavu kada mreža nakon određenog broja iteracija počne pamtiti trening set, a nesposobna je za generalizaciju te je precizna samo u slučaju trening seta. Kad je pretrenirana, mreža ne nauči samo temeljnu povezanost između ulaznih i izlaznih podataka, nego i fine nijanse te buku specifičnu za trening set. Zbog toga postoji kalibracijski set koji provjerava rad mreže s trenutnim težinskim faktorima te zaustavlja trening u trenutku degradacije performanse mreže (slika 2-7) (Dalbelo-Bašić et al., 2008; Du et al., 2003).



Slika 2-7 Odstupanje stvarnog izlaza kroz iteracije (Dalbelo-Bašić et al, 2008)

Druga krajnost je podtreniranost u kojoj umjetna neuronska mreža ne može naučiti niti najgrublji obrazac povezanosti zbog primjene novog nivoa arhitekture, premalog broja iteracija ili velikog koeficijenta učenja (Du et al., 2003).

U drugoj fazi se odvija testiranje mreže, u kojoj mreža više ne uči (težinski faktori su fiksni), nego joj se dovode novi ulazni podatci koji nisu korišteni u fazi treninga te se mreža ocjenjuje izračunavanjem greške ili nekog drugog mjerila točnosti (npr. stope točnosti) (<http://www.mathos.unios.hr/~mdjumic/uploads/diplomski/dum05.pdf/27.1.2017./23:49>).

Na kraju se pomoću verifikacijskog seta provjerava točnost i preciznost obrade podataka. Najčešće se računa srednja kvadratna greška (engl. *root mean square error*), a njena jednadžba glasi:

$$RMS\ ERR = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2} \quad (2-7)$$

Pri tome je n broj slučajeva u uzorku, t_i izračunati izlaz iz mreže, a o_i željeni izlaz.

2.2.9.2. Pretprocesiranje ili skaliranje podataka

U teoriji, podatci mogu imati veliki raspon vrijednosti, što doprinosi nestabilnosti neuronske mreže. Zbog toga, prije nego mreža uđe u fazu učenja, radimo pretprocesiranje ili skaliranje podataka, čiji je cilj smanjenje raspona vrijednosti. Rezultat toga je da, umjesto korištenja podataka u normalnim fizičkim rasponima njihovih vrijednosti, koristimo bezdimenzionalan oblik s rasponom vrijednosti od 0 do 1 ili od -1 do 1. Bezdimenzionalni izlaz računa se jednadžbom:

$$O_{new} = \frac{O_{old} - \min(O_{old})}{\max(O_{old}) - \min(O_{old})} \quad (2-8)$$

gdje su: O_{new} - skalirana vrijednost
 O_{old} - originalna vrijednost

Svaka normalizirana varijabla računa se tako da se nenormalizirana vrijednost oduzme od minimalne vrijednosti iz svakog seta podataka te podijeli razlikom između maksimalne i minimalne vrijednosti izlaznih podataka (Gharbi i Elsharkawy, 1997).

2.2.9.3. Iteracije i epohe

Koraci učenja umjetne neuronske mreže nazivaju se iteracije i epohe. Iteracija je korak u kojem se odvija podešavanje težinskih faktora u algoritmu za učenje, a epoha je jedno predstavljanje cjelokupnog seta za učenje (http://matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf /13.01.2017./17:09).

2.2.9.4. *Pojedinačno i grupno učenje*

Za vrijeme trajanja jedne iteracije mreži se može prikazati jedan ili svi primjeri za učenje te zbog toga razlikujemo pojedinačno i grupno učenje. U pojedinačnom se učenju (engl. *on-line training*) tijekom jedne iteracije prikazuje samo jedan primjer za učenje, što znači da se težinski faktori mijenjaju za svaki predloženi primjer. Kod grupnog učenja (engl. *batch training*) tijekom jedne iteracije prikazuju se svi primjeri za učenje te se iteracije podudaraju s epohama, a težinski se faktor mijenja tek kad se akumulira njegova promjena, na kraju epohe (Dalbello-Bašić et al., 2008).


2.2.10. Podjela neuronskih mreža

Model NM definiran je arhitekturom (topologijom) mreže, tj. shemom veza između neurona, zatim pravilima koja određuju hoće li neuron aktivirati transformacijsku funkciju i pravilima koja upravljaju promjenama relativne važnosti pojedinih veza između neurona, odnosno zakonima učenja (Ali, 1994).

Postoji puno različitih podjela neuronskih mreža te ih možemo klasificirati prema broju slojeva, načinu povezivanja neurona, načinu treninga, smjeru kretanja informacija te prema vrsti podataka koje koriste.

2.2.10.1. *Podjela prema broju slojeva*

Prema broju slojeva mreže dijelimo na jednoslojne i višeslojne (slika 2-8), koje se danas najviše koriste. Ulazni se sloj ne računa jer nije procesni sloj.



Slika 2-8 Jednoslojna mreža (a) i višeslojna mreža (b)

(https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/12.1.2017. / 16:15)

2.2.10.2. Podjela prema načinu povezivanja neurona


Arhitektura umjetne neuronske mreže označava specifično uređenje i povezivanje neurona ulaznog, nevidljivog i izlaznog sloja u obliku mreže.

Složenije neuronske mreže često imaju više skrivenih slojeva, povratne petlje i elemente za odlaganje vremena koji služe što efikasnijem odvajanju važnih karakteristika podataka s ulaznog sloja.


Ovisno o arhitekturi razlikujemo četiri temeljne vrste mreža:

- acikličke (engl. *feedforward net*) mreže, koje ne sadrže povratne veze (slika 2-9)
- cikličke mreže, koje sadrže povratne veze (engl. *recurrent net*) (slika 2-9)
- lateralno povezane mreže (rešetkaste)
- hibridne mreže (Dalbelo-Bašić et al., 2008)

• acikličke – ne sadrže povratne veze



• cikličke – sadrže povratne veze




Slika 2-9 Primjeri acikličke i cikličke mreže


(https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/12.1.2017./16:31)

Prema povezanosti mreže dijelimo na djelomično povezane te potpuno povezane (slika 2-10) u kojima je svaki neuron prethodnog sloja povezan sa svakim neuronom sljedećeg sloja.

Djelomično povezane



Potpuno povezane



Slika 2-10 Djelomično i potpuno povezane mreže

(https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/12.1.2017./16:40)

2.2.10.3. Podjela prema načinu učenja ili treninga

Jedna od najvažnijih karakteristika neuronskih mreža je sposobnost učenja od okoline, a to se odvija kroz iterativni proces podešavanja težinskih koeficijenata te mreža nakon svake iteracije ima sve više znanja o okolini.

S obzirom na način učenja postoje nadgledane, polunadgledane i nenadgledane mreže.

- Nadgledane mreže – učenje se odvija uspoređivanjem dobivenih izlaznih vrijednosti iz mreže sa željenim vrijednostima, a njihove razlike se korigiraju težinski koeficijenti (npr. perceptron, backpropagation algoritam). Većina primijenjenih NM u naftnom inženjerstvu temeljena je na nadgledanim algoritmima za treniranje koji dozvoljavaju učenje pomoću povratnih veza.
- Polunadgledane mreže – rade na principu ocjenjivanja mreže koja uči samostalno, a onda dobiva ocjenu prethodnog rada. Podatci za ovu vrstu mreža pribavljaju se interaktivno iz okoline te nisu dani kao prethodna mjerenja.
- Nenadgledane mreže – posebne su po tome što za učenje ne koriste nikakav oblik povratne veze putem koje će saznati koliko je odstupanje te se na temelju toga prilagoditi, već dobivaju samo ulazne podatke koje uspoređuju te pokušavaju pronaći zajedničke karakteristike na temelju kojih će ih razvrstati u grupe. To zahtijeva određen stupanj redundancije ulaznih podataka. Nenadgledane mreže sastoje se od dvaju slojeva, ulaznog i izlaznog te je svaki neuron ulaznog sloja spojen na svaki neuron izlaznog sloja, a svaka veza ima pridruženu težinu. Najpoznatiji primjer nenadgledane mreže je Kohonenova samoorganizirajuća mapa (Dalbelo-Bašić et al., 2008; <http://solair.eunet.rs/~ilicv/neuro.html> 10.01.2017. / 21:39).

2.2.10.4. Podjela prema smjeru kretanja informacija

Prema smjeru kretanja informacija, NM mogu se podijeliti na nepovratne i povratne. U nepovratnim ili acikličkim (engl. *feedforward*) mrežama neuroni svakog sloja su povezani sa svim neuronima sljedećeg sloja te nema veza među neuronima istog sloja.

Tako informacije stalno putuju prema naprijed, od ulaznog preko skrivenih (ako postoje) do izlaznog sloja te ne postoje povratne petlje ili veze u mreži (<http://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/Architecture/feedforward.html> /28.1.2017./1:57).

Povratne ili cikličke (engl. *feedback*) mreže su vrsta umjetnih neuronskih mreža u kojima uz pomoć povratnih petlji informacije mogu putovati u oba smjera što im omogućuje da budu vrlo moćne, ali i iznimno složene. Izračuni dobiveni na temelju prijašnjih ulaznih podataka se vraćaju u mrežu, što im daje neku vrstu memorije. Povratne mreže su vrlo dinamične te im se stanje konstantno mijenja sve do stadija ravnoteže u kojem ostaju sve dok se ulazne vrijednosti ne promijene te se stanje ravnoteže naruši (<http://stats.stackexchange.com/questions/2213/feed-forward-and-recurrent-neural-networks> /28.1.2017./2:10).

2.2.10.5. Podjela prema vrsti podataka

Prema vrsti podataka NM mogu se podijeliti na kontinuirane (npr. od 0 do 1) i diskretne (npr. ili 0 ili 1), ali ova podjela rijetko se koristi jer su skoro sve NM diskretne (Tablica 2-1).

Tablica 2-1 Najčešće vrste neuronskih mreža (vrste NM ovisno o vrsti učenja i smjeru kretanja informacija) (solair.eunet.rs/~ilicv/neuro.html /10.01.2017./ 21:39)

NENADGLEDANO UČENJE		NADGLEDANO UČENJE	
<i>FEEDBACK MREŽE</i>	<i>FEEDFORWARD MREŽE</i>	<i>FEEDBACK MREŽE</i>	<i>FEEDFORWARD MREŽE</i>
Aditivna Grossbergova mreža	Matrice s mogućnošću učenja	Neizravne (<i>fuzzy</i>) kognitivne mape	Perceptron
Grossbergova neuronska mreža s odlaganjem	Pobuđeno-primorano učenje	Bolcmanova mašina	Adaline, Madaline
Teorija binarne adaptivne rezonancije	Linearna asocijativna memorija	Rekurzivno kaskadno povezivanje	Backpropagation
Teorija analogne binarne rezonancije	Optimizirana linearna asocijativna memorija	Povratna propagacija kroz vrijeme	Cauchyjeva mašina
Diskretna Hopfieldova mreža	Slabo raspoređena distribuirana asocijativna memorija	Povratno učenje u realnom vremenu	Asocijativno nagrađivanje
Kontinuirana Hopfieldova mreža	Fuzzy asocijativna memorija		Artmap
Diskretna bidirekcijska asocijativna memorija	Counterpropagation		Adaptivne logičke mreže
Privremena asocijativna memorija			Kaskadne veze
Kohonenove			Kvantizacija vektora

samoorganizirajuće mape			učenja
Kompetitivno učenje			Opće regresijske NM

2.2.11. Višeslojne perceptronske mreže

Višeslojne perceptronske neuronske mreže (engl. *multilayer perceptron* - MLP) su nepovratne mreže koje se sastoje od perceptrona koji se nalaze u serijski povezanim slojevima pri čemu postoji najmanje jedan skriveni sloj. Uglavnom se koriste višeslojne perceptronske mreže s dva ili tri skrivena sloja, iako ne postoji teoretsko ograničenje. Svi neuroni, osim ulaznih, imaju nelinearnu aktivacijsku funkciju što višeslojnoj perceptronskoj mreži omogućuje razlikovanje podataka koji nisu linearno odvojivi (Dalbelo-Bašić et al., 2008; <http://neuroph.sourceforge.net/tutorials/MultiLayerPerceptron.html> /28.1.2017.4:05).

2.2.12. Radijalno temeljene funkcijske mreže

Radijalno temeljene funkcijske mreže (engl. *radial basis function* - RBF) imaju nekoliko prednosti nad MLP mrežama. Mogu modelirati bilo koju nelinearnu funkciju koristeći jedan skriveni sloj neurona, što otklanja projektne nedoumice o broju slojeva. Nadalje, jednostavna linearna transformacija na izlaznom sloju može biti podešena u potpunosti koristeći tradicionalne linearne tehnike modeliranja koje su brze te nemaju problema s lokalnim minimumom koji muči MLP mreže. RBF mreže mogu zbog toga biti istrenirane vrlo brzo. Međutim, iskustvo pokazuje da RBF mreže zahtijevaju dosta više neurona za adekvatno modeliranje većine funkcija. Posljedično, RBF mreže bit će sporije pri izvođenju te zahtijevati više memorije nego odgovarajuća MLP mreža. RBF mreže su također osjetljivije na dimenzionalnost te imaju više poteškoća ako je broj ulaznih varijabli velik (Osman i Al-Marhoun, 2005).

2.2.13. Algoritam povratnog propagiranja

Algoritam povratnog propagiranja (engl. *backpropagation*) vjerojatno je najpoznatiji i najkorišteniji algoritam nepovratne ili acikličke mreže (engl. *feedforward*). Nakon primjene ulaznog niza na prvi sloj neuronske mreže on se širi sljedećim slojevima

dok se ne generiraju izlazni podatci koji se zatim uspoređuju sa željenim izlaznim podacima te se računa greška za svaki od njih. Te greške se zatim prenose natrag iz izlaznog sloja na svaki neuron nevidljivog sloja, pri čemu svaki neuron nevidljivog sloja prima samo dio ukupne greške, a raspodjela se temelji na relativnom doprinosu koji je neuron dao originalnom izlaznom podatku.

Dakle, signali se ne rasprostiru samo prema naprijed kroz mrežu, već se greške prosljeđuju unatrag, ali mreža može zadržati naziv nepovratna ili aciklička jer se pod tim nazivom podrazumijeva samo smjer kretanja ulaznih podataka (Dalbelo-Bašić et al., 2008). Temeljeno na primljenom signalu greške, težinski faktori se ažuriraju na svakom neuronu ne bi li došlo do konvergencije mreže prema stanju koje daje najpovoljnije rezultate, a učenje traje dok se ne zadovolji uvjet zaustavljanja koji može biti određen brojem iteracija ili maksimalno dozvoljenom vrijednošću greške (Ali, 1994).

Algoritam povratnog propagiranja koristi se gradijentnim spustom u cilju minimiziranja greške. Učenje ovim algoritmom temelji se na pretraživanju u n -dimenzionalnom prostoru hipoteza, pri čemu je „ n “ ukupan broj težinskih faktora u mreži. Greška u takvom prostoru može imati više lokalnih minimuma, a nama je cilj pronalaženje globalnog minimuma, što se pospješuje korištenjem algoritma povratne veze s momentom inercije (Dalbelo-Bašić et al., 2008).

Neuroni u mreži s povratnom vezom koriste sigmoidalnu prijenosnu funkciju kojoj je minimalna vrijednost 0, a maksimalna vrijednost 1 te je diferencijabilna svugdje s pozitivnim kutom nagiba. Derivacija prijenosne funkcije potrebna je za izračun greške koja se vraća unazad, a derivaciju sigmoidalne funkcije jednostavno je izračunati (Osman et al., 2001).

2.3. PRIMJENE NEURONSKIH MREŽA U NAFTNOM INŽENJERSTVU

Neuronske mreže korisne su u slučajevima koji zahtijevaju mnogo vremena ili su nerješivi konvencionalnim metodama, kada ne postoje detaljna pravila za rješavanje problema ili su ona preteška za razumijevanje, a poznati su željeni ulazno-izlazni podatci te ako su podatci nepotpuni ili oštećeni ili je potrebna velika brzina procesuiranja podataka. Nadalje, neuronske mreže pokazale su odličan potencijal za stvaranje preciznih analiza i rezultata iz velikih baza podataka koje inženjerima nisu potrebne kad su u pitanju konvencionalne metode (Mohaghegh, 2000). Čak i u slučaju gdje ostale klasične metode

mogu biti uspješno primijenjene, robusnost istrenirane NM te neosjetljivost na male promjene u problemu daju dugoročnu prednost po pitanjima prilagodljivosti i pouzdanosti (Ali, 1994).

Neki od primjera korištenja NM u naftnom inženjerstvu uključuju prepoznavanje seizmičkih dijagrama, predviđanje propusnosti i raspucanosti ležišta, ispitivanje bušotina, razradu ležišta, raspoznavanje pješčenjačkih površina, dvofazni protok u cijevima, odabir bušaćih dlijeta te analize i poboljšanja proizvodnosti bušotina. Tehnologija NM također bi mogla značajno doprinijeti analizi, predviđanju i optimizaciji proizvodnih karakteristika bušotina, integriranih karakteristika ležišta te portfelj menadžmenta (Ali, 1994). U sljedećem dijelu bit će predstavljeni neki primjeri primjene NM na probleme u naftnom inženjerstvu.

2.3.1. Obrada slike te primjena u 3D seizmici

Ključ uspjeha u istraživanju ležišta tijekom devedesetih godina 20. st. i kasnije nesumnjivo je ležao u upotrebi računala za obradu i interpretaciju velikih količina podataka dostupnih iz detaljnih 3D seizmičkih istraživanja kojih je bilo sve više. 3D seizmika igra važnu ulogu u ocrtavanju ležišta. Tehnika je posebno popularna u Sjevernom moru zbog svoje mogućnosti da prostorno riješi složene rasjede, tektonske rovove te solne dome. Nadalje, budući da 3D seizmika tretira relativne amplitude seizmičkih refleksija bolje od 2D tehnike, relativne amplitudne promjene mogu biti interpretirane da modeliraju promjene šupljikavosti ili da identificiraju prisustvo plinova.

Cilj interpretacije je predstaviti neizobličenu vremensku strukturu ležišta te modelirati litološke varijacije. Da bi se postigao ovaj cilj potrebno je sistematski pregledati svaku neprilagođenost u sloju, zabilježiti rasjede, dubinske nepravilnosti te modelirati debljinu i litologiju ležišta. Nadalje, interpretator mora pregledati svaku nepravilnost u ležištu da odredi mogu li fluidi protjecati kroz rasjed.

Interpretacija, temeljena na ručnom izračunu vrlo je komplicirana te zahtjeva mnogo vremena, posebno kad postoji puno podataka kao što je slučaj u 3D seizmičkim istraživanjima gdje je potrebno odabrati, unakrsno provjeriti te kartirati 100000 ili više podatkovnih točaka ako želimo provesti interpretaciju. Dobro dizajnirana NM za seizmičku interpretaciju značajno će pojednostavniti proceduru.

NM razvijene su za prepoznavanje seizmičkih zona te biranje zona i putanja rasjeda pomoću seizmičkih podataka. Biranje zona i dalje se uglavnom radi ručno te je sklono

pogreškama i vremenski je vrlo zahtjevno. Glavni razlog leži u tome što je trenutni način odabiranja odbijenih valova vrlo subjektivan, svaki inženjer ima svoje vlastite trikove i načine gledanja na problem. Pokušaji automatiziranog odabira zona su spriječeni odsutnošću jasnog, robusnog i univerzalnog algoritma za odabir. Automatsku tehniku odabira koja bi koristila istreniranu povratnu mrežu opisao je Hariggan et al. Oni su pokazali da je neuronska mreža korisna u izdvajanju geofizičkih događaja kada konvencionalni obrasci zakažu, posebno ako su zone diskontinuirane.

Obrada slike odnosi se na rukovanje digitalnom slikom u svrhu izdvajanja više informacija nego što je vidljivo iz početnog vizualnog pregleda. Geoznanstvenici trebaju izvesti jedan od dvaju zadataka s digitalnom slikom: odrediti kvalitativnu i kvantitativnu ukupnost značajki dominantne strukture ili pojave te naći značajnije strukture malih razmjera.

Obrada slika predstavlja problem trenutačnim NM zbog velikih dimenzija neobrađenih podataka. Slike visoke rezolucije vrlo lako mogu sadržavati milijun ili više elemenata u ulaznom vektoru. Zbog ograničenja veličine trenutačnih NM problemi obrade slike zahtijevaju posebnu obrađivačku tehniku, primjerice popločavanje (engl. *tiling*) ili brzu Fourierovu transformaciju podatka te se uvijek mora smanjiti veličina ulaznih podataka (Ali, 1994).

2.3.2. Predviđanja propusnosti i šupljikavosti

Zadatak inženjera je, korištenjem različitih metoda kao što su seizmika, ispitivanja bušotine, karotaža, analiza krhotina te jezgrovanje, što potpunije i preciznije opisati ležište. Ove metode predstavljaju vrijedan izvor podataka različitih redova veličina – od fotomikrografija jedne čestice ilita i karotažnog dijagrama nekoliko metara oko kanala bušotine do ispitivanja bušotine ispitujući stotine ili tisuće metara u formaciju te omogućuju da se pomoću njih predvide ključne ležišne karakteristike poput poroznosti, zasićenja fluidima te propusnosti.

Glavni problem s kojim se inženjeri suočavaju je taj što različite metode mogu dati različite rezultate pa tako npr. šupljikavost mjerena na jezgri koja se više ne nalazi pod utjecajem ležišnog tlaka, temperature i fluida, očišćena, osušena te ponovo zasićena može dati različite rezultate od šupljikavosti izmjerene iz karotažnih dijagrama. Jezgrovanje i karotaža ne samo da mjere poroznost na različite načine, već također uzimaju uzorke različitih vrsta poroznosti pri različitim horizontalnim i vertikalnom silama te pri različitim

fizikalnim i kemijskim uvjetima. Pri obradi podataka iz nekoliko mjerenja zbog toga je potrebna kalibracija, pogotovo ako korištena tehnika, kao npr. karotažno dobivena poroznost, nema kalibracijski standard. Analiza jezgre često se javlja kao standard te je tada potrebno kalibrirati ostala mjerenja prema ovom standardu i odrediti sve veze koje postoje između poroznosti, propusnosti te zasićenja fluidima.

Za razvoj linearne veze između poroznosti i propusnosti koje su dobivene iz jezgre, obično se koristi regresijska analiza najmanjeg kvadrata koja pretpostavlja linearnost između poroznosti i propusnosti te se na mnogo polja ova međuveza pokazala potpuno neispravnom. Tamo gdje petrološki čimbenici, poput velike količine cementa, velikog raspona veličina zrna te dijagenetske promjene imaju utjecaj, linearna povezanost nestaje i raspršenost je karakterizirana složenom mješavinom kao posljedica kombinacije mnogo linearnih trendova od kojih je svaki ovisan o pojedinačnim petrološkim čimbenicima. Poroznost sama ne služi kao dobar predskazivač propusnosti.

Da bi imali kvalitetno predviđanje, potrebno je izmjeriti petrološke čimbenike što se može postići ako su napravljena dobra ispitivanja na jezgrama za kasnije treniranje NM. Ovo je područje koje trenutno pridobiva najviše pažnje.

Osborne je koristio model povratne veze za ispitivanje propusnosti na Wasson polju u Teksasu. Mreža je imala 5 ulaza (geografsku lokaciju bušotine u x-y koordinatama, dubinu, poroznost i strujanje fluida u ležištu) s odgovarajućom propusnosti koja je bila izlaz. Presjecište propusnosti dobivene iz analize jezgre te propusnosti dobivene NM dala je korelacijski koeficijent čija je vrijednost 0,81, dok je regresijom dobivena vrijednost korelacijskog koeficijenta iznosila 0,44 (Ali, 1994).

2.3.3. Optimizacija

Optimizacija u naftnoj industriji utječe na izbor opreme i radnih uvjeta za proizvodnju nafte i plina tako da se profit što više poveća.

Epping i Nitters (Ali, 1994) koristili su model s povratnim propagiranjem za analizu i poboljšanje proizvodnosti velikog broja bušotina u dva duboka slabopropusna plinska ležišta koja nisu proizvodila prema očekivanjima.

Stoisits et al. (Ali, 1994) koristili su model s povratnom vezom za stvaranje determinističkog modela za određivanje optimalne primjene plinskih dizalica na bušotine, a bio je postavljen tako da su ulazne varijable bile: tlak u ležištu, indeks produktivnosti bušotine, tlak na ušću bušotine, stupanj zavodnjenja te rastući plinski faktor, a optimalni


GLR je definiran kao izlaz. Model s povratnom vezom dao je precizniju analizu odabira plinskog lifta nego prethodna metoda koja je temeljena na nelinearnoj regresiji ležišnih podataka (Ali, 1994).

2.3.4. Karakterizacija ležišta

NM naučene podacima iz konvencionalne bušotinske karotaže koriste za predviđanje ili virtualno mjerenje ležišnih karakteristika kao što su poroznost, propusnost te zasićenje fluidima. Jedno mjerenje ovih karakteristika ležišta uspješno je izvedeno za heterogenu formaciju u zapadnoj Virginiji pomoću karotažnih podataka kao ulaznih podataka sparenih s analizama jezgre odgovarajuće dubine. Od ranih šezdesetih godina 20. st., pomoću matematičkih i statističkih funkcija, napravljeni su mnogi pokušaji korelacije propusnosti sa šupljikavošću jezgre ili karotažnim dijagramima. Pokazalo se da pažljivo napravljena analiza pomoću NM daje preciznije i konzistentnije rezultate nego prije korištene metode.

Karotažni dijagrami osiguravaju kvalitetne informacije o stijeni, ali zakazuju u mjerenju i izračunu njene propusnosti. Ovisnost stijenske propusnosti o parametrima koji mogu biti izmjereni pomoću karotažnih dijagrama, ostali su jedni od glavnih istraživačkih područja u naftnom inženjerstvu. Korištenjem konvencionalnih alata znanstvenici nisu bili u mogućnosti dokazati da postoji određena funkcionalna ovisnost koja može objasniti vezu među parametrima.

S geofizičkim karotažnim podacima kao ulaznim podacima (ukupna gustoća, gama-zračenje te indukcijski dijagrami), NM istrenirana je da predvidi propusnost ležišta izmjerenu iz laboratorijskih analiza jezgre. Podatci karotažne i jezgrene propusnosti bili su dostupni iz četiri bušotine. Mreža je trenirana s podacima iz triju bušotina te je pokušano predviđanje mjerenja četvrte bušotine. Ovo je ponovljeno dva puta, svaki puta s različitom bušotinom kao verifikacijskom bušotinom. Slika 2-11 pokazuje rezultate neuronske mreže u usporedbi s laboratorijskim mjerenjima (Mohaghegh, 2000).



Slika 2-11. Usporedba propusnosti dobivene mjerenjima iz jezgre te predikcijom pomoću neuronske mreže za bušotinu 1110 Big Injun ležišta (Mohaghegh, 2000)

2.3.5. Predviđanje PVT svojstava neuronskim mrežama

Za precizan izračun ležišnih karakteristika potrebne su što preciznije vrijednosti PVT svojstava poput tlaka zasićenja, faktora otopljenog plina te volumnog faktora nafte. Jednom istrenirane, neuronske mreže mogu raditi izvrsnu predikciju PVT svojstava fluida. Neuronska mreža može predvidjeti tlak zasićenja ili volumni faktor nafte na temelju faktora otopljenog plina, relativne gustoće plina, relativne gustoće nafte te temperature. Praksa naftne industrije je da se radije oslanja na podatke dobivene mjerenjima nego korelacijama. Međutim, problem nastaje kada nisu dostupni pouzdani podatci dobiveni mjerenjem i tada moramo koristiti korelacije kojima dobivamo dovoljan broj podataka potrebnih za izračun.

Višestruka regresija na kojoj se temelji konvencionalni pristup razvoja PVT korelacija nije najpreciznija za razliku od neuronskih mreža koje daju izvrsne predikcije PVT svojstava (Gharbi i Elsharkawy, 1997).

Gharbi i Elsharkawy 1997. godine napravili su istraživanje predviđanja tlaka zasićenja te volumnog faktora nafte pri tlaku zasićenja koristeći mrežu s dva skrivena sloja. Neuronska mreža za tlak zasićenja sastojala se od osam neurona u prvom skrivenom sloju te četiri neurona u drugom. Volumni faktor nafte pri tlaku zasićenja imao je po šest neurona u oba sloja. Iz literature i neobjavljenih izvora prikupljeno je 498 podatkovnih setova te iskorišteno za učenje mreže, a preostala 22 podatkovna seta iskorištena su za testiranje.

Rezultati ovog istraživanja pokazali su poboljšanje u odnosu na konvencionalne korelacije (Adeeyo, 2016).

Također, Gharbi i Elsharkawy, 1997. godine, predstavili su još jedan model neuronske mreže za predviđanje tlaka zasićenja te volumnog faktora nafte pri tlaku zasićenja za univerzalnu upotrebu. Ta mreža imala je samo jedan skriveni sloj s pet neurona, četiri ulazna čvora te dva izlazna. Ukupna učinkovitost bila je bolja od ijedne izdane korelacije. Korelacijski koeficijent za tlak zasićenja je iznosio 0,9891, a za volumni faktor nafte 0,9875 s prosječnom apsolutnom postotnom pogreškom (E_a) koja je iznosila 6,48 i 1,97 (Adeeyo, 2016).

Al-Shammmasi je 1999. publicirao istraživanje o modelu neuronske mreže za predviđanje tlaka zasićenja te volumnog faktora nafte pri tlaku zasićenja. Model tlaka zasićenja razvijen je korištenjem 137 globalnih setova podataka za testiranje modela te 1106 za treniranje. Model je imao dva skrivena sloja, pet neurona u prvom sloju te tri u drugom. Neuronska mreža je imala prosječnu apsolutnu pogrešku od 15,08%. Model volumnog faktora nafte pri tlaku zasićenja razvijen je korištenjem 180 globalnih setova podataka za testiranje te 1165 za učenje. Prosječna apsolutna postotna pogreška modela iznosila je 11,68% (Adeeyo, 2016).

Osman et al. su (2001) koristeći 803 seta podataka (Katz - 53, Vasquez i Beggs - 254, Glaso - 41, Ghetto et al. - 173, Omar i Todd - 93, Gharbi i Elsharkawy - 22 i Farshad et al. - 146 sa Srednjeg istoka, iz Malezije, Kolumbije i Meksičkog zaljeva razvili model neuronske mreže za predviđanje tlaka zasićenja te volumnog faktora nafte. Svaki set podataka sastojao se od temperature ležišta, relativne gustoće nafte, relativne gustoće plina, faktora otopljenog plina, tlaka zasićenja te volumnog faktora nafte pri tlaku zasićenja. Upotrijebljeno je 403 seta podataka za treniranje modela neuronske mreže, 200 za kalibraciju veza ostvarenih tijekom procesa učenja te preostalih 200 za testiranje modela i ocjenjivanja njihove preciznosti i stabilnosti. Rezultati su pokazali da je razvijena neuronska mreža dala bolju preciznost nego objavljene empirijske korelacije (Osman et al., 2001).

Model je dao predviđanje volumnog faktora nafte pri tlaku zasićenja s apsolutnom prosječnom postotnom pogreškom od 1,789%, standardnim odstupanjem od 2,2053% i korelacijskim koeficijentom od 0,988. Napravljen je test nagiba krivulje radi provjere ponašanja predviđenih vrijednosti volumnog faktora nafte za bilo kakvu promjenu ležišne temperature, plinskog faktora, relativne gustoće nafte i plina. Pokazalo se da trendovi poštuju zakone fizike (Osman et al., 2001).

Za usporedbu preciznosti i performansi modela s ostalim empirijskim korelacijama korišteno je pet korelacija, a to su: Standingova (1947), Vasquez i Beggs (1980), Glasova (1980), Al-Marhounova (1988), Al-Marhounova (1992). U tablici 2-2 dani su statistički rezultati usporedbe različitih empirijskih korelacija pomoću prosječne postotne relativne pogreške (E_r), prosječne apsolutne postotne relativne pogreške (E_a), najmanje (E_{min}) i najveće (E_{max}) apsolutne postotne relativne pogreške, korijena prosječne sume kvadrata pojedinačnih pogrešaka ili standardno odstupanje (E_{rms}) i koeficijenta korelacije (R).

Tablica 2-2 Statistička analiza rezultata različitih empirijskih korelacija (preuzeto od Osman et al., 2001)

Korelacija	E_r	E_a	E_{min}	E_{max}	E_{rms}	R
Standing (1947)	-0,1696	2,7238	0,0081	20,1795	4,2025	0,9742
Vasquez i Beggs (1980)	2,3083	2,9755	0,0136	15,5368	4,0417	0,9842
Glaso (1980)	1,8186	3,3743	0,0030	17,7763	4,5663	0,9715
Al-Marhoun (1988)	0,3395	2,3334	0,0112	13,2590	3,3810	0,9811
Al-Marhoun (1992)	-0,1152	2,2053	0,0033	13,1794	3,4162	0,9806
Neuronska mreža	0,3024	1,7886	0,0076	11,7751	2,7193	0,9878

Model umjetne neuronske mreže nadmašuje sve empirijske korelacije. Dani model je pokazao visoku preciznost u predviđanju vrijednosti volumnog faktora nafte te postigao najmanju apsolutnu postotnu relativnu pogrešku, najmanju minimalnu pogrešku, najmanju maksimalnu pogrešku, najmanji korijen prosječne sume kvadrata pojedinačnih pogrešaka te najveći koeficijent korelacije (Osman et al., 2001).

Adeeyo je 2016. godine razvio model za predviđanje tlaka zasićenja te volumnog faktora nafte pri tlaku zasićenja za Nigerijsku sirovu naftu. Podatci korišteni u ovom istraživanju dobiveni su analizom 500 uzoraka s dna bušotine iz različitih Nigerijskih ležišta. Dobiveno je 2500 eksperimentalnih točaka. Prikupljeni su iz različitih ležišta različitih kemijskih sastava Nigerijskih ležišta u delti rijeke Niger. Nakon pregleda podataka napravljena je selekcija te je uzeto 2114 podatkovnih točaka za tlak zasićenja te 2024 točke za volumni faktor nafte pri tlaku zasićenja. Svi podaci su normalizirani na vrijednosti od -1 do 1 te podijeljeni na podatke za učenje, kalibraciju i verifikaciju u omjeru 3:1:1. Za izgradnju mreže korišten je Matlab software, algoritam s povratnim propagiranjem te Levenberg-Marquardtova procedura za optimizaciju. Kao kriteriji procijene ovog istraživanja su korištene statističke i grafičke analize pogreške. Nakon procijene mnoštva korelacija izabrane su one s najboljim performansama za daljnje

ocjenjivanje i usporedbu s neuronskom mrežom. Analize pogreške provedene su na temelju usporedbe predviđenih vrijednosti s originalnim eksperimentalnim podacima. Korištene statističke metode za ovo istraživanje su prosječna postotna relativna pogreška (E_r), prosječna apsolutna postotna relativna pogreška (E_a), standardno odstupanje (E_{rms}) i koeficijent korelacije (R). Dobar model treba imati nizak E_a te visok R (Adeeyo, 2016). Usporedba performansi neuronske mreže te korelacija za tlak zasićenja prikazani su u tablici 2-3. Iz te tablice vidljivo je da neuronska mreža nadmašuje ostale korelacije s obzirom na prosječnu postotnu relativnu pogrešku, apsolutnu pogrešku te korelacijski koeficijent koji su redom iznosili -0,36217, 7,6169 i 0,93.

Tablica 2-3 Rezultati neuronske mreže i korelacija za tlak zasićenja (preuzeto od Adeeyo, 2016)

Korelacija	E_r	E_a	E_{max}	E_{rms}	R
Standing (1947)	-1,73	18,68	763	1564	0,81
Glaso (1980)	-17,4	21,65	483	1439	0,82
Vasquez i Beggs (1980) API<30	-24,1	16,21	683	1457	0,63
Vasquez i Beggs (1980) API>30	-3,78	29,44	816	1553	0,77
Al-Marhoun (2004)	-29,3	32,57	1503	1773	0,81
Neuronska mreža	-0,36217	7,6169	34,097	412,4	0,93

Rezultat modela neuronskih mreža za volumni faktor nafte pri tlaku zasićenja je uspoređen s performansama Standingove, Glasove, Al-Marhounove, Vasquez-Beggsove te Petrosky-Farshadove korelacije. Pokazalo se da neuronske mreže daju najbolje rezultate s prosječnom postotnom relativnom pogreškom (E_r), prosječnom apsolutnom postotnom relativnom pogreškom (E_a) te najvećim koeficijentom korelacije (R) koji su iznosili 0,02, 0,00011 i 0,98. Rezultati svih korelacija i neuronske mreže dani su u tablici 2-4.

Tablica 2-4 Rezultati neuronske mreže i korelacija za volumni faktor nafte (preuzeto od Adeeyo, 2016)

Korelacija	E_r	E_a	E_{max}	E_{rms}	R
Standing (1947)	-0,56	4,04	81,55	0,2863	0,925
Glaso (1980)	1,43	4,18	67,73	0,2708	0,93
Kartoatmodjo	0,33	3,73	58,37	0,2572	0,94
Petrosky	-9,80	10,35	90	0,3374	0,929
Al-Marhoun (2004)	-7,07	8,27	64,44	0,2439	0,936
Vasquez i Beggs (1980) API<30	-0,45	2,7	101,52	0,0934	0,73
Vasquez i Beggs (1980) API>30	4,09	6,4	59,68	0,1938	0,80
Neuronska mreža	0,0201	0,0011	13,51	0,051	0,98

3. PODATCI I RAČUNALNI PROGRAM KORIŠTENI PRI IZRADI OVOG RADA

3.1. Podatci

Pri izradi ovog rada korištena su tri seta podataka koji su dobiveni simulacijom PVT svojstava nafte iz Žutice.

3.1.1. Prvi set podataka – volumni faktor nafte

Prvi set podataka se sastoji od pet varijabli, četiri ulazne i jedne izlazne. Ulazne varijable su plinski faktor (R_s), relativna gustoća plina (γ_g), relativna gustoća nafte (γ_o) i temperatura (T), a izlazna varijabla je volumni faktor nafte (B_o). Raspon vrijednosti podataka, prosječna vrijednost i standardna devijacija su dani u tablici 3-1.

Tablica 3-1. Karakteristične vrijednosti prvog seta podataka

	R_s , [m ³ /m ³]	γ_g	γ_o	T , [°C]	B_o , [m ³ /m ³]
min	20	0,6	0,75	30	1,0567
max	100	1,6	0,9	150	1,6884
prosjek	60	1,04	0,7958	97,5	1,2939
standardna devijacija	28,2843	0,3441	0,0519	42,6468	0,1238

Svi podatci prvog seta se nalaze u prilogu.

3.1.2. Drugi set podataka – plinski faktor

U drugom setu podataka ulazne varijable su tlak zasićenja nafte (p_b), relativna gustoća plina, relativna gustoća nafte i temperatura, a izlazna varijabla je plinski faktor nafte. Treći set podataka se nalazi u prilogu, a u tablici 3-2 su dane neke njegove karakteristične vrijednosti.

Tablica 3-2 Karakteristične vrijednosti drugog seta podataka

	P_b , [bar]	γ_g	γ_o	T , [°C]	R_s , [m ³ /m ³]
Min	10	0.649131	0.718932	30	9.592591
Max	76.73052	1.609843	0.881945	150	132.614

Prosjek	41,8498	0,8939	0,8080	93,4615	47,4005
St. dev.	20,8904	0,1990	0,0434	39,1685	28,4908

3.1.3. Treći set podataka – tlak zasićenja nafte

Treći set podataka se sastoji od istih ulaznih varijabli kao i prvi set, a razlika je jedino u izlaznoj varijabli koja je u drugom setu tlak zasićenja nafte. Raspon vrijednosti, prosječna vrijednost te standardna devijacija su dani u tablici 3-2, a čitav set podataka se nalazi u prilogu.

Tablica 3-3 Karakteristične vrijednosti drugog seta podataka

	R_s , [m ³ /m ³]	γ_g	γ_o	T , [°C]	p_b , [bar]
min	19.301594	0.67603105	0.7189317	30	9.21983886
max	94.643288	0.93663073	0.8574293	150	50.7752181
prosjek	47,4525	0,9001	0,8063	93,4615	40,0904
st. dev.	17,7965	0,1953	0,0411	39,1685	16,4624

3.1.4. Odabir podataka

Postoje različiti omjeri podjele podatkovnih setova na trening set, kalibracijski set te set za verifikaciju, no najčešće se oko polovice uzme za trening, te po četvrtina za kalibraciju i verifikaciju. Osim toga, izuzetno je važno pažljivo odabrati setove za trening i kalibraciju pazeći da njihove vrijednosti budu iz čitavog raspona vrijednosti podataka jer performanse neuronskih mreža značajno opadaju ako se testiraju na podacima čije su vrijednosti izvan poznatih granica.

3.2. Software

Pri izradi ovog rada korišten je računalni program „JustNN“, koji se može besplatno preuzeti s interneta na adresi <http://www.justnn.com/>.


3.2.1. Unos podataka

Prvo što je potrebno napraviti nakon pokretanja programa je unos podataka. Podatci se unose pomoću rešetkaste tablice u kojoj su podatkovni setovi poredani u redovima, a ulazne i izlazne varijable podijeljene u stupcima. Moguće je izmijeniti vrijednost svakog polja i vrstu podatkovnog seta svakog retka. Nakon podešavanja imena redaka i stupaca,

odabira vrsta setova podataka te unošenja vrijednosti potrebno je naučiti neuronsku mrežu željenom ponašanju.

3.2.2. Podešavanje neuronske mreže za učenje

Nakon unosa podataka pojavljuje se prozor „New Network“ (slika 3-1) u kojem se određuje broj skrivenih slojeva koje će mreža koristiti (od 0 do 3) te maksimalan broj neurona svakog sloja.



Slika 3-1 Prozor za odabir broja skrivenih slojeva i najvećeg dopuštenog broja neurona

Nakon stvaranja nove neuronske mreže te izvještaja o tome koliko slojeva ima nova mreža te koliko je neurona u svakom od njih i koliki je broj težinskih koeficijenata među neuronima, slijedi podešavanje kontrola (slika 3-2). Tu je moguće odrediti stopu učenja i moment, te odabrati opcije da se sami optimiziraju ili vrate na prijašnju vrijednost ako je došlo do porasta pogreške. Također, može se odrediti vrijednost ciljane pogreške, postavke testiranja, odabrati opcija sporog učenja kojima se usporavaju iteracije za nekoliko milisekundi ili odrediti fiksni broj iteracija ili vrijeme nakon kojeg će se učenje zaustaviti.

Controls

Learning
 Learning rate: ☒ Decay ☒ Optimize
 Momentum: ☒ Decay ☒ Optimize

Validating
 Cycles before first validating cycle:
 Cycles per validating cycle:
 Select examples at random from the
 Training examples = 150

Target error stops
☒ Stop when Average error is below
 or ☐ stop when All errors are below

Validating stops
☒ Stop when % of the validating examples
 are ☐ Within % of desired outputs
 or ☒ Correct after rounding

Slow learning
☐ Delay learning cycles by millisecs


Fixed period stops
☐ Stop after seconds
☐ Stop on cycles

OK Cancel

Slika 3-2 Podešavanje kontrolnih opcija neuronske mreže

3.2.3. Učenje neuronske mreže

Nakon odabira željenih opcija, započinje proces učenja. JustNN će kreirati shematsku skicu svih neurona i njihovih međuveza u mreži. Veze među neuronima su prikazane pravocrtnim linijama zelene i crvene boje, zelena za pozitivne vrijednosti, a crvena za negativne. Debljina linija predstavlja važnost težinskog faktora, što je linija deblja, veza je značajnija. Isprekidanom linijom su označene zanemarive veze. Klikom na svaki od neurona prikazuju se njegove četiri karakteristične vrijednosti; ulazna vrijednost, aktivacijska vrijednost, prednaponski koeficijent te pogreška. Shematska skica neurona i međuveza se može vidjeti na slici 3-3.




Slika 3-3 Shematska skica neuronske mreže u JustNN-u

Nadalje, JustNN računa osjetljivost neuronske mreže na ulazne varijable. Slika 3-4 pokazuje redoslijed važnosti varijabli, od najvažnije prema najmanje važnoj.



Slika 3-4 Redoslijed važnosti ulaznih varijabli

Učenje mreže se može najbolje pratiti na grafu učenja koji prikazuje broj iteracija na osi apscisa te maksimalne, minimalne i srednje vrijednosti trening pogreške i pogrešku testiranja. Slika 3-5 prikazuje graf učenja.




Slika 3-5 Graf učenja


4. ANALIZA I REZULTATI

4.1. Predikcija volumnog faktora nafte


Za analizu predikcije volumnog faktora nafte korišteno je ukupno 300 setova podataka. Njih 151 je odabrano za trening, 49 za kalibraciju, a ostalih 100 je iskorišteno za verifikaciju mreže. Ukupno je napravljeno 10 analiza, svaka je imala različitu arhitekturu, te istu stopu učenja i moment koji su iznosili 0,6 i 0,8. Sve su mreže postavljene tako da se učenje zaustavi nakon 10000 iteracija, kada prosječna greška padne ispod 0,01 ili kada svi kalibracijski setovi budu točni nakon zaokruživanja. Na slici 4-1 je dan grafički prikaz koeficijenata korelacije za svaki od deset slučajeva, a najbolji rezultat ima mreža sa samo jednim skrivenim slojem te dva neurona te je njezin koeficijent korelacije 0,9805. Ista mreža ima najmanju najveću prosječnu apsolutnu grešku (slika 4-2) i najmanju prosječnu apsolutnu postotnu grešku (slika 4-3) te one iznose 0,03788 i 1,323%.



Slika 4-1 Graf koeficijenata korelacije (R)



Slika 4-2 Graf najveće prosječne apsolutne greške (E_{max})



Slika 4-3 Graf prosječne apsolutne postotne greške (E_a)

U tablici 4-1 nalaze se postavke učenja svih mreža.

Tablica 4-1 Postavke za učenje mreže – volumni faktor nafte

ANALIZA	ARHITEKTURA			POSTAVKE UČENJA MREŽE		
	1S	2S	3S	BR. ITER.	STOPA UČ.	MOMENT
1.	1	0	0	10000	0,6	0,8
2.	2	0	0	10000	0,6	0,8
3.	1	1	0	10000	0,6	0,8
4.	2	1	0	10000	0,6	0,8
5.	3	1	0	601	0,6	0,8

6.	1	1	1	10000	0,6	0,8
7.	2	1	1	10000	0,6	0,8
8.	2	1	2	10000	0,6	0,8
9.	2	1	7	10000	0,6	0,8
10.	3	1	2	1301	0,6	0,8

Tablica 4-2 prikazuje prosječne, najveće i najmanje vrijednosti grešaka na podacima za trening.

Tablica 4-2 Pogreške na trening setu – volumni faktor nafte

	ARHITEKTURA			TRENING POGREŠKE		
ANALIZA	1S	2S	3S	PROSJEČNA	MAKS.	MIN.
1.	1	0	0	0,002099	0,043173	0,000000
2.	2	0	0	0,000543	0,008952	0,000000
3.	1	1	0	0,003388	0,094032	0,000000
4.	2	1	0	0,000880	0,023668	0,000000
5.	3	1	0	0,000599	0,016444	0,000000
6.	1	1	1	0,003623	0,097268	0,000000
7.	2	1	1	0,001079	0,032629	0,000000
8.	2	1	2	0,000638	0,010414	0,000000
9.	2	1	7	0,000616	0,009529	0,000000
10.	3	1	2	0,000635	0,016982	0,000001

Tablica 4-3 sadrži informacije u broju kalibracijskih setova koji su bili točni nakon zaokruživanja. U dva slučaja je 100% podataka bilo točno nakon zaokruživanja te je u tom trenutku učenje zaustavljeno iako nije odrađeno svih 10000 iteracija. Prvi slučaj je mreža s dva skrivena sloja, tri neurona u prvom i jednim neuronom u drugom sloju, a čije je učenje stalo nakon 601 iteracije te je postigla koeficijent korelacije od 0,9792, najveću prosječnu apsolutnu grešku u iznosu 0,03778 te prosječna apsolutna postotna greška od 1,586%, a zbog svega toga je druga najbolja opcija za predviđanje volumnog faktora nafte. Druga mreža čije je učenje zaustavljeno zbog 100% točnosti kalibracijskih setova nakon zaokruživanja je mreža s arhitekturom 3-1-2, dakle tri skrivena sloja, tri neurona u prvom sloju, jedan neuron u drugom sloju te dva neurona u trećem sloju, a ona je prema statističkoj analizi treća najbolja opcija za predikciju volumnog faktora nafte.

Tablica 4-3 Uspješnost kalibracije – volumni faktor nafte

	ARHITEKTURA			KALIBRACIJA		
ANALIZA	1S	2S	3S	BR. PR. UNUTAR 10%	TOČNO NAKON ZAOK.	%
1.	1	0	0	0	47	95,92
2.	2	0	0	0	48	97,96
3.	1	1	0	0	47	95,92
4.	2	1	0	0	48	97,96
5.	3	1	0	0	49	100,00
6.	1	1	1	0	47	95,92
7.	2	1	1	0	47	95,92
8.	2	1	2	0	48	97,96
9.	2	1	7	0	48	97,96
10.	3	1	2	0	49	100,00

U tablici 4-4 prikazana je važnost ulaznih varijabli za konačan rezultat predikcije.

Tablica 4-4 Osjetljivost predikcije na ulazne varijable – volumni faktor nafte

	ARHITEKTURA			VAŽNOST VARIJABLI				
ANALIZA	1S	2S	3S	R _s , m3/m3	T, °C	γ _g	γ _o	Redoslijed važnosti
1.	1	0	0	1,8779	0,8996	0,8016	0,5780	R _s , T, γ _g , γ _o
2.	2	0	0	5,5385	3,2965	2,1240	1,6226	R _s , T, γ _g , γ _o
3.	1	1	0	2,7418	0,6514	1,1175	1,0246	R _s , γ _g , γ _o , T
4.	2	1	0	6,7409	3,3630	2,2667	1,6317	R _s , T, γ _g , γ _o
5.	3	1	0	9,2869	5,6922	3,2394	2,5773	R _s , T, γ _g , γ _o
6.	1	1	1	2,6532	0,6104	1,0383	1,0066	R _s , γ _g , γ _o , T
7.	2	1	1	7,1685	3,1966	2,3000	1,5745	R _s , T, γ _g , γ _o
8.	2	1	2	7,9671	3,9101	2,3761	1,6939	R _s , T, γ _g , γ _o
9.	2	1	7	7,8666	3,9258	2,3452	1,6942	R _s , T, γ _g , γ _o
10.	3	1	2	9,5377	6,1779	3,2310	2,5449	R _s , T, γ _g , γ _o


U tablici 4-5 dani su statistički rezultati svih analiza.

Tablica 4-5 Statistički rezultati analize – volumni faktor nafte


	ARHITEKTURA			REZULTATI				
ANALIZA	1S	2S	3S	E _{max}	E _{min}	E _a	E _r	R.
1.	1	0	0	0,06310	0,00037	0,02100	0,00631	0,9149
2.	2	0	0	0,03788	0,00032	0,01323	0,00998	0,9805
3.	1	1	0	0,11786	0,00005	0,04708	0,04001	0,7637
4.	2	1	0	0,05363	0,00001	0,01828	0,01324	0,9572

5.	3	1	0	0,03778	0,00034	0,01586	0,01335	0,9792
6.	1	1	1	0,12121	0,00023	0,04819	0,04119	0,7541
7.	2	1	1	0,05016	0,00050	0,01841	0,00708	0,9411
8.	2	1	2	0,04672	0,00026	0,01844	0,01381	0,9582
9.	2	1	7	0,91965	0,63152	0,80052	0,80052	0,9602
10.	3	1	2	0,04388	0,00072	0,01992	0,01798	0,9736


Na slikama 4-4 do 4-13 prikazani su grafovi raspršenosti originalnih podataka i podataka dobivenih predviđanjem pomoću neuronske mreže. Idealan slučaj poklapanja bi bio kad bi sve točke ležale na pravcu čiji je nagib 45°. Pokazatelj odstupanja od idealnog pravca je upravo koeficijent korelacije čija bi vrijednost u slučaju savršenog poklapanja iznosila 1. Slika 4-5 prikazuje graf neuronske mreže s najboljim koeficijentom korelacije, te su na tom grafu sve točke jako blizu pravca što je pokazatelj njezine uspješnosti u računanju volumnog faktora nafte.




Slika 4-4 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1




Slika 4-5 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2




Slika 4-6 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1




Slika 4-7 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-7




Slika 4-8 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-2




Slika 4-9 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1-1




Slika 4-10 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-3-1



Slika 4-11 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-1-1-1



Slika 4-12 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-3-2-1




Slika 4-13 Volumni faktor nafte Gaćininom korelacijom i volumni faktor nafte neuronskom mrežom NN-2-1-1


4.2. Predikcija plinskog faktora

Analiza predikcije plinskog faktora rađena je pomoću 52 podatkovna seta, od kojih je 26 odabrano za trening, 10 za kalibraciju te 16 za verifikaciju mreže. Napravljeno je devet analiza na šest različitih arhitektura. Šest analiza je napravljeno na tri arhitekture s tim da su učile 10000 ili 100000 iteracija, a cilj je bio usporediti rezultate te vidjeti kako će 10 puta veći broj iteracija utjecati na rezultat uz istu arhitekturu mreže. U tablicama 4-6 do 4-10 se mogu vidjeti vrijednosti bitne za ovu analizu. Najbolji rezultat postigla je mreža s arhitekturom 3-3-3 i 100000 iteracija te koeficijent korelacije iznosi 0,9998, uz prosječnu apsolutnu postotnu pogrešku od 0,8144.


Za analizu utjecaja broja iteracija na kvalitetu mreže odabrane su tri jednostavne arhitekture s jednim skrivenim slojem u kojem se nalaze od jednog do tri neurona. Mreže s jednim neuronom ostvarile su identične, a ujedno i najgore rezultate. Mreža s dva neurona i 100000 iteracija je dala bolji koeficijent korelacije od mreže s identičnom arhitekturom i 10 puta manje iteracija, no zakazala je po pitanju najveće prosječne apsolutne greške i prosječne apsolutne greške gdje je mreža s manje iteracija ipak bila bolja. Kao najbolja, se pokazala mreža s tri neurona koji su učeni 10000 iteracija, dok je ista mreža sa 100000 iteracija za nijansu slabija. Na slici 4-14 je dan graf performansi ovih mreža, a na slikama 4-15 do 4-17 vrijednosti statističke analize za svih devet slučajeva.




Slika 4-14 Graf usporedbe vrijednosti $E_{\max}$, E_a i R za tri iste arhitekture koje su učene 10000 i 100000 iteracija



Slika 4-15 Graf koeficijenta korelacije (R) za analizu predikcije plinskog faktora



Slika 4-16 Graf najveće postotne apsolutne greške (E_{max}) za plinski faktor



Slika 4-17 Graf prosječne apsolutne postotne greške (E_a) za plinski faktor

Tablica 4-6 Postavke za učenje mreže – plinski faktor

	ARHITEKTURA			POSTAVKE UČENJA MREŽE		
ANALIZA	1S	2S	3S	BR. ITER.	STOPA UČ.	MOMENT
1.	1	0	0	100000	0,6	0,8
2.	2	0	0	100000	0,6	0,8
3.	3	0	0	100000	0,6	0,8
4.	2	0	0	10000	0,6	0,8
5.	3	3	0	100000	0,6	0,8
6.	3	3	3	100000	0,6	0,8
7.	1	0	0	10000	0,6	0,8
8.	3	0	0	10000	0,6	0,8
9.	3	1	0	10000	0,6	0,8

Tablica 4-7 Pogreške na trening setu – plinski faktor

	ARHITEKTURA			TRENING POGREŠKE		
ANALIZA	1S	2S	3S	PROSJEČNA	MAKS.	MIN.
1.	1	0	0	0,002218	0,017337	0,000001
2.	2	0	0	0,000117	0,000983	0,000001
3.	3	0	0	0,000013	0,000142	0,000000
4.	2	0	0	0,000184	0,002094	0,000002
5.	3	3	0	0,000003	0,000034	0,000000
6.	3	3	3	0,000002	0,000030	0,000000
7.	1	0	0	0,002218	0,017337	0,000001
8.	3	0	0	0,000062	0,001060	0,000000
9.	3	1	0	0,000112	0,001175	0,000000

Tablica 4-8. Uspješnost kalibracije – plinski faktor

	ARHITEKTURA			KALIBRACIJA		
ANALIZA	1S	2S	3S	BR. PR. UNUTAR 10%	TOČNO NAKON ZAOK.	%
1.	1	0	0	0	1	10,00
2.	2	0	0	0	3	30,00
3.	3	0	0	0	7	70,00
4.	2	0	0	0	2	20,00
5.	3	3	0	0	7	70,00
6.	3	3	3	0	6	60,00
7.	1	0	0	0	1	10,00
8.	3	0	0	0	3	30,00
9.	3	1	0	0	1	10,00


Tablica 4-9 Osjetljivost predikcije na ulazne varijable – plinski faktor

	ARHITEKTURA			BR. ITER.	VAŽNOST VARIJABLI				
ANALIZA	1S	2S	3S		p_b , bar	T, °C	γ_g	γ_o	RED. VAŽ.
1.	1	0	0	100000	0,8595	1,1637	0,6543	3,5153	γ_o , T, p_b , γ_g
2.	2	0	0	100000	3,9488	5,2652	1,7580	12,7144	γ_o , T, p_b , γ_g
3.	3	0	0	100000	15,5870	4,7544	1,3571	21,0210	γ_o , p_b , T, γ_g
4.	2	0	0	10000	4,3302	1,5667	2,6800	8,0678	γ_o , p_b , γ_g , T
5.	3	3	0	100000	12,4942	3,0113	0,7112	13,7770	γ_o , p_b , T, γ_g
6.	3	3	3	100000	11,0432	3,3551	0,6613	11,0667	γ_o , p_b , T, γ_g
7.	1	0	0	10000	0,8595	1,1637	0,6543	3,5153	γ_o , T, p_b , γ_g
8.	3	0	0	10000	12,0815	1,7370	0,7737	13,4797	γ_o , p_b , T, γ_g
9.	3	1	0	10000	10,6282	1,6752	1,2463	11,2246	γ_o , p_b , T, γ_g


Tablica 4-10 Statistički rezultati analize – Plinski faktor

	ARHITEKTURA			BR. ITER.	REZULTATI				
ANALIZA	1S	2S	3S		E_{max}	E_{min}	E_a	E_r	R
1.	1	0	0	100000	1,015483	0,003763	0,063468	0,038594	0,9881
2.	2	0	0	100000	0,382530	0,005437	0,023908	0,015581	0,9984
3.	3	0	0	100000	0,224887	0,000415	0,014055	0,002659	0,9988
4.	2	0	0	10000	0,350949	0,000894	0,021934	0,013979	0,9973
5.	3	3	0	100000	0,169467	0,000477	0,010592	0,004637	0,9995
6.	3	3	3	100000	0,130298	0,001825	0,008144	0,004404	0,9998
7.	1	0	0	10000	1,015483	0,003763	0,063468	0,038594	0,9881
8.	3	0	0	10000	0,222698	0,000564	0,013919	0,004433	0,9993
9.	3	1	0	10000	0,297263	0,003547	0,018579	0,007110	0,9984


Na slikama 4-18 do 4-26 prikazani su grafovi raspršenosti originalnih podataka i podataka dobivenih predviđanjem pomoću neuronske mreže.




Slika 4-18 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-1-100k




Slika 4-19 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-2-100k




Slika 4-20 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-100k




Slika 4-21 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-2-10k




Slika 4-22 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-3-100k




Slika 4-23 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-3-3-100k



Slika 4-24 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-1-10k



Slika 4-25 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-10k




Slika 4-26 Plinski faktor Gaćininom korelacijom i plinski faktor neuronskom mrežom NN-3-1-10k


4.3. Predikcija tlaka zasićenja nafte

Analiza predikcije tlaka zasićenja nafte je rađena na setu od 52 podataka te je 26 podataka iskorišteno za trening, 10 za kalibraciju te 16 za verifikaciju, no napravljena je i jedna mreža u kojoj je prvih 5 kalibracijskih podataka dodano trening setu koji je onda brojio 31 set i ta mreža je prema statističkoj analizi postigla najbolje rezultate uz koeficijent korelacije u iznosu od 0,9838, te najmanju prosječnu apsolutnu grešku i najmanju najveću prosječnu apsolutnu grešku koje su iznosile 3,3894% i 0,118379.


Ukupno je napravljeno devet analiza na pet različitih arhitektura, a kao najbolja se pokazala arhitektura s tri sloja te dva neurona u prvom, jednim u drugom i šest neurona u trećem skrivenom sloju. Ta arhitektura je odabrana za još četiri analize pri čemu je za jednu promijenjena stopa učenja (omogućena je njena optimizacija te ju je program sam odabrao), za drugu je povećan broj iteracija na jedan milijun (sve ostale analize predikcije tlaka zasićenja su rađene s 10000 iteracija), u trećoj, već spomenutoj, je kalibracijski set smanjen na polovicu u korist trening seta, a u zadnjoj je stopa učenja „ručno“ postavljena na 0,4, a zanimljivo je da je postigla bolji rezultat od one koju je odabrao program, a čija je vrijednost bila 0,7. Grafovima na slikama od 4-27 do 4-29 su dane vrijednosti statističke analize za svih devet slučajeva, a u tablicama 4-11 do 4-15 postavke za učenje, pogreške trening seta, uspješnost kalibracije, osjetljivost na ulazne varijable te statistički rezultati.



Slika 4-27 Koeficijenti korelacije (R) za p_b




Slika 4-28 Najveće prosječne apsolutne greške ($E_{\max}$) za p_b




Slika 4-29 Prosječne apsolutne postotne greške (E_a) za p_b

Budući da volumni faktor nafte i tlak zasićenja nafte imaju iste ulazne parametre, napravljena je usporedba osjetljivosti na ulazne parametre (slika 4-30). Prema grafu se može zaključiti da na volumni faktor najveći utjecaj ima plinski faktor, zatim temperatura, pa relativna gustoća plina i relativna gustoća nafte, dok je za tlak zasićenja najutjecajniji parametar relativna gustoća plina, nakon koje slijede plinski faktor, relativna gustoća nafte i temperatura.



Slika 4-30 Usporedba osjetljivosti predikcije volumnog faktora nafte i tlaka zasićenja na ulazne parametre

Na slici 4-31 nalazi se graf koji prikazuje koeficijente korelacije koje su postigle mreže istih arhitektura, s 10000 iteracija, ali za predikciju različitih parametara. Plavom bojom su označeni stupci s koeficijentima korelacije za plinski faktor, a narančastom za tlak zasićenja. Najbolje rezultate je za oba parametra ima mreža s tri neurona, a najgore ona sa samo jednim. Za svaku arhitekturu je koeficijent korelacije mreže za predikciju plinskog faktora veći od koeficijenata korelacije za predikciju tlaka zasićenja iz čega se može zaključiti da neuronske mreže općenito bolje pogađaju plinski faktor nego tlak zasićenja.



Slika 4-31 Usporedba koeficijenata korelacije za predikciju različitih parametara na mrežama s različitim brojem iteracija

Tablica 4-11 Postavke za učenje mreže – tlak zasićenja nafte

	ARHITEKTURA			POSTAVKE UČENJA MREŽE		
ANALIZA	1S	2S	3S	BR. ITER.	STOPA UČ.	MOMENT
1.	1	0	0	10000	0,6	0,8
2.	2	0	0	10000	0,6	0,8
3.	3	0	0	10000	0,6	0,8
4.	2	1	0	10000	0,6	0,8
5.	2	1	6	10000	0,6	0,8
6.	2	1	6	10000	0,7	0,8
7.	2	1	6	1000000	0,6	0,8
8.	2	1	6	10000	0,6	0,8
9.	2	1	6	10000	0,4	0,8

Tablica 4-12 Pogreške na trening setu – tlak zasićenja nafte

	ARHITEKTURA			TRENING POGREŠKE		
ANALIZA	1S	2S	3S	PROSJEČNA	MAKS.	MIN.
1.	1	0	0	0,002845	0,007963	0,000000
2.	2	0	0	0,001078	0,004932	0,000000
3.	3	0	0	0,000189	0,000740	0,000001
4.	2	1	0	0,001140	0,004818	0,000001
5.	2	1	6	0,000177	0,000827	0,000002
6.	2	1	6	0,000172	0,000609	0,000000
7.	2	1	6	0,000108	0,000381	0,000000
8.	2	1	6	0,000173	0,001224	0,000000
9.	2	1	6	0,000360	0,001334	0,000000

Tablica 4-13 Uspješnost kalibracije – tlak zasićenja nafte

	ARHITEKTURA			KALIBRACIJA		
ANALIZA	1S	2S	3S	BR. PR. UNUTAR 10%	TOČNO NAKON ZAOK.	% VAL.
1.	1	0	0	0	2	20,00
2.	2	0	0	0	2	20,00
3.	3	0	0	0	2	20,00
4.	2	1	0	0	2	20,00
5.	2	1	6	0	2	20,00
6.	2	1	6	0	2	20,00
7.	2	1	6	0	2	20,00

8.	2	1	6	0	1	20,00
9.	2	1	6	0	3	30,00


Tablica 4-14 Osjetljivost predikcije na ulazne varijable – tlak zasićenja nafte

	ARHITEKTURA			BR. ITER.	VAŽNOST VARIJABLI				
MREŽA	1S	2S	3S		R _s , m3/m3	T, °C	γ _g	γ _o	Red. VAŽN.
1.	1	0	0	10000	2,4216	1,2105	3,3941	2,1294	γ _g , R _s , γ _o , T
2.	2	0	0	10000	6,0598	6,5929	4,0026	4,2590	T, R _s , γ _o , γ _g
3.	3	0	0	10000	10,0041	8,0191	16,7713	5,9086	γ _g , R _s , T, γ _o
4.	2	1	0	10000	5,7726	9,0752	7,2903	1,7806	T, γ _g , R _s , γ _o
5.	2	1	6	10000	10,3305	3,0915	13,9312	5,5495	γ _g , R _s , γ _o , T
6.	2	1	6	10000	11,6307	3,3679	14,3115	5,7838	γ _g , R _s , γ _o , T
7.	2	1	6	1000000	10,1542	2,9660	13,0265	5,6790	γ _g , R _s , γ _o , T
8.	2	1	6	10000	11,1764	2,7540	12,4496	5,5235	γ _g , R _s , γ _o , T
9.	2	1	6	10000	9,5558	3,0221	15,3804	4,7565	γ _g , R _s , γ _o , T


Tablica 4-15 Statistički rezultati analize – tlak zasićenja nafte

	ARHITEKTURA			DODATNE INFORMACIJE	REZULTATI				
ANALIZA	1S	2S	3S		E _{max}	E _{min}	E _a	E _r	KOEF. KOR.
1.	1	0	0	10000	0,296092	0,0267	0,107579	0,042828	0,9358
2.	2	0	0	10000	0,136021	0,006049	0,060313	-0,01071	0,9558
3.	3	0	0	10000	0,154903	0,003549	0,057883	0,012439	0,9656
4.	2	1	0	10000	0,139588	0,007989	0,059838	0,017685	0,9620
5.	2	1	6	10000	0,119235	0,001634	0,03579	0,007106	0,9799
6.	2	1	6	10k SU	0,118973	0,000465	0,043436	0,011448	0,9749
7.	2	1	6	1000000	0,117926	0,001274	0,034394	0,009526	0,9803
8.	2	1	6	10TS+5	0,118379	0,001062	0,033894	0,020932	0,9838
9.	2	1	6	SU04	0,137211	0,000138	0,04579	-0,0027	0,9771


Na slikama 4-32 do 4-40 prikazani su grafovi raspršenosti originalnih podataka i podataka dobivenih predviđanjem pomoću neuronske mreže.




Slika 4-32 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-1-10k




Slika 4-33 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-10k




Slika 4-34 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-3-10k




Slika 4-35 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-10k




Slika 4-36 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-10k




Slika 4-37 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-SU



Slika 4-38 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-1M



Slika 4-39 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-TS+5



Slika 4-40 Tlak zasićenja Gaćininom korelacijom i tlak zasićenja neuronskom mrežom NN-2-1-6-SU04

5. ZAKLJUČAK

Kvalitetni rezultati umjetnih neuronskih mreža ovise o jako puno različitih i međusobno nepovezanih parametara, a to dizajn neuronskih mreža čini vrlo zahtjevnim. Već na samom početku se pojavljuje problem pravilne podjele te se mora paziti da se podatkovni set na najbolji mogući način podijeli na trening set, kalibracijski i verifikacijski set, ne samo gledajući na ukupnost podatkovnog seta, već i na raspon vrijednosti svakog parametra unutar samog seta. Nakon toga postavljaju se pitanja arhitekture mreže, broja iteracija, stope učenja itd. Kod rješavanja cijele spomenute problematike ne postoje egzaktna pravila, već je potrebno testiranjem različitih postavki doći do najboljeg rezultata, a to je vremenski vrlo zahtjevno. Iako rezultati predikcija neuronskim mrežama mogu izgledati privlačno, jer se prema nekim statističkim pokazateljima njihova točnost približava vrijednosti od 100%, postavlja se pitanje što je dovoljno točno, jer čak i tako mala odstupanja od idealne predikcije u velikim industrijama poput naftne mogu donijeti velike dobitke, ali i enormne gubitke, a spremnost vrhovnog menadžmenta na rizik utječe na razvoj i istraživanje samih neuronskih mreža.

Međutim, hipoteza iz uvoda je potvrđena i neuronska mreža se može koristiti za testiranje nezavisnih varijabli u fizikalno povezanim parametrima – može se detektirati koji će parametar najviše utjecati na druge procjene.

Tako npr. volumni faktor očito primarno ovisi o plinskom faktoru, a težinski utjecaj zatim najčešće pripada temperaturi kao parametru koji predstavlja nezavisnu varijablu (Tablica 4-4).

Plinski faktor ponajviše ovisi o gustoći nafte, a jako malo o gustoći plina. Tlak zasićenja i temperatura utječu više ili manje jedan od drugog, ovisno o ostalim uvjetima tj. nezavisnim varijablama (tablica 4-9).

Zanimljivo je da tlak zasićenja, koji sadrži iste parametre u korelaciji kao i plinski faktor, pri učenju neuronske mreže najveći značaj daje upravo gustoći plina. Ovo upućuje da jednostavna transformacija korelacija za plinski faktor u korelaciju za tlak zasićenja ne garantira jednako točnu korelaciju tlaka zasićenja.

Konačno se može zaključiti da neuronska mreža za predikcije svojstava fluida u ležištima ugljikovodika treba biti korištena oprezno, te na temelju velikog broja ulaznih podataka, ali da može poslužiti za provjeru reprezentativnosti podataka, tj. može ukazati na parametre koji trebaju biti eksperimentalno određeni s većom pozornošću.

6. LITERATURA

- 1) Adeeyo, Y.A., 2016, August. Artificial Neural Network Modelling of Bubblepoint Pressure and Formation Volume Factor at Bubblepoint Pressure of Nigerian Crude Oil. In *SPE Nigeria Annual International Conference and Exhibition*. Society of Petroleum Engineers.
- 2) Al-Fattah, S.M. and Al-Naim, H.A., 2009. Artificial-intelligence technology predicts relative permeability of giant carbonate reservoirs. *SPE Reservoir Evaluation & Engineering*, 12(01), pp.96-103.
- 3) Ali, J.K., 1994, January. Neural networks: a new tool for the petroleum industry?. In *European petroleum computer conference*. Society of Petroleum Engineers.
- 4) Alimadadi, F., Fakhri, A., Farooghi, D. and Sadati, H., 2011. Using a committee machine with artificial neural networks to predict PVT properties of Iran crude oil. *SPE Reservoir Evaluation & Engineering*, 14(01), pp.129-137.
- 5) Al-Marhoun, M.A. and Osman, E.A., 2002, January. Using artificial neural networks to develop new PVT correlations for Saudi crude oils. In *Abu Dhabi international petroleum exhibition and conference*. Society of Petroleum Engineers.
- 6) Braswell, G., 2013. Artificial Intelligence Comes of Age in Oil and Gas. *Journal of Petroleum Technology*, 65(01), pp.50-57.
- 7) Bošnjak, M., 2011. Neuronske mreže
URL: https://web.math.pmf.unizg.hr/nastava/su/index.php/download_file/-/view/109/ [12 siječanj 2017]
- 8) Dalbelo Bašić, B., Čupić, M. and Šnajder, J., 2008. Umjetne neuronske mreže. *Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska*.
URL: https://www.fer.hr/_download/repository/UmjetneNeuronskeMreze.pdf [15 Prosinac 2016]
- 9) Du, Y., Weiss, W.W., Jianyun, X., Balch, R.S. and Dacun, L., 2003, January. Obtain an optimum artificial neural network model for reservoir studies. In *SPE Annual Technical Conference and Exhibition*. Society of Petroleum Engineers.
- 10) Dumančić, S., 2014. Neuronske mreže. *Sveučilište Josipa Jurja Strossmayera u Osijeku*.
URL: <http://www.mathos.unios.hr/~mdjumic/uploads/diplomski/dum05.pdf> [27.1.2017.]
- 11) El-Sebakhy, E.A., Sheltami, T., Al-Bokhitan, S.Y., Shaaban, Y., Raharja, P.D. and Khaeruzzaman, Y., 2007, January. Support vector machines framework for predicting the PVT properties of crude oil systems. In *SPE Middle East Oil and Gas Show and Conference*. Society of Petroleum Engineers.
- 12) Gharbi, R.B. and Elsharkawy, A.M., 1997, January. Neural network model for estimating the PVT properties of Middle East crude oils. In *Middle East Oil Show and Conference*. Society of Petroleum Engineers.
- 13) Gharbi, R.B. and Elsharkawy, A.M., 1997, January. Neural network model for estimating the PVT properties of Middle East crude oils. In *Middle East Oil Show and Conference*. Society of Petroleum Engineers.
- 14) Gharbi, R.B., Elsharkawy, A.M. and Karkoub, M., 1999. Universal neural-network-based model for estimating the PVT properties of crude oil systems. *Energy & Fuels*, 13(2), pp.454-458.
- 15) Goda, H.M., Shokir, E.M., Eissa, M., Fattah, K.A. and Sayyoub, M.H., 2003, January. Prediction of the PVT data using neural network computing theory. In *Nigeria annual international conference and exhibition*. Society of Petroleum Engineers.

- 16) Ikiensikimama, S.S. and Azubuike, I.I., 2012, January. Modeling Approach for Niger-Delta Oil Formation Volume Factor Prediction Using Artificial Neural Network. In *Nigeria Annual International Conference and Exhibition*. Society of Petroleum Engineers.
- 17) Ilić, V., URL: <http://solair.eunet.rs/~ilicv/neuro.html> [10 siječanj 2017]
- 18) Kaviani, D., Bui, T., Jensen, J.L. and Hanks, C., 2006, January. The application of artificial neural networks with small data sets: An example for analysis of fracture spacing in the Lisburne formation, northeastern Alaska. In *SPE Annual Technical Conference and Exhibition*. Society of Petroleum Engineers.
- 19) Kumoluyi, A.O., 1994, January. Higher-order neural networks in petroleum engineering. In *SPE Western Regional Meeting*. Society of Petroleum Engineers.
- 20) Mohaghegh, S., 2000. Virtual-intelligence applications in petroleum engineering: Part 1—Artificial neural networks. *Journal of Petroleum Technology*, 52(09), pp.64-73.
- 21) Numbere, O.G., Azuibuike, I.I. and Ikiensikimama, S.S., 2013, August. Bubble Point Pressure Prediction Model for Niger Delta Crude using Artificial Neural Network Approach. In *SPE Nigeria Annual International Conference and Exhibition*. Society of Petroleum Engineers.
- 22) Popčević, J., Varga, I., Žuvela, P., 2012, Seminarski rad iz kolegija Uvod u matematičke metode u inženjerstvu
URL:
matematika.fkit.hr/novo/izborni/referati/Popcevic_Varga_Zuvela_Neuronske_mreze.pdf
[13 siječanj 2017]
- 23) Osman, E.A., Abdel-Wahhab, O.A. and Al-Marhoun, M.A., 2001, January. Prediction of oil PVT properties using neural networks. In *SPE Middle East Oil Show*. Society of Petroleum Engineers.
- 24) Osman, E.S.A. and Al-Marhoun, M.A., 2005, January. Artificial neural networks models for predicting PVT properties of oil field brines. In *SPE Middle East Oil and Gas Show and Conference*. Society of Petroleum Engineers.
- 25) Varotsis, N., Gaganis, V. and Nighswander, J., 2002. Quality assurance tool for PVT simulator predictions. *SPE Reservoir Evaluation & Engineering*, 5(06), pp.499-506.
- 26) Varotsis, N., Gaganis, V., Nighswander, J. and Guieze, P., 1999. A novel non-iterative method for the prediction of the PVT behavior of reservoir fluids. In *SPE annual technical conference*.

Internet izvori:

Na koji način se učenjem stvara neuronska mreža? [ONLINE]

Dostupno na: <http://eris.foi.hr/11neuronske/nn-predavanje4.html> [28.1.2017.]

Upute za korištenje programa JustNN [ONLINE]

Dostupno na: <http://www.justnn.com/> [25.1.2017.]

Nepovratne mreže [ONLINE]

Dostupno na: <http://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/Architecture/feedforward.html> [28.1.2017.]

<http://stats.stackexchange.com/questions/2213/feed-forward-and-recurrent-neural-networks>

[28.1.2017.]

Višeslojne perceptronske mreže [ONLINE]

Dostupno na: <http://neuroph.sourceforge.net/tutorials/MultiLayerPerceptron.html>
[28.1.2017]

7. DODATCI

7.1. Specifične vrijednosti neurona za volumni faktor nafte (B_o)

Tablica 7-1 B_o NN-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	0,214286	0,0
1	0,0	0,0	0,338557	0,0
2	0,0	0,0	-0,334803	0,0
3	0,0	0,0	0,387234	0,0
Skriveni sloj				
4	1,140539	0,757779	2,079469	-0,171127
Izlazni sloj				
5	-1,455035	0,189228	2,335354	0,207781

Tablica 7-2 B_o NN-2

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,043474	0,0
1	0,0	0,0	-0,048326	0,0
2	0,0	0,0	0,123890	0,0
3	0,0	0,0	0,163228	0,0
Skriveni sloj				
4	4,187861	0,985048	5,656767	-0,036238
5	-1,617838	0,165503	-0,317518	-0,058442
Izlazni sloj				
6	-1,561899	0,173374	4,029712	0,094615

Tablica 7-3 B₀ NN-1-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	0,338557	0,0
1	0,0	0,0	-0,334803	0,0
2	0,0	0,0	0,387234	0,0
3	0,0	0,0	0,214255	0,0
Skriveni sloj 1				
4	2,042651	0,885203	3,413564	-0,122018
Skriveni sloj 2				
5	-0,152322	0,461993	3,283168	0,362590
Izlazni sloj				
6	-1,588773	0,169557	-4,174704	0,306646

Tablica 7-4 B₀ NN-2-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,048326	0,0
1	0,0	0,0	0,123890	0,0
2	0,0	0,0	0,163228	0,0
3	0,0	0,0	-0,209037	0,0
Skriveni sloj 1				
4	4,774947	0,991632	6,367817	-0,031195
5	-2,427885	0,081071	-0,650287	-0,040091
Skriveni sloj 2				
6	0,695120	0,667105	-6,428762	-0,102090
Izlazni sloj				
7	-1,425634	0,193780	1,973391	0,153844

Tablica 7-5 B₀ NN-3-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	0,170370	0,0
1	0,0	0,0	-0,188223	0,0
2	0,0	0,0	0,295770	0,0
3	0,0	0,0	-0,379482	0,0
Skriveni sloj 1				
4	-5,119953	0,005941	-6,179065	-0,052983
5	1,645882	0,838334	-0,487114	-0,050477
6	-3,989890	0,018166	-5,441239	-0,052779
Skriveni sloj 2				
7	0,630015	0,652493	3,376623	0,063499
Izlazni sloj				
8	-1,516485	0,179980	2,395886	-0,045681

Tablica 7-6 B₀ NN-1-1-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,334803	0,0
1	0,0	0,0	0,387234	0,0
2	0,0	0,0	0,214255	0,0
3	0,0	0,0	-0,043474	0,0
Skriveni sloj 1				
4	1,546397	0,824393	2,873002	-0,124687
Skriveni sloj 2				
5	-2,182699	0,101315	0,603703	0,14801
Skriveni sloj 3				
6	-1,278897	0,217738	-0,675657	-0,866064
Izlazni sloj				

7	-1,606042	0,167139	1,211289	0,311878
---	-----------	----------	----------	----------

Tablica 7-7 B₀ NN-3-1-2

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,379482	0,0
1	0,0	0,0	-0,188162	0,0
2	0,0	0,0	-0,245933	0,0
3	0,0	0,0	-0,160695	0,0
Skriveni sloj 1				
4	-3,395776	0,032428	-4,861110	-0,036185
5	1,624927	0,835473	-0,618866	-0,043679
6	-5,465913	0,004211	-6,525618	-0,045073
Skriveni sloj 2				
7	-1,547608	0,175432	-4,674934	-0,054909
Skriveni sloj 3				
8	-1,004971	0,267965	0,049144	0,055404
9	2,417054	0,918119	3,069459	0,040863
Izlazni sloj				
10	-1,583694	0,170273	3,749457	-0,042510

Tablica 7-8 B₀ NN-2-1-7

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,419553	0,0
1	0,0	0,0	-0,180013	0,0
2	0,0	0,0	0,153127	0,0
3	0,0	0,0	0,390500	0,0
Skriveni sloj 1				

4	-2,912280	0,051550	-0,835328	-0,073885
5	3,996961	0,981960	5,853288	-0,043894
Skriveni sloj 2				
6	1,947148	0,875135	-2,861786	-0,100607
Skriveni sloj 3				
7	-3,771247	0,022505	-1,238008	0,022214
8	-8,131125	0,000294	-1,557753	0,033238
9	-9,164253	0,000105	-0,850457	0,040794
10	-3,514197	0,028911	-1,256039	0,020310
11	1,540048	0,823472	10,132973	0,068794
12	-5,129772	0,005883	-1,632780	0,024230
13	-6,426812	0,001615	-1,861184	0,026375
Izlazni sloj				
14	-1,406248	0,196826	-8,151937	0,097616

Tablica 7-9 B₀ NN-2-1-2

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	-0,209037	0,0
1	0,0	0,0	-0,070421	0,0
2	0,0	0,0	0,170370	0,0
3	0,0	0,0	-0,188223	0,0
Skriveni sloj 1				
4	3,973046	0,981531	5,838055	-0,042673
5	-2,889400	0,052680	-0,770855	-0,072645
Skriveni sloj 2				
6	1,563181	0,826809	-3,006422	-0,121369
Skriveni sloj 3				
7	-7,534252	0,000534	-0,553003	0,086080
8	1,268417	0,780472	6,961862	0,071189
Izlazni sloj				

9	-1,391665	0,199142	-7,345905	0,102048
----------	-----------	----------	-----------	----------

Tablica 7-10 B₀ NN-2-1-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,5	0,5	0,123890	0,0
1	0,0	0,0	0,163228	0,0
2	0,0	0,0	-0,209037	0,0
3	0,0	0,0	-0,070421	0,0
Skriveni sloj 1				
4	5,022207	0,993453	6,666046	-0,031159
5	-2,726389	0,061434	-0,785954	-0,038726
Skriveni sloj 2				
6	0,522420	0,627714	-7,283105	-0,083760
Skriveni sloj 3				
7	-0,597631	0,354886	1,873144	0,156645
Izlazni sloj				
8	-1,295176	0,241978	-3,379832	0,180636

7.2. Specifične vrijednosti neurona za plinski faktor (R_s)

Tablica 7-11 R_s NN-1

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	0,214286	0,0
1	0,299713	0,299713	0,338557	0,0
2	0,941939	0,941939	-0,334803	0,0
3	0,0	0,0	0,387234	0,0

Skriveni sloj				
4	1,530761	0,822118	-1,550201	0,026054
Izlazni sloj				
5	-2,089558	0,110116	3,709606	-0,046114

Tablica 7-12 R_s NN-2

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	-0,043474	0,0
1	0,299713	0,299713	0,338557	0,0
2	0,941939	0,941939	0,123890	0,0
3	0,0	0,0	0,163228	0,0
Skriveni sloj				
4	-1,347002	0,206361	-5,055863	0,005962
5	8,106336	0,999698	1,059763	0,005557
Izlazni sloj				
6	-2,457150	0,078917	13,383703	-0,020917

Tablica 7-13 R_s NN-3

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	-0,070421	0,0
1	0,299713	0,299713	0,170370	0,0
2	0,941939	0,941939	-0,188223	0,0
3	0,0	0,0	0,295770	0,0
Skriveni sloj				
4	2,472202	0,922170	-1,482490	0,000185
5	-1,826220	0,138689	-1,117314	0,000343
6	20,220916	1,0	8,281139	0,000424

Izlazni sloj				
7	-2,525868	0,074065	11,720501	-0,006738

Tablica 7-14 R_s NN-2-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	-0,043474	0,0
1	0,299713	0,299713	-0,048326	0,0
2	0,941939	0,941939	0,123890	0,0
3	0,0	0,0	0,163228	0,0
Skriveni sloj				
4	-0,709843	0,329633	-2,352702	0,003009
5	6,691559	0,998760	2,098740	0,003292
Izlazni sloj				
6	-2,529070	0,073845	8,103598	-0,020269

Tablica 7-15 R_s NN-3-3-100k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	-0,419553	0,0
1	0,299713	0,299713	-0,180013	0,0
2	0,941939	0,941939	0,153127	0,0
3	0,0	0,0	-0,390500	0,0
Skriveni sloj 1				
4	-2,308821	0,090395	0,741858	-0,000322
5	2,420393	0,918369	1,358139	-0,000378
6	-12,872007	0,000003	-5,598347	-0,000416
Skriveni sloj 2				
7	-0,802893	0,309407	2,461695	0,000205

8	-0,835303	0,302525	2,693176	0,000237
9	7,224559	0,999272	6,081350	0,000256
Izlazni sloj				
10	-2,452642	0,079246	9,062111	-0,005844

Tablica 7-16 R_s NN-3-3-3-100k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	0,469573	0,0
1	0,299713	0,299713	-0,362667	0,0
2	0,941939	0,941939	0,190207	0,0
3	0,0	0,0	-0,297845	0,0
Skriveni sloj 1				
4	-10,535207	0,000027	-4,810407	-0,000452
5	3,104392	0,957074	1,718805	-0,000485
6	1,859371	0,865224	-0,943432	0,000262
Skriveni sloj 2				
7	-6,203205	0,002019	-4,047323	-0,000262
8	0,513646	0,625661	-1,928909	-0,000405
9	-1,426298	0,193676	-1,138442	-0,000160
Skriveni sloj 3				
10	-0,726165	0,326037	2,399180	0,000200
11	-0,540033	0,368180	2,352317	0,000183
12	4,364350	0,987437	4,917836	0,000195
Izlazni sloj				
13	-2,428359	0,081036	8,383860	-0,005496

Tablica 7-17 R_s NN-1-10k

Ulazni sloj				
Broj neurona	Ulazna	Aktiv.	Prednap. koef.	Pogreška

	vrijednost	vrijednost		
0	0,041756	0,041756	0,214286	0,0
1	0,299713	0,299713	0,338557	0,0
2	0,941939	0,941939	-0,334803	0,0
3	0,0	0,0	0,387234	0,0
Skriveni sloj 1				
4	1,530761	0,822118	-1,550201	0,033016
Izlazni sloj				
5	-2,089558	0,110116	3,709606	-0,071002

Tablica 7-18 R_s NN-3-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	-0,070421	0,0
1	0,299713	0,299713	0,170370	0,0
2	0,941939	0,941939	-0,188223	0,0
3	0,0	0,0	0,295770	0,0
Skriveni sloj 1				
4	-1,551314	0,174897	-1,413827	0,000494
5	12,141291	0,999995	4,916394	0,000611
6	2,447865	0,920405	0,450150	0,000275
Izlazni sloj				
7	-2,463979	0,078422	7,569774	-0,009781

Tablica 7-19 R_s NN-3-1-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,041756	0,041756	0,170370	0,0
1	0,299713	0,299713	-0,188223	0,0

2	0,941939	0,941939	0,295770	0,0
3	0,0	0,0	-0,379482	0,0
Skriveni sloj 1				
4	-2,111431	0,107991	-0,494153	-0,000170
5	-2,099513	0,109144	-1,760260	0,000732
6	-10,678466	0,000023	-4,591038	-0,001020
Skriveni sloj 2				
7	1,257584	0,778610	0,886022	0,002573
Izlazni sloj				
8	-2,486013	0,076845	6,053627	-0,015435

7.3. Specifične vrijednosti neurona za tlak zasićenja nafte (p_b)

Tablica 7-20 p_b NN-1-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	0,214286	0,0
1	0,072857	0,072857	0,338557	0,0
2	0,934856	0,934856	-0,334803	0,0
3	0,0	0,0	0,387234	0,0
Skriveni sloj 1				
4	-1,191988	0,232904	-3,466168	-0,007648
Izlazni sloj				
5	0,582821	0,641716	-2,747349	-0,003570

Tablica 7-21 p_b NN-2-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,043474	0,0
1	0,072857	0,072857	-0,048326	0,0

2	0,934856	0,934856	0,123890	0,0
3	0,0	0,0	0,163228	0,0
Skriveni sloj 1				
4	0,488884	0,619843	-2,798092	0,000696
5	-0,730993	0,324977	-2,521563	0,000447
Izlazni sloj				
6	0,511362	0,625126	-7,128401	0,000513

Tablica 7-22 p_b NN-3-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,070421	0,0
1	0,072857	0,072857	0,170370	0,0
2	0,934856	0,934856	-0,188223	0,0
3	0,0	0,0	0,295770	0,0
Skriveni sloj 1				
4	2,140993	0,894824	-0,556869	0,008806
5	-1,461702	0,188207	-3,006934	0,013482
6	-2,617710	0,068007	-4,869200	0,017746
Izlazni sloj				
7	-0,055656	0,486090	-6,254914	0,013518

Tablica 7-23 p_b NN-2-1-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,048326	0,0
1	0,072857	0,072857	0,123890	0,0
2	0,934856	0,934856	0,163228	0,0
3	0,0	0,0	-0,209037	0,0

Skriveni sloj 1				
4	-2,427796	0,081078	0,065865	-0,009502
5	0,201648	0,550242	0,032957	-0,014915
Skriveni sloj 2				
6	-0,643042	0,344559	1,605358	0,028732
Izlazni sloj				
7	0,408828	0,600807	-3,574431	0,018346

Tablica 7-24 p_b NN-2-1-6-10k

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,160695	0,0
1	0,072857	0,072857	-0,033555	0,0
2	0,934856	0,934856	-0,419553	0,0
3	0,0	0,0	-0,180013	0,0
Skriveni sloj 1				
4	2,113310	0,892190	5,900833	-0,012778
5	-3,669551	0,024854	-1,019809	-0,011852
Skriveni sloj 2				
6	0,353027	0,587351	-6,194186	-0,012543
Skriveni sloj 3				
7	-5,882958	0,002779	0,683114	0,005171
8	-5,166472	0,005672	-1,344120	0,002915
9	-3,644153	0,025477	-1,963359	0,001219
10	-3,591523	0,026817	-1,952761	0,001171
11	3,185857	0,960299	8,813089	0,006236
12	-3,999319	0,017998	-1,948488	0,001478
Izlazni sloj				
13	0,641415	0,655073	-7,471147	0,005222

Tablica 7-25 p_b NN-2-1-6-SU

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,160695	0,0
1	0,072857	0,072857	-0,033555	0,0
2	0,934856	0,934856	-0,419553	0,0
3	0,0	0,0	-0,180013	0,0
Skriveni sloj 1				
4	1,862802	0,865623	5,810318	-0,006262
5	-4,767296	0,008432	-1,801198	-0,005740
Skriveni sloj 2				
6	0,365368	0,590339	-6,089596	-0,006446
Skriveni sloj 3				
7	-6,184018	0,002058	0,794112	0,002625
8	-5,262555	0,005155	-1,406463	0,001376
9	-3,844147	0,020956	-2,155208	0,000555
10	-3,842386	0,020992	-2,144306	0,000550
11	3,452480	0,969305	9,378361	0,003100
12	-4,224559	0,014421	-2,131933	0,000690
Izlazni sloj				
13	0,695746	0,667244	-7,523134	0,002544

Tablica 7-26 p_b NN-2-1-6-1M

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,160695	0,0
1	0,072857	0,072857	-0,033555	0,0
2	0,934856	0,934856	-0,419553	0,0
3	0,0	0,0	-0,180013	0,0
Skriveni sloj 1				

4	1,822782	0,860900	6,214205	-0,007178
5	-4,300333	0,013383	-2,106155	-0,017597
Skriveni sloj 2				
6	-0,035383	0,491155	-5,825862	-0,006666
Skriveni sloj 3				
7	-8,811482	0,000149	0,036888	0,006021
8	-7,617554	0,000492	-2,784684	0,002055
9	-2,186985	0,100925	-1,310960	0,000964
10	-2,164999	0,102938	-1,274441	0,000946
11	3,748248	0,976983	7,140769	0,007008
12	-2,367423	0,085691	-1,522282	0,001024
Izlazni sloj				
13	0,650784	0,657187	-14,316952	0,003276

Tablica 7-27 p_b NN-2-1-6-TS+5

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,160695	0,0
1	0,072857	0,072857	-0,033555	0,0
2	0,934856	0,934856	-0,419553	0,0
3	0,0	0,0	-0,180013	0,0
Skriveni sloj 1				
4	2,211246	0,901255	6,510677	0,045879
5	-3,825666	0,021339	-1,418718	0,043178
Skriveni sloj 2				
6	0,499379	0,622313	-6,219695	0,027715
Skriveni sloj 3				
7	-6,065865	0,002315	0,967324	-0,033380
8	-5,456496	0,004250	-1,072481	-0,020330
9	-4,131150	0,015810	-2,063321	-0,008918
10	-4,040876	0,017278	-2,056611	-0,008419

11	2,947881	0,950163	9,202278	-0,041414
12	-4,505772	0,010924	-2,017758	-0,010873
Izlazni sloj				
13	0,611845	0,648362	-7,577324	-0,020619

Tablica 7-28 p_b -NN-2-1-6-SU04

Ulazni sloj				
Broj neurona	Ulazna vrijednost	Aktiv. vrijednost	Prednap. koef.	Pogreška
0	0,219185	0,219185	-0,160695	0,0
1	0,072857	0,072857	-0,033555	0,0
2	0,934856	0,934856	-0,419553	0,0
3	0,0	0,0	-0,180013	0,0
Skriveni sloj 1				
4	-3,115034	0,042491	-0,818241	-0,002625
5	3,139808	0,958505	6,263577	-0,002417
Skriveni sloj 2				
6	0,078133	0,519523	-5,692349	-0,002198
Skriveni sloj 3				
7	-2,684002	0,063924	0,276677	0,001196
8	-2,545172	0,072752	0,055242	0,001044
9	-1,954452	0,124069	-0,471491	0,000643
10	-2,225750	0,097462	-0,186419	0,000844
11	2,295739	0,908524	5,211842	0,001444
12	-1,968961	0,122500	-0,382375	0,000682
Izlazni sloj				
13	0,410337	0,601169	-6,712208	0,001639

7.4. Prvi set podataka – Volumni faktor nafte (B_o)

	R_s, m³/m³	γ_g	γ_o	T, °C	B_o Gacina, m³/m³
1	100	1.6	0.9	150	1.514839
2	80	1.6	0.9	150	1.445662
3	60	1.6	0.9	150	1.375952
4	40	1.6	0.9	150	1.304964
5	80	1.2	0.9	150	1.407165
6	60	1.2	0.9	150	1.346697
7	40	1.2	0.9	150	1.284882
8	60	1	0.9	150	1.330166
9	100	0.8	0.9	150	1.410347
10	80	0.8	0.9	150	1.36144
11	20	0.8	0.9	150	1.206729
12	40	0.6	0.9	150	1.246273
13	20	0.6	0.9	150	1.198755
14	100	1.6	0.8	150	1.618714
15	60	1.6	0.8	150	1.438952
16	40	1.6	0.8	150	1.347932
17	100	1.2	0.8	150	1.556591
18	80	1.2	0.8	150	1.479184
19	20	1.2	0.8	150	1.239995
20	80	1	0.8	150	1.451209
21	40	1	0.8	150	1.307845
22	100	0.8	0.8	150	1.483291
23	80	0.8	0.8	150	1.420287
24	100	0.6	0.8	150	1.43973
25	80	0.6	0.8	150	1.385177
26	60	0.6	0.8	150	1.329942
27	20	0.6	0.8	150	1.213563
28	60	1.6	0.75	150	1.480903
29	40	1.6	0.75	150	1.376367
30	80	0.6	0.9	150	1.334082
31	60	0.8	0.9	150	1.311813
32	40	0.8	0.9	150	1.260809
33	60	1.2	0.8	150	1.401353
34	40	1.2	0.8	150	1.32233
35	60	0.8	0.8	150	1.35668
36	40	0.8	0.8	150	1.291745
37	80	1.2	0.75	150	1.527243
38	60	1.2	0.75	150	1.437665
39	100	1	0.75	150	1.576335
40	80	1	0.75	150	1.495014
41	60	1	0.75	150	1.413326
42	20	0.8	0.75	150	1.234516
43	100	0.6	0.75	150	1.481799

44	80	0.6	0.75	150	1.419086
45	40	0.6	0.75	150	1.291118
46	80	1.6	0.9	120	1.387196
47	60	1.6	0.9	120	1.320919
48	100	0.8	0.75	150	1.531978
49	80	0.8	0.75	150	1.45943
50	20	1.6	0.9	120	1.184429
51	100	1.2	0.9	120	1.407552
52	80	1.2	0.9	120	1.350548
53	40	1.2	0.9	120	1.235025
54	20	1.2	0.9	120	1.174373
55	100	1	0.9	120	1.381889
56	80	1	0.9	120	1.329946
57	60	1	0.9	120	1.277619
58	40	1	0.9	120	1.224355
59	60	0.8	0.9	120	1.260325
60	40	0.8	0.9	120	1.212496
61	20	0.8	0.9	120	1.162254
62	100	0.6	0.9	120	1.321492
63	80	0.6	0.9	120	1.281314
64	60	0.6	0.9	120	1.240631
65	40	0.6	0.9	120	1.198937
66	20	0.6	0.9	120	1.1549
67	100	1.6	0.8	120	1.553022
68	80	1.6	0.8	120	1.466813
69	100	0.8	0.8	120	1.423117
70	80	0.8	0.8	120	1.363028
71	60	0.8	0.8	120	1.302668
72	40	0.8	0.8	120	1.241463
73	20	0.8	0.8	120	1.177815
74	20	0.6	0.8	120	1.168571
75	100	1.6	0.75	120	1.620192
76	80	1.6	0.75	120	1.520269
77	60	1.6	0.75	120	1.420834
78	100	1.2	0.8	120	1.493321
79	80	1.2	0.8	120	1.419191
80	60	1.2	0.8	120	1.345025
81	40	1.2	0.8	120	1.270231
82	20	1	0.75	120	1.197154
83	100	0.8	0.75	120	1.469716
84	80	0.8	0.75	120	1.400329
85	60	0.8	0.75	120	1.33082
86	40	0.6	0.75	120	1.240874
87	20	0.6	0.75	120	1.1775
88	100	1.6	0.8	90	1.489896

89	80	1.6	0.8	90	1.407376
90	60	1.2	0.8	90	1.291648
91	40	1.2	0.8	90	1.221303
92	20	1.2	0.8	90	1.149685
93	100	1	0.8	90	1.400786
94	80	0.8	0.8	90	1.308676
95	60	0.8	0.8	90	1.251723
96	40	0.8	0.8	90	1.194458
97	40	0.6	0.8	90	1.178431
98	20	0.6	0.8	90	1.127214
99	100	1.6	0.75	90	1.554444
100	80	1.6	0.75	90	1.458497
101	60	1.6	0.75	90	1.363548
102	20	1.6	0.75	90	1.174406
103	100	1.2	0.75	90	1.487927
104	80	1.2	0.75	90	1.405815
105	20	1.2	0.75	90	1.161005
106	100	1	0.75	90	1.450844
107	20	0.8	0.75	90	1.145002
108	100	0.6	0.75	90	1.364363
109	80	0.6	0.75	90	1.307593
110	60	0.6	0.75	90	1.250911
111	60	1.6	0.8	60	1.273234
112	40	1.6	0.8	60	1.196774
113	20	1.6	0.8	60	1.120683
114	100	1.2	0.8	60	1.37485
115	80	1.2	0.8	60	1.307689
116	60	1.2	0.8	60	1.241372
117	40	1	0.8	60	1.163944
118	20	1	0.8	60	1.104038
119	100	0.8	0.8	60	1.311225
120	80	0.8	0.8	60	1.257373
121	60	0.8	0.8	60	1.204016
122	40	0.8	0.8	60	1.150943
123	40	0.6	0.8	60	1.136228
124	20	0.6	0.8	60	1.089797
125	100	1.6	0.75	60	1.491261
126	80	1.6	0.75	60	1.399439
127	60	1.6	0.75	60	1.309169
128	20	1.2	0.75	60	1.120319
129	100	1	0.75	60	1.392137
130	80	1	0.75	60	1.321336
131	60	1	0.75	60	1.25148
132	100	0.6	0.75	60	1.30994
133	80	0.6	0.75	60	1.256355

134	20	1.6	0.8	30	1.083959
135	100	1.2	0.8	30	1.319874
136	80	1.2	0.8	30	1.256445
137	60	1.2	0.8	30	1.194373
138	40	1.2	0.8	30	1.133761
139	20	1.2	0.8	30	1.0745
140	100	1	0.8	30	1.291138
141	100	0.8	0.8	30	1.259772
142	80	0.8	0.8	30	1.209287
143	60	0.8	0.8	30	1.15975
144	20	0.6	0.8	30	1.056721
145	100	1.6	0.75	30	1.430735
146	80	1.6	0.75	30	1.343206
147	80	1	0.75	30	1.269294
148	60	1	0.75	30	1.203789
149	40	0.6	0.75	30	1.110723
150	20	0.6	0.75	30	1.063119
151	100	1.6	0.75	150	1.688419
152	20	1.6	0.9	150	1.230675
153	100	1	0.9	150	1.440094
154	80	1.6	0.8	150	1.528949
155	100	1	0.8	150	1.521743
156	20	1	0.9	150	1.213648
157	20	1.2	0.75	150	1.253181
158	60	0.8	0.75	150	1.386393
159	80	1	0.8	120	1.392486
160	60	1	0.8	120	1.324909
161	40	1	0.8	120	1.256592
162	20	1	0.8	120	1.185869
163	20	1.2	0.75	120	1.205375
164	100	0.6	0.8	120	1.381542
165	80	0.6	0.8	120	1.329667
166	20	0.8	0.75	120	1.187997
167	100	0.6	0.75	120	1.42169
168	80	0.6	0.75	120	1.361884
169	20	1.6	0.8	90	1.161405
170	100	1.2	0.8	90	1.432705
171	60	1	0.8	90	1.272661
172	20	1	0.8	90	1.143048
173	100	0.8	0.8	90	1.36572
174	80	0.8	0.75	90	1.344052
175	60	0.8	0.75	90	1.278236
176	100	1	0.8	60	1.344486
177	80	1	0.8	60	1.283694
178	60	1.2	0.75	60	1.272138

179	100	0.8	0.75	60	1.353383
180	80	0.8	0.75	60	1.290728
181	40	0.6	0.75	60	1.150438
182	20	0.6	0.75	60	1.097123
183	100	1.6	0.8	30	1.371731
184	80	1.6	0.8	30	1.297058
185	40	1	0.8	30	1.122995
186	100	0.6	0.8	30	1.224733
187	80	0.6	0.8	30	1.18174
188	40	0.6	0.8	30	1.09789
189	40	1.6	0.75	30	1.174904
190	20	1.6	0.75	30	1.094578
191	80	1.2	0.75	30	1.295655
192	60	1.2	0.75	30	1.223086
193	40	0.8	0.8	30	1.11118
194	20	0.8	0.8	30	1.063346
195	20	1.2	0.75	30	1.083635
196	20	1	0.75	30	1.077506
197	100	0.8	0.75	30	1.299549
198	60	0.8	0.75	30	1.182685
199	20	0.8	0.75	30	1.070754
200	100	0.6	0.75	30	1.258562
201	100	1.2	0.9	150	1.466998
202	20	1.2	0.9	150	1.219832
203	80	1	0.9	150	1.385471
204	40	1	0.9	150	1.273493
205	100	0.6	0.9	150	1.376557
206	60	0.6	0.9	150	1.290859
207	20	1.6	0.8	150	1.253645
208	60	1	0.8	150	1.38016
209	20	1	0.8	150	1.232225
210	20	0.8	0.8	150	1.223546
211	40	0.6	0.8	150	1.273338
212	80	1.6	0.75	150	1.584654
213	20	1.6	0.75	150	1.268697
214	100	1.2	0.75	150	1.616581
215	40	1.2	0.75	150	1.347057
216	40	1	0.75	150	1.330496
217	20	1	0.75	150	1.244359
218	40	0.8	0.75	150	1.31211
219	60	0.6	0.75	150	1.355766
220	20	0.6	0.75	150	1.223206
221	100	1.6	0.9	120	1.453297
222	40	1.6	0.9	120	1.253882
223	60	1.2	0.9	120	1.293228

224	20	1	0.9	120	1.168648
225	100	0.8	0.9	120	1.353573
226	80	0.8	0.9	120	1.307173
227	60	1.6	0.8	120	1.380801
228	40	1.6	0.8	120	1.294395
229	20	1.6	0.8	120	1.205809
230	20	1.2	0.8	120	1.193092
231	100	1	0.8	120	1.459909
232	100	1.2	0.75	120	1.550969
233	80	1.2	0.75	120	1.465178
234	60	1.2	0.75	120	1.379574
235	40	1.2	0.75	120	1.293569
236	60	0.6	0.8	120	1.277408
237	40	0.6	0.8	120	1.22421
238	40	1.6	0.75	120	1.321312
239	20	1.6	0.75	120	1.219867
240	100	1	0.75	120	1.512277
241	80	1	0.75	120	1.434324
242	60	1	0.75	120	1.356406
243	40	1	0.75	120	1.277931
244	40	0.8	0.75	120	1.260604
245	60	0.6	0.75	120	1.301803
246	60	1.6	0.8	90	1.325516
247	40	1.6	0.8	90	1.243951
248	80	1.2	0.8	90	1.361985
249	80	1	0.8	90	1.336604
250	40	1	0.8	90	1.208558
251	20	0.8	0.8	90	1.135664
252	100	0.6	0.8	90	1.32622
253	80	0.6	0.8	90	1.277149
254	60	0.6	0.8	90	1.22802
255	40	1.6	0.75	90	1.269272
256	60	1.2	0.75	90	1.324353
257	40	1.2	0.75	90	1.243175
258	80	1	0.75	90	1.376392
259	60	1	0.75	90	1.302409
260	40	1	0.75	90	1.22851
261	20	1	0.75	90	1.153425
262	100	0.8	0.75	90	1.410147
263	40	0.8	0.75	90	1.212304
264	40	0.6	0.75	90	1.19391
265	20	0.6	0.75	90	1.135376
266	100	1.6	0.8	60	1.42943
267	80	1.6	0.8	60	1.350749
268	40	1.2	0.8	60	1.175735

269	20	1.2	0.8	60	1.110041
270	60	1	0.8	60	1.223576
271	20	0.8	0.8	60	1.097382
272	100	0.6	0.8	60	1.273897
273	80	0.6	0.8	60	1.227777
274	60	0.6	0.8	60	1.181965
275	40	1.6	0.75	60	1.220405
276	20	1.6	0.75	60	1.132545
277	100	1.2	0.75	60	1.427548
278	80	1.2	0.75	60	1.349265
279	40	1.2	0.75	60	1.196051
280	40	1	0.75	60	1.182419
281	20	1	0.75	60	1.113431
282	60	0.8	0.75	60	1.228796
283	40	0.8	0.75	60	1.167406
284	20	0.8	0.75	60	1.105804
285	60	0.6	0.75	60	1.203258
286	60	1.6	0.8	30	1.224113
287	40	1.6	0.8	30	1.153075
288	80	1	0.8	30	1.233911
289	60	1	0.8	30	1.177843
290	20	1	0.8	30	1.069196
291	60	0.6	0.8	30	1.139467
292	60	1.6	0.75	30	1.257837
293	100	1.2	0.75	30	1.369938
294	40	1.2	0.75	30	1.152409
295	100	1	0.75	30	1.336273
296	40	1	0.75	30	1.139883
297	80	0.8	0.75	30	1.240509
298	40	0.8	0.75	30	1.126151
299	80	0.6	0.75	30	1.208337
300	60	0.6	0.75	30	1.159051

7.5. Drugi set podataka – Plinski faktor (R_s)

	γ_g	p_b , bar	γ_o	T, °C	R_s Gacina, m^3/m^3
1	0.936631	76.73	0.718932	150	132.614
2	0.948657	70.00	0.724087	150	119.2139
3	1.139433	30.00	0.754017	150	55.38565
4	1.609843	10.00	0.770859	150	29.03048
5	0.852934	75.82	0.748979	130	103.7249
6	0.862258	70.00	0.752921	130	94.70794

7	0.95611	40.00	0.772825	130	55.17234
8	1.40911	10.00	0.794038	130	22.6726
9	0.797343	70.00	0.778172	110	77.86475
10	0.937826	30.00	0.802077	110	36.14201
11	1.043123	20.00	0.808137	110	27.43967
12	1.271895	10.00	0.814848	110	18.47609
13	0.744863	71.22368	0.799744	90	67.15472
14	0.783222	50	0.811519	90	46.6257
15	0.815263	40	0.81698	90	38.15471
16	0.866338	30	0.822415	90	30.31438
17	0.707372	67.5709	0.821384	70	54.95515
18	0.717087	60	0.82535	70	48.34269
19	1.069179	10	0.851059	70	13.0951
20	0.676031	63.07133	0.840982	50	45.34187
21	0.679267	60	0.842528	50	42.94542
22	0.747066	30	0.857429	50	22.52613
23	0.972046	10	0.86708	50	11.15148
24	0.671775	40	0.867592	30	26.04669
25	0.656906	50	0.862658	30	32.46266
26	0.873754	10	0.881945	30	9.592591
27	1.006956	50.00	0.73912	150	84.33376
28	1.283676	20.00	0.761803	150	42.32401
29	0.912506	50.00	0.766247	130	67.19125
30	0.840827	50.00	0.790208	110	55.26565
31	0.791583	73.98	0.775744	110	82.85586
32	0.958532	20	0.827893	90	22.93619
33	0.88236	20	0.845864	70	19.45124
34	0.734727	50	0.830545	70	40.23434
35	0.810874	20	0.862286	50	16.7278
36	0.744999	20	0.877292	30	14.72188
37	0.972528	60.00	0.731654	150	100.9045
38	1.058215	40.00	0.746539	150	69.25265
39	0.882982	60.00	0.759626	130	80.31298
40	1.024786	30.00	0.779433	130	44.0582
41	1.145732	20.00	0.786259	130	33.53105
42	0.815334	60.00	0.784226	110	66.0674
43	0.878433	40.00	0.796142	110	45.3383
44	0.746345	70	0.800429	90	65.86185
45	0.761596	60	0.806006	90	55.83164
46	1.16555	10	0.833735	90	15.45708
47	0.761092	40	0.835688	70	32.775
48	0.803676	30	0.840787	70	25.88642
49	0.692817	50	0.847543	50	35.56042
50	0.713357	40	0.852512	50	28.775

51	0.649131	57.78625	0.858797	30	37.85857
52	0.696697	30	0.87248	30	20.15719

7.6. Treći set podataka – Tlak zasićenja nafte (p_b)

	R_s , m^3/m^3	γ_g	γ_o	T, °C	p_b Gacina, bar
1	94.64329	0.936631	0.718932	150	50.77522
2	88.25506	0.948657	0.724087	150	47.91907
3	79.02538	0.972528	0.731654	150	43.3502
4	43.0209	1.283676	0.761803	150	19.42116
5	31.65007	1.609843	0.770859	150	10.84895
6	75.51596	0.852934	0.748979	130	50.65533
7	63.05998	0.882982	0.759626	130	43.02058
8	55.42405	0.912506	0.766247	130	37.65325
9	40.19714	1.024786	0.779433	130	25.24396
10	21.90104	1.40911	0.794038	130	9.219839
11	57.83657	0.815334	0.784226	110	47.73063
12	50.82034	0.840827	0.790208	110	41.86016
13	29.11279	1.043123	0.808137	110	19.99992
14	63.42394	0.744863	0.799744	90	60.70651
15	62.59437	0.746345	0.800429	90	60.03883
16	55.83154	0.761596	0.806006	90	54.22459
17	28.5434	0.958532	0.827893	90	23.80052
18	55.19027	0.717087	0.82535	70	61.445
19	28.81431	0.88236	0.845864	70	28.69454
20	19.99757	1.069179	0.851059	70	15.72099
21	48.75863	0.692817	0.847543	50	61.49687
22	42.39891	0.713357	0.852512	50	53.68954
23	20.91565	0.972046	0.86708	50	19.85229
24	42.43606	0.713357	0.852512	30	49.82667
25	29.28925	0.810874	0.862286	30	31.53681
26	21.45912	0.972046	0.86708	30	18.76432
27	61.26704	1.058215	0.746539	150	32.797
28	70.87575	0.862258	0.752921	130	47.95886
29	67.86252	0.791583	0.775744	110	55.15441
30	19.5046	1.271895	0.814848	110	10.2025
31	42.54627	0.815263	0.81698	90	40.86878
32	35.79409	0.866338	0.822415	90	32.97831
33	35.77358	0.803676	0.840787	70	38.74259
34	48.732	0.734727	0.830545	70	54.71324
35	35.97591	0.747066	0.857429	50	44.7708
36	53.9081	0.679267	0.842528	30	62.26845

37	70.07179	1.006956	0.73912	150	38.34058
38	52.40148	1.139433	0.754017	150	26.57352
39	47.86379	0.95611	0.772825	130	31.77145
40	32.00913	1.145732	0.786259	130	17.85342
41	64.98445	0.797343	0.778172	110	53.12767
42	43.8445	0.878433	0.796142	110	35.41201
43	36.742	0.937826	0.802077	110	28.22113
44	49.17531	0.783222	0.811519	90	47.87845
45	19.30159	1.16555	0.833735	90	12.43857
46	60.12642	0.707372	0.821384	70	66.12913
47	42.30262	0.761092	0.835688	70	47.2358
48	57.12514	0.676031	0.840982	50	70.49874
49	55.1574	0.679267	0.842528	50	68.49735
50	29.22138	0.810874	0.862286	50	34.10079
51	48.87461	0.692817	0.847543	30	57.24932
52	35.97388	0.747066	0.857429	30	41.42273

IZJAVA

Izjavljujem da sam ovaj rad izradio samostalno.

Marčelo Pavić