

UNIVERZITET U BEOGRADU
RUDARSKO-GEOLOŠKI FAKULTET

Seyed Ali S. Razeghi

**RAZVOJ MODELA UPRAVLJANJA
CIRKULACIJOM U POSTUPKU BUŠENJA
KORIŠĆENJEM NEURO FAZI SISTEMA
ZAKLJUČIVANJA**

doktorska disertacija

Beograd, 2022.

UNIVERSITY OF BELGRADE
FACULTY OF MINING AND GEOLOGY

Seyed Ali S. Razeghi

**THE DEVELOPMENT OF A CIRCULATION
CONTROL MODEL IN THE DRILLING
PROCESS USING THE NEURO-FUZZY
INFERENCE SYSTEM**

Doctoral Dissertation

Belgrade, 2022

Mentori:

Dr Miloš Tanasijević, redovni profesor

Univerzitet u Beogradu, Rudarsko-geološki fakultet

Uža naučna oblast: Elementi mašinskih i energetske sistema

Dr Branko Leković, redovni profesor

Univerzitet u Beogradu, Rudarsko-geološki fakultet

Uža naučna oblast: Inženjerstvo nafte i gasa

Članovi komisije:

Dr Dejan Ivezić, redovni profesor

Univerzitet u Beogradu, Rudarsko-geološki fakultet

Uža naučna oblast: Elementi mašinskih i energetske sistema

Dr Dušan Danilović, vanredni profesor

Univerzitet u Beogradu, Rudarsko-geološki fakultet

Uža naučna oblast: Inženjerstvo nafte i gasa

Dr Uglješa Bugarić, profesor

Univerzitet u Beogradu, Mašinski fakultet

Uža naučna oblast: Industrijsko inženjerstvo

Datum odbrane: _____

Razvoj modela upravljanja cirkulacijom u postupku bušenja korišćenjem neuro fazi sistema zaključivanja

Sažetak

Gubitak isplake predstavlja nekontrolisano isticanje bušaćeg fluida kroz formacije kao što su kaverne, pukotine, ili drugi slojevi. Tradicionalne metode procene gubitka isplake se zasnivaju na primeni seizmičkih podataka ili pronalasku „mesta“ gubitka isplake na osnovu raspoloživih podataka iz susednih bušotina. Međutim, ove metode procene nisu pouzdane.

U disertaciji je izvršena analiza i procena uticaja parametara bušenja, geoloških faktora, karakteristika formacije i fluida na gubitak isplake kao i na formiranje fraktura u formacijama. Uspostavljeni su modeli koji podrazumevaju proces obrade i izbor bušaćeg fluida koji je kompatibilan sa karakteristikama izbušene formacije. Cilj disertacije je stvaranje složenog modela za analizu i predviđanje gubitka isplake tokom procesa izrade kanala bušotine, i to primenom fuzzy logike i neuronskih mreža.

U radu je opisan problem gubitka isplake, njegovo predviđanje i prevencija. Objašnjena je koncepcija fuzzy logike i pravila na kojima se ona zasniva, radi boljeg razumevanja problema. Detaljno je opisana tehnika adaptivnog neuro - fuzzy sistema zaključivanja (ANFIS) uključujući jezički aspekt, numeričke informacije za integraciju kombinacije predstavljenih podataka i način na koji ovaj model može da se poveže sa gubitkaom isplake.

Disertacija predlaže ANFIS model za predikciju gubitaka cirkulacije isplake tokom bušenja u naftnoj i gasnoj industriji. U ovoj disertaciji ANFIS model je upoređen sa kNN (eng. k-nearest neighbors k- najbližih suseda) modelom i metodom stablao odlučivanja (MSO). Rezultati su pokazali da se ANFIS i PSO_ANFIS (Particle Swarm Optimization_ANFIS) modeli mogu kvalitetno koristiti u slučajevima prevencije gubitka isplake i da ANFIS model obezbeđuje bolje predikcije od kNN i MSO modela.

Ključne reči: naftna bušotina, gubitak isplake, fuzzy logika, ANFIS model

Naučna oblast: Rudarsko inženjerstvo

Uža naučna oblast: Inženjerstvo nafte i gasa, Elementi mašinskih i energetskih sistema

UDC broj:

004:005.7

004.81:510.644

519.237/.245/.87

551.4:553.983

621.31

622:007.5

622:681.3(043.3)

The development of a circulation control model in the drilling process using the neuro-fuzzy inference system

Abstract

The circulation loss represents uncontrollable flow of mud into a formation which can be found in natural caverns, cracks or other layers. Traditional estimation techniques of lost circulation often use seismic data, or find the lost circulation location according to adjacent well data. However, these efforts are still not enough because the precision and details in the applied methods have not been as good as possible.

In this dissertation, the effect of drilling parameters, geological factors, and characteristics of formations and fluids on the lost circulation process or formation of fractures within the layers is predicted. In this regard, some models are established which encompass the processes of treatment and choice of fluid compatible with characteristics of drilled layers. The aim of the dissertation is the creation of a complex model for analysis and prediction of the circulation lost during the drilling process, using fuzzy theory and neural networks.

The dissertation describes in detail the problem of circulation loss, its prediction and prevention. In addition, the procedure of fuzzy logic and the basic rules on which it is based, for better interpretation of the problem. The adaptive neuro - fuzzy inference system (ANFIS) technique, model characteristics and how this model can be related to circulation loss models are also described in detail.

The dissertation proposes an ANFIS model for the prediction of mud circulation losses during drilling in the oil and gas industry. In this dissertation, the ANFIS model is compared with the kNN model and the decision tree method. The research results in this dissertation have shown that the applied ANFIS and PSO_ANFIS (Particle Swarm Optimization_ANFIS) models can be used well in cases of mud loss prevention. The results also show that the ANFIS model provides better predictions than the kNN and MSO models.

Keywords: oil well, circulation loss, fuzzy logic, ANFIS model

Scientific field: Mining engineering

Scientific subfield: Petroleum engineering, Elements of mechanical and energetics systems

UDC:

004:005.7

004.81:510.644

519.237/.245/.87

551.4:553.983

621.31

622:007.5

622:681.3(043.3)

SADRŽAJ

1 UVOD	1
1.1 Značaj i cilj istraživanja	2
1.2 Metodologija istraživanja.....	2
1.3 Struktura disertacije sa kratkim pregledom poglavlja.....	4
2 CIRKULACIJA ISPLAKE	5
2.1 Problem gubitka isplake.....	5
2.2 Preporučeni parametri postupka bušenja	10
2.2.1 Gustina fluida za bušenje	10
2.2.2 Opterećenje na dleto (WOB)	11
2.2.3 Brzina protoka i kapacitet pumpe (strokes per minute, SPM).....	11
2.2.4 Broj obrtaja (o/min)	12
2.2.5 Brzina bušenja (rate of penetration, ROP).....	12
2.3 Potencijalni gubitak cirkulacije isplake	12
2.4 Metode kontrole, sanacije i smanjenja gubitaka u cirkulaciji isplake.....	13
2.5 Uzroci neuspeha u prevenciji gubitka cirkulacije	15
3 MAŠINSKO UČENJE I EKSPERTNI SISTEMI	17
3.1 Upotreba mašinskog učenja u procesu bušenja.....	17
3.2 Fuzzy logika.....	20
3.2.1 Osnovni pojmovi fuzzy logičkog zaključivanja.....	20
3.2.2 Fuzzy skup, funkcije pripadnosti i fuzzy broj.....	21
3.2.3 Fuzzy algebra i operacije nad fuzzy skupovima	24
3.2.4 Fuzzy relacije	24
3.3 Neuronske mreže.....	28
3.4 Mogućnost stvaranja neuro-fuzzy sistema	40
4 ANALIZA PREDMETNE LITERATURE	50
4.1 Analiza radova na temu gubitaka isplake na bazi konvencionalnih i tradicionalnih metoda	50
4.2 Primena ekspertnih sistema u tehnici uopšte	50
4.3 Primena ekspertnih sistema u tehnici bušenja.....	51
4.4 Primena ekspertnih sistema u predikciji gubitka isplake	51
4.5 Rezime i zaključna razmatranja	55
5 RAZVOJ NEURO-FUZZY MODELA UPRAVLJANJA CIRKULACIJOM	56
5.1 Skupovi podataka.....	56
5.2 Selekcija promenljivih	58

5.3 Dizajn ANFIS-a	61
5.3.1 Normalizacija podataka	62
5.4. Parametri	62
5.4.1 Izbor funkcije pripadnosti.....	63
5.4.2 Određivanje broja funkcija pripadnosti za svaku karakteristiku	69
5.4.3 Određivanje stope učenja.....	70
5.5 Izbor podataka.....	74
5.6 Postavljanje funkcije pripadnosti za svaku karakteristiku	74
5.7 Kreiranje pravila	80
5.8. Algoritam učenja.....	80
6 PRIMENA MODELA ZA UPRAVLJANJE CIRKULACIJOM – STUDIJA SLUČAJA ZA NAFTNA POLJA AGHAJARI I GADVAN	87
6.1 Eksperimenti i rezultati	87
6.2 Metrike procena	87
6.3 Rezultati	88
6.4 Novi problem	89
6.5 Rešenje.....	90
6.6 Rezultati	91
7 ZAKLJUČAK.....	95
LITERATURA	97
PRILOG.....	101

1 UVOD

Gubitak isplake jedan je od najčešćih problema koji se javljaju tokom procesa izrade kanala bušotine. Ovaj problem ne utiče samo na zastoj u proizvodnji i operativne troškove već direktno može da izazove niz nepovoljnih događaja kao što su nestabilost kanala bušotine, prilepljivanje bušaćeg alata (cevi) i erupciju bušotine (Li i sar., 2018). Najčešće do gubitka isplake dolazi kod nekonsolidovanih, kavernozih ili šupljikavih i frakturiranih formacija.

Međutim, problem gubitka isplake u prirodno frakturiranom krečnjaku je ozbiljan sa složenim mehanizmom. Stoga je važno razumeti mehanizam gubitka isplake u različitim slojevima a zatim primeniti model procene rizika od gubitka tokom bušenja, koji bi sprečio prekomerne gubitke (Li i sar., 2018).

Tehnologija izolacije slojeva različitim materijalima za začepljenje, a u cilju sprečavanja gubitka isplake do sada su istraživani u više navrata. Terenskim iskustvom došlo se do zaključka da izolacija slojeva navedenim materijalima nije efikasna. Najveći broj slučajeva prekomernog gubitka isplake koji su se javili tokom procesa bušenja uobičajeno su bili istraživana i analizirani preko parametara bušenja. Navedena istraživanja (Li i sar., 2018) nisu bila usredsređena na procenu rizika od gubitka isplake, posebno pomoću inteligentnog modela procene koja u obzir uzima geološke i inženjerske faktore.

Tradicionalna tehnologija procene gubitka isplake zasniva se na identifikaciji u frakturiranim slojevima, primenom seizmičkih podataka, ili se empirijski pronalaze „mesta“ gubitka isplake na osnovu raspoloživih podataka susednih bušotina. Međutim, vremenom je ustanovljeno da primenjene metode procene nisu pouzdane ni precizne, obzirom da nisu mogle adekvatno predvideti stepen gubitka (Li i sar., 2018) što ostavlja prostor za unapređenje metoda u tom smislu. Savremeni način za postizanje veće preciznosti u predviđanju je primena različitih simulacionih modela (Feng i Gray, 2017).

U novije vreme, osnovna tema studija vezanih za gubitak isplake može da se definiše sa dva pitanja: kako smanjiti gubitak isplake i kada će se oni javiti, odnosno kako dolazi do gubitka isplake? (Agin i sar., 2018). Sa druge strane, problem gubitka isplake predstavlja izazov za izvođača radova u smislu očuvanja sigurnosti funkcionisanja sistema i ekonomsku stabilnost bušenja. Takođe, prilikom izrade dubokih bušotina neophodno je posedovati sveobuhvatne programe i algoritme upravljanja prilikom pojave prekomernog gubitka isplake, kao i nove strategije za suočavanje izazovima koji predstoje (Ramasamy i sar., 2019).

1.1 Značaj i cilj istraživanja

Proces izrade bušotine predstavlja skup različitih tehničko – tehnoloških zahteva koji se ostvaruju primenom složenog sistema vođenja i praćenja procesa. Takođe, ovaj sistem mora pouzdano funkcionisati uz minimalne troškove izrade bušotine.

Predmet ovog istraživanja kroz doktorsku disertaciju je predviđanje gubitaka isplake u različitim formacijama, a sve sa ciljem istraživanja perspektivnih ležišta ugljovodonika i njihove eksploatacije.

Gubitak isplake predstavlja nekontrolisani protok bušačeg fluida kroz formacije kao što su kaverne, pukotine, ili drugi slojevi, u koje je isplaka dospela hidrauličkim ili mehaničkim lomljenjem stena. Problem gubitka isplake u praksi se rešava monitoringom statičkog i dinamičkog pritiska nižeg od pritiska frakturiranja, kao i primenom različitih materijala za začepljivanje u zavisnosti od promera pukotina.

Uzimajući u obzir činjenicu da je gubitak isplake kod rotacionog bušenja jedan od najstarijih i najčešćih problema, koji direktno utiče na povećanje zastoja u radu i troškova predviđanja gubitaka bušačeg fluida, pronalaženje optimalnog rešenja za gubitak isplake bi predstavljalo veliki doprinos u stručnom i naučnom domenu.

Planirano je da se ovo istraživanje zasniva na postavljanju i dokazivanju sledećih stavki:

- U naučno – stručnoj literaturi, kao i u inženjerskoj praksi, ne postoji standardizovani model koji strukturno definiše i predviđa gubitke isplake u cirkulacionom sistemu tokom procesa bušenja.
- Neophodno je identifikovati mehanizme stvaranja gubitka ispirnog fluida, koji nastaju kao posledica prirode formacija ili usled dejstva viskog pritiska na dno bušotine.
- Loše vođenje procesa bušenja, bez prediktivnih smernica, može dovesti do neželjenih uslova za bušenje. Dakle, model predviđanja mora biti primenjiv za sve uslove bušenja.
- Predviđanjem zone, dubine, vrste i veličine gubitaka isplake, sa velikim stepenom pouzdanosti, može se odrediti adekvatan način za promenu parametara bušenja, odnosno za smanjenje troškova.
- Značajni parametri su hibridnog karaktera. U procesima dominiraju nesigurnost, subjektivnost, dvosmislenost i relativnost. Međuzavisnost nije jasno definisana i može se izraziti samo na osnovu empirijskog istraživanja i primenom metoda mašinskog učenja.

1.2 Metodologija istraživanja

U ovoj disertaciji izvršiće se procenjivanje uticaja parametara bušenja, geoloških faktora, karakteristika formacija i fluida na gubitak isplake kao i na formiranje fraktura u formacijama. Neki od postojećih modela procene uticaja parametara podrazumevaju proces izbora i pripremne obrade fluida koji su kompatibilni sa karakteristikama izbušene formacije. Pod kompatibilnošću se podrazumeva usklađenost parametar i karakteristika fluida koji doprinose smanjenju gubitka isplake, kao što su gustina, reologija i brzina protoka fluida.

Cilj disertacije je stvaranje modela za analizu i predviđanje gubitka isplake tokom procesa izrade kanala bušotine kao sastavni deo eksploatacije ugljovodonika primenom fuzzy logike i

neuronskih mreža. Primenom složenog modela predikcije izbor isplake vršice se u zavisnosti od petrofizičkih parametara i lokacije bušotine. Složenost modela se ogleda u tome da je on sastavljen od dva skupa podataka: skup ulaznih podataka (premissa) i skup izlaznih podataka (konsekvence).

U disertaciji su primenjene sledeće naučne metode, sa ciljem da se istraže tehnički, geološki i ekonomski pokazatelji sistema bušenja:

- Analiza postojeće naučne i stručne literature koja se odnosi na naftno i gasno inženjerstvo, hibridne neurofuzzy sisteme i ekspertske sisteme uopšte.
- Analiza terenskih podataka vezanih za bušenje.
- Konvencionalni proračun ekonomskih i tehničkih pokazatelja rada bušaće opreme.
- Statistička analiza podataka.
- Model predviđanja na osnovu neuronskih mreža.
- Optimizacija fuzzy modela identifikacije ulaznih parametara.

Specifičnost metoda istraživanja je u:

- Formiranju modela analize i predviđanja delimičnih pokazatelja rada sistema za bušenje, od kojih svaki ima svoje specifičnosti prema prirodi pojave, kao i uslovima rada.
- Formiranju hibridnog, sintetizovanog modela koji će kombinovati tehničke, ekonomske i geološke pokazatelje rada.

Tema disertacije je aktuelna, naučni doprinos se vidi u definisanju poboljšanog modela sintetizovane procene gubitaka isplake sa stanovišta fizičkih i ekonomskih pokazatelja. Na ovaj način se daje naučni doprinos u:

- Oblasti naftnog i gasnog inženjerstva sa poboljšanom tehnologijom bušenja.
- Primeni fuzzy logike i neuronske mreže u oblasti naftnog i gasnog inženjerstva, sa razvojem modela predviđanja.
- Analizi postojećih koncepata i parametara bušenja.
- Modelovanju procesa eksploatacije i održavanja opreme za bušenje.

Rezultati istraživanja gubitaka isplake i razvoj modela predikcije, mogu se primeniti za dalji razvoj i unapređenje:

- 1) Sistematskog pristupa u vršenju eksploatacije nafte i gasa, kao i
- 2) Sveobuhvatne analize raspoloživosti opreme za bušenje.

Plan istraživanja koncipiran je na osnovu razvoja modela analize značajnih parametara bušenja sa posebnim osvrtom na gubitak ispirog fluida, kroz dimenziju delimičnih pokazatelja, dimenziju predviđanja kretanja vrednosti delimičnih pokazatelja, kroz dimenziju sinteze i kroz dimenziju optimizacije uzimajući u obzir sledeće:

1. Indikatore povezane sa geološkim karakteristikama izbušenih formacija.
2. Indikator fizičkih karakteristika ispirog fluida.
3. Indikatori pouzdanosti i raspoloživosti bušaćih postrojenja.
4. Indikatori koji se odnose na tehničke karakteristike bušenja.
5. Ekonomski indikatori vezani za određene tehnološke troškove.

6. Mogućnost sinteze analiziranih indikatora i definisanje strukture njihove nezavisnosti.
7. Mogućnost formiranja modela za prognozu sa ciljem predviđanja mogućih gubitaka isplake.

U primeni će biti dati:

- Analitički pristup sa ciljem preciznog definisanja ulaznih parametara na osnovu statističkih modela.
- Sintezni pristup sa ciljem definisanja optimizacionog modela koji daje nezavisne ulazne parametre povezane sa gubicima ispirog fluida i sa ciljem pronalaženja indikatora optimizacije nivoa gubitaka isplake.

1.3 Struktura disertacije sa kratkim pregledom poglavlja

U strukturnom smislu ova disertacija je napisana u skladu sa uspostavljenim ciljevima i hipotezama istraživanja. Sačinjena je od sedam poglavlja.

Prvo poglavlje predstavlja uvod i analizu značaja problematike, sa kratkim osvrtom na predmet, ciljeve i hipotezu istraživanja.

Drugo poglavlje daje osvrt na problem gubitka cirkulacije isplake. Takođe, opisane su metode kontrole, sanacije i smanjenja gubitaka u cirkulaciji isplake. Prikazana je analiza faktora značajnih za gubitke isplake koji su povezani sa geološkim karakteristikama, sa karakteristikama ispirog fluida, karakteristikama primenjene opreme, opisani su značajni indikatori procesa bušenja.

Treće poglavlje obuhvata razmatranja koja se tiču upotrebe mašinskog učenja u procesu bušenja, fuzzy logike, fuzzy logičkog zaključivanja, fuzzy skupova, funkcija pripadnosti i fuzzy broja, fuzzy algebre i neuronskih mreža.

Četvrto poglavlje se odnosi na pregled aktuelnih studija iz oblasti tehnologije izrade bušotina, sa posebnim akcentom na primenu mašinskog učenja u tehnologiji bušenja. Izvršena je analiza slične problematike koja se javljala prethodnih godina.

Peto poglavlje prezentuje razvoj neuro – fuzzy modela upravljanja cirkulacijom. Prezentovani su skupovi podataka, promenljive, parametri. Opisan je dizajn ANFIS-a kao i postavljanje funkcije pripadnosti za svaku karakteristiku. Na kraju poglavlja je prezentovano kreiranje pravila i algoritama učenja.

Šesto poglavlje predstavlja primena modela za upravljanje cirkulacijom – studiju slučaja za naftna polja Aghajari i Gadvan. Navedene su terenske studije analiziranih fenomena pojava gubitaka isplake gde se vršilo prikupljanje podataka i analiza na osnovu statistike i teorije verovatnoće. Prikazani su eksperimenti i rezultati kao i metrike procena. Izvršena je verifikacija modela poređenjem proračuna i rezultata dobijenih na terenu.

Sedmo poglavlje daje zaključke o razmatranoj temi uz naglasak na doprinos ove disertacije. U ovom poglavlju su predložene mere za buduća istraživanja u cilju unapređenja predloženog modela.

Poglavljima pet i šest je obuhvaćen naučni i praktičan doprinos ove disertacije.

2 CIRKULACIJA ISPLAKE

Gubitak isplake tokom bušenja predstavlja jedan od najvećih izazova sa kojima se susreće posada koja vrši bušenje. Takođe, važno je istaći da gubitak isplake uzrokuje i produženo vreme bušenja. Iz tog razloga naftna industrija na godišnjem nivou izdvaja značajna finansijska sredstva za saniranje ovog problema. Sredstva koja se izdvajaju za te namene na godišnjem nivou u celom svetu iznose oko 800 miliona američkih dolara (Murchison, 2006).

Prvi korak u rešavanju problema gubitka isplake jeste prevencija gubitka isplake. Ovo se može postići identifikacijom problematičnih mesta u toku bušenja. Planiranje gubitka isplake obuhvata kako prevenciju tako i primenu metoda remedijacije. Zaustavljanje gubitaka tokom njihovog nastanka jednako je važno kao i prevencija njihovog nastanka jer može uštedeti vreme i novac. Do gubitka isplake može doći na bilo kojoj dubini tokom procesa izrade kanala bušotine. Postoje četiri tipa formacije u kojima može doći do gubitaka isplake: a) prirodno ili indukovano frakturirane formacije; b) šupljikave ili kavernozone formacije; c) visoko propusne formacije; d) nekonsolidovane formacije. U gore pomenutim formacijama gubitak isplake je sasvim izvestan (Asin i sar., 2018).

Postoji veliki broj faktora koji direktno utiču na gubitak isplake. U ove faktore spadaju: gradijent pritiska u formaciji, gradijent pritiska u frakturama formacije, petrofizička svojstva formacije, karakteristike fluida, postojanje fraktura ili kaverni u formacijama, parametri bušenja kao što su kapacitet pumpe, opterećenje na dleto (WOB), kao i mnoštvo drugih parametara koji mogu direktno ili indirektno da utiču na gubitak cirkulacije (Agin i sar., 2018). Kroz istoriju najviše pažnje se posvećivalo sprečavanju gubitka isplake, dok se predviđanju mogućih gubitaka nije pridavao značaj.

2.1 Problem gubitka isplake

Kod bušenja formacije svaki gubitak isplake u poroznim formacijama naziva se gubitak isplake (Almagro i sar., 2014). Gubitak isplake bio je značajan problem od samog početka izrade naftnih i gasnih bušotina. Ovaj problem je postao značajniji kako su bušene dublje bušotine. Naftne kompanije godišnje troše ozbiljna finansijska sredstva na probleme gubitka ispirnog fluida. Gubitak isplake izaziva probleme kao što su lepljenje cevi za bušenje, produžetak vremena za bušenje, isticanje iz bušotine, gubitak velikih količina fluida za bušenje i oštećenje formacije. Do lepljenja cevi za bušenje za bušotinu dolazi zbog razlike u pritisku između isplake i formacije kroz koju se buši, odnosno usled pojave diferencijalnog pritiska (Behnoud far & Hosseini, 2016).

Praksa je pokazala da je jedan od najčešćih uzroka zaglavlivanja alata u kanalu bušotine, njegovo prilepljivanje o zid bušotine prouzrokovano delovanjem diferencijalnog pritiska. Da bi se nastavilo sa daljom fazom izrade kanala bušotine neophodno je ukloniti prilepljeni alat za bušenje. Postupak spasavanja alata iz kanala bušotine naziva se instrumentacija. Rezultati ispitivanja bušotine u frakturiranim formacijama pokazali su da bušotine sa delimičnim ili potpunim gubitkom isplake uzrokuju ozbiljna oštećenja u proizvodnim formacijama.


Gubitak isplake može prouzrokovati ulazak čestica malog promera u pore prostora oko bušotine, čime dolazi do smanjenja permeabilnosti zone oko bušotine. Pored toga, prilikom filtriranja mulja može doći do hemijske reakcije između čestica mulja i jedinjenja isplake i do taloženja proizvoda reakcije, što takođe može dovesti do smanjenja propusnosti pribušotinske zone.

Da bi se ovaj problem prevazišao neophodno je primeniti skupe operacije kao što su stimulacija ili obrada formacije kiselinom (Ebrahim i sar., 2014; Fidan i sar., 2004).

Gubitak isplake obično se javlja u formacijama sa sledećim karakteristikama (slika 2.1):

- nekonsolidovane formacije visoke propusnosti (A),
- šupljikave i kavernoze formacije (B),
- ispucale formacije i formacije sa mikro frakturama (C),
- frakturirane formacije koje su nastale usled hidrauličkog udara stuba isplake (formacije sa indukovanim frakturama) (D).

Isplaka ili cementna smeša može da prodre kroz poroznu formaciju ukoliko je propusnost formacije veća od 10 D (darsi). Sa druge strane, mogući su gubici isplake u konsolidovanom peščaru niske propusnosti. Na ovaj tip formacija može se naići na malim dubinama. Tokom bušenja kroz ove formacije, gubici isplake su u početku postepeni, a sa povećanjem dubine dolazi i do značajnijih gubitaka isplake. Brzina gubitka isplake zavisi od stepena propusnosti formacije, kao što prikazuje slika 2.1 (Alhameedi, 2017; Alkinani i sar., 2018b).



Slika 2.1: Gubitak isplake u zavisnosti od karakteristika formacije (Alkinani i sar., 2018b)

Čvrsta formacija može imati prirodne frakture u koje može prodreti isplaka za bušenje. Pojava i rast horizontalnih i vertikalnih fraktura su često rezultat delovanja litostatičkog pritiska. Iznenadni gubici isplake u konsolidovanim formacijama često su posledica prirodnih fraktura (Shahbazi and Nazemi, 2019; Alkinani i sar., 2018b).

Prilikom bušenja slojeva krečnjaka ili dolomita često se nailazi na velike šupljine i kaverne u formacijama. Bušenjem kroz pomenute formacije dolazi do iznenadne pojave totalnih gubitaka isplake (Amanullah i sar., 2018).

U slučaju kada je pritisak u bušotini veći od pritiska u porama, dolazi do prodora isplake ili cementne smeše u pore ili frakture stena kroz koje se buši. Postoje tri tipa objašnjenja za ovaj fenomen (Li i sar., 2018):

1. Formiranje glinenog prstena u međuprostoru tj. na zidovima bušotine, kao rezultat povećane cirkulacije isplakom ili cementnom mešavinom. Ova pojava može dovesti do pojave hidrauličkog frakturiranja.
2. Kada se buši kroz nekonsolidovane formacije, najčešće kada se radi o *offshore* bušenju.
3. Kada se buši na velikoj nadmorskoj visini, bušenje se najčešće izvodi kroz različite formacije sa malim litostatičkim pritiskom, što lako može dovesti do formiranja fraktura.

Do pojave fraktura u formacijama može doći usled primene isplake velike gustine kao i usled naglog spuštanja i vađenja alata za bušenje.

Prema karakteru i intenzitetu gubitaka, gubici isplake se mogu svrstati u sledeće grupe (Alhameedi i sar., 2018; Alkinani i sar., 2018b; Duarte i sar., 2018):

- Gubici tipa filtracije: slučaj kada je količina izgubljene isplake manja od 1500 litara po satu, kada čvrste materije u isplaci ne mogu da spreče prodor isplake kroz frakture. Ovaj tip gubitaka može da se pojavi kod bilo kog tipa formacije ali se najčešće javlja kod propusnih formacija.
- Delimični gubici: slučaj kada je količina izgubljene isplake između 1.600 i 80.000 litara na sat. Ovaj tip gubitaka se javlja u šljunkovitim formacijama velike poroznosti i u formacijama sa prirodno nastalim frakturama. Dalje je navedeni tip gubitaka podeljen na dve kategorije: mali gubici (gubici isplake su između 1.600 i 16.000 litara po satu) i značajni gubici (gubici isplake su između 16.000 i 80.000 litara po satu).
- Potpuni gubici: slučaj kada je sva količina isplake izgubljena i cirkulacija isplake u sistemu zaustavljena, tj. nema iznošenja nabušenog materijala na površinu. Potpuni gubici se javljaju u šljunkovitim formacijama, prirodno nastalim frakturama velikog promera, formacijama sa veštački nastalim frakturama i kavernama.

Važno je istaći da se smanjenje zapremine isplake usled izdvajanja filtrata isplake ili punjenja nove bušotine, bitno razlikuje od pojave gubitka isplake. Gubitak isplake se može pojaviti na bilo kojoj dubini tokom procesa izrade kanala bušotine. Izbor dobrog materijala za sprečavanje gubitka isplake prvenstveno zavisi od osnovnih podataka koji se odnose na tip formacije i dubinu na kojoj se nalazi problematična formacija.

Mesto gubitka isplake određuje se korišćenjem podataka iz bušenja susednih bušotina, podataka o promenama formacije i različitih metoda merenja. Različite promenljive utiču na tip gubitka isplake kao što su: gradijent pritiska frakturiranja, karakteristike isplake, litologija formacije, postojanje fraktura i kaverni u formaciji, parametri u procesu bušenja kao što su pritisak, kapacitet pumpe i mnoge poznate i nepoznate promenljive zbog kojih je veoma teško predvideti količinu gubitaka isplake tokom izrade kanala bušotine u određenoj formaciji (Alkinani i sar., 2018b; Almagro i sar., 2014).

Prisustvo fraktura u formacijama moguće je na svim dubinama. Na fizičke karakteristike fraktura utiču poreklo, mehanička svojstva stena i proces dijageneze. Frakture mogu imati značajnu ulogu u povećanju poroznosti i propusnosti stene rezervoara, kao i u povećanju iskorišćenja ležišta, i to posebno u karbonatnim formacijama. Nasuprot tome, frakture u formacijama mogu uzrokovati

značajne gubitke ispirnog fluida što dovodi do pojave ozbiljnih problema poput oštećenja formacije ili do nekontrolisanog dotoka fluida u kanal bušotine (Shahbazi and Kazemi, 2019; Lu, 2007).

Proučavanjem i ispitivanjem fraktura, sagledavanjem problematike i načina njihovog širenja po ležištu sa ciljem iskorišćenja postojećih fraktura i sprečavanja gubitaka isplake tokom procesa izrade kanala bušotine, mogu se osmisliti i predložiti programi toka bušenja koji mogu značajno doprineti razradi polja, lociranju pogodnih mesta za izradu bušotina i produženju životnog veka ležišta.

Neželjeni efekti gubitka ispirnog fluida su (Almagro i sar., 2014; Behnoudfar and Hosseini, 2016):

- gubitak isplake eliminiše određeni pritisak isplake u međuprostoru, a kao rezultat dolazi do bubrenja okolne formacije što dovodi do prilepljivanja alata za bušenje ili cevi, a najčešće se javlja kod “*open hole*” bušenja;
- rizik od dotoka slojnog fluida visokog pritiska koji sadrži gas, usled pojave diferencijalnog pritiska;
- mogućnost potonuća postrojenja za bušenje je velika usled gubitaka isplake u plitkim nekonsolidovanim formacijama;
- troškovi usled neproduktivno utrošenog vremena, osoblja, amortizacije opreme i ekološkog otpada;
- oštećenje formacije;
- oštećenje dragocenih minerala sa ekonomsko-eksploatacionim potencijalom;
- troškovi gubitaka ispirnog fluida i njegove nadoknade.

Na osnovu već ranije iznetih činjenica, troškovi koji se javljaju usled gubitka isplake mogu se kretati od 20% do 40% od ukupnih troškova izrade kanala bušotine (James i sar., 2008).

Proces sanacije gubitaka isplake sastoji se od 7 koraka (Sheremetov i sar., 2008):

- 1) Ulazni podaci: postoji pet grupa ulaznih podataka koji opisuju isplaku, litologiju, kanal bušotine sa alatima za bušenje i zaštitnim cevima, operacije izvršene u kanalu bušotine i brzina gubitaka isplake. Navedeni podaci se pronalaze u različitim izvorima, kao što je na primer program perforiranja.
- 2) Utvrđivanje tipa gubitaka: u ovoj fazi se utvrđuje tip gubitaka. Ako se dogode potpuni gubici isplake, postoji potreba za primenom materijala za sprečavanje daljeg gubljenja isplake sa ciljem daljeg nastavka bušenja.
- 3) Smanjenje broja hodova pumpe i brzine bušenja i povećanje vremena ciklusa: moraju se ponovo izvršiti hidraulički proračuni i primeniti relevantni reološki modeli.
- 4) Prikupljanje laboratorijskih podataka, analiza i merenja: ako problem nije rešen, pristupa se unošenju dodatnih podataka u sistem laboratorijskim ispitivanjem i merenjem u kanalu bušotine.
- 5) Smanjenje gustine: u sledećem koraku se analizira mogućnost smanjenja gustine isplake.
- 6) Primena materijala za sprečavanje gubitaka isplake i cementnog čepa: ako su gore navedene metode bile bez uspeha, prikupljeni podaci omogućavaju da pređemo direktno na još ozbiljniji korak ili da primenimo dve manje zahtevne metode, kao što su primena materijala za sprečavanje gubitaka isplake ili cementnog čepa.
- 7) Sprovođenje najozbiljnijih mera: ako nijedna od gore navedenih radnji ne funkcioniše, preduzimaju se najzahtevnije mere.

Ako se izvrši pravilno identifikovanje mesta gubitka isplake i utvrdi njegova stvarna dubina, tokom bušenja mogu se sprečiti različiti operativni problemi. Na manjim dubinama, stvarna pozicija gubljenja isplake unutar prirodnih propusnih slojeva može se kontrolisati različitim tipovima čepova. Dakle, gubitak isplake na manjim dubinama nije mnogo važan. Međutim, ako se gubitak isplake javi na dubinama većim od 1500 metara, materijali za začepljivanje ne mogu da spreče dalji gubitak isplake. U ovom slučaju treba utvrditi tačno mesto na kome se javlja gubitak isplake a zatim se neposredno pre nastavka bušenja vrši zaptivanje problematične formacije. Do gubitka isplake može doći bilo gde u kanalu bušotine, a njeni efekti se mogu otkriti u bilo kom trenutku.

Metode za utvrđivanje dubine zone gubitaka isplake su sledeće (Information Resources Management Association, 2015):

1. Merenje termometrom: nakon pokretanja uređaja, vrši se merenje i beleži se prvi gradijent temperature u bušotini. Nakon toga se deo isplake ispumpava i vrši se drugo merenje. Svaka veća promena između ova dva merenja ukazuje na gubitak isplake. Jedan od benefita ove metode je to da merenje može da se izvodi sa gustim fluidima za bušenje koji sadrže materijal za zaptivanje. Takođe, za merenje je potrebna mala količina fluida za bušenje.

2. Merenje elisom: merenje elisom nije pogodno u slučajevima gde postoji velika količina materijala za zaptivanje u isplaci, jer to može da spreči rotaciju elise. U ovom metodu, mali rotor sa žicom za navođenje se dovodi u bušotinu gde ga rotira sama isplaka, a brzina okretanja se beleži na ekranu.

3. Merenje radioaktivnog zračenja: metod se zasniva na merenju radioaktivnog zračenja unutar formacije. Nakon spuštanja uređaja za merenje radijacije gama zraka u bušotinu, dodaje se mala količina radioaktivnog jedinjenja u bušotinu i upoređuje se sa prvim merenjem. Smanjenje radioaktivnosti ukazuje na lokaciju gubitka cirkulacije isplake. Razlog ovome jeste što se tada radioaktivni materijal već inkorporirao u slojeve i merenje pokazuje manje vrednosti. Iako veoma skup, ovaj metod je vrlo pouzdan u otkrivanju mesta gubitka cirkulacije isplake.

4. Merenje vrućom žicom: metod se zasniva na promenama temperature bušotine, merenjem otpora žice koji je osetljiv na temperaturne varijacije. Ukoliko je mesto gubitka cirkulacije isplake ispod uređaja, fluid za bušenje će promeniti otpor žice. Stoga, ukoliko se otpor žice ne promeni, to označava da se uređaj nalazi ispod tačke gubitka cirkulacije isplake. Ovaj metod se može koristiti za merenje kod bilo kog tipa isplake, međutim, zahteva njegovu veliku količinu.

5. Metoda mernih pretvarača pritiska: da bi se odredio gubitak cirkulacije isplake, ovaj uređaj je potrebno pravilno postaviti u različite delove bušotine kako bi registrovao signale gubitka protoka. Metoda je efikasna kod svih tipova fluida za bušenje, sa različitim materijalima za zaptivanje. Značajni nedostatak ovog uređaja jeste što zahteva veliki protok isplake, kao i poteškoće pri njegovoj nabavci.

6. Upotreba podataka o otpornosti: jedan način za predviđanje mesta fraktura, je precizna i temeljna primena instrumenata za merenje otpornosti. Ovi instrumenti sa pouzdanosću procenjuju efekte okoline, kao što su veličina šupljina i indukovanih fraktura.

2.2 Preporučeni parametri postupka bušenja

Kada se govori o različitim metodama bušenja i njihovoj međusobnoj povezanosti, važno je napomenuti da mnogi faktori mogu da smanje ili povećaju gubitke cirkulacije isplake. Najvažniji od njih su opterećenje na dleto, brzina bušenja, broj obrtaja dleta u minuti, ulazni protok u bušotinu kao i gustina fluida za bušenje. Ispitivanjem uticaja pomenutih faktora na gubitak cirkulacije isplake, ovaj problem se sa lakoćom može kontrolisati i mogu se sprečiti potencijalni gubici.

Varijable samog bušenja mogu da se podele na nezavisne i zavisne. Opterećenje na dleto, kapacitet ispiranja i broj obrtaja dleta u minuti se smatraju nezavisnim varijablama. Suprotno tome, brzina bušenja i izlazni pritisak pumpe su zavisne varijable. Potrebno je naglasiti da su opterećenje na dleto i kapacitet ispiranja funkcionalno zavisne varijable.

Najbolji način kontrole gubitka isplake je regulacija opterećenja pritiska na dleto, kapaciteta ispiranja i same brzine bušenja. Obzirom da pritisak pumpe i kapacitet ispiranja imaju direktan uticaj na čišćenje same bušotine, potrebno je kontrolisati prvenstveno količinu isplake upumpanu u bušotinu da bi se ona očistila, a u isto vreme vršila i kontrola gubitka cirkulacije isplake (Al-Hameedi, 2018).

2.2.1 Gustina fluida za bušenje

Jedan od glavnih parametara pri sprečavanju gubitka cirkulacije isplake jeste gustina fluida za bušenje. Kada se gustina povećava, raste i hidrostatički pritisak, te ekvivalentna cirkulaciona gustina isplake (equivalent circulation density, ECD) može da dostigne najvišu tačku. Stoga, prekomerna gustina fluida za bušenje može da dovede do gubitka cirkulacije isplake. Ekvivalentna cirkulaciona gustina isplake predstavlja efektivnu gustinu isplake, gde se stvarnoj gustini dodaje vrednost gustine izračunate zbog otpora prilikom proticanja isplake kroz bušotinu.

Dinamička gustina, koja nastaje usled protoka fluida kroz bušotinu, ima višu vrednost od statičke gustine fluida. Ekvivalentna gustina isplake u bilo kojoj tački je suma hidrostatičkog pritiska fluida za bušenje i pada pritiska usled trenja iznad te tačke. Prema Elzenary i sar. (2018), faktori koje treba uzeti u obzir za gubitak pritiska u prstenastom prostoru su:


- gustina fluida za bušenje,
- reologija fluida za bušenje,
- brzina protoka,
- koncentracija čvrstih materija u prstenastom prostoru,
- dubina bušotine.

Stoga, ekvivalentna gustina isplake zavisi od svojstava bušenja ili parametara vezanih za fluid za bušenje i prikazuje se jednačinom (Elzenary i sar., 2018):

$$ECD = ESD(1 - C_a) + (\rho_s C_a + \frac{\Delta p}{9.8.H \times 10^{-3}})^{8.345} \quad (2-1)$$

gde ESD predstavlja statičku gustinu isplake (equivalent static density, ESD), C_a koncentraciju čvrstih čestica (%), ρ_s gustinu fluida (g/cm^3), H je dubina bušotine i Δp je gubitak pritiska u prstenastom prostoru (MPa). Veličine ESD i ECD imaju jedinicu gustine (g/cm^3).

Vrednosti gustine fluida za bušenje treba da budu između vrednosti pritiska u porama formacije i pritiska u frakturi, kako bi se sprečili neželjeni efekti. Zato je potreban pažljiv monitoring tokom procesa bušenja. Stanje same bušotine određuje gustinu fluida za bušenje i stoga je potrebno konstantno podešavanje gustine fluida. Studija sprovedena od strane Alhameedi i sar. (2017) na 75 bušotina u zoni Dammam pokazuje da povećanje gustine fluida za bušenje utiče i na gubitke isplake, tako da bi optimalna gustina fluida trebala biti između 1,05 i 1,06 g/cm³, što je ilustrovano na slici 2.2.



Slika 2.2: Efekat gustine bušaćeg fluida na gubitak cirkulacije isplake (Alhameedi i sar., 2017)

2.2.2 Opterećenje na dleto (WOB)

Brzina prodiranja kroz podlogu je indikator napretka bušenja i direktno je povezana sa opterećenjem na dleto, tako da efektivna gustina fluida za bušenje može da se pripiše povećanju brzine prodiranja usled visokog opterećenja na dleto.

Direktni i indirektni uticaji opterećenja na dleto pri gubitku isplake su dokazani. Stoga, potrebno je odrediti optimalni opseg opterećenja kako bi se sprečile neželjene posledice.

2.2.3 Brzina protoka i kapacitet pumpe (strokes per minute, SPM)

Ovaj parametar opisuje ciklus cirkulisanja isplake kroz sistem, od pumpe kroz bušotinu i nazad. Čišćenje bušotine u prstenastom prostoru strogo zavisi od dva parametra: pritiska pumpe i pritiska u prstenastom prostoru.

Ukoliko je pritisak pumpe visok, povećava se pritisak u prstenastom prostoru na zidove bušotine. Shodno tome, potrebno je odrediti optimalni raspon vrednosti ova dva parametra da se spreči gubitak isplake.

2.2.4 Broj obrtaja (o/min)

Praćenjem ovog parametra dobija se uvid o broju obrtaja alata za bušenje, povezanom sa brzinom prodiranja kroz podlogu. Što su više o/min vrednosti, povećava se količina čvrstih čestica u prstenastom prostoru, što ima za posledicu i povećanje pritiska na dno bušotine kao i sužavanje prstenastog prostora. Kao i kod prethodnih parametara, potrebno je naći optimalne vrednosti broja obrtaja da bi se smanjili gubici.

2.2.5 Brzina bušenja (rate of penetration, ROP)

Pritisak na dno bušotine je direktno povezan sa brzinom bušenja. Sa druge strane, postoji linearna povezanost između brzine bušenja i gustine fluida u formaciji, kao i parametara poput WOB, SPM i o/min. Da bi se izbeglo povećanje pritiska u prstenastom prostoru i ekvivalentne gustine isplake, potrebno je odrediti optimalne vrednosti brzine bušenja.

Osim gore spomenutih, ovo istraživanje će se baviti i drugim parametrima koji utiču na gubitak cirkulacije isplake poput: prečnika i dubine bušotine, pritiska pumpe, osobina bušaćeg fluida, časova rada dleta, kao i tipovima formacija.

2.3 Potencijalni gubitak cirkulacije isplake

U cilju određivanja potencijalnih gubitaka cirkulacije isplake, treba imati kvantitativnu predstavu o propusnosti i poroznosti formacije, kao i kvalitativni opis bušotine. To podrazumeva uvid u prisustvo prirodnih i indukovanih fraktura i kaverni.

Postojanje fraktura se određuje uz pomoć FI indeksa (*fracture intensity index*). Ukoliko je njegova vrednost 10 to ukazuje na basene sa visokim stepenom fraktura, a ukoliko je 1 prisutne su nefrakturirane formacije. Slično tome, prisustvo šupljina u stenama se određuje VI indeksom (indeks šupljikavosti ili *vuggy index*). Kada je vrednost VI=10, u pitanju su šupljikave stene, dok vrednost VI=1 znači odsustvo šupljina u steni. Vrednosti indeksa FI i VI određuju se proizvoljno, na osnovu procene stanja stena od strane korisnika.

Potencijalni gubitak cirkulacije isplake se kroz ove četiri varijable može izračunati na sledeći način:

$$LCI = \left[\frac{K}{4000} \right] \left[\frac{\text{poroznost}}{0.4} \right] \left[\frac{FI}{10} \right] \left[\frac{VI}{10} \right] \quad (2-2)$$

gde je LCI potencijalni gubitak cirkulacije isplake (*lost circulation index*), K je propusnost stene u mD (mildarsi), dok se poroznost odnosi na frakture i izražava se u procentima. Maksimalna propusnost stena koja se beleži kod formacija sa naftom iznosi 4000 mD, dok najveća poroznost može iznositi 40%. Na osnovu izračunatih vrednosti potencijalnog gubitka cirkulacije isplake može se zaključiti sledeće (Alajmi and Schubert, 2003; Garrouch and Lababidi, 2001):

- LCI ≥ 5% - postoje ozbiljni gubici cirkulacije isplake,
- LCI < 0.1% - nema gubitaka u cirkulaciji isplake,
- 0.1% ≤ LCI < 5% - postoje umereni gubici u cirkulaciji isplake.

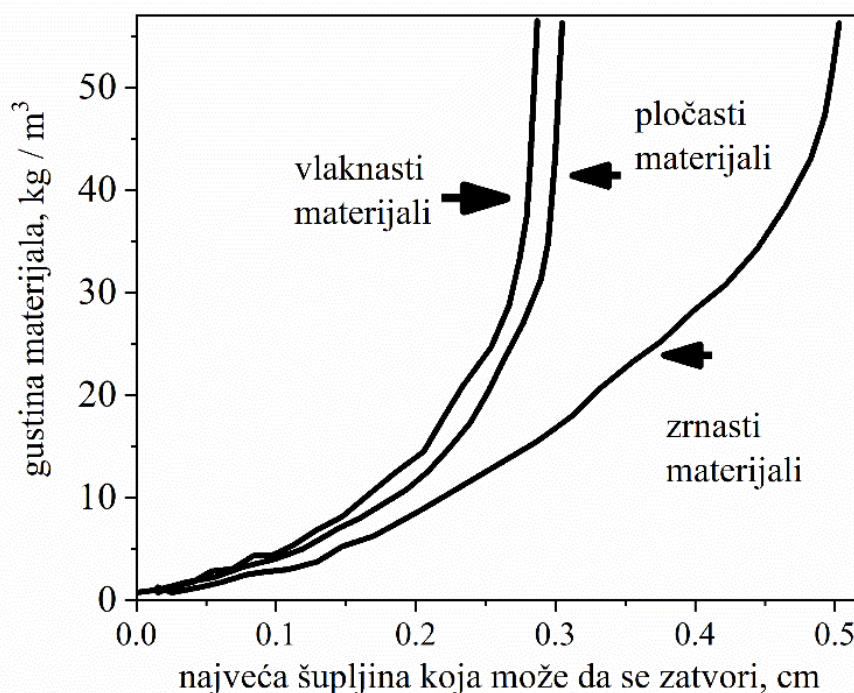
2.4 Metode kontrole, sanacije i smanjenja gubitaka u cirkulaciji isplake

Metode koje se koriste za rešavanje problema gubitka cirkulacije isplake se dele u zavisnosti od vremena izvršenja. Inhibitorne metode su one koje se koriste pre nego što se gubitak desi, a metode koje se koriste po nastanku problema su metode sanacije. Materijali koji se koriste za sprečavanje problema su materijali za sanaciju. Tokom bušenja ili cementiranja koriste se mnogi materijali koji pomažu da se izgubljena isplaka priključi nazad u proces cirkulacije, radi obnove sistema protoka. Priroda materijala koji se koristi zavisi od tipa gubitka, faze bušenja, te tipa formacije. Svaka od metoda remedijacije ima za cilj nešto od navedenog (Alkinani i sar., 2018b):

- da premosti protok isplake preko postojećih šupljina ili fraktura,
- da spreči širenje indukovanih fraktura.

Primena materijala za sprečavanje gubitka cirkulacije (*lost circulation material*, LCM): različiti tipovi materijala se mogu koristiti u ovu svrhu, odvojeno ili zajedno, i kategorišemo ih na sledeći način, kao što ilustruje slika 2.3:

- vlaknasti materijali (usitnjene stabljike šećerne trske, automobilske gume, piljevina ili celuloza),
- pločasti materijali (delovi celofana, liskun i iverje),
- zrnasti materijali (ljuspe oraha, staklo i čestice škriljca).
-



Slika 2.3: Zavisnost između gustine različitih vrsta materijala za sprečavanje gubitka cirkulacije i veličine frakture (Caenn i sar., 2017)

Kao što je prikazano na slici 2.3, veće frakture mogu da se zatvore uz primenu većih količina materijala za sprečavanje gubitka cirkulacije. Zrnasti materijali su se pokazali kao najbolji za blokiranje fraktura (Caenn i sar., 2017).

Jasno je da se svi gore pomenuti materijali mogu koristiti i kao mešavine, pogotovo ukoliko su u pitanju gubici sa značajno većim posledicama. U najnovijoj klasifikaciji prema Alkinani i sar. (2018b) dodate su još dve kategorije - visoko viskozni materijali za sprečavanje gubitka cirkulacije i materijali za formiranje čepova, koji su dizajnirani za sanaciju manjih gubitaka, kao što ilustruje tabela 2.1.

Tabela 2.1: Materijali za sprečavanje gubitka cirkulacije za različite vrste gubitka isplake (Alkinani i sar., 2018b)

Materijali za sprečavanje gubitaka cirkulacije			
Curenje	Delimični gubici	Značajni gubici	Potpuni gubici
bentonit	aditivi za zaptivanje visoke viskoznosti (HV-Patch)	aditivi visoke efikasnosti za prevenciju značajnih gubitaka fluida	čepovi na bazi cementa
polimeri	zrnasti materijali	smeše materijala za zaptivanje sa karakteristikom bubrenja/hidratacije	čepovi na bazi umreženog cementa
karboksimetil celuloza niske viskoznosti (CMC-LV)	pločasti materijali	„super stop“ materijali	čepovi na bazi aditiva gilsonita
karboksimetil celuloza visoke viskoznosti (CMC-HV)	vlaknasti materijali	isplaka visoke viskoznosti i niske gustine + smeša materijala za zaptivanje	cementni čepovi sa vlaknastim aditivima
skrob	materijali za začepljivanje	cementni čep	čepovi na bazi bentonita, cementa ili polimera sa dizel gorivom
polianjonski celulozni polimer niske viskoznosti (PACR-LV)	smeša materijala za zaptivanje	viskozaptivni aditivi i smeše	čepovi na bazi gline atapulgita
polianjonski celulozni polimer visoke viskoznosti (PACR-HV)		ultra-viskozaptivni aditivi i smeše	čepovi na bazi bubrečnih suspenzija
natrijum poliakrilat (SPA)		taložne hemijske suspenzije, silikati, lateks	čepovi na bazi barita
lignini i tanini			
resinex			

Alternativno rešenje za postupak sanacije gubitka cirkulacije je upotreba cementa. U svojoj studiji Ramasamy (2019) je pokazao da je primena cementa čak uspešnija u pomenutom procesu od standardnih materijala za sprečavanje gubitka cirkulacije.

Upotreba materijala za sprečavanje gubitka cirkulacije nekada može biti nedovoljna. Ovo se posebno odnosi na slučajeve izrazito dubokih bušotina, formacija koje su osiromašene u gasu i nafti usled prethodne eksploatacije i ležišta sa prirodnim frakturama. Zato, pre pojave gubitka cirkulacije, ovaj problem mora biti sprečen.

Metode prevencije omogućavaju ojačavanje zidova bušotine i zaptivanje stvorenih fraktura tokom bušenja, smanjuju naprezanja oko bušotine, smanjuju broj fraktura u formaciji i povećavaju dozvoljeni opseg gustine fluida za bušenje (Salehi and Nygaard, 2011).








Neke od uspešnijih metoda prevencije su: upotreba nanočestica, hemijske injekcione mase, formiranje čepova, tretmani smolom, grafitom i kalcijum-karbonatom (Alkinani i sar., 2018b). Na slici 2.4 su prikazane različite metode sanacije, u odnosu na stepen gubitka cirkulacije.

Sprečavanje značajnih ili potpunih gubitaka cirkulacije se može postići bušenjem na slepo ili primenom cementirajućih materijala. Pri bušenju na slepo, fluid za bušenje se ne vraća na površinu, već odlazi u frakture i zaptiva ih (Alkinani i sar., 2018a).

2.5 Uzroci neuspeha u prevenciji gubitka cirkulacije

Neki od najčešćih razloga za neuspeh u prevenciji gubitaka cirkulacije su (Aldred i sar., 1998; Abbas i sar., 2004):

- oprema nije postavljena na njeno unapred predviđeno mesto ili postoje greške u inženjerstvu i geološkim kalkulacijama bušačkog procesa;
- menjanje karakteristika bušačkog fluida u odnosu na formaciju;
- nedostatak precizno definisanih regiona u kojima se dešavaju gubici;
- upotreba neadekvatnih metoda implementacije, sastava i distribucije materijala za sprečavanje gubitka cirkulacije;
- krhkost geomehaničkih svojstava formacije usled delovanja pritiska fluida za bušenje.

Gubici		
Delimični	Značajni	Potpuni
- metod čekanja - smanjenje SPM i RPM - regulacija ECD - primena dleta bez mlaznice 	fluid za bušenje visoke viskoznosti i niske gustine + mešavina LCM materijala 	bušenje na slepo pre primene bilo kog tretmana, ako je to izvodljivo 
NEUSPEŠNO		
- primena 10 – 15 m ³ LCM materijala niske gustine sa sledećim aditivima (svi aditivi u koncentraciji 15 kg/m ³): Mica Fine, Mica Medium, Nut Plug, fini i grubi CaCO ₃ 	cementni čep 	materijali na bazi dizel goriva, bentonita i cementa (DOBC materijal)
NEUSPEŠNO		
isplaka visoke viskoznosti, sa bentonitom, krečom ili slanom glinom	primena 15 – 20 m ³ LCM materijala niske gustine sa sledećim aditivima (svi aditivi u koncentraciji 30 kg/m ³): Mica Fine, Mica Medium, Nut Plug, fini i grubi CaCO ₃ 	fluid za bušenje visoke viskoznosti i niske gustine + cementni čep 
NEUSPEŠNO		
	- „super stop“ materijal	cementni čep

Slika 2.4: Najčešće strategije za rešavanje problema gubitka isplake (Alhameedi, 2018)

3 MAŠINSKO UČENJE I EKSPERTNI SISTEMI

Poslednjih godina u naftnoj industriji porasla je potreba za inovacijama u predviđanju gubitaka isplake. Inteligentno modelovanje poboljšano je razvojem novih pristupa kao što je *soft computing*, u svim oblastima nauke i tehnologije.

Jedan od pristupa soft computing-a je Adaptivni neuro fuzzy sistem zaključivanja (*Adaptive neuro fuzzy inference system*, ANFIS). Fuzzy logiku po prvi put je uveo Zadeh (Zadeh, 1965). Zatim je Jang predložio novi model koji uključuje fuzzy logiku i neuronske mreže. Ovaj pristup se može primeniti u situacijama koje se bave neizvesnošću i velikim brojem podataka (Jang, 1993).

Aplikacija ANFIS se široko primenjuje u različitim oblastima nauke i tehnologije. Funkcije ANFIS-a našle su primenu u naftnom rudarstvu i koriste se za poboljšanje parametara bušenja, istraživanja i za kategorizaciju ležišta. Na osnovu već ranije istaknutih činjenica može se zaključiti da glavni problem tokom procesa izrade kanala bušotine predstavlja gubitak isplake.

Shermetov je predložio način na koji se može rešiti problem gubitka isplake, zasnovan na primeni fuzzy logike (Shermetov i sar., 2008). Pored toga, Moazeni i sar. je koristio neuronsku mrežu za predviđanje količine izgubljene isplake na jednom od naftnih polja u Iranu (Moazzeni i sar., 2010).

3.1 Upotreba mašinskog učenja u procesu bušenja

Metode prikupljanja podataka se mogu definisati kao skup različitih pristupa i aktivnosti u cilju prikupljanja raznih tipova podataka, računskih nedoumica, otkrivanja skrivenih šablona i izvlačenja korisnih informacija. Ove metode imaju ključnu ulogu pri proceni budućih trendova, rešavanja problema te predviđanja ponašanja/reagovanja kada tradicionalne metode zakažu. Postoje dva tipa tradicionalnih modela predviđanja: prvi tip se zasniva na statistici (pomoću ulaznog skupa podataka, statističkih metoda i pretpostavki određuje se algoritam koji služi za predviđanje tzv. prilagođavanje modela ili eng. *fitting model to data*), dok se drugi tip zasniva na iskustvenim saznanjima stručnjaka u datim oblastima. Ulazi se transformišu u predviđanje tzv. predviđanje zasnovano na pravilima ili eng. *prediction based on rules*).

Tradicionalne metode modelovanja su često dugotrajne i zasnivaju se na tehnici pokušaja i pogreški. Ukoliko se želi postići zadani cilj, učestala podešavanja i prepravke metode su neizbežni. Takođe, ovde se zanemaruje prisustvo nepotpunih podataka i ekstremnih vrednosti, a tradicionalne metode ne reaguju dobro ni na komplikovaniju međuzavisnost podataka zbog tendencije da se čitav proces pojednostavi (Noshi i Jerome, 2018).

Upotrebom interneta i napretkom tehnologije, omogućeno je kreiranje velikog broja podataka, kao i skladištenje istih. U naftnoj i gasnoj industriji skladištenje i analiza podataka su otežani zbog nekompatibilnosti sa konvencionalnim alatima obrade podataka (Mishra i Datta-Gupta 2017). Pretraga podataka (eng. *data mining*) je jedna od ključnih komponenti u analizama koje se zasnivaju na pretrazi podataka jer omogućava ekstrakciju naizgled skrivenih podataka. Ovaj proces integriše vizualizaciju i statističke metode sa mašinskim učenjem i kognitivnim šablonima radi prepoznavanja korisnih repetitivnih trendova. Algoritmi koji se koriste u procesu pretrage podataka (*SHA-256, Ethash, Scrypt, X11, Equihash, Cryptonight*) imaju izuzetne sposobnosti da, koristeći ranije podatke, da predviđaju i prepoznaju prikrivene trendove (Hastie i sar., 2009).

Glavne kategorije mašinskog učenja su nadgledano, nenadgledano, polu-nadgledano i učenje uslovljavanjem (Delhommelle, 2018). Nadgledano učenje je princip da se preko velikog broja primera iz skupa podataka za treniranje, mreža zaključuje na osnovu datih podataka iz treninga. Tačno definisani uslovi međusobne zavisnosti ulaznih i izlaznih varijabli na osnovu skupa

podataka za treniranje daju tačnu vrednost funkcije za podatak sa kojim se prvi put sreće. U nenadgledanom učenju, ne postoje već unapred predodređeni skupovi podataka za trening. Osnovna razlika ova dva vida mašinskog učenja je što u nenadgledanom učenju nisu definisane izlazne varijable. U slučajevima kada postoji puno ulaznih varijabli, a samo neke od njih imaju definisan izlazni skup podataka, radi se o polu-nadgledanom učenju. Najzad, algoritam koji se razvija samostalno u okruženju zasnovanom na sistemu pokušaja i pogreški se naziva učenje uslovljavanjem.

U današnje vreme, umesto modela zasnovanih na fizičkim procesima, modeli bazirani na velikoj količini podataka i veštačkoj inteligenciji imaju značajno mesto u naftnoj industriji, konkretno u procesima bušenja. Njihova prednost je što predstavljaju moćnu alatku pri rešavanju problema u ovoj industriji, ali da bi se sistem još više unapredio potrebno je uzeti u obzir dosta uticajnih faktora. (Razeghi i sar., 2017).

Problemi poput zanemarivanja verovatnoće i skrivenih zavisnosti između obrađenih i sirovih podataka, poteškoće u izvlačenju korisnih saznanja iz modela mašinskog učenja, otežavaju pronalazak algoritma koji bi davao najkonstruktivnija rešenja. Ovome doprinose i često nejasni, dvosmisleni podaci koji dolaze kombinovanjem mašinskog učenja sa modelima zasnovanim na fizičkim procesima (Solomatine i sar., 2008).

Brz i jednostavan način modelovanja linearnog tipa podataka je linearna regresija koja ne zahteva suviše računskih procesa. Ipak, u nekim slučajevima metoda nije potpuno pouzdana. Drugi način je stablo odlučivanja koje predstavlja vizuelno jednostavna rešenja, a uspešan je metod i u slučaju nepotpunih podataka ili ekstremnih vrednosti. Ovaj metod nije pogodan kada je prisutan veliki broj različitih tipova podataka.

Metode potpornih vektora (eng. Support Vector Machine - SVM) su pokazale zadovoljavajući odgovor na podatke linearnog i nelinearnog tipa kada se pojavljuju ekstremne vrednosti. One brzo primenjuju naučenu ciljanu funkciju, ali ovako visokom stepenu autonomije u računanju prethodi zahtevno programiranje. Veštačke neuronske mreže (ANNs) se mogu primeniti u situacijama gde je relacija između ulaznih i izlaznih parametara nejasna, što pokazuje njihov potencijal ka sposobnosti samostalne optimizacije i prilagođavanja projektima industrije nafte i gasa (Haykin, 2005).

Veštačka inteligencija činjenično predviđa buduće performanse na osnovu malo dostupnih podataka iz prošlosti o određenoj bušotini. Ovaj metod je robustan, dugotrajan i ne koristi standardizovane metode kalkulacija. Još jedna od metoda je fuzzy logika, gde je proces selekcije olakšan u skupovima podataka nelinearnog tipa. Posebna vrsta problema jesu izrazito nelinearni procesi višeg reda koji su izloženi velikom uticaju spoljašnjih poremećaja. Sa takvim sistemima, jedino preostalo rešenje je upravo ono koje se primenjuje u praksi: takvim procesima upravljaju operateri koristeći svoje višegodišnje iskustvo i znanje o statičkim i dinamičkim karakteristikama sistema.

Dostignut kvalitet upravljanja je proporcionalan znanju i iskustvu operatera. Iskustvo operatera je povezano sa praćenjem relevantnih procesnih promenljivih, i u zavisnosti od njihovog stanja i odstupanja od željenih vrednosti, operater odlučuje gde, kako i koliko je potrebno delovati na proces. Takođe, metoda daje i određeni stepen istinitosti ostalim tehnikama (Jovanović, 2020). Genetski algoritam može da bude od velikog značaja u uniformnim skupovima podataka, ali je takođe robustan i ima tendenciju davanja dvosmislenih rezultata.

ANFIS (eng. adaptive neuro-fuzzy inference system) je tip adaptivne mreže koja integriše neuronske mreže i fuzzy logiku. Neuronske mreže primenjuju informacije iz baza podataka iz prošlosti za procenu budućih rezultata. Fuzzy logika se zasniva na principu rada ljudskog mozga, odnosno razmišljanja. Meru neke veličine čovek opisuje jezičkim izrazima, na primer, brzo, sporo, veliko, malo itd. U složenijim slučajevima uvode se granični, konkretniji izrazi, kao što su: vrlo veliko, ne tako malo i slično.

Na osnovu svega rečenog do sada, može se zaključiti da mašinsko učenje predstavlja vid veštačke inteligencije gde računarski uređaji uče na osnovu prethodnog iskustva. Jedno od najvažnijih ljudskih dostignuća u nauci je koncept veštačke inteligencije. Među naučnicima ne postoji jedna univerzalna, usaglašena definicija ovog pojma zbog velikog obima stvari koje obuhvata. McCarthy je 2007. godine dao jednu od definicija- veštačka inteligencija predstavlja spoj nauke i tehnike gde se preko stvaranja kompjuterskih programa, mašinama daju svojstva ljudske inteligencije.

Prema Rable-u (2017), merljivost sposobnosti veštačke inteligencije je njena mogućnost da reši kompleksne probleme, uspešnije nego ljudski mozak, analizirajući usput velike količine podataka radi identifikacije mogućih trendova i predviđanja budućih scenarija. Kao osobina veštačke inteligencije se takođe smatra i moguća ušteda u vremenu i troškovima zadate operacije.



Slika 3.1: Mesto nadgledanog mašinskog učenja u odnosu na veštačku inteligenciju

(Duarte i sar., 2018)

Metod veštačke inteligencije je do sada primenjen u svim sektorima naftne i gasne industrije prilikom procesa proizvodnje i eksploatacije. Neki od sektora pomenutih u literaturi su bušenje, izbor bušotine, određivanje lokacije bušotine, analiza stepena eksploatiranosti bušotine, predviđanje performansi pumpi za podizanje gasa, karakterizacija rezervoara, istraživanja prošlih događaja, optimizacija interpretacije modela ispitivanja bušotine, procena štete i dvofazni protok kroz gasovod (Agwu i sar., 2018).

Treba naglasiti da se naftna i gasna industrija suočavaju sa velikim brojem problema. Nestabilnost kanala bušotine, gubitak cirkulacije isplake, te oštećenja i taloženje uz zidove kanala

su samo neki od problema koji vode utrošenom vremenu i novcu. Za bušači fluid, koji se naziva i srž operacije bušenja, se vezuje najveći broj poteškoća. Prema Bloys i sar. (1994), bušači fluid može biti uzročnik svih nastalih problema tokom bušenja, te da sam pričinjava 15% troškova čitave operacije. Shadravan je 2015. godine zaključio da nam je potreban sistem koji koristi sve raspoložive informacije i u njima prepoznaje šablone, te pruža potencijalne buduće predikcije. Nauka koja poseduje sve navedene karakteristike je veštačka inteligencija (AI).

Postoji nekoliko benefita primene tehnika veštačke inteligencije. Na primer, jedna od prednosti jeste mogućnost da se uspešno snalazi u situacijama gde postoje komplikovane relacije između ulaznih i izlaznih varijabli, jer ovaj metod daje najbolja rešenja sa malom verovatnoćom greške (Agwu i sar., 2018).

Veštačka inteligencija se koristi u naftnoj industriji u vidu veštačkih neuronskih mreža, fuzzy logike, algoritma roja čestica, vektor mašina za podršku, genetskih algoritama, sistema hibridne inteligencije i rezonovanja zasnovanog na slučaju.

3.2 Fuzzy logika

Stvarni svet je suviše komplikovan da bi se mogao detaljno opisati. Stoga, potrebno je uvesti model približnog opisa koji je u isto vreme dovoljno prihvatljiv i analitičan. Za to je potrebno definisati hipotezu koja će biti približna ljudskom znanju na jedan sistematičan način, kako bi se ona uvela u tehnički sistem sa ostalim matematičkim modelima. Fuzzy logika prevazilazi binarni sistem nula i jedinica klasičnih softvera. Ona otvara nova vrata programiranja, jer u svom načinu funkcionisanja obuhvata beskonačan prostor između nula i jedinica.

U fuzzy logici, svaka od ovih vrednosti se određuje na osnovu funkcije pripadnosti nejasnih vrednosti koje se nalaze između nule i jedinice. Postoji diskusija da fuzzy logika počinje sa ljudskom mišlju. Suprotno probabilističkoj dualnosti gde postoje jasne razlike i granice između dva ishoda, u fuzzy logici se ova stanja prepliću (Foroozandeh i sar., 2018; Heubo-Kwegna, 2016).

3.2.1 Osnovni pojmovi fuzzy logičkog zaključivanja

Fuzzy logiku je izumeo Lofti Zade 1965. godine i više od 20 godina nije upotrebljavana izvan teorijskih analiza pošto nisu postojali personalni računari koji su je mogli podržati. Sredinom osamdesetih godina prošlog veka, japanska industrija je prepoznala vrednost ove nauke i počela je da je koristi. Prvi projekat je bio dizajn i kontrola potpuno automatizovane podzemne železnice koji je konstruisao i sagradio Hitachi.

Osnove fuzzy logike zasnivaju se na mapiranju komponenti ulaznog skupa podataka sa odgovarajućim komponentama izlaznog skupa. Iz tog razloga, koriste se serije fraza ako-onda, koje nazivamo pravilima. Pre kreiranja sistema za interpretaciju pravila, potrebno je da se definišu svi korišćeni pojmovi i funkcije koje ih opisuju.

Fuzzy logika se zasniva na četiri osnovna koncepta, koji su objašnjeni dalje u tekstu (Nikam i sar., 2012):

1. Fuzzy skupovi: Fuzzy logika počinje sa konceptom fuzzy skupova koje je prvi kao pojam uveo Zadeh 1960. godine. Fuzzy skup je potpuno definisan skup bez jasnih granica. Svaka komponenta može da mu pripada samo delimično. Ovo je ekstenzija diskretnih skupova u kojima element ili pripada ili ne pripada određenom skupu. Fuzzy logika daje rezultate sa više vrednosti.

Ukoliko se postavi pitanje ‘Da li je X član skupa A ’, odgovor može biti da jeste (1), nije (0) ili još hiljadu vrednosti između ove dve. Shodno tome, X može delimično da bude član skupa A . Logika koja pruža više ishoda se potpuno kosi sa dualnom logikom u diskretnim skupovima, gde se mogu koristiti samo odgovori ‘da’ i ‘ne’.

2. Funkcije pripadnosti: Kriva funkcije pripadnosti dodeljuje stepen pripadnosti svakoj komponenti iz ulaznog skupa, uz uslov da su vrednosti stepena pripadnosti između nula i jedan. Oblik krive zavisi od tipa problema. Ove funkcije igraju važnu ulogu u fuzzy sistemu zaključivanja, imaju različite forme od kojih je svaka kreirana na osnovu njene korespondentske veze. U ovom tipu veza postoje određeni fiksni parametri koji zavise od forme funkcije pripadnosti. Izbor ovih parametara vrši iskusan korisnik ili se koriste skupovi podataka. Neke od ovih funkcija su trouglasta, trapezoidna, Gausova, zvonasta ili sigmoidalna. Navedene funkcije pripadnosti nisu komplikovane i mogu da se definišu na osnovu potreba za specifičnu primenu, sa odgovarajućim matematičkim zapisom.

3. Logički operateri: sabiranje, deljenje i upotpunjavanje osnovnih operatera u diskretnim skupovima. Fuzzy skupovi imaju slične funkcije koje su prvobitno definisane od strane osnivača. Ovi operateri, koji kreiraju nove fuzzy skupove od već postojećih su: sabiranje, deljenje i upotpunjavanje.

4. Pravila ako-onda: Kreiranje veza između ulaznih i izlaznih podataka u fuzzy sistemu zaključivanja, primenom uslovnih tj. pogodnih rečenica pomoću termina ako-onda, kada su u pitanju lingvističke (jezičke) promenljive. Lingvističke promenljive imaju vrednost koja je predstavljena jezičkom terminologijom. Na ovaj način, reči u skupovima definisane varijablama se definišu kao fuzzy skupovi. Deo uslova ili rešenja može da bude jednostavan fuzzy iskaz ili kombinacije više jednostavnih fuzzy iskaza čime se dobijaju složeni iskazi koji se spajaju logičkim veznicima ‘i’, ‘ili’, ‘ako ... onda’, ‘ako i samo ako’ i ‘n’, koji označavaju redom, konjunkciju, disjunkciju, implikaciju ekvivalenciju i negaciju.

3.2.2 Fuzzy skup, funkcije pripadnosti i fuzzy broj

U ovom delu predstavljene su opšte informacije o teoriji fuzzy logike. U daljem tekstu se navode neki od osnovnih pojmova i definicija (Jovanović, 2020, Castillo i Melin 2000).

Fuzzy skup predstavlja skup uređenih parova generičkih elemenata x i njihovih odgovarajućih stepena pripadnosti $\mu_A(x)$, odnosno za fuzzy skup A važi:

$$A = \{(x, \mu_A(x)) | x \in X\}, \text{ za } \mu_A(x): X \rightarrow [0,1] \quad (3-1)$$

Iz ove definicije se jasno vidi da funkcija pripadnosti fuzzy skupa A $\mu_A(\cdot)$ svakom generičkom elementu x iz nekog univerzalnog skupa X dodeljuje određeni stepen pripadnosti koji će uzimati vrednosti na intervalu između nula i jedan. Ako svaki element skupa ima stepen pripadnosti jednak tačno nula (potpuno odsustvo iz skupa) ili tačno jedan (potpuna pripadnost skupu) onda će se analiza svoditi na klasične skupove.

Međutim, za sve decimalne vrednosti između ova dva broja element x će delimično pripadati datom fuzzy skupu, odnosno pripadaće skupu sa određenim stepenom. Upravo zbog ovoga se može reći da su fuzzy skupovi i logika na neki način samo uopštavanje klasičnih matematičkih diskretnih skupova, pri čemu ti klasični skupovi figurišu samo graničnim vrednostima intervala fuzzy funkcije pripadnosti.

Primeri funkcija pripadnosti (trouglasta, trapezoidna, Gausova) mogu se videti na slici 3.2 i opisane su sledećim formulama:

Troglasta funkcija pripadnosti:

$$\text{triangle}(x; a, b, c) = \begin{cases} 0, & x \leq a \\ (x - a) / (b - a), & a \leq x \leq b \\ (c - x) / (c - b), & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (3-2)$$

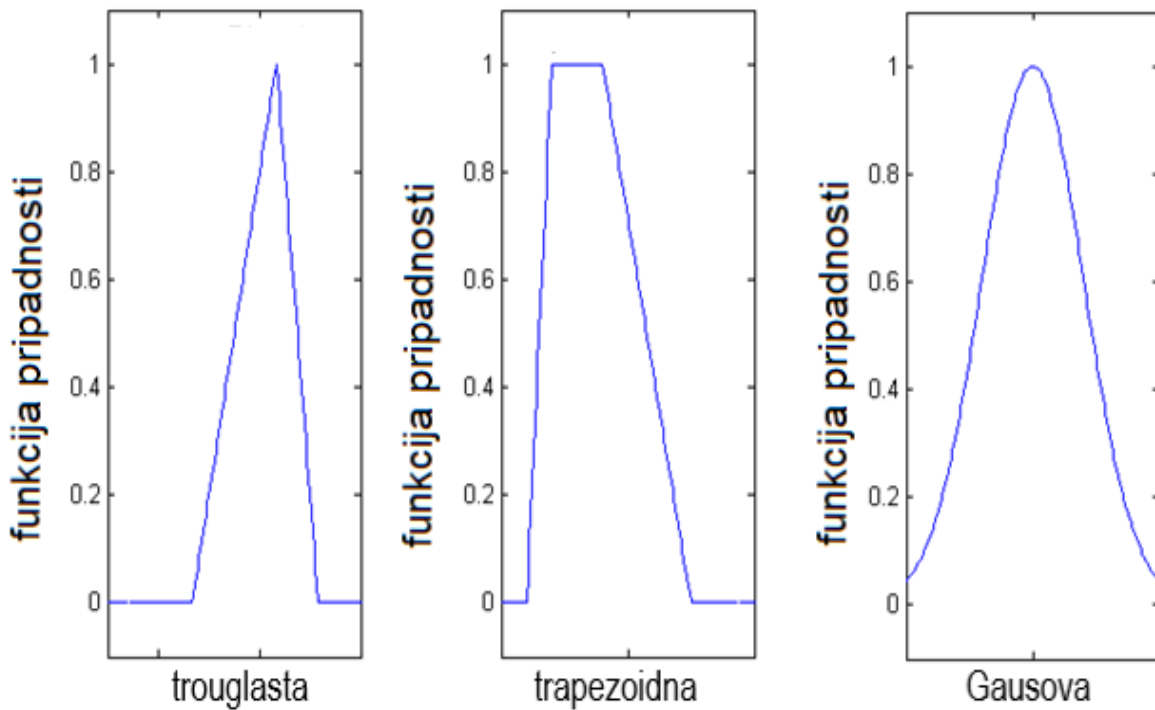
Trapezoidna funkcija pripadnosti:

$$\text{trapezoidal}(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ (x - a) / (b - a), & a \leq x \leq b \\ 1, & b \leq x \leq c \\ (d - x) / (d - c), & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (3-3)$$

Gausova funkcija pripadnosti:

$$\text{gaussian}(x; c, \sigma) = e^{\frac{-(x-c)^2}{2\sigma}} \quad (3-4)$$

Jasno je, iz priloženih matematičkih formula, da je u delovima gde funkcija opada ispred promenljive x stoji negativan predznak. Suprotno, u delovima u kojima funkcija raste ispred promenljive je pozitivan znak. Što se tiče Gausove funkcije pripadnosti, variranjem parametara c i σ menja se njen oblik. Tako se, u opštem slučaju, promenom parametra c menja i centar funkcije, dok se σ menja širina funkcije.



Slika 3.2: Primeri funkcija pripadnosti (Kovandžić N., 2020).

Da bi se definisali neki osnovni pojmovi iz teorije fuzzy logike, koji će biti neophodni za kasniju analizu, potrebno je prikazati osobine i karakteristike fuzzy skupova (Jovanović 2020).

Visina fuzzy skupa B, koji je određen na univerzalnom skupu X, označava se sa $hgt(B)$ i predstavlja maksimalni stepen pripadnosti koji se javlja u tom skupu:

$$hgt(B) = \sup_{x \in X} \mu_A(x) \quad (3-5)$$

Za onaj fuzzy skup za koji važi: $hgt(B) = 1$ se kaže da je *normalizovan fuzzy skup*.

Još jedna važna osobina nekog fuzzy skupa jeste njegova *konveksnost*. Za fuzzy skup se kaže da je konveksan kada važi sledeće: Ako se na apscisi uoče dva elementa x_1 i x_2 i nacrtta linija koja ih spaja, onda stepeni pripadnosti svih tačaka na liniji moraju biti veći ili jednaki od manje vrednosti između $\mu(x_1)$ i $\mu(x_2)$. Matematički zapis ovog iskaza glasi:

$$\mu(w) \geq \min(\mu(u), \mu(v)), \text{ za } u \leq w \leq v \text{ i } \mu(u), \mu(w), \mu(v) > 0 \quad (3-6)$$

Sada se, konačno, može definisati veoma važan pojam u fuzzy teoriji: *fuzzy broj*, kao fuzzy skup C sa sledećim osobinama:

- $hgt(C) = 1$,
- C je konveksan skup,
- Za samo jedan element x važi da je njegov stepen pripadnosti $\mu_C(x) = 1$,
- $\mu_C(x)$ je u delovima neprekidna.

3.2.3 Fuzzy algebra i operacije nad fuzzy skupovima

Fuzzy algebra i operacije koje važe za klasične matematičke skupove postoje i mogu se definisati i za fuzzy skupove:

- Jednakost $A = B$ važi ako i samo ako: $\mu_A(x) = \mu_B(x), \forall x \in X$
- Unija $A \cup B$ važi ako i samo ako: $\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)), \forall x \in X$
- Presek $A \cap B$ važi ako i samo ako: $\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)), \forall x \in X$
- Komplement od A : $\mu_{\bar{A}}(x) = 1 - \mu_A(x), \forall x \in X$
- m -ti stepen $\mu_{A^m} = (\mu_A)^m(x)$
- Algebarska suma: $\mu_{A+B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x), \forall x \in X$
- Algebarski proizvod: $\mu_{A \cdot B}(x) = \mu_A(x) \cdot \mu_B(x), \forall x \in X$

Osobine koje važe za klasične skupove, a zajedničke su i za fuzzy su: idempotentnost, komutativnost, asocijativnost, distributivnost, apsorpcija, involucija i De Morganovi zakoni.

3.2.4 Fuzzy relacije

Kao i kod funkcija pripadnosti, tako se i kod fuzzy relacija ne može govoriti o potpunom postojanju ili ne postojanju veze. Fuzzy relacija je skup parova elemenata i stepena pripadnosti te relacije. Funkcija pripadnosti relacije predstavlja preslikavanje iz Kartezijevog proizvoda $X_1 \times X_2 \times X_3 \dots \times X_n$ na interval $[0,1]$ i ona određuje jačinu preslikavanja. Fuzzy relacija se definiše sledećim zapisom:

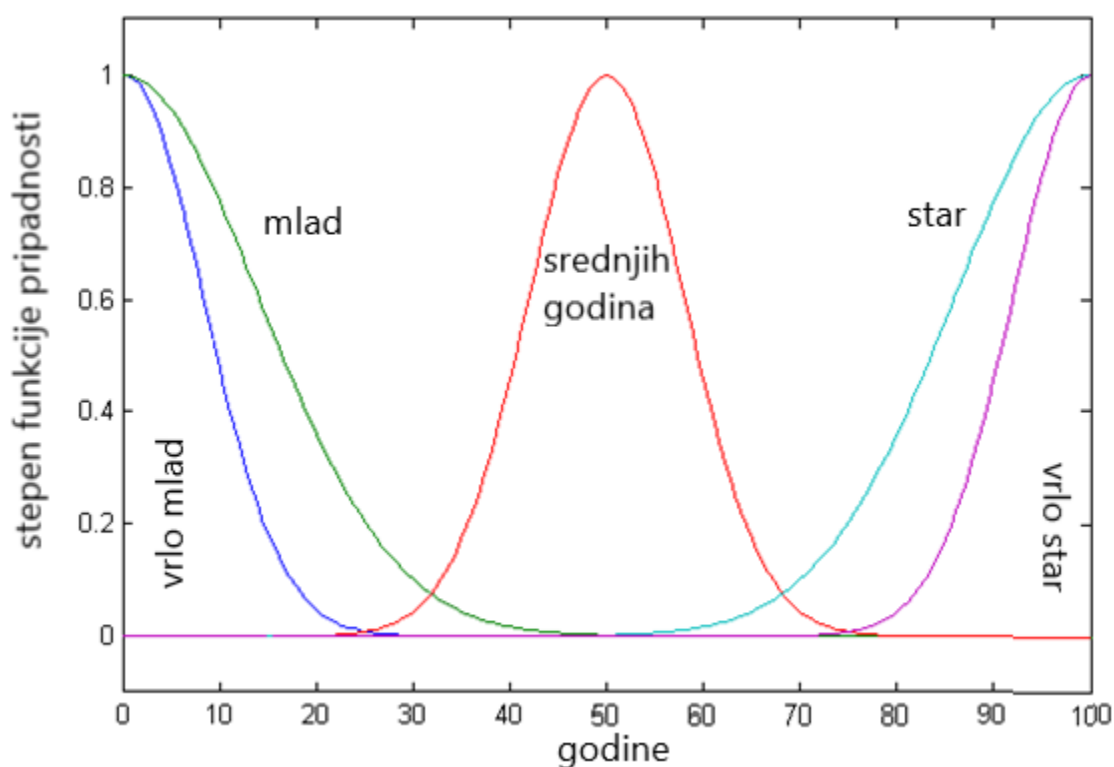
$$\mu_R : X_1 \times X_2 \times X_3 \dots \times X_n \rightarrow [0,1] \quad (3-7)$$

$$R = \{((x_1, x_2, \dots, x_n), \mu_R(x_1, x_2, \dots, x_n)) \mid (x_1, x_2, \dots, x_n) \in X_1 \times X_2 \times X_3 \dots \times X_n, \mu_R \geq 0\} \quad (3-8)$$

3.2.5 Fuzzy lingvističke promenljive

Koncept lingvističkih varijabli je uveo Zadeh (1973) da bi omogućio bazu za približno rasuđivanje. Lingvistička varijabla je definisana kao varijabla čije su vrednosti reči ili rečenice. Na primer, *godine* mogu da budu lingvistička varijabla ako su njene vrednosti lingvističke, a ne brojevi: mlad, vrlo mlad, star, vrlo star itd. umesto 20, 21, 23, 45...

Slika 3.3 ilustruje termin skupa *Godine* izražen preko Gausove metode funkcija pripadnosti. Skup *vrlo mlad* obeležen je plavom bojom, *mlad* zelenom, *srednje godine* crvenom, *star* tirkiznom i *vrlo star* ljubičastom. Kada se uzme neka vrednost npr. *pet godina* vidi se da je ta vrednost u vezi sa skupom *mlad* i *vrlo mla*, što je i logično. Isto važi i za sve druge promenljive. Skup *srednje godine* ima najveći stepen pripadnosti (jedan) za vrednost *pedeset godina*. Stepene pripadnosti ostalih skupova za ovu vrednost jednak je nuli što i opravdava smisao ovih grafika.



Slika 3.3: Ilustracija termina skupa *Godine* preko Gausove funkcije pripadnosti (Kovandžić N., 2020).

Formalnu definiciju, koja se može naći u literaturi (Jovanović 2020) prvi je predložio Zadeh. Matematički zapis lingvističke promenljive glasi:

$$\langle X, \mathcal{L}X, \mathcal{X}, M_X \rangle \quad (3-9)$$

gde su X simboličko ime lingvističke promenljive; $\mathcal{L}X$ skup lingvističkih vrednosti koje promenljiva X može da uzme, a čiji se proizvoljni element označava sa LX ; \mathcal{X} fizički domen na kojem je promenljiva definisana i M_X semantičko pravilo koje svaku lingvističku vrednost LX povezuje sa fuzzy skupom definisanim na fizičkom domenu \mathcal{X} .

Pomoću ovog načina obeležavanja može se dati primer:

- Lingvistička promenljiva *brzina automobila* ima simboličko ime X ;
- $\mathcal{L}X = \{mala, srednja, velika\}$;
- $\mathcal{X} = [0, v_{max}]$, gde je v_{max} maksimalna brzina koju automobil može imati.

3.2.6 Fuzzy kompozicija relacija

Postoje dva ustaljena oblika kompozicija fuzzy relacija i to su tzv. *sup – min* i *sup – product* kompozicija.

Ako su R i S dve fuzzy relacije takve da važi: $R \subseteq X \times Y$ i $S \subseteq Y \times Z$ onda se fuzzy relacija $R \circ S \subseteq X \times Z$ naziva *kompozicijom* i definisana je:

$$\mu_{R \circ S}(x, z) = \sup_{y \in Y} \min(\mu_R(x, y), \mu_S(y, z)) \text{ za sup – min,}$$

$$\mu_{R \circ S}(x, z) = \mu_R(x, y) \cdot \mu_S(y, z) \text{ za sup – product kompoziciju.}$$

Napomena: U slučaju rada sa diskretnim skupovima, umesto supremuma koristi se funkcija maksimuma, pa gornje dve jednačine poprimaju oblik:

$$\mu_{R \circ S}(x, z) = \max_{y \in Y} [\min(\mu_R(x, y), \mu_S(y, z))] \text{ za sup – min,}$$

$$\mu_{R \circ S}(x, z) = \max_{y \in Y} [(\mu_R(x, y) \cdot \mu_S(y, z))] \text{ za sup – product kompoziciju.}$$

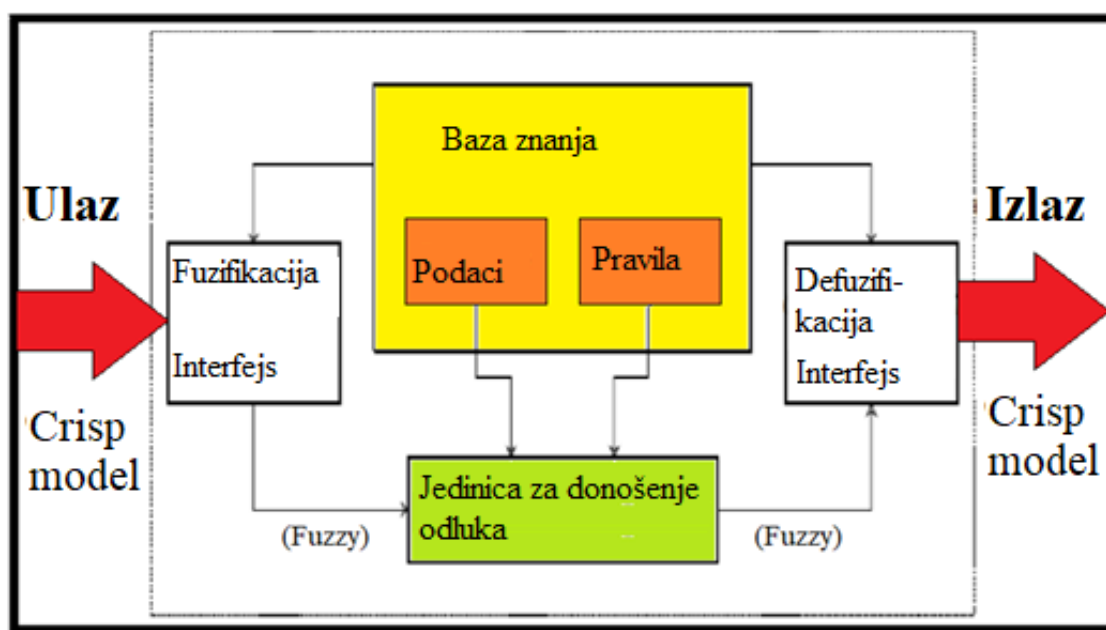
3.2.7 Fuzzy sistemi zaključivanja

Uopšteno govoreći, postoje tri vrste sistema zaključivanja: Mamdani, Sugeno i Takagi model. Razlika između njih ogleda se u rezultatima koje daju specifična pravila kao i u rezultatima nastalim kombinacijom i procesima defuzzyfikacije. Prvi tip je Takagi model, drugi Mamdani i treći tip je Sugeno model. Osnovna razlika između modela Sugano i ostala dva je u izlaznim vrednostima funkcija pripadnosti koje su linearne ili fiksne (Kaur and Kaur, 2012).

Razumljivo, da bi se proces proizvodnje planski sproveo, veoma su važni procena rezervi i računanje preostalih količina nafte, posedovanje dovoljno informacija o bušotini, kao i poznavanje fizičkih i hemijskih karakteristika bušačeg fluida i njegovog ponašanja u različitim sredinskim uslovima (Lababidi i sar., 2004).

Odskora, tzv. pametne metode, pogotovo fuzzy sistemi, su jasno pokazali visok stepen sposobnosti za predviđanje i procenu osobina rezervoara nafte. Takođe, primena metode fuzzy sistema u drugim oblastima petrohemijske, pogotovo petrofizike, je pokazala da uprkos visokom stepenu anizotropije i manjka uniformnosti stena u horizontalnom i vertikalnom pravcu, može dati dobre i pouzdane predikcije za permeabilnost ili neke druge parametre. Dakle, može se zaključiti da fuzzy sistemi mogu biti vrlo korisno oruđe petrohemijskom inženjeru, u vreme kada dostupna interpretirana informacija nije dovoljna (Mendel i sar., 2014; Lababidi i sar., 2004).

Fuzzy tip zaključivanja je proces formiranja spona između ulaznih i izlaznih podataka, posredstvom fuzzy logike. Osnove fuzzy sistema zaključivanja čine tri komponente: pretpostavke, fuzzy pravila i zaključivanje. Fuzzy sistemi koriste se u mnogim oblastima: uspostavljanje automatizovane kontrole, kategorizacija podataka, analiza, napredni sistemi, predikcije, robotika i prepoznavanje šablona. Fuzzy system zaključivanja se sastoji iz pet koraka (Foroozandeh i sar., 2018; Nikam i sar., 2012), kao što prikazuje slika 3.4.



Slika 3.4: Koraci u fuzzy sistemu zaključivanja (Foroozandeh i sar., 2018)

3.2.8 Fuzzyfikacija

Ulazne vrednosti u ovom sistemu mogu da budu numeričke vrednosti, kontinualne funkcije ili funkcije pripadnosti. Ako je u pitanju broj, stepen pripadnosti svake od postojećih vrednosti fuzzy skupu se određuje na osnovu njene funkcije pripadnosti.

U fuzzyifikaciji, ulazna vrednost je uvek broj u naznačenom opsegu za tu lingvističku varijablu, a izlazna vrednost je fuzzy stepen pripadnosti u fuzzy skupu (lingvističkog karaktera) i uvek je između nula i jedan. U ovom stadijumu se sva pravila paralelno implementiraju (Kayacan and Ahmadih Khanesar 2016; Ross Timothy, 2005).

3.2.9 Primena fuzzy operatora i metoda zaključivanja

Nakon ulaznih fuzzy vrednosti, u svakoj klauzuli pravila je određen stepen pripadnosti. Ako postoji više nego jedan kondicionalni deo, fuzzy operater konvertuje ove fuzzy vrednosti u jedan konkretan broj koji zamenjuje čitavu ako-onda postavku. Pre nego što se primeni metoda rasuđivanja, potrebno je odrediti vrednost premise svakog pravila. Svako pravilo ima svoj stepen pripadnosti (broj između nula i jedan) koji se primenjuje na broj dobijen iz druge faze. Ova vrednost je najčešće jedan i zbog toga ne utiče na ukupan proces rasuđivanja.

Rezultat koji daje svako pravilo formira fuzzy skup. Zato se funkcija pripadnosti grupe rezultata modifikuje primenom broja dobijenog iz kondicionalnog dela (broj dobijen u drugom koraku). Shodno tome, ulazna vrednost metode argumenta jednog od uslovnih delova i njene izlazne vrednosti čini fuzzy skup (transformacija funkcije pripadnosti grupacije rezultata u pravilu). Za primenu ove metode se koriste različite operacije (Foroozandeh i sar., 2018; Nikam i sar., 2012).

3.2.10 Kombinovanje izlaznih vrednosti

Obzirom da se evaluacija fuzzy pravila određuje na osnovu ispitivanja svih fuzzy pravila, za donošenje odluke ove je rezultate potrebno kombinovati sa određenim metodama. Prirodno je da ukoliko neko pravilo nije aktivno ono nema stepen aktivacije, tj. da ima nula stepen aktivacije. Ovaj stepen predstavlja pandan stepenu pripadnosti, u smislu da pokazuje u kojoj meri je neko pravilo aktivno pri odlučivanju. Što je ovaj stepen manji to je manji značaj pravila na ukupni rezultat zaključivanja.

Proces u kome se objedinjuju svi skupovi svih rezultata zajedno, da bi se dobio fuzzy skup naziva se slaganje. Ima primenu samo jednom na izlazne vrednosti svake varijable. Izlazne vrednosti za svaku od jezičkih vrednosti su takođe fuzzy skup. Prilikom zaključivanja mogu se desiti različite kombinacije: postojanje samo jednog pravila i premise; postojanje jednog pravila ali sa više premisa ili postojanje mnogo pravila i mnogo premisa. Zavisno od slučaja evaluacija pravila se vrši na različite načine pri čemu je najviše u upotrebi Mamdanijeva metoda.

3.2.11 Defuzzyfikacija

Predstavlja metod konvertovanja fuzzy skupa u broj. Ulazne vrednosti procesa defuzzyfikuju su fuzzy skupovi, a izlazne brojevi (Kayacan and Ahmadiéh Khanesar 2016; Ross Timothy, 2005, Nikam i sar., 2012). Neke od najpoznatijih metoda defuzzyfikacije su: metoda težišta, metoda centra suma i metoda maksimalne visine (Banjanović-Mehmedović 2020).

3.3 Neuronske mreže

U ovom odeljku će biti okarakterisane osobine neuronskih mreža i ovaj pojam će biti detaljnije objašnjen. Pre svega, biće opisani pojam predikcije, biće dat model neurona i arhitektura neuronskih mreža. Nakon toga, biće objašnjena prenosna funkcija, razlika između online i offline obučavanja neuronskih mreža i zakoni učenja. Takođe, adaptivne mreže će biti date kao primer neuronskih mreža sa povratnim postupkom i hibridnih algoritama učenja.

3.3.1 Pojam i definicija neuronskih mreža

Navigacija, prepoznavanje oblika, prevođenje teksta u realnom vremenu, komponovanje muzike...samo su neke od primena neuronskih mreža. Iako neuronske mreže (i ove inženjerske aplikacije generalno) predstavljaju samo podskup dubokog učenja, koje je opet samo deo oblasti mašinskog učenja, sve one se zasnivaju na građi ljudskog mozga. Uzimajući strukturu koja je inspirisana biološkim algoritmom i neki obučavajući skup podataka (*data set*) na ulazu, one se obučavaju tako da prepoznaju šablone i daju izlaze. Ulazni i izlazni podaci mogu biti i diskretni i kontinualni.

Neuronske mreže se sastoje od slojeva (*layers*) u kojima su smešteni neuroni. Upravo ovi neuroni predstavljaju procesne jedinice mreže. Ako bi se neuron posmatrao čisto matematički, iz njegovog biološkog modela bi se lako moglo zaključiti da je on specifična jedinica za nelinearno preslikavanje ulaznih u izlazne veličine. Procvat neuronskih mreža dogodio se relativno nedavno, pre svega zbog povećanja snaga računara koje su omogućile kreiranje i razvijanje različitih biblioteka za implementaciju algoritama u borbi sa složenim problemima. Neki od najčešćih problema koji se mogu javiti su:

- Preveliki broj faktora u bazama koji su u većoj ili manjoj meri povezani sa izlaznom veličinom. Što je veći broj ovih podataka to će mreža zahtevati više vremena za rad i obučavanje i biće teže vizualizovati ulazni skup obučavajućih podataka za kasniji rad.
- Obučavajući skupovi ili baze podataka sadrže veliki broj grešaka ili podataka koji nedostaju
- Jako teško razumevanje (matematičkog) modela koji se dobija primenom neuronskih mreža

Nakon što je obučavanje (treniranje) završeno ukoliko su obučavanje i validacija zadovoljavajući jedan od sledećih koraka je predviđanje izlaza korišćenjem novih ulaznih podataka, na kojima mreža nije obučavana.


3.3.2 Pojam predikcije

Kod predviđanja suštinski se prosleđuju neupareni test podaci s modela u cilju da će neuronska mreža predvideti izlaz. Ova predviđanja zavise od onoga što je model *naučio* za vreme treninga. Tako se može utvrditi koliko je model pouzdan u određivanju izlaza koje nije bio dat kao rešenja u procesu obučavanja. Na isti način, može se dobiti uvid u ono šta je model naučio, kako je bio istreniran, da li su validacija i estimacija dobro odrađene. Npr. kada bi se mreža obučavala da prepozna i sortira velike objekte, a testrala na malim malo je verovatno da bi ona dala dobre rezultate, jer je uopšteno obučavana na podacima koji u ovom slučaju ne bi bili slični sa test podacima. U ovim modelima, zavisno od veličine baze, i jedan skriveni sloj može biti dovoljan. Komplikovaniji model ne mora značiti bolje rezultate u predviđanju rezultata izlazne veličine.

Četiri velike oblasti u kojima je često primenjivana predikcija korišćenjem veštačkih neuronskih mreža su: energetske sistemi (potrošnja energije, obnovljivi sistemi...), finansije (trgovina, berza...), turizam i društvene mreže. Ove oblasti su jako pogodne iz dva razloga: velika dostupnost baza podataka i potreba za predikcijom ishoda određenih radnji u ovim sferama.


3.3.3 Modeli neurona i arhitektura mreže

Neuron je specijalizovana nervna ćelija organizma sa električnom aktivnošću. Ove ćelije su usmerene ka operacijama upravljanja organizmom. Šema neurona je prikazana na slici 3.5 Neuron se sastoji iz tela koje je okruženo membranom. Ima dendrite i akson, koji predstavljaju ulazna i izlazna mesta signala. Akson jednog neurona formira sinaptički kontakt (sinapsu) sa dendritom drugog neurona.



Slika 3.5: Šema biološkog neurona (Simonović B., 2016)

Kao što je prikazano na slici 3.5, ulazni signali dendritskog stabla se sakupljaju u telu neurona, a informacija za izlazni signal se kreira u aksonima. Intenzitet signala je posledično rezultat sume ulaznih signala. Izlazni signal se kreće kroz razgranate aksonske grane i dolazi do sinapse. Preko sinapsi, signal se transformiše u novi ulazni signal susednog neurona. Ulazni signal može da bude pozitivan ili negativan (ekscitirajući ili inhibirajući), u zavisnosti od sinapse (Aliev 2001). U skladu sa biološkim modelom, predloženo je više matematičkih modela. Matematički model neurona koji se najčešće koristi simulacijom kroz neuronske mreže, prikazan je na slici 3.6.



Slika 3.6: Matematički neuron (Simonović B., 2016)


Objašnjenje slike 3.6 je jednostavno: neuron prima skup ulaznih signala x_1, x_2, \dots, x_n (vektor X) koji predstavljaju izlazne signale susednih neurona. Svaki ulazni signal je pomnožen sa odgovarajućom jačinom konekcije (težinski faktor w) analogno sa efikasnošću sinapse. Jačina ulaznih signala se sumira u modulu koji odgovara telu neurona, gde se vrši zbir jačine signala i određuje nivo ekscitiranja neurona:

$$I = \sum_{i=1}^n x_i w_i \quad (3-10)$$

Izlazni signal neurona se određuje proverom nivoa ekscitovanja neurona preko funkcije f , nazvane funkcija aktivacije, o kojoj će biti više reči u narednom podpoglavlju i koja je prikazana sledećom jednačinom:

$$y = f(I) \quad (3-11)$$

Ukupan broj neurona koji su povezani jedni sa drugima i sa spoljašnjom okolinom, čine neuronsku mrežu. Slika 3.7 prikazuje osnovu strukture neuronske mreže. Ulazni vektor stiže do mreže aktivirajući ulazne neurone.



Slika 3.7: Osnovna struktura neuronske mreže (Simonović B., 2016)

Skup ulaznih signala u neuronsku mrežu se naziva vektor ulazne aktivacije. Težinski faktor neuronske mreže se predstavlja u formi matrice W , element w_{ij} , gde se jačina povezanosti gleda između i -tog i j -tog neurona. Tokom rada mreže, ulazni vektor se transformiše u izlazni, što znači da se odigrao prenos informacije. Stoga, računarska jačina mreže rešava probleme sa svojim spojevima. Spojevi povezuju ulazni signal jednog neurona i izlazni signal sa drugim neuronom. Jačina spone (povezanosti) se meri preko njenog koeficijenta. Neuronske mreže imaju sklonost da tretiraju neuron kao protivtežu. Ova funkcija ima ulogu da obezbedi prag za aktivaciju svih neurona unutar mreže.

Neuronske mreže, prema svojoj strukturi, mogu da se podele na dva tipa: nepovratne i povratne. Nepovratne mreže ne dobijaju povratnu informaciju tokom svog delovanja. U ovom tipu mreža, neuroni j -tog sloja primaju signale iz spoljašnje sredine (kada je $j=1$) ili od neurona iz prethodnog ($j-1$)-tog sloja kada je ($j>1$) i prosleđuju izlazne signale neuronima susednog ($j+1$)-tog sloja ili u spoljašnju sredinu (kada je j poslednji sloj).

Nepovratne mreže mogu da budu jednoslojne ili višeslojne. Višeslojna mreža se sastoji od ulaznog, izlaznog i skrivenog sloja. Upotreba skrivenih slojeva dobronosi većoj jačini sistema mreže. Biranjem najbolje strukture mreže, povećava se pođdanost i računarska snaga, a smanjuje vreme potrebno za obradu.

Percepcija u više slojeva (MLP), adaptivne mreže, funkcija radijalne osnove neuronskih mreža (RBFNN), mreža kvantizacije vektora za učenje (LVQ) i mreža grupne metode obrade podataka (GMDH) su primeri nepovratnih mreža (Bulsari A.B. 1995). Povratne neuronske mreže (RNN) imaju sličnu strukturu standardnih nepovratnih mreža sa slojevima povezanim preko težinskog faktora nepovratne konekcije, ali uključuju i odloženu povratnu informaciju ili povratnu konekciju u svojoj arhitekturi (Himmelblau 2000). Važna prednost RNN je sposobnost približavanja kontinualnom ili diskretnom nelinearnom dinamičkom sistemu preko neuronske

dinamike definisane sistemom nelinearnih diferencijalnih jednačina. Ovo predstavlja sjajnu priliku i opravdanje za korišćenje upravo ovih mreža u problemima adaptivne kontrole. Primeri RNN su Hopfield, Elman i Jordan mreža.


3.3.4 Funkcija aktivacije

Kao što se vidi sa slike 3.8 izlaz iz neurona se dobija nakon preslikavanja koje se odvija preko aktivacione funkcije. Iako dobijena veličina predstavlja izlaz iz neurona, ona može i ne mora biti izlaz iz cele neuronske mreže. Ukoliko dobijeno y nije izlaz iz cele mreže, onda ova veličina predstavlja ulaz u sledeći neuron (neuron u sledećem sloju). Uslov koji aktivaciona funkcija mora da ispunjava jeste da ona bude u delovima neprekidna. Njena ograničenost nije ograničavajući faktor, pa tako ona može biti i ograničena ili neograničena. Pregled nekih od najpoznatijih aktivacionih funkcija dat je u narednom tekstu.

Linearna funkcija:

$$y = k I, k = \text{konstanta} \quad (3-12)$$

Kako je ova funkcija neograničena i rastuća i kako kada se konstantu k odabere broj jedan, onda će i gradijent ove funkcije takođe biti jednak k odnosno jedan. Zbog ove osobine linearna aktivaciona funkcija se često koristi u neuronskim mrežama. Grafik zavisnosti aktivacione funkcije od ulaza I u slučaju kada je konstanta $k = 1$ prikazan je na sledećoj slici 3.8, gde se jasno vide osobine o kojima je malopre bilo reči.



Slika 3.8: Linearna aktivaciona funkcija

Binarna (granična) funkcija:


$$y = \begin{cases} 1, & \text{za } I \geq 0 \\ 0, & \text{za } I \leq 0 \end{cases} \quad (3-13)$$

Naziva se još i odskočna, Hevisajdova funkcija. U zavisnosti od toga da li se u njoj javlja kontinualni skok ili prekid, može se raditi i o matematičkoj funkciji tipa znaka $sign()$ odnosno $sgn()$. Ovako prikazana granična funkcija smatra se unipolarnom, ali u slučaju da je druga vrednost koju ova funkcija daje na izlazu jednaka -1, tada se kaže da je aktivaciona funkcija bipolarna.

Sigmoidalna funkcija:

$$y = \frac{1}{1+e^{-\lambda(I)}} \quad (3-14)$$

Slično graničnoj funkciji i sigmoidalna funkcija se može razvrstati na funkciju unipolarnog i funkciju bipolarnog tipa. U literaturi se za unipolarnu funkciju može još naći i termin logistička funkcija, dok se naziv hiperbolički tangens koristi za obeležavanje bipolarne sigmoidalne funkcije. Na slici 3.9 prikazan je prvi tip, logistička aktivaciona funkcija. Treba obratiti pažnju na parametar λ . Pored toga što je on uvek pozitivan i što je veći to je nagib ove aktivacione funkcije strmiji. Kada bi težio beskonačnosti sigmoidalna funkcija bi se pretvorila u graničnu aktivacionu funkciju, što se vidi sa slike 3.9.



Slika 3.9: Sigmoidalna aktivaciona funkcija

3.3.5 Proces učenja u neuronskim mrežama

Uopšteno, učenje je proces gde se neuronska mreža adaptira na stimulse i kao rezultat daje željeni odgovor tokom procesa učenja, mreža prilagođava svoje parametre, jačinu sinaptičke povezanosti, kao odgovor na ulazne stimulse tako da njen odgovor konvergira željenom izlaznom odgovoru. Kada je stvarni izlazni signal jednak željenom, smatra se da je mreža uspešno završila proces učenja.

Pravila učenja su opisana matematičkim izrazima koje nazivamo jednačine za učenje. Neuronu u neuronskim mrežama mogu biti međusobno povezani na različite načine. Različite metode učenja odgovaraju različitim neuronskim mrežama (Kartalopoulos 1996). Postoje dve kategorije učenja neuronskih mreža, nadgledano i nenadgledano učenje.

Kod nadgledanog učenja, dostupni su i ulazni signali i dati odgovor i željeni odgovor, te se to koristi za određivanje stope grešaka. Ako se dati odgovor razlikuje od željenog, neuronska mreža stvara signal da se desila greška koji se onda koristi za prilagođavanja koja treba uvesti u jačinu mreže, tako da dati izlazni odgovor zapravo odgovara željenom (Jain 1997).

Nadgledano učenje se može izvesti na dva načina tj. U dva različita režima online i offline modu.

Online učenje

Online metoda učenja je važna zbog online identifikacije parametara za sisteme promenljivih karakteristika. Mreža se obučava paralelno sa radom sistema i podešava svoje parametre tako da se prilagodi novim uslovima. Gradijent opadanja se zasniva na E_p u ovoj metodi, umesto na E . Faktor zaboravljanja je dodat originalnoj sekvencijalnoj jednačini da bi se smanjio efekat starih parova podataka, dok novi ne postanu dostupni. Ovaj pristup dodeljuje više faktore skorijim parovima podataka i zbog toga su uračunati i vremenski karakteri. Originalna sekvencijalna formula za online učenje glasi:

$$X_{i+1} = X_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T X_i) \quad (3-15)$$

$$S_{i+1} = \frac{1}{\lambda} \left[S_i - \frac{S_i a_i a_{i+1}^T S_i}{\lambda + a_{i+1}^T S_i a_{i+1}} \right] \quad (3-16)$$

gde je λ između nula i jedan. Što je λ manje, brži je efekat raspadanja starih podataka. Zbog ovog načina rada za mreže koje su obučavane u online režimu rada se kaže da su dinamičke.

Offline učenje

Pravilo hibridnog učenja kombinuje metodu gradijenta i najmanje kvadratne pretpostavke (LSE) za identifikaciju parametara. Pretpostavljajući da adaptivna mreža ima samo jedan ulazni signal, izlazni može da se predstavi na sledeći način:

$$\text{output} = F(I, S) \quad (3-17)$$

I je skup ulaznih varijabli, a S skup parametara. "Ako postoji funkcija H takva da je funkcija $H \circ F$ linearna sa nekim od elemenata iz S, ovi elementi onda mogu da se identifikuju preko najmanje kvadratne pretpostavke." (Jang 1993). Pošto skup parametara S može da se razloži u dva podskupa: S_1 i S_2 takve da je $H \circ F$ linearna u elementima iz S_2 . Kada uvrstimo H u jednačinu (3-17) dobija se sledeće:

$$\text{output} = H \circ F(I, S) \quad (3-18)$$

Dobijene vrednosti elemenata iz $S_{1,P}$ skupa podataka za treniranje se uvrste u jednačinu (3-17) i dobija se jednačina matrica:

$$AX = B \quad (3-19)$$

X je nepoznati vektor čiji su elementi parametri u S_2 . Pošto je broj parova skupova podataka za treniranje uglavnom veći od broja lineranih parametara, ovo je pre-determinisan problem i ne postoji tačno rešenje za jednačinu (3-19). Da bi se ovaj problem rešio, Jang je predložio sekvencijalni model. Prema ovoj metodi, X se računa učestalo preko sekvencijalnih formula:

$$X_{i+1} = X_i + S_{i+1}a_{i+1}(b_{i+1}^T - a_{i+1}^T X_i) \quad (3-20)$$

$$S_{i+1} = S_i - \frac{S_i a_i a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}}, \quad i = 0, 1, \dots, P - 1 \quad (3-21)$$

U jednačini a_i^T predstavlja i-ti vektor matrice A definisanog u jednačini (3-19), a b_i^T je i th element od B. S_i se naziva matrica kovarijanse. Svaka epoha u procesu hibridnog učenja se sastoji iz prosleđivanja podataka unapred i unazad. Tokom prosleđivanja unapred, ulazni podaci i funkcionalni signali se kreću unapred i imaju za cilj da izračunaju izlazne vrednosti svakog čvora dok se matrice A i B iz jednačine (3-19) ne izračunaju. Nakon toga, parametri u S_2 se mogu identifikovati preko formule uzastopno najmanjih kvadrata. Posle identifikacije parametara u S_2 funkcionalni signali se i dalje kreću napred sve dok se ne izračuna mera greške.

Kod prosleđivanja unazad, stopa greške se širi od izlaznog ka ulaznom kraju, a parametri u S_1 se ažuriraju preko metode gradijenta (jednačina 3-18). Offline tip učenja nije dinamički jer se nakon učenja struktura mreže ne menja i ostaje ista, tj. jednom obučena mreža se pušta da radi uvek na isti način.

Za razliku od nadgledanog učenja, kod nenadgledanog učenja ne postoji željeni izlazni odgovor. Tokom perioda treniranja, mreža prima ulazne signale sa mnogo različitih ulaznih šablona i proizvoljno ih organizuje u kategorije. Kasnije kada se pojavi stimulus, mreža daje izlazni odgovor na osnovu klase kojoj stimulus pripada. Ukoliko za određeni stimulus ne postoji poznata klasa, generiše se nova. Ovakav tip učenja se nekada naziva i samoorganizovano učenje.

3.3.6 Propagacija (prostiranje) greške i zakon učenja

Algoritam sa povratnim postupkom (Rumelhart i sar. 1986) je osnova mehanizama učenja i vrlo je popularna u literaturi. U ovom algoritmu pri pojavljivanju ulaznog signala, izlazni signal mreže se poredi sa željenim izlaznim rešenjem i stepenom greške koji se javlja. Ovaj stepen greške se onda koristi za modifikaciju faktora težine u sistemu matrice, da bi se naposljetku smanjio stepen greške. Praćenjem velikog broja informacija iz podataka za trening, očekuje se da ukupna greška sistema počne da se smanjuje do prihvatljivog nivoa, jer je mreža naučila kako da reši problem na osnovu informacija dobijenih na treningu.

Primer algoritma sa povratnim postupkom učenja (povratnim prostiranjem greške) će biti objašnjen u narednom tekstu.


Algoritam za učenje je matematička alatka koja ocrtava metodologiju i brzinu neuronskih mreža da uspešno dostigne stabilno stanje sa svojim parametrima, faktorom težine (jačina povezanosti) i graničnim vrednostima. Cilj je da se minimalizuju greške u jačini povezanosti mreže.

Kada je funkcija greške nula, ili dovoljno niska, onda se smatra da je stabilno stanje između mreže i njenih parametara postignuto. Tokom procesa učenja, funkcija greške se smanjuje i faktor težine ažurira. Smanjenje stope greške može biti postignuto različitim tehnikama optimizacije kao što su Delta pravilo, Bolcmanov algoritam, algoritam sa povratnim postupkom učenja i simulacija stapanja. Biranje funkcije greške i optimizacione metode je važno, jer povećava stabilnost, nestabilnost ili zaglavljivanje rešenja u lokalnom minimumu.

3.3.7 Adaptivne mreže

Adaptivne mreže (slika 3.10) su primer višeslojnih nepovratnih neuronskih mreža u kojima svaki čvor obavlja određenu funkciju (funkcija čvora) za dolazeće signale, kao i za skup parametara vezanih za taj čvor. Formule za funkcije čvorova variraju između njih i izbor funkcije svakog čvora zavisi od ukupnih ulazno-izlaznih funkcija koje adaptivna mreža treba da iznese. Veze u adaptivnoj mreži jedino ukazuju na pravac signala među čvorovima. Faktor težine (jačina veze) nije povezan sa čvorovima (Jang 1993).

Osnovno pravilo učenja adaptivnih mreža je i algoritam sa povratnim postupkom učenja. Međutim, obzirom da je dosta sporo i često zarobljeno u lokalnom minimumu, 1993. od strane Janga predloženo je hibridno pravilo algoritma za učenje sa ciljem da ga ubrza.



Slika 3.10: Adaptivna mreža

3.3.8 Algoritam povratnog postupka učenja u adaptivnim mrežama

Pretpostavićemo da adaptivna mreža u slici 3.10 ima N slojeva. (j,i) je čvor na i -toj poziciji j -tog sloja, a $O_{j,i}$ predstavlja izlazni signal čvora. Obzirom da izlazni signal čvora zavisi od dolazećeg signala i njegovog skupa parametara, može da se definiše na sledeći način:

$$O_{j,i} = f_{j,i}(O_i^{j-1}, \dots, O_{\#(j-1)}, a, b, c \dots \dots) \quad (3-22)$$

a, b, c su parametri koji se odnose na ovaj čvor, a f je funkcija čvora. Ako pretpostavimo da podaci za trening imaju P ulaznih signala, stopa greške može da se definiše za $(1 \leq p \leq P)$ broj ulaznih signala u grupi podataka za trening, kao suma kvadrata grešaka:

$$E_p = \sum_{k=1}^{\#N} (d_k - O_{N,k})^2 \quad (3-23)$$

d_k je k -ta komponenta p -tog ciljnog vektora, a $O_{N,k}$ je k -ta komponenta stvarnog izlaznog vektora koji se javlja uvođenjem p -tog ulaznog vektora. Stoga, ukupna greška sistema merenja može da se izrazi kao:

$$E = \sum_{p=1}^P E_p \quad (3-24)$$

Kada je E_p jednako nuli, mreža je u stanju da izvede identičan željeni izlazni vektor u p -th paru podataka za trening. Cilj je minimizirati ukupnu vrednost izmerene greške. Prvi izvod greške

$E_{\partial p O \partial}$ za p -th podatke treninga i za izlaznu vrednost svakog čvora treba da se izračuna. Izvod greške za izlazni čvor u N sloju se računa na sledeći način:

$$\frac{\partial E_p}{\partial O_{i,p}^N} = -2(d_{i,p} - O_{i,p}^N) \quad (3-25)$$

Za unutrašnji čvor na i -toj poziciji j sloja, izvod greške može da se izvede preko lanca komandi diferencijalnom računicom:

$$\frac{\partial E_p}{\partial O_{i,p}^j} = \sum_{k=1}^{\#j+1} \frac{\partial E_p}{\partial O_{k,p}^{j+1}} \frac{\partial O_{k,p}^{j+1}}{\partial O_{i,p}^j} \quad (3-26)$$

gde je ($1 \leq j \leq N-1$). Izvod greške unutrašnjeg čvora na sloju j može da se predstavi kao linearna kombinacija izvoda greške sloja $j+1$. Stoga, za sve $1 \leq j \leq N$ i $1 \leq i \leq \#(j)$ stopa greške može da se izračuna preko jednačina (3-25) i (3-26). Ovo se naziva procedura sa povratnim postupkom jer se izvod greške dobija sinhrono od izlaznog sloja nazad ka ulaznom sloju. Vektor gradijenta se definiše kao parcijalni izvod greške celokupnog merenja u odnosu na α i jednak je:

$$\frac{\partial E_p}{\partial \alpha} = \sum_{O^* \in S} \frac{\partial E_p}{\partial O^*} \frac{\partial O^*}{\partial \alpha} \quad (3-27)$$

S je skup čvorova čiji izlazni signali zavise od α . Parcijalni izvod ukupne greške E u odnosu na α je:

$$\frac{\partial E}{\partial \alpha} = \sum_{p=1}^P \frac{\partial E_p}{\partial \alpha} \quad (3-28)$$

Prema metodi najbržeg spusta ili najstrmijeg pada, unapređena formula za generički parametar α je:

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (3-29)$$

gde η stopa učenja, koja dalje može da se predstavi kao:

$$\eta = \frac{k}{\sqrt{\sum_{\alpha} \frac{\partial E^2}{\partial \alpha}}} \quad (3-30)$$

Ovde k označava "veličinu koraka" odnosno dužinu svake promene u prostoru parametra. Uočeno je da ako je k malo, metoda gradijenta će biti vrlo približna putanji gradijenta, ali proces približavanja će biti spor jer se gradijent mora preračunati više puta. Sa druge strane, ako je k

visoko, proces približavanja će u početku biti brz, ali će algoritam oscilirati oko optimuma. Iz ovog razloga, predloženo je da ako mera greške pretrpi četiri uzastopna smanjenja, k treba da se poveća za 10%. Ako mera greške pretrpi dve uzastopne kombinacije jednog povećanja i jednog smanjenja, k treba da se smanji za 10% (Jang 1993).

U offline učenju, unapređena formula za generički parametar α se zasniva na jednačini (3-29) i unapređivanje se dešava tek kada se čitav skup podataka za trening predstavi npr. posle svake epohe. Sa druge strane, parametri se unapređuju momentalno nakon što se javi svaki ulazno-izlazni par u online učenju, a unapređena formula se bazira na jednačini (3-30) (Castillo and Melin 2001).

3.4 Mogućnost stvaranja neuro-fuzzy sistema

Neuro-fuzzy sistemi se koriste u oblasti kontrolnih sistema i analize podataka. Vrlo su korisna i efikasna alatka pri radu sa kompleksnim sistemima. Ovi sistemi koriste informacije i lingvističke i numeričke prirode. Postoji više načina da se kombinuju neuronske mreže i fuzzy sistemi. Generalno, postoji klasifikacija neuro-fuzzy sistema u tri tipa, u zavisnosti od toga kako mreže funkcionišu sa fuzzy sistemima: konkurentni, kooperativni i hibridni neuro – fuzzy sistemi. (Agin i sar. 2018; Sabah i sar. 2019).

3.4.1 Neuro – fuzzy modeliranje i upravljanje

Fuzzy-neuronska tehnika postoji zahvaljujući kombinaciji tehnika neuronskih mreža i fuzzy logike koja se naziva adaptivni neuro-fuzzy sistem zaključivanja (ANFIS). Kao glavne alatke za rešavanje problema vezanih za računarsku inteligenciju koriste se obeležja tj. karakteristike objekta. Karakteristike koje su bitnije imaće više neurona u mreži, odnosno veći stepen pripadnosti u fuzzy logici. Godine 1993. Jung je kombinovao ove dve tehnike uzimajući najbolje od obe, te tako uveo u priču pomenuti sistem. Prednost obeležja je u tome što poznaje lingvistiku fuzzy logike, ima sposobnost unapređenja neuronskih mreža i samoučenja.

Cilj je kreirati odgovarajući sistem za implementaciju fuzzy sistema kod prikazivanja podataka informativnih metoda, te sposobnost neuronske mreže da usmeri učenje podataka radi prilagođavanja parametara funkcija pripadnosti i povećanja performansi sistema.

Adaptivni neuro-fuzzy system zaključivanja je poseban tip fuzzy sistema zaključivanja koji je baziran na Sugeno modelu. Postoje i različite modifikacije ANFIS modela kao što je npr. M – ANFIS (eng. Mamdani Model based Adaptive Neural Fuzzy Inference System) baziran na Mamdanijevoj metodi zaključivanja. U ovom sistemu, parametri njegove pripadnosti su modelovani na osnovu metoda propagacije ili zajedno sa metodom najmanjih kvadrata. Takođe, postoje i različite modifikacije ANFIS mreže sa drugim metodama za fitovanje.


Ovaj sistem ima sledeće karakteristike:

- Sistem je prvog ili nultog reda
- samo jedna ulazna i sve izlazne funkcije pripadnosti moraju biti istog tipa linearne ili konstantne
- različita fuzzy pravila ne mogu da imaju iste funkcije pripadnosti za izlazne vrednosti
- broj izlaznih funkcija pripadnosti mora biti jednak broju pravila.

Da bi se pojednostavio opis strukture infiltracije, fuzzy sistem zaključivanja je objašnjen primenom dve ulazne vrednosti i jedne izlazne. Pravila ako-onda za fuzzy Takagi Sugeno se izražavaju na sledeći način:

ako X odgovara A, a Y je B, onda je Z f(X,Y)

A i B su primitivni fuzzy skupovi, dok je Z definisana konačna funkcija. Uopšteno, Z je generički skup varijabli za X i Y, ali takođe može da bude neka druga funkcija koja opisuje približne izlazne vrednosti fuzzy sistema. Kada Z ima konstantnu vrednost, formira se Sugeno-fuzzy nulti model, koji se smatra posebnom vrstom Mamdani fuzzy sistema zaključivanja. ANFIS struktura sa dve ulazne vrednosti je prikazana na slici 3.11 (Sabah i sar. 2019, Abdelgawad i sar., 2019).



Slika 3.11: ANFIS struktura sa dve ulazne vrednosti x_1 , x_2 i jednom izlaznom vrednošću, f

3.4.2 Pojam optimizacije

Cilj optimizacije se svodi na nalaženje argumenata pri kojima neka funkcija ima ekstremne vrednosti (maksimalne ili minimalne). Uopšteni problemi optimizacije umeju biti jako teški za efikasno rešavanje pre svega zbog visoke nelinearnosti i velikog broja lokalnih minimuma. U potrazi za globalnim minimumom istraživači se sreću sa različitim problemima: od prevelike brzine konvergencije algoritma do zapadanja i zaglavljivanja u lokalnim minimumima. Klasične metode mogu potpuno podbaciti u rešavanju ovog zadatka ili uspeti da ih reše ali u jako velikom vremenskom periodu (nekada su u pitanju čak i godine).

Za razliku od metoda linearnog i nelinearnog programiranja, koje prilikom rešavanja problema optimizacije daju tačna rešenja, heuristički i metaheuristički metodi daju neprecizna, odnosno rešenja koja se samo nalaze u okolini optimalnog rešenja. U navedenim modelima težnja za brzim rešenjem smanjuje nivo kvaliteta postupka optimizacije. Kvalitet ponekad može biti narušen u cilju brzog dobijanja rešenja. Iako rade na sličnom principu postoje i uočljive razlike između heurističkih i metaheurističkih metoda i algoritama.

Priroda heurističkih metoda određena je nizom uzoraka tj. za nju se kaže da je deterministička. Metaheuristika, sa druge strane, podrazumeva nasumično razvrstavanje ili tzv. randomizaciju u spoju sa heuristikom. Obe metode su iterativnog tipa pri čemu je metaheuristika okrenuta algoritmima inspirisani prirodom. Primeri za metaheurističke algoritme koji uključuju nasumično razvrstavanje su genetski algoritam (GA), rojevi čestica (PSO), kolonija mrava (ACO),

ponašanje sivih vukova (GWO), kitova (WOA), kao i mnogih drugih životinja i pojava u prirodi. Metaheuristika kao vrsta algoritama za globalnu optimizaciju se pokazala kao jako efikasna metoda za rad sa nekonveksnim, nelinearnim i višedimenzionalnim problemima.

U daljem tekstu posebna pažnja se obraća na PSO metaheuristički algoritam (Particle Swarm Optimization).

Optimizacija rojem čestica (Particle swarm optimization – PSO) je metaheuristički algoritam koji oponaša ponašanje roja insekata, jata ptica ili riba u potrazi za hranom. Kako svaka čestica (insekt, ptica ili riba) ima svoj pravac kretanja u potrazi ovaj algoritam omogućava dobru pokrivenost prostora. Međutim, ostali agenti će pratiti onu česticu koja je opazila izvor hrane tako da pored divergencije ovaj algoritam omogućava i konvergenciju ka jedinstvenom rešenju.

Optimizacija rojem čestica se može prikazati sledećim pseudokodom:

Početak

Za

svaku česticu iz roja vrši se slučajna inicijalizacija brzine v_i i pozicije x_i .

Odrediti

kriterijum zaustavljanja (maksimalan broj iteracija, vremensko ograničenje proračuna, minimalna greška...)

Dok se ne ispuni kriterijum zaustavljanja

- Izabрати brojeve r_g i r_p uniformno iz intervala (0,1)
- $v_i = c_v v_i + c_p r_p (p_i - x_i) + c_g r_g (g - x_i)$
- $x_i = v_i + x_i$
- AKO $f(x_i) < f(p_i)$ ONDA $p_i = x_i$
- AKO $f(x_i) < f(g)$ ONDA $g = x_i$

c_v, c_p, c_g su već određeni parametri, koji se mogu i ne moraju menjati tokom rada programa, a promenljive r_g i r_p se biraju u svakoj iteraciji. Takođe, u svakoj iteraciji se ažurira i vrednost vektora p_i i g – trenutne i globalne najbolje pozicije tim redeom. Rešenje je sadržano u vektoru g i ovaj algoritam će se ponavljati do ispunjenja kriterijuma zaustavljanja.

Optimizacija roja čestica je tehnika optimizacije izvedena iz EO [5]: glavne karakteristike su inspiracija prirodom (poput evolucijskih procesa) i mogućnost implementiranja PSO na različite nivoe - od nivoa činioaca (kao problem pretrage u fizičkom svetu) do nivoa rešenja u prostoru. Opisivanje PSO počinje se od drugog bio-inspirisanog grupnog modela ponašanja- optimizacija kolonije mrava, tehnika za kombinatornu optimizaciju inspirisanu ponašanjem mrava. [8]. Optimizacija kolonije mrava je uvedena kao tehnika za kombinatornu optimizaciju (pogledati [7]). Izvor inspiracije za model optimizacije kolonije mrava je njihovo ponašanje tokom traženja hrane. Srž problema ovog ponašanja je indirektna komunikacija između mrava preko hemijskih

feromonskih tragova koja im omogućuje da nađu najkraći put između izvora hrane i njihovog habitata.

Ova karakteristika kolonija mrava je iskorištena za algoritme u cilju rešavanja diskretnih i kontinualnih problema optimizacije, usmeravanja i balansiranja opterećenja u telekomunikaciji, a u skorije vreme u mobilnim i ad - hoc mrežama, kao što su senzorne mreže. Optimizacija roja čestica i optimizacija kolonija mrava imaju neke zajedničke karakteristike. Prednost ovog pristupa je njegova fleksibilnost i prilagodljivost algoritma, te je tekuće poglavlje posvećeno diskusiji na ovu temu.

U PSO definišemo x_k kao vektor sa pozicijom čestice k , v_k je trenutna brzina čestice k i pravac čestice k , p_k (drugim rečima p_k je najbolja pozicija čestice k). Računamo g , indeks čestice koja je našla najbolju poziciju. Definišemo $Q(x)$ kao kvalitet pozicije x . Drugim rečima, Q je ili vrednost objektnih funkcija ili vrednovanje objektnih funkcija u multi-objektnoj optimizaciji.

$$g = \operatorname{argmax}_k Q(p_k) \quad (3-31)$$

Sada pišemo dinamiku brzine u ovoj formi:

$$v_k^{t+1} = [wv_k + \phi_1(p_k - x_k) + \phi_2(p_g - x_k)]_{\text{za vreme } t} \quad (3-32)$$

Jednačina je opis dinamike ubrzanja (a) u $w \in [0,1]$ je inercijalni faktor: čestica teži ka tome da održi pravac. $\phi_1(p_k - x_k)$ je tzv. vektor spoznaje: čestice bi trebalo da se kreću ka najboljoj poziciji u blizini; ϕ_1 je nasumična uniformna varijabla raspoređena između vrednosti $[0,2]$.

$\phi_2(p_g - x_k)$ je socijalni deo dinamike:

Čestica bi trebalo da se kreće ka najboljoj poziciji. Ažuriramo poziciju sa:

$$x_k' = v_k \quad (3-33)$$

Moguće je ubaciti PSO u familiju hibridnih algoritama: u PSO(1) se primenjuju sile na pojedince u evoluiranoj populaciji da bi se došlo do rešenja (kao genetički algoritam) (2) modifikuje se pravac evolucione putanje koristeći intra-individualne interakcije. Na primer, imitacija roja, gde svi idu skoro istom putanjom kao i susedi. Osnova ovih ponašanja je fleksibilnost, robusnost i samoorganizacija. Ove karakteristike su ključne u multi-objektnoj optimizaciji.

Kao što je pomenuto u prethodnom delu, PSO koristi populaciju čestica da traži najbolje zajedničko rešenje predstavljeno pozicijom u prostoru gde svaka lokacija ima "kvalitet" određen ciljnom funkcijom. Svaka čestica k ima trenutnu poziciju, trenutnu brzinu i najbolju poziciju. Takođe, sve ili poneke čestice znaju indeks čestice sa najboljom pozicijom do sad. Pravilo ažuriranja brzine je funkcija privatne informacije i socijalnog uticaja. Naravno, pozicija je funkcija brzine. Prema tome, PSO je dvostruki prirodni algoritam: PSO imitira evolucionu dinamiku i imitacionu dinamiku između pojedinaca.

Generalno gledano, PSO treba da se ubaci u klasifikaciju optimizacionih tehnika. Jedna dimenzija je stepen objektnosti funkcije, a druga dimenzija je linearnost. PSO iz evolucione

optimizacije nasleđuje značajnu indiferenciju u pogledu svojstva stepen - linearnost objektnih funkcija. S ove tačke gledišta, PSO nije klasičan algoritam gradijenta i forma površine objektna funkcije je značajna samo za probleme lokalnog minimuma.

Sada se sagledava opis češćih detalja impementacije PSO. Lista će biti nepotpuna: izučavanje PSO implementacije je najbitnija stavka u oblasti PSO [19].

(1) Topologija. Da li je istina da svaka čestica zna lokaciju svih ostalih? Ne. Trebalo bi razumeti topologiju konekcija na takav način da čestica samo vidi podskup čestica. Na primer, topologija može biti krug (čestica vidi samo dve čestice). U ovom slučaju informacija struji.

(2) Prostorno proširenje. Čestica može da ima telo. Korištenjem prostornog proširenja može se izbeći preuranjenu konvergenciju, konkretno u slučajevima sa mnogo objektnih funkcija i velikom razmenom među njima.

(3) Trenje. Ako dinamika brzine ima komponentu trenja, može se biti u prednosti u vezi sa stabilnosti konvergencije. Ovo važi u situacijama sa jakim ograničenjima npr. u okviru mikroekonomije (cene moraju biti takve da ima dobiti, ali u isto vreme i da prizvod bude prvi izbor potrošača).

Kao što je predstavljeno ranije, PSO je stohastički populaciono zasnovan optimizacioni algoritam. Originalnu verziju su predstavili Kennedy i Eberhart [17] (kompletan opis ovog metoda je u [18]). U PSO roj čestica se pomera (leti): jedan metod, mnogo mogućih primena u n-dimenzionalnom prostoru u potrazi za najboljim rešenjem. Sada će se implementirati metod na malom problemu.

U daljem tekstu se pokazuju neke od varijacija u klasičnom PSO okviru da bi se ukazalo na tipične probleme u evolucionom istraživanju:

(1) Čestice mogu da emituju određenu vrstu signala da bi ukazale na promene u svom unutrašnjem stanju. Na primer, čestice mogu da odaju signal ako menjaju svoju brzinu;

(2) Algoritmi koji kontrolišu gradijent brzine mogu da implementuju neka pravila u vezi sa njihovom pozicijom: primer u ovom poglavlju u oblasti mikroekonomije će biti pokazan.

(3) PSO se, između ostalog, koristi da za rešavanje problema ovog tipa - veštački stvoreni uslovi u odnosu taktičkog ponašanja (izbeći predatora) i strateškog ponašanja (ostati u oblasti sa puno resursa). U ovom slučaju se vidi da PSO može da inkorporira neka od ograničenja u objektnu funkciju bez smanjenja kvaliteta performansi.

Da bi se PSO koristio, potrebno je upoznati se sa njegovim elementima. Pre svega, kratko će biti prikazan koncept PSO elemenata:

- Čestice: Mogu da se definišu kao $P_i \in [a, b]$ gde $i = 1, 2, 3, \dots, D$ i $a, b \in \mathbb{R}$. D predstavlja dimenziju, \mathbb{R} realne brojeve.
- Funkcija podobnosti: Funkcija koja se koristi za traženje optimalnog rešenja. Obično je to objektna funkcija.
- Najbolja lokalna pozicija: Najbolja pozicija čestice do sad.
- Najbolja globalna pozicija: Najpogodnija postignuta pozicija svih čestica .
- Ažuriranje brzine: Brzina je vektor koji određuje brzinu i pravac kretanja čestice.
- Ažuriranje pozicije: Sve čestice teže ka poziciji u kojoj se ostvaruje najveća podobnost. Svaka čestica u PSO ažurira svoju poziciju da bi se pronašao globalni optimum.

3.4.3 Hibridni modeli

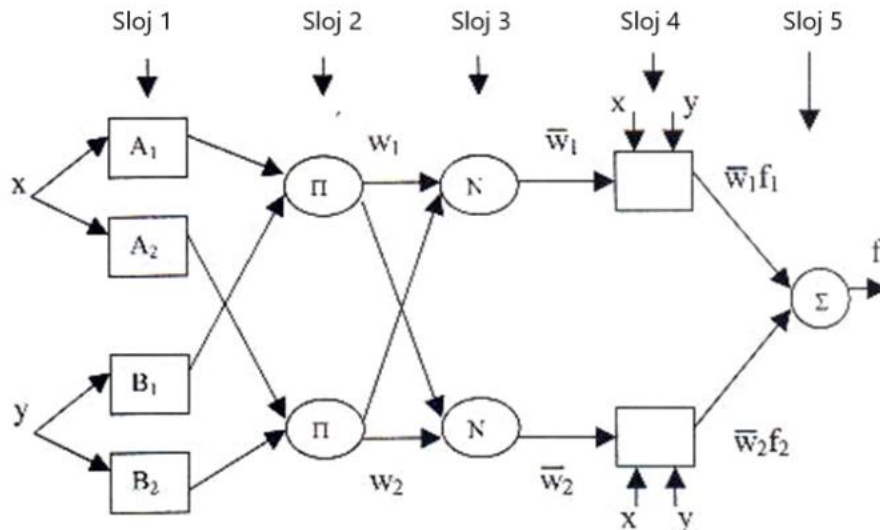
Kao što je pomenuto ranije, ANFIS je adaptivna mreža koja je funkcionalno ekvivalentna fuzzy sistemu zaključivanja (Jang 1993) i u literaturi se navodi kao "adaptivna mreža zasnovana na fuzzy sistemu zaključivanja" ili "adaptivni neuro-fuzzy sistem zaključivanja". O uvom odeljku predstaviće se struktura ANFIS-a.

Struktura ANFIS-a

U ANFIS-u se koristi Takagi-Sugeno fuzzy sistem zaključivanja. Izlaz svakog pravila može da bude linearna kombinacija ulaznih varijabli sa konstantnim terminom ili može da bude samo konstantni termin. Krajnji izlaz je prosečna težina izlaznih vrednosti svakog pravila. Osnovna ANFIS struktura koja ima dva ulaza x i y i jedan izlaz je prikazana na slici 3.12. Mreža sadrži dva Takagi-Sugeno ako-onda pravila:

Pravilo 1: Ako x je A_1 i y je B_1 , onda $f_1 = p_1x + q_1y + r_1$

Pravilo 2: Ako x je A_2 i y je B_2 , onda $f_2 = p_2x + q_2y + r_2$



Slika 3.12: Osnovna arhitektura ANFIS-a

Funkcije čvora u istom sloju su opisane ispod:

Sloj 1: Svaki čvor u ovom sloju je kvadratni čvor sa funkcijom:

$$0_{1,i} = \mu_{A_i}(x), \text{ for } i = 1,2 \quad (3-34)$$

$$0_{1,i} = \mu_{B_{i-2}}(y), \text{ for } i = 1,2 \quad (3-35)$$

Gde x predstavlja ulaznu vrednost čvora i, a Ai (ili Bi-2) je lingvistička oznaka (kao što je "malo" ili "veliko") povezana sa ovim čvorom. Drugim rečima, 0I,i je oznaka pripadnosti fuzzy skupa A i određuje stepen kojim dati ulaz x zadovoljava kvantifikatora A. Funkcija pripadnosti za A može biti bilo koja odgovarajuća funkcija pripadnosti, kao što je trouglasta ili Gausova. Kada se promene parametri funkcije pripadnosti, izabrana funkcija varira shodno tome, prikazivajući različite forme funkcija pripadnosti za fuzzy skup A. Parametri ovog sloja se nazivaju "parametri premisa".

Sloj 2: Svaki čvor ovog sloja je fiksni i označen kao II, čije su izlazne vrednosti produkti svih ulaznih signala:

$$0_{2,i} = w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2 \quad (3-36)$$

Izlazna vrednost svakog čvora predstavlja snagu nivo aktivacije fuzzy pravila.

Sloj 3: Svaki čvor ovog sloja je fiksni čvor označen kao N-ti čvor računa odnos nivoa aktivacije pravila sa sumom nivoa aktivacije svih pravila:

$$0_{3,i} = w_i = w_i/(w_1 + w_2), \quad i = 1,2 \quad (3-37)$$

Izlazne vrednosti ovog sloja se nazivaju "normalizovani nivoi aktivacije".

Sloj 4: Svaki čvor i u ovom sloju je adaptivni čvor sa funkcijom:

$$0_{4,i} = \overline{w}_i f_i = \overline{w}_i / (p_i x + q_i y + r_i) \quad (3-38)$$

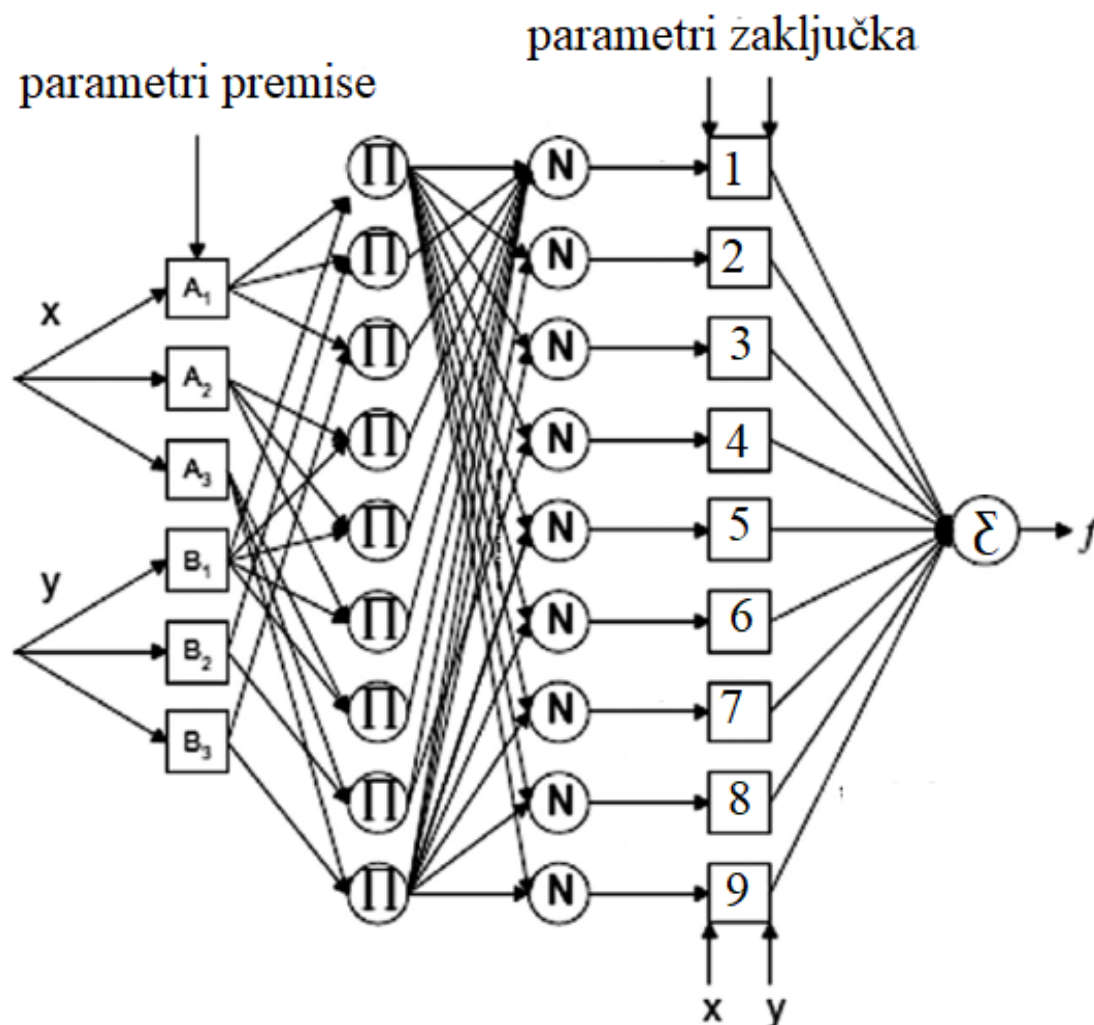
Gde wi predstavlja normalizovan nivo aktivacije sloja 3, a { } pi ,qi ,ri je skup parametara ovog čvora. Parametri ovog sloja se nazivaju "posledični parametri".

Sloja 5: Pojedinačni čvor ovog sloja je fiksni i označava se sa Σ te računa opšte ulazne vrednosti i sumira sve dolaze ulazne signale:

$$\text{ukupni izlaz} = o_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3-39)$$

3.4.4 Adaptivni fuzzy sistemi zaključivanja

Adaptivna mreža, koja predstavlja funkcionalni ekvivalent Takagi-Sugeno tipa fuzzy sistema zaključivanja, se gradi na način prikazan na slici 3.12. Drugi primer ANFIS-a sa devet pravila je prikazan na slici 3.13 (Ramezani, R. i sar, 2017). Tri funkcije pripadnosti su povezane sa svakim ulazom, tako da ulazni prostor učestvuje u devet fuzzy potprostora. Deo pravila koja opisuju fuzzy potprostore su premise, a posledični deo se odnosi na izlazne vrednosti ovog potprostora.



Slika 3.13: Struktura ANFIS-a sa devet pravila (Ramezani, R. i sar, 2017).

ANFIS algoritam učenja

Iz predložene ANFIS strukture iznad (slika 3.13.), izlazna funkcija je:

$$f = \frac{w_1}{w_1+w_2} f_1 + \frac{w_2}{w_1+w_2} f_2 \quad (3-40)$$

$$f = \overline{w_1}(p_1x + q_1y + r_1) + \overline{w_2}(p_2x + q_2y + r_2) \quad (3-41)$$

$$f = (\overline{w_1}x)p_1 + (\overline{w_1}y)q_1 + (\overline{w_1})r_1 + (\overline{w_2}x)p_2 + (\overline{w_2}y)q_2 + (\overline{w_2})r_2 \quad (3-42)$$

Gde su p_1, q_1, r_1, p_2, q_2 i r_2 linearni posledični parametri. Metode za ažuriranje ovih parametara su navedene ispod:

- 1) Pad gradijenta: Svi parametri se ažuriraju sa povratnim postupkom pada gradijenta.
- 2) Najmanja kvadratna pretpostavka se primenjuje samo jednom na samom početku da bi se dobile inicijalne vrednosti posledičnih parametara, a onda ulogu preuzima pad gradijenta da ažurira sve parametre.
- 3) Gradijent i LSE: Ovo je hibridno pravilo učenja.

Pošto pristup hibridnog učenja konvergira mnogo brže, tako što smanjuje dimenzije prostora pretrage, s toga je i popularniji i traženiji za korišćenje. Tokom protiranja algoritma unapred, izlazi čvorova idu unapred dok se sloj 4 i posledični parametri ne identifikuju preko metode najmanjih kvadrata. U prostiranju unazad, stopa greške se širi unazad i parametri premise se ažuriraju padom gradijenta.

3.4.5 Algoritam neuro – fuzzy sistema

U procesu učenja se radi o pronalaženju najboljih vrednosti za pravila zaključivanja. Drugim rečima, cilj ovog koraka je da optimizuje vrednosti svakog parametra pravila da bi se smanjile greške u predviđanju. Da bi se došlo do ovoga, prvo se uzme u obzir podskup već postojećeg skupa podataka za trening, a sledeća formula se definiše kao ciljna funkcija:

$$J(W) = \frac{1}{2} \sum_{i=1}^M (y_i - \hat{y}_i)^2 \quad (3-43)$$

W predstavlja vektor koji sadrži skup svih parametara, a y_i i \hat{y}_i su stvarne i predviđene vrednosti promenljive za i -ti uzorak. Dodatno, formula defuzifikacija za predviđanja vrednosti i^{th} uzorka, može da se definiše na sledeći način:

$$\hat{y}_i = \frac{\sum_{r=1}^{10} w_{ir} z_r}{\sum_{r=1}^{10} w_{ir}} \quad (3-44)$$

$$w_{ir} = \prod_{j=1}^{11} \mu_{irj} \quad (3-45)$$

μ_{irj} je vrednost pripadnosti j^{th} karakteristike u i^{th} uzorku r^{th} pravila. Vrednosti r između 1 i 10 predstavljaju najkompatibilnija pravila od svih mogućih iz datog uzorka. Na osnovu kompatibilnosti, određuju se pravila koja izvlače maksimum performansi datog uzorka.

Poznavanjem ciljne funkcije, može da se izračuna process napretka na osnovu gradijalnog pada:

$$z_r = z_r - \alpha \frac{\partial J(W)}{\partial z_r} \quad (3-46)$$

$$\frac{\partial J(W)}{\partial z_r} = - \sum_{i=1}^M (y_i - \hat{y}_i) \frac{w_{ir}}{\sum_{r=1}^{10} w_{ir}} \quad (3-47)$$

4 ANALIZA PREDMETNE LITERATURE

U novijim studijama i u literaturi analiziran je problem razvoja inteligentnih sistema u naftnom i gasnom inženjerstvu. Najveći deo istraživanja bavi se primenom fuzzy logike i neuronskim mrežama, kroz analizu i sintezu značajnih parametara na radnim pokazateljima kao i na njihovom predviđanju.

4.1 Analiza radova na temu gubitaka isplake na bazi konvencionalnih i tradicionalnih metoda

Problem gubitka isplake je bio očigledan još od samih početaka naftne industrije i značajno se uvećao kada se počelo bušiti dublje i/ili kada su formacije postale osiromašene (Moazzeni, A.R. i sar, 2009). Godišnje se potroše milioni dolara u borbi protiv gubitka isplake i štetnih efekata koje prouzrokuje, kao što je utrošak vremena za postavljanje opreme, zapušanje cevi i eksplozije. Često se dešavaju i napuštanje skupo održivih bušotina, prekomerni troškovi zbog gubitka isplake, oštećenja formacija zbog gubitaka u zoni proizvodnje ili nepotpuna izolacija zbog manjka cementa na vrhu bušotine (Pilehvari, A.A. i sar. 2002). Preko 90% izgubljenog povrata troškova, dešava se zbog širenja fraktura (Dupriest, F.E. 2005). Treba uzeti u obzir i druge forme gubitaka kao što su curenje kroz matriks i gubici filtrata.

Parametri kao što su gradijent pritiska formacije, gradijent pritiska fraktuirane formacije, osobine bušačkog fluida, petrofizičke osobine formacije, postojanje fraktura i kaverni u formacijama, bušači parametri (kao što su pritisak i kapacitet pumpe), te mnogi drugi znani i neznani parametri mogu da utiču na ozbiljnost gubitka cirkulacije isplake. Posledično, vrlo je teško predvideti da li i koliko, će doći do gubitaka cirkulacije isplake u nekoj formaciji. Zbog svih navedenih potencijalnih problema i gubitaka, naftni inženjer mora temeljno da istraži sve ove stavke. Zbog ovih razloga, tekuće poglavlje ima za cilj da prouči način za predviđanje postojanja i količine gubitaka, posedujući podatke o gubicima pre i tokom bušenja na terenu, koristeći neuronske mreže koje su deo veštačke inteligencije.

Konvencionalne metode predviđanja gubitka cirkulacije se uglavnom zasnivaju na identifikaciji šupljina i sistema fraktura preko seizmičke metode, ili za predikciju lokacije i strukture gde bi moglo doći do gubitaka, zasnovanu na podacima susednih bušotina. Kakogod, ovo je daleko od dovoljnog zbog nedostatka tačnosti i preciznosti.

4.2 Primena ekspertnih sistema u tehnici uopšte

Ključna karakteristika mašinskog učenja je njegova sposobnost da kroz tipične procese učenja prepozna ključne šablone sa odgovarajućom preciznošću u davanju pretpostavki (Alkamil i sar., 2018). Takođe, mašinsko učenje može da da intuitivna rešenja za komplikovane probleme, bez detaljnih opisa propratnih fizičkih karakteristika.

Ovaj metod može da kreira asocijacije, transformacije i združivanje objekata ili podataka, te se dokazao kao potencijalno sredstvo za rešavanje problema koji zahtevaju prepoznavanje šablona. Među metodama mašinskog učenja, ANFIS je najmoćnija i najefikasnija tehnika za identifikaciju kompleksnih veza, zasnovana na prethodnom iskustvu, sa odgovarajućim novčanim i vremenskim utroškom (Abbas i sar., 2018a).

4.3 Primena ekspertnih sistema u tehnici bušenja

Ekspertni sistem se može opisati kao računarski sistem koji primenjuje algoritam zasnovan na određenim pravilima, u cilju davanja ekspertize u vezi sa određenim slučajem. Razvijen je veliki broj ekspertnih sistema za primenu u tehnici bušenja. Pravila se uzimaju od inženjera koji rade na bušotinama i zatim se ugrađuju u algoritme čija je uloga da kopiraju znanje i pristup inženjera u cilju rešavanja realnih problema koji se javljaju na bušotini.

Prema (Bello i sar.), većina ekspertnih sistema je ograničena na specifične namene, na primer interpretacija rezultata merenja nagiba slojeva u bušotini, karakterizacija rezervoara, prevencija nekontrolisanog isticanja fluida iz bušotine, izbor bušaćeg fluida, predviđanje stanja i rada dleta, prepoznavanje seizmičkih obrazaca, predikcija poroznosti i permeabilnosti formacije, predikcija pritiska u bušotini, optimizacija proizvodnje na bušotini, projekcija performansi bušotine. Jedna od najvažnijih uloga ekspertnih sistema je pomoć u brzom i logičkom donošenju odluka u skupim operacijama bušenja.

Kao primer primene softverskog modelovanja u tehnici bušenja, u prethodnom radu (Razeghi i sar., 2017) izvršeno je modelovanje rada jedne bušotine primenom softvera za simulacije, *Eclipse-300*. Primenom simulacije, analiziran je uticaj parametara ubrizgavanja fluida (kvalitet vodene pare, brzina ubrizgavanja pare, pritisak pare, dubina na kojoj se para ubrizgava) na prinos i kvalitet proizvodnje teške nafte iz bušotine. Izvršena je klasifikacija raspoloživih podataka o parametrima fluida u nekoliko grupa. Napravljeno je pet modela koji su podrazumevali različite stepene kvaliteta fluida, tri modela koji su podrazumevali različite pritiske ubrizgavanja fluida i tri modela sa različitim brzinama protoka fluida. Zaključeno je da primena optimalnih parametara ubrizgavanja fluida može povećati efikasnost eksploatacije teške nafte iz bušotine.

Najpoznatiji ekspertni sistemi koji se već dve decenije primenjuju u tehnici bušenja su Artificial Neural Networks (ANN), Generic Algorithms, Support Vector Machines i Fuzzy Logic (Bello i sar.).

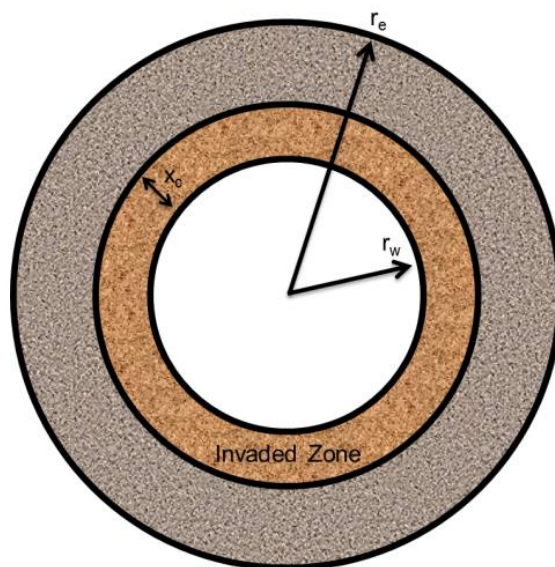
4.4 Primena ekspertnih sistema u predikciji gubitka isplake

Ghalambor i sar. su predložili model za predviđanje gubitaka cirkulacije isplake tokom procesa bušenja. On je podelio gubitke u tri kategorije i predložio odgovarajući model za svaku:

- Gubici kroz propustljivi matriks

Ovaj tip gubitka dešava se tokom bušenja kroz propustljive formacije (kao što je pesak) i gde su statički i dinamički pritisci isplake viši od pritiska fluida u formaciji. Ovakav ishod je očekivan jer su permeabilne formacije porozne i gubici će se dešavati sve dok se krupne čestice iz fluida ne natalože na zidove kanala bušotine formirajući na taj način oblogu koja usporava, a na kraju i zaustavlja dalji gubitak bušaćeg fluida u formaciju. Ipak, neminovni su manji gubici sve dok traje proces bušenja. Predviđanje gubitaka se bazira na Darsijevom zakonu za protok fluida kroz poroznu sredinu, uzimajući u obzir pozitivne efekte formirane glinene obloge. Uvek je zgodno pretpostaviti ishod najgoreg mogućeg scenarija, a to je nepostojanje glinene obloge. Ove rezultate bi trebalo koristiti za menadžment bušotina i procenu dostupne isplake na lokaciji bušotine.

Stopa filtracije i debljina glinene obloge su objašnjeni sledećom šemom i formulama (slika 4.1) (Parn-anurak i Engler, 2005.):



Slika 4.1: Šematski prikaz glinene obloge na zidu bušotine

$$q(t) = \frac{2\pi kh\Delta p}{u_f \ln\left(\frac{r_e}{r_w}\right)} \frac{\left(\frac{k_c}{k}\right) \ln\left(\frac{r_e}{r_w}\right)}{\left[\left(\frac{k_c}{k}\right) \ln\left(\frac{r_e}{r_w}\right) - \ln\left(\frac{r_w - x_c}{r_w}\right)\right]} \quad (4-1)$$

$$\frac{dx_c}{dt} = \frac{q(0) \left(\frac{k_c}{k}\right) \ln\left(\frac{r_e}{r_w}\right) (1-\phi) C_{solid}}{2\pi(r_w - x_c(t)) h \left[\left(\frac{k_c}{k}\right) \ln\left(\frac{r_e}{r_w}\right) - \ln\left(\frac{r_w - x_c}{r_w}\right)\right] (1-\phi_c) \rho_c} - \frac{k_\tau \tau}{g(1-\phi_c) \rho_c}, \quad x_c(0) \quad (4-2)$$

- Gubici kroz male prirodne frakture

Prirodne frakture postoje unutar stena rezervoara u različitim orijentacijama zbog Zemljinih tektonskih pomeranja. Ove frakture se ukrštaju sa bušotinama tokom izvođenja radova i na taj način dolazi do gubitka bušaćeg fluida. Iako su prirodne frakture male širine, gubitak fluida može biti značajan zbog potencijalnih proširenja i postojanja mreže pukotina. U ovim slučajevima, poznavanje geometrije fraktura, propusnosti i njihovih lokacija ima veliki značaj za predviđanja gubitka bušaćeg fluida.

Predviđanje gubitaka bušaćeg fluida u prirodnim frakturama se najčešće bazira na teoriji podmazivanja i zanemaruje gubitke u okolni matriks. Na osnovu nekoliko reoloških modela, razvijene su različite metode za protok bušaćeg fluida u frakturu. Neki od njih su: Njutnovski (Sanfillippo i sar. 1997), Bingham-plastični (Lietard i sar. 1996), Power Law Model (Lavrov i Tronvoll 2004) i Yield Power Law Model (Majidi i sar. 2010). U ovim modelima, pretpostavlja se da je širina fraktura konstantna tokom gubitka bušaćeg fluida. Međutim, prema terenskim podacima, frakture menjaju širinu tokom procesa bušenja.

Zbog promena pritiska u frakturama, menja se njihova širina (poznato kao i baloniranje fraktura), te je ovaj podatak potrebno uzeti u obzir tokom računskih operacija da bi se što preciznije mogao predvideti gubitak cirkulacije isplake. Zakon efekta deformacije frakture, na primer linearna

deformacija (Lavrov i Tronvoll 2004) i eksponencijalna deformacija (Lavrov i Tronvoll 2005), na gubitak volumena fluida su ispitivani u Power Law modelu. Kasnije, Shahri i sar. (2012) su proširili model da uključi i Power Law Model reoloških karakteristika fluida. Efekat geometrije prirodnih fraktura na gubitak fluida su takođe istraživali Lavrov i Tronvoll (2006), te Shahri i Mehrabi (2012).

Da bi se što realističnije oponašale osobine fraktura, proučavan je i efekat čvrstine površine frakture na gubitak fluida, korištenjem teorije fraktala (Ozdemirtas i sar. 2009 i Lavrov 2013). Objasnjeni pokušaji modelovanja gubitka bušačkog fluida u prirodnim frakturama pokazuju kompleksnost problema i njegovu važnost tokom procesa bušenja. U tekućem poglavlju, istražuje se jednačina potrebna za računanje gubitka bušačkog fluida u prirodnim frakturama.

Teorija podmazivanja se koristi kao fundamentalna jednačina za modelovanje protoka fluida unutar prirodnih fraktura:

$$\frac{\partial(w\bar{v})}{\partial r} + \frac{1}{r}w\bar{v} + \frac{\partial w}{\partial t} = 0 \quad (4-3)$$

U pomenutoj jednačini, promene širine frakture i brzine fluida se mogu menjati u zavisnosti od slučaja. Na primer, može se pretpostaviti da je širina frakture konstantna vrednost tokom gubitka bušačkog fluida ili da se menja u zavisnosti od različitih linearnih ili eksponencijalnih zakona deformacije. Dodatno, brzina fluida unutar frakture zavisi od reoloških karakteristika (Njutnovski, Bingham-plastični i Power Law model). Opšti reološki model, npr. Power Law model, može se koristiti za iskazivanje brzine fluida u odnosu na pad pritiska preko sledeće jednačine:

$$\bar{v} = \left(\frac{m}{2m+1}\right) \left(\frac{w^{\frac{m+1}{m}}}{2^{\frac{m+1}{m}} k^{\frac{1}{m}}}\right) \left(-\frac{dp}{dr} - \left(\frac{2m+1}{m+1}\right) \left(\frac{2\tau_y}{w}\right)^{\frac{1}{m}}\right) \quad (4-4)$$

Zamena gornje jednačine u teoriju podmazivanja i primena odgovarajućeg zakona deformacije frakture, rezultuje u ispod navedenoj parcijalno diferencijalnoj jednačini koju je potrebno rešiti korištenjem numeričkog pristupa. Granične vrednosti mogu biti naznačene u zavisnosti od prekomernog pritiska bušotine.

$$\left(\frac{m}{2m+1}\right) \left(\frac{1}{2^{\frac{m+1}{m}} k^{\frac{1}{m}}}\right) \frac{\partial}{\partial r} \left(w^{\frac{2m+1}{m}} \left(-\frac{dp}{dr} - \left(\frac{2m+1}{m+1}\right) \left(\frac{2\tau_y}{w}\right)^{\frac{1}{m}}\right) \right) + \left(\frac{m}{2m+1}\right) \left(\frac{1}{2^{\frac{m+1}{m}} k^{\frac{1}{m}}}\right) \frac{1}{r} w^{\frac{2m+1}{m}} \left(-\frac{dp}{dr} - \left(\frac{2m+1}{m+1}\right) \left(\frac{2\tau_y}{w}\right)^{\frac{1}{m}}\right) + \frac{\partial w}{\partial t} = 0 \quad (4-5)$$

Nakon rešavanja gornje jednačine, stopa gubitka bušaćeg fluida može da se izračuna na sledeći način:

$$q_w = 2\pi r_w w_w v_w \quad (4-6)$$

Kumulativni gubitak u prirodnim frakturama može da se izračuna integrisanjem stope gubitka u vremenu:

$$V_{cum} = \int_0^t q_w dt \quad (4-7)$$

U pomenutom modelu, Ghalambor i sar. su pretpostavili da je širina frakture konstantna tokom gubitaka, te su izostavili efekte poput baloniranja frakture. Prema tome, jednačina (4-7) može da bude pojednostavljena upotrebom formulacija koje su dali Majidi i sar. 2010.

- Indukovani gubici cirkulacije isplake

Ghalambor i sar. su tvrdili da je gubitak cirkulacije kroz stvaranje indukovanih fraktura verovatno najčešći slučaj tokom bušenja, manevra alatom i/ili cementiranja. Osvrtom na podatke sa terena, uočeno je da se ovaj tip gubitaka često dešava zbog neprikladne gustine isplake. Kao primer je navedena bušotina u Meksičkom zalivu.

Ghalambor i sar. su zaključili da u slučajevima gde su gubici neizbežni zbog šupljina i kaverni, bušenje se može nastaviti dok dleto ne prođe kroz zonu gde se dešavaju gubici. Ovo se savetuje samo ukoliko su gubici prihvatljivi, ukoliko ne dolazi do oštećenja rezervoara i okoliša i ako su rezerve isplake na površini dovoljne da nadomeste gubitak tokom čitavog intervala. Inače, može da se koristi bušenje sa sniženim pritiskom isplake, ako zid bušotine ima zadovoljavajući integritet.

Ne postoje modeli koji bi predvideli količinu gubitaka u šupljinama i kavernama jer je ovaj sistem u potpunosti otvoren i neograničena količina isplake bi mogla da se pumpa bez otpora formacije, osim pornog pritiska. S toga, cilj je da se buši izazivajući minimalne gubitke. Bušenjem naslepo i na mestima poremećene unutrašnje ravnoteže postoje značajna ograničenja i rizici, koji bi trebali da se prevaziđu upotrebom nekonvencionalnih metoda da bi bušenje kroz ove segmente bilo uspešno. Da bi se smanjila verovatnoća zaglavlivanja dok se buši naslepo, gust čep od isplake može da se upumpa u prstenasti prostor istovremeno sa nekim tipom tečnosti (najčešće morska voda). U modifikovanoj verziji, kada se vrši bušenje sa podešavanjem pritiska, čep od isplake pod pritiskom može da zameni gust čep od isplake.

Još jedna napredna tehnologija za totalne gubitke je bušenje sa oscilatornim pomeranjem bušaće cevi, jer može lakše da popuni prstenasti prostor oko bušaće cevi. Efekat malterisanja koji

ostavlja cev koja se horizontalno pomera, takođe pomaže da se spreči zatrpavanje bušaćih cevi i urušavanje oslabljenih formacija koje se nalaze iznad zona gubitka cirkulacije.

4.5 Rezime i zaključna razmatranja

Kao što je i ranije zaključeno, ne postoji dovoljno precizan model koji bi predvideo gubitke u cirkulaciji. Nekoliko faktora utiče na ozbiljnost gubitaka cirkulacije isplake. Uopšteno, ovi faktori mogu da se klasifikuju u dve kategorije: parametri bušenja i bušaćeg fluida. Zbog velike kompleksnosti i nelinearnog ponašanja ovih parametara, pronalazak odgovarajućeg analitičkog rešenja za predviđanje gubitaka cirkulacije nije jednostavan (Toreifi i sar., 2014). Zbog svih pomenutih poteškoća, mašinsko učenje se čini kao vrlo pogodna alternativa za modelovanje ovih kompleksnih fizičkih procesa. Fokus na predikcije rizika gubitaka cirkulacije je premali, usled nedostatka modela inteligentnih predviđanja koji će uzimati u obzir veliki broj faktora koji proizilaze iz parametrara bušenja i parametara bušaćeg fluida.

Glavni cilj ovog poglavlja bio je da omogući uvid u prethodna istraživanja na temu gubitka isplake i metoda predviđanja gubitka isplake.

5 RAZVOJ NEURO–FUZZY MODELA UPRAVLJANJA CIRKULACIJOM

Termin ANFIS (*Adaptive neuro fuzzy inference system*) označava adaptivni neuro fuzzy sistem zaključivanja, kao jedan pristup u inteligentnom modelovanju. Cilj ovog istraživanja jeste ispitivanje mogućnosti primene ANFIS metodologije kao hibridne strukture za estimaciju gubitaka fluida u procesu bušenja. Primena ove metode se zasniva na prethodnim istraživanjima Yildiza (2020) u kojima je ANFIS model primenjen za predikciju protoka fluida na branama. U njihovom istraživanju, rezultati dobijeni modelom su poređeni sa laboratorijski dobijenim rezultatima za protok fluida na određenoj dubini brane.

U ovoj disertaciji ANFIS model pronalazi novu primenu. Performanse ANFIS estimatora porede se sa performansama NN (*eng. Nearest Neighbors*) i EKF (*eng. extended Kalman filter*) estimatora koji je javno dostupan u širokom dijapazonu literature. U ovom poglavlju biće objašnjen dizajn ANFIS arhitekture za procenu delimičnih ili potpunih gubitaka isplake.


5.1 Skupovi podataka

ANFIS može da se koristi za procenu zavisnih promenljivih u toku postupka bušenja. U procesu dizajniranja, ANFIS je konstruisan i naučen da traži arhitekturu tj. topologiju mreže (način na koji su neuroni međusobno povezani) koja daje najbolje performanse estimatora.

Da bi se dizajnirao estimator, pre svega trebalo bi generisati skup podataka za trening mreže estimatora. Ovaj skup podataka je sakupljan iz dnevnih izveštaja sa bušotina, izveštaja o bušačem fluidu i dnevnih izveštaja o bušačem fluidu iz 73 bušotine naftnih polja u jugozapadnom Iranu kao i Iraku, uključujući Južni Azadegan, Yaran, Yadavaran, Darquain, Sohrab i Arvandan. Podaci su dobijeni uvidom u dnevnik koji su vođeni na bušotinama i koji predstavljaju poslovnu tajnu.


Pripremljeni skup podataka sastoji se od 1500 uzoraka, svaki sadržeći 20 atributa i jednim odzivom – gubitkom.

Podaci su kategorisani u tri velike kategorije prema H. Rabia koje se sastoje od: curenja, delimičnih i jakih gubitaka. Dalje su podaci potkategorisani u 8 manjih klasa, kao što prikazuje slika 5.1:



Slika 5.1: Vrste gubitaka: 1. malo curenje (160 – 320 l/č), 2. srednje curenje (320 – 800 l/č), 3. jako curenje (800 – 1600 l/č), 4. mali delimični gubici (1600 – 2400 l/č), 5. srednji delimični gubici (2400 – 4000 l/č), 6. jaki delimični gubici (4000 – 8000 l/č), 7. jaki gubici (8000 – 12800 l/č) i 8. totalni gubici (>12800 l/č).

Predikcije gubitaka isplake bile bi uspješnije kada bi postojale potkategorije prvenstveno zbog toga što ne postoji postupak za rešavanje problema u slučaju malih curenja. Takođe, iako su gubici od 1760 l/č i 8000 l/č svrstani u istu kategoriju po H. Rabia, kontrolisanje istih se umnogome razlikuje. Iako se jaki i totalni gubici retko dešavaju, u istraživanju je pokušano da se što vernije prikaže ujednačen skup podataka u svim potkategorijama kako nedostatak podataka ne bi uticao na ishod predviđanja. Kao što je prikazano na slici 5.2, najmanji broj skupova podataka (odnosno 50) je raspoloživ za potpune gubitke. Međutim, u ovom istraživanju je odlučeno da se i ti podaci uzmu u obzir pri proračunima.



Slika 5.2: Prikaz histograma promenljive odziva za različite opsege gubitka cirkulacije: a) 160 – 320; b) 320 – 800; c) 800 – 1600; d) 1600 – 2400; e) 2400 – 4000; f) 4000 – 8000; g) 8000 – 12800; h) potpuni gubitak


5.2 Selekcija promenljivih

Dizajn eksperimenata (DOE) je grana primenjene statistike koja se bavi planiranjem, sprovođenjem, analizom i interpretacijom kontrolisanih testova za procenu faktora za kontrolisanje vrednosti parametara ili grupe parametara. DOE je moćno oruđe za analizu i skupljanje podataka koje ima širok dijapazon upotrebe u eksperimentalnim situacijama.

U ovom radu sakupljen je veliki broj podataka uključujući 20 parametara kao što je nabrojano na slici 5.3. Neki od ovih parametara bi se mogli zanemariti jer ne utiču na gubitak isplake, kao što je vreme, ali se uzimaju u obzir da bi dobili što verniji odabir promenljivih. Dizajn eksperimenta je takav da procenjuje efekte tih promenljivih na rezultat i određuju se najefektniji parametri.

Sprovođenjem DOE-a mogu se odrediti efekti svakog parametra. Slika 5.3 prikazuje efekte svake promenljive na gubitke cirkulacije isplake. Veličina efekta je određena dijagramom koji prikazuje promenljive od one sa najvećim ka onoj s najmanjim efektom, s leva na desno. Na osnovu slike se zaključuje da najveći varijabilni efekat ima dubina, a promenljiva sa najmanjim efektom je vreme bušenja.

Uticaj različitih varijabli



Slika 5.3: Dijagram efekata različitih promenljivih

Neke od promenljivih će ukratko biti objašnjene:

Plastična viskoznost (skraćeno PV, merna jedinica centipoaz, mPas): odnosi se na viskoznost bušačeg fluida u bušotinama kada se izračunava vrednost brzine smicanja baziranom na Bingamovom modelu. Kada PV ima malu vrednost, to ukazuje na to da će se brže bušiti zbog male viskoznosti bušačeg fluida koji izlazi iz bušotine. Visoka vrednost PV je rezultat prisustva viskozne bazne tečnosti i prevelikih količina koloidne čvrste materije. Da bi se smanjila vrednost PV, može se smanjiti zapremina čvrste materije tako što će se razrediti bušači fluid.

Granica tečenja (Pa), eng. Yield Point: skraćeno YP, je u tehnologiji bušačih isplaka početni otpor strujanju isplavnog fluida, odnosno naprezanje koje je potrebno za prevladavanje otpora strujanju i za početak njegovog strujanja.

Pritisak frakturiranja (Pa): pritisak potreban da se slomi formacija i prouzrokuje povlačenje bušačeg fluida iz bušotine u stvorene pukotine. Sa porastom dubine bušotine, linearno raste pritisak fluida u porama stena, dakle na većoj dubini se lakše može dostići pritisak frakturiranja.

Pritisak u porama (Pa): pritisak fluida u porama stena.

Ove promenljive se mogu kategorisati u tri klase:

1. Prirodne promenljive su karakteristične za prirodu i na njih se ne može uticati.
2. Parametri bušenja koje je moguće menjati, a promena tih parametara ne zahteva velike troškove.
3. Svojstva bušačkog fluida se takođe mogu menjati, ali je jako skupo u odnosu na menjanje parametara bušenja.

Prirodne promenljive izučavane u ovom radu su: dubina, prečnik bušotine, pritisak frakturiranja, porni pritisak, formacija, obrtni moment i lokacija bušotine. Srednja vrednost ovih parametara je: 0,52. Ova vrednost je dobijena kao aritmetička sredina veličina efekata očitanih sa dijagrama na slici 5.3, za navedene veličine.

Parametri bušenja koji su izučavani u radu su: ROP, broj obrtaja dleta, kapacitet pumpe, pritisak pumpi, broj obrtaja bušačkog alata, broj časova rada dleta, opterećenje na dleto, opterećenje na kuki, trajanje bušenja. Srednja vrednost ovih parametara je: 0.23, izračunata kao aritmetička sredina veličina efekata sa slike 5.3. za navedene parametre.

Svojstva bušačkog fluida izučavana u ovom radu su: plastična viskoznost, granica tečenja, gustina bušačkog fluida i temperature bušačkog fluida. Srednja vrednost ovih parametara je 0.56, izračunata na isti način kao za prethodne parametre.

Da bi se dizajnirao, modifikovao i optimizovao što bolji ANFIS model, promenljive za koje je na dijagramu 5.3 indeks efektivnosti 0.3 ili manje, su isključene iz ovog istraživanja. Tako da devet parametara (obrotni moment, pritisak pumpe, broj obrtaja bušačkog alata, broj časova rada dleta, opterećenje na dleto, opterećenje na kuki, temperatura bušačkog fluida, lokacija bušotine i trajanje bušenja) se isključuje iz istraživanja, a jedanaest parametara (dubina, pritisak frakturiranja, YP, PV, prečnik bušotine, formacija, broj obrtaja dleta, ROP, porni pritisak, kapacitet pumpe, gustina bušačkog fluida) se istražuje i deo su dizajniranja ANFIS modela. Razumnije je i praktičnije praviti ANFIS model sa 11 varijabli za takav skup podataka.

Ograničenja svakog od parametara u ovom istraživanju prikazana su u tabeli 5.1.

Tabela 5.1: Ulazni parametri za proračun

Karakteristika	Merna jedinica	Min	Max
Gubitak cirkulacije	l/h	0	80.000
Dubina	m	12	4468
Porni pritisak	kPa	406	21.081
ROP	m/h	0	53
Broj obrtaja dleta	o/min	0	211
Pritisak frakturiranja	kPa	6.976	37.772
Kapacitet pumpe	l/min	521	3.655
Gustina isplake	kg/m ³	1.025	2.146
Granica tečenja	Pa	0,586	1,855
PV	mPas	25	96
Prečnik bušotine	cm	10.477	66.04
Formacija	-	Aghajari	Gadvan

5.3 Dizajn ANFIS-a

Ideja iza neuro-adaptivnih tehnika učenja je veoma jednostavna. Ove tehnike obezbeđuju metodu za modelovanje fuzzy procedure za dobijanje skupova podataka sa ciljem da se izračunaju funkcije pripadnosti parametara. ANFIS konstruiše mapiranje bazirano na ljudskom znanju kao i na sakupljenim podacima.

Parametri koji su u vezi sa funkcijama pripadnosti se mogu menjati kroz process učenja. Izračunavanje ovih parametara (ili njihovo podešavanje) je olakšano vektorom gradijenta koji obezbeđuje vrednost koja govori o tome u kojoj meri ANFIS modeluje ulazno/izlazne podatke za dati skup parametara. Algoritam za učenje, koji je opisan u prethodnom poglavlju, može se primeniti za podešavanje parametara kada se dobije vektor gradijenta.

Kao što je prethodno ustanovljeno, ANFIS se koristi u modelovanju i procenama u naftnom inženjeringu kao i ostale veštačke inteligencije kao što su NN i fuzzy logika FL. U ovom radu dizajnirani ANFIS se koristi kao estimator. Estimacija se vrši za sastav bušačkog fluida i merenje pumpnih parametara. U nastavku će detaljno biti objašnjeni koraci implementacije.

5.3.1 Normalizacija podataka

U statistici, normalizacija podataka se odnosi na primenu determinističkih matematičkih funkcija u svakoj tački skupa podataka, gde se svaki podatak zamenjuje sa normalizovanom vrednošću. Normalizacija se obično koristi da bi prikaz podataka bio približan predviđenim vrednostima u proceduri statističkih smetnji koje se primenjuju ili da se poboljša grafička interpretacija. Skoro uvek, funkcija koja se koristi za normalizaciju podataka je kontinualna. Normalizacija se obično koristi na skupu poredivih merenja.

Partikularna statistička analiza daje uputstvo za normalizaciju podataka i da li se uopšte podaci trebaju normalizovati. U ovom radu, opseg svake karakteristike je konvertovan u $[0, 1]$. Ova konverzija izjednačava uticaj svake karakteristike u procesu učenja. Da bi se to postiglo, koristi se minimalnu i maksimalnu tehniku normalizacije koja je za datu karakteristiku $X_1 \in R^{N \times 1}$ implementirana na sledeći način:

$$\tilde{X}_1 = \frac{X_1 - \min(X_1)}{\max(X_1) - \min(X_1)} \quad (5-1)$$

Gde su min i max funkcije one koje vraćaju minimum i maksimum karakteristika vektora respektivno. Sve karakteristike datog skupa podataka su normalizovane preko date formule.

5.4 Parametri

ANFIS-u je potrebno nekoliko prethodno definisanih parametara kao što su funkcije pripadnosti, broj funkcija pripadnosti definisanih za svaku karakteristiku, stopa učenja, broj pravila u skladu sa predikcijama i broj epoha učenja. Ovi parametri su ukratko objašnjeni:

- Funkcija pripadnosti: U matematici, funkcija pripadnosti fuzzy skupa, generalizacija je indikatorske funkcije za uobičajen skup. U fuzzy logici, predstavlja nivo istinitosti procene. Nivoi istinitosti se često mešaju sa verovatnoćama iako su oni konceptualno različiti jer fuzzy istina predstavlja združenost nejasno različitih skupova, a ne ishod događaja ili uslova. Funkcije pripadnosti je prvi pomenuo Zadeh (1965) koji je predložio korišćenje funkcija pripadnosti (čiji se opseg kreće između nula i jedan) koje rade na domenu svih mogućih vrednosti.
- Stopa učenja: U mašinskom učenju i statistici, stopa učenja je podešavajući parametar algoritma za optimizaciju koji određuje veličinu koraka svake iteracije dok teži ka minimumu funkcije gubitaka. (Ghazanfari, 2014) Obzirom da utiče na to koliko nova informacija prevazilazi staru, metaforički predstavlja brzinu kojom model "uči". (Kia, 2014) U literaturi adaptivnog upravljanja, stopa učenja se drugačije zove i dobit. (Jang, 1997)

U uspostavljanju stope učenja, javlja se zamena između brzine konvergencije i prekoračenja. Silazna putanja se određuje gradijentom funkcije gubitaka, a stopa učenja određuje koliki korak se preduzima u tom smeru. (Wang, 1997) Ako je prevelika stopa učenja onda će doći do preskakanja minimuma, a ako je premala, onda će ili predugo vremena trebati da se konvergira ili će se zaustaviti na neželjenom lokalnom minimumu. (Jang, 1993) Da bi se postigla brža konvergencija, sprečile oscilacije i zaustavljanje na neželjenom lokalnom minimumu, stopa učenja je promenljiva u toku trenažnog postupka - ili se menja u skladu sa rasporedom brzine učenja ili korištenjem adaptivne stope učenja. (Medsker, 1995)

Stopa učenja i njena podešavanja takođe se mogu razlikovati za svaki parametar, a u tom slučaju to je dijagonalna matrica koja može da se prikaže kao aproksimacija inverzne Hesianove (Hessian) matrice preko Njutnove metode. (Zhang, 2004) Stopa učenja je usko povezana sa dužinom koraka određenim nepreciznom pretragom preko kvazi Njutnovih metoda i sličnih algoritama za optimizaciju. (Kasabov, 2002)

- Epoha: Termin koji se koristi u mašinskom učenju i ukazuje na broj završenih prolaza u celom skupu podataka za trening. Skupovi podataka su obično grupisani u serije (pogotovo kada postoje velike količine podataka). U optičaju je i izraz “iteracija” koji se odnosi na propuštanje jedne serije podataka kroz obradu u modelu u vidu iteracije.

U disertaciji je testirano nekoliko funkcija pripadnosti i epoha. Da bi se odredila stopa učenja, testirane su različite vrednosti od 0.1 do 0.99. Tip funkcije pripadnosti je izabran nakon testiranja velikog broja algoritama za trening. Gausov algoritam je izabran jer ima najviši R^2 i zbog toga je on najbolji prediktivni model. Cilj je bio da se izgradi mreža koja ima najmanju vrednost srednje kvadratne greške (MSE). MSE se računa jednačinom (5-2)

$$MSE^* = \frac{1}{2M} \sum_{m=1}^M (y_i - \tilde{y}_i)^2 \quad (5-2)$$

5.4.1 Izbor funkcije pripadnosti

Ovo je korak od ključnog značaja za pravljenje mreže. Postoji veliki izbor raspoloživih funkcija. Tabela 5.2 sumira sve funkcije pripadnosti upotrebljene u ovom radu. Nakon što su testirani svi algoritmi, algoritam sa najnižom srednjom kvadratnom greškom i sa najvišom sumom kvadrata reziduala (R^2) je izabran za treniranje mreže.

Sumu kvadrata reziduala se računa preko sledeće jednačine:

$$R^2 = \frac{SSR}{SST} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5-3)$$

SSR – regresiona suma kvadrata; SST – ukupna suma kvadrata; \hat{y}_i - predviđene vrednosti zavisne promenljive; y_i - vrednost stvarne promenljive; \bar{y} - aritmetička vrednost promenljive

Red	Ispitivane funkcije pripadnosti
1	Parcijalno definisana linearna
2	Singleton
3	Gausova
4	Trouglasta
5	Trapezoidalna
6	Parcijalno definisana linearna

U tabelama 5.2 – 5.7 prikazane su vrednosti sume kvadrata reziduala i različite vrednosti greške, kada se u eksperimentu menjala vrednost stope učenja i uz primenu različitih funkcija pripadnosti.

Tabela 5.2: Rezultati eksperimenta za različite stope učenja uz primenu Bell-shape funkcije pripadnosti. Oznake u kolonama imaju sledeće značenje: R^2 = suma kvadrata reziduala; AE = prosečna greška (*average error*); MEAN-SE = srednja kvadratna greška (*mean square error*); MED-E = srednja greška (*median error*); MEAN-AE = srednja absolutna greška (*mean absolute error*); MED-AE = srednja absolutna greška (*median absolute error*).

Stopa učenja	R^2	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,556467	-0,4785	56,47141	0	1,373072	0,100131
0,02	0,909773	-0,1216	16,96206	0	0,921519	0,086625
0,05	0,855832	-0,2947	37,7152	-6,88E-06	1,029772	0,089324
0,1	0,863743	-0,03677	17,07541	0	0,751782	0,066604
0,2	0,896538	-0,0981	5,454184	0	0,53204	0,043812
0,5	0,976821	-0,10461	4,529499	-6,80E-05	0,511609	0,037612
0,75	0,996224	-0,04541	1,186339	0	0,349988	0,046582
0,9	0,986742	-0,05461	1,28842	0	0,322595	0,033161

Tabela 5.3: Rezultati eksperimenta za različite stope učenja uz primenu Gausove funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3.

Stopa učenja	R²	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,493777	-0,09894	94,22227	0	1,126916	0,077739
0,02	0,417682	-0,01718	156,9013	0	1,296141	0,056522
0,05	0,721547	-0,11785	88,34206	-4,97E-30	1,092079	0,053303
0,1	0,936905	-0,04751	16,12336	0	0,705401	0,052524
0,2	0,829302	-0,0192	23,15881	0	0,43873	0,035798
0,5	0,987536	0,002319	3,338758	0	0,389288	0,024986
0,75	0,770553	0,006604	45,82008	0	0,727966	0,034069
0,9	0,464023	0,011619	38,21144	-2,39E-06	0,639195	0,019086

Tabela 5.4: Rezultati eksperimenta za različite stope učenja uz primenu Pi funkcije pripadnosti (Pimf). Oznake u kolonama imaju značenja opisana u tabeli 5.3.

Stopa učenja	R²	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,971135	-0,0233	1,757086	-2,46E-22	0,056327	3,34E-06
0,02	0,989295	-0,01427	2,589891	-5,40E-21	0,073478	1,67E-06
0,05	0,994278	0,011864	1,384673	0	0,047688	1,13E-06
0,1	0,997295	0,005602	0,111988	-4,77E-21	0,023445	4,77E-07
0,2	0,999774	0,004172	0,042608	-1,54E-22	0,010048	2,38E-07
0,5	0,999782	0,00248	0,036296	0	0,007021	5,39E-14
0,75	0,999299	-0,0053	0,093547	0	0,014961	0
0,9	0,999115	0,001686	0,124885	0	0,017054	0

Tabela 5.5: Rezultati eksperimenta za različite stope učenja uz primenu Sigma funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3.



Stopa učenja	R²	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,098499	-0,15723	172,966	0	3,1945	1,772864
0,02	-0,06124	-0,80513	56,22853	-0,01111	3,24522	1,734787
0,05	0,109524	0,034196	173,0031	0	3,200897	1,6768
0,1	0,121439	0,030843	115,9686	0	2,865755	1,379828
0,2	0,108461	-0,158	168,072	-0,09125	3,080419	1,573925
0,5	0,107669	0,463767	160,5188	0	3,053356	1,370592
0,75	0,115076	-0,11477	172,8954	-0,81267	3,228927	2
0,9	0,09045	-1,51986	175,6954	-2,25999	3,720444	2,706943

Tabela 5.6: Rezultati eksperimenta za različite stope učenja uz primenu Trapezoidne funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3.

Stopa učenja	R²	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,992661	0,013632	1,296549	0	0,039064	2,98E-06
0,02	0,997045	0,01537	0,90953	0	0,034629	1,55E-06
0,05	0,999869	-0,00464	0,034314	-1,13E-18	0,006359	9,54E-07
0,1	0,99979	-0,00359	0,040857	0	0,008823	4,77E-07
0,2	0,997908	0,006725	0,4055	0	0,026656	2,38E-07
0,5	0,986725	0,021469	1,571564	0	0,042755	3,47E-12
0,75	0,999833	-0,00055	0,040904	0	0,00937	0
0,9	0,999618	0,001822	0,096228	0	0,013068	0

Tabela 5.7: Rezultati eksperimenta za različite stope učenja uz primenu Trouglaaste funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3.

Stopa učenja	R²	AE	MEAN-SE	MED-E	MEAN-AE	MED-AE
0,01	0,971135	-0,0233	1,757086	-2,46E-22	0,056327	3,34E-06
0,02	0,989295	-0,01427	2,589891	-5,40E-21	0,073478	1,67E-06
0,05	0,994278	0,011864	1,384673	0	0,047688	1,13E-06
0,1	0,997295	0,005602	0,111988	-4,77E-21	0,023445	4,77E-07
0,2	0,999774	0,004172	0,042608	-1,54E-22	0,010048	2,38E-07
0,5	0,999782	0,00248	0,036296	0	0,007021	5,39E-14
0,75	0,999299	-0,0053	0,093547	0	0,014961	0
0,9	0,999115	0,001686	0,124885	0	0,017054	0




Slika 5.4: Funkcije pripadnosti

Slike 5.3 i 5.4 prikazuju izračunate vrednosti za srednju kvadratnu grešku i sumu kvadrata reziduala, za nekoliko ispitanih funkcija. Na osnovu dobijenih rezultata prikazanih u tabelama 5.3 – 5.8 i na slikama 5.3 i 5.4, izabrana je Gausova funkcija pripadnosti, jer se veoma lako uočava da je ona bolja od ostalih obzirom da je funkcija sa najnižom srednjom kvadratnom greškom i sa najvišom sumom kvadrata reziduala. Pod terminom *bolja* misli se na jasnu činjenicu koja sledi sa slike 5.3, a to je da Gausova funkcija pripadnosti daje najveću sumu kvadrata reziduala, dok je istovremeno ona najbolji izbor ako se kao kriterijum uzme srednja kvadratna greška, jer upravo za nju MSE ima najmanju vrednost.

5.4.2 Određivanje broja funkcija pripadnosti za svaku karakteristiku

Broj funkcija pripadnosti koje utiču na svaku karakteristiku je od krucijalnog značaja za oblikovanje ANFIS modela tako da je posle velikog broja pokušaja selektovan optimalni kvantitet funkcija pripadnosti. MSE i suma kvadrata reziduala su indeksi koji prikazuju performanse modela. Isto kao i pri odabiru funkcije pripadnosti i ovde se dogodilo da je za isti broj (25) funkcija pripadnosti suma kvadrata reziduala najveća, a srednja kvadratna greška najmanja. Rezultati su prikazani na sledećoj slici:



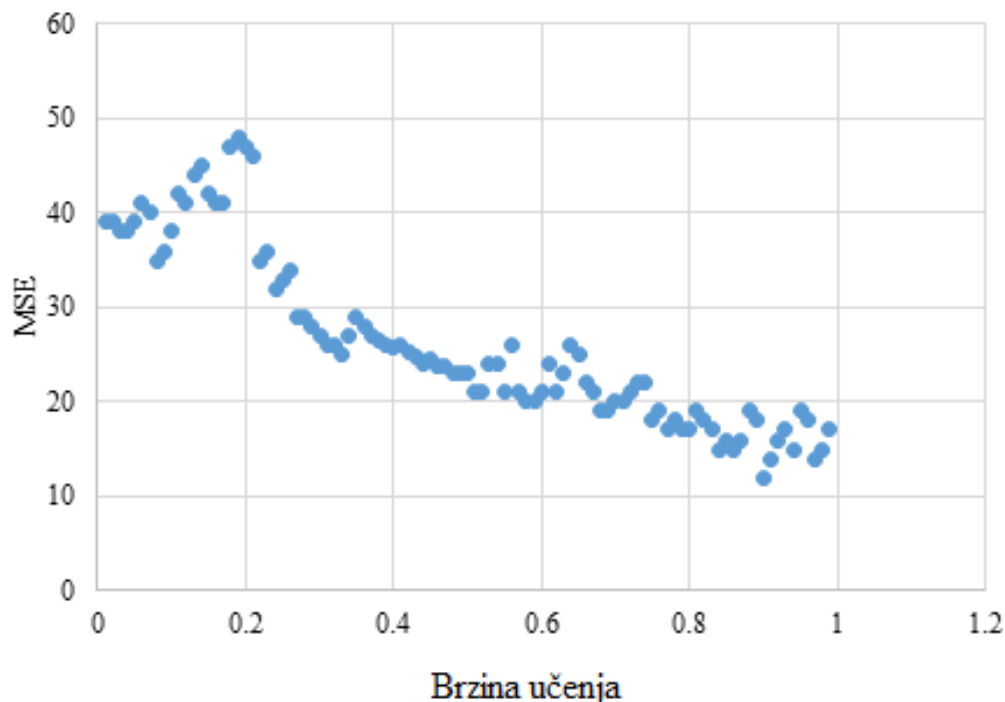
Slika 5.5: Broj funkcija pripadnosti


Slika 5.5 prikazuje uticaj broja funkcija na veličinu srednje kvadratne greške i sumu kvadrata reziduala. Na oba dijagrama se može primetiti da je suma kvadrata reziduala najveća, a srednja kvadratna greška najmanja, kada je broj funkcija pripadnosti 25, pa je prema tome odlučeno da u daljem radu broj funkcija pripadnosti bude 25.

5.4.3 Određivanje stope učenja

Menjanje stope učenja može da promeni celi ANFIS model i način na koji je model istreniran, stoga je veoma bitno da se izabere stopa učenja koja pomaže modelu da se valjano istrenira, a da se ne izgubi nijedan podatak od značaja i da brzina uspostavljanja rada modela bude razumna. Zbog toga su isprobane mnoge vrednosti stope učenja za veliki dijapazon brojeva dok su ostali parametri ostali nepromenjeni.

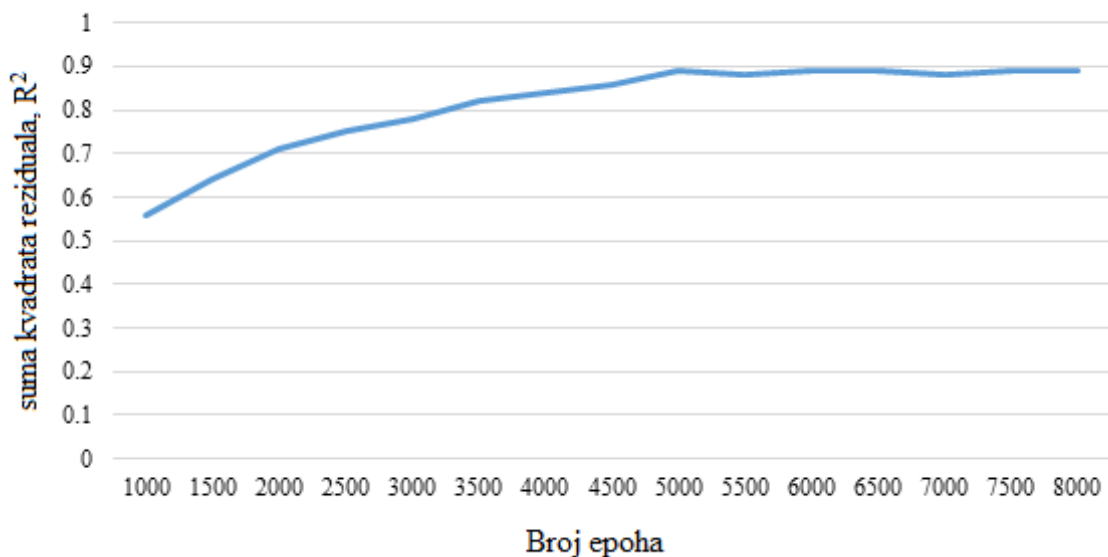
Na osnovu krivih sa slika, 0.9 je najbolja vrednost parametra. Ista procedura je primenjena za određivanje optimalnog broja epoha i pravila po kojima se prave predikcije. Na isti način su odabrani i parametri koji slede. Na slici 5.6 je prikazan rezultat. Sa slika je evidentna najniža srednja kvadratna greška u području brzine učenja 0.9 dok se maksimum vidi u zoni 0.2. Takođe, evidentna je i najbolja vrednost parametra sume kvadrata reziduala u oblasti 0.9 brzine učenja.






Slika 5.6: Brzina učenja


Na osnovu krivih sa slika, 0.9 je najbolja vrednost parametra. Ista procedura je primenjena za određivanje optimalnog broja epoha i pravila po kojima su pravljeni predikcije. Na slici je prikazan rezultat:






Slika 5.7: Broj epoha

Za određivanje optimalnog broja pravila koja utiču na rezultat predikcije, izvršena je ista procedura, a rezultati su prikazani ispod:





Slika 5.8: Broj razmatranih pravila

Ovde su prikazani svi izabrani parametri koji utiču na oblik modela i vrednost predikcije:

Tabela 5.8: Izabrani ANFIS parametri

Parametar	Vrednost
Tip funkcije pripadnosti	Gaussian
Broj funkcija pripadnosti svake karakteristike	25
Stopa učenja	0.9
Epohe	5000
Optimalan broj pravila za predikcije	10


5.5 Izbor podataka

U ovoj fazi pažljivo se selektuje skup podataka primenom klasterovanja metodom k-srednjih vrednosti. Preciznije, primenjuje se algoritam k-srednjih vrednosti na ulazne podatke i podesi se broj klastera na 1500[†]. Nakon toga se uzme centre klastera kao što je novi redukovani skup podataka. Redukovani skup podataka je prikladna reprezentacija originalnog skupa podataka i olakšava prethodno pomenute probleme.

5.6 Postavljanje funkcije pripadnosti za svaku karakteristiku


Kao što je rečeno u prethodnom poglavlju, korišćeno je 25 Gausovih funkcija za svaku karakteristiku (videti tabelu 5.1). Jasno je da Gausova funkcija ima dva parametra μ i σ . Stoga, da bi se odredio μ parametar, primenjuje se algoritam k-srednjih vrednosti na sve karakteristike i postavi broj klastera na 25 (videti tabelu 5.1).

Do optimalne vrednosti $\sigma = 0.005$ se došlo empirijskim putem uzimajući u obzir da se varijansa računa kao prosečna vrednost kvadrata odstupanja svih empirijskih posmatranja. Slike 5.9 – 5.19. prikazuju sve Gausove funkcije pripadnosti za svaku karakteristiku.




Slika 5.9: Vizualizacija funkcije pripadnosti komponente Dubina bušotine


^{2*} empirijski se došlo do ove vrednosti




Slika 5.10: Vizualizacija funkcije pripadnosti komponente Broj obrtaja dleta (ROP)




Slika 5.11: Vizualizacija funkcije pripadnosti komponente Opterećenje na dleto (WOB)




Slika 5.12: Vizualizacija funkcije pripadnosti komponente Kapacitet pumpe




Slika 5.13: Vizualizacija funkcije pripadnosti komponente Pritisak pumpe




Slika 5.14: Vizualizacija funkcije pripadnosti komponente Protok bušačeg fluida




Slika 5.15: Vizualizacija funkcije pripadnosti komponente Gustina isplake




Slika 5.16: Vizualizacija funkcije pripadnosti komponente Korigovani d-eksponent



Slika 5.17: Vizualizacija funkcije pripadnosti komponente Broj časova rada dleta



Slika 5.18: Vizualizacija funkcije pripadnosti komponente Prečnik bušotine



Slika 5.19: Vizualizacija funkcije pripadnosti komponente Gubitak isplake

5.7 Kreiranje pravila

Koristi se Sugeno-fuzzy nulti model, što znači da su krajnje posledice pravila skalari. Na primer, i pravilo može da ima formu “ako X_1 je A_1 i X_2 je A_2 i ... i X_{11} je A_{11} onda $y = z_i$ ”, gde je z_i skalar.

Inicijalna pravila se određuju kreiranjem jednog pravila za svaki pojedinačni podatak. Obzirom da postoji 1500 podataka u redukovanom skupu podataka, postoji i 1500 inicijalnih pravila. Da bi kreirali pravilo za svaki dati podatak, prvo se traži najkompatibilniju fuzzy funkciju pripadnosti za svaku karakterističnu vrednost tog podatka i onda koristi y -vrednost tog podatka kao njegov konsekvant. Izbor najkompatibilnije funkcije pripadnosti je prikazan u prethodnom poglavlju, gde je izabrana Gausova funkcija.

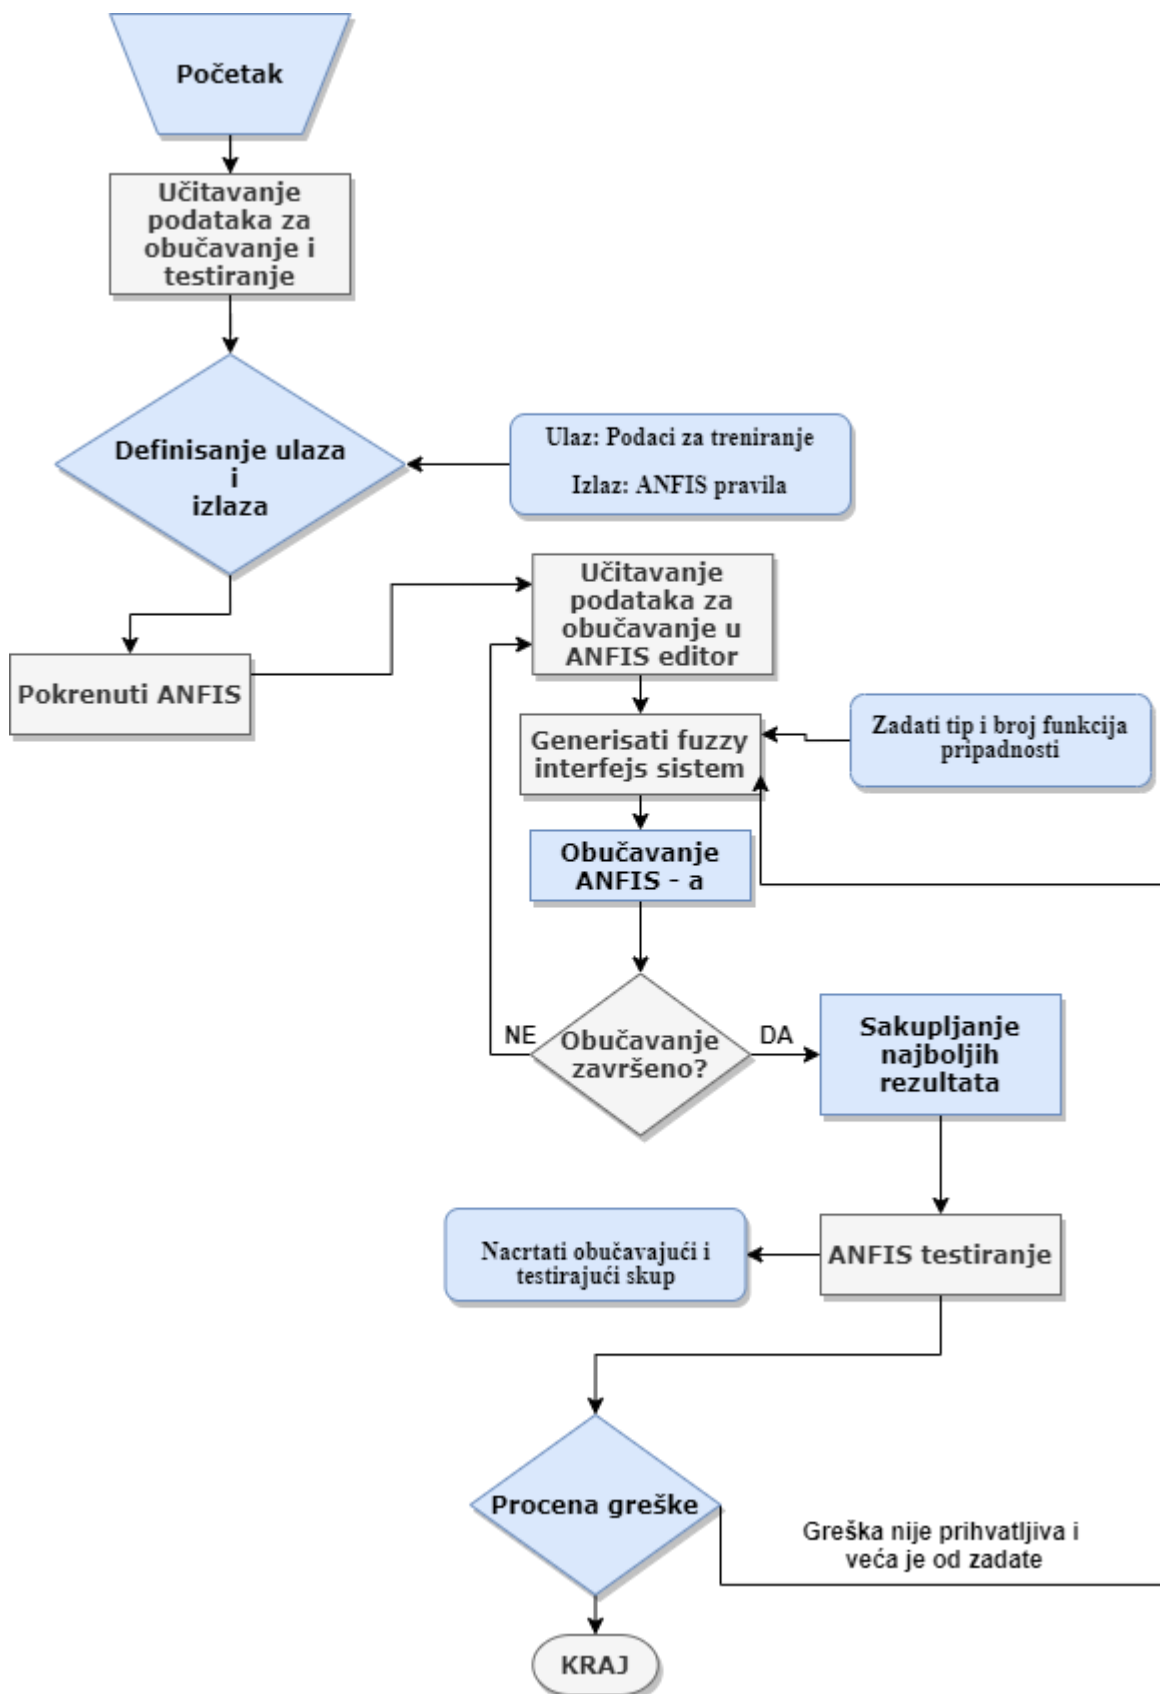
5.8 Algoritam učenja

Na osnovu jednačina pomenutih u potpoglavljju 2.10.4 na slici 5.20 sumira se algoritam učenja.

Input: podaci za treniranje $X \in R^{M \times N}$, $y \in R^{M \times 1}$


Output: ANFIS Pravila

1. Pravila = Inicijalizacija_Pravila(X, y)
2. Za svako x u X
 - a. Nađi 10 najkompatibilnijih pravila iz Pravila
 - b. Izračunaj predviđenu vrednost \hat{y}_x koristeći jednačinu 3
 - c. Ažuriraj vrednosti $z_i, i = 1, \dots, 10$ pravila spomenutih u jednačini 2, koristeći jednačinu 5



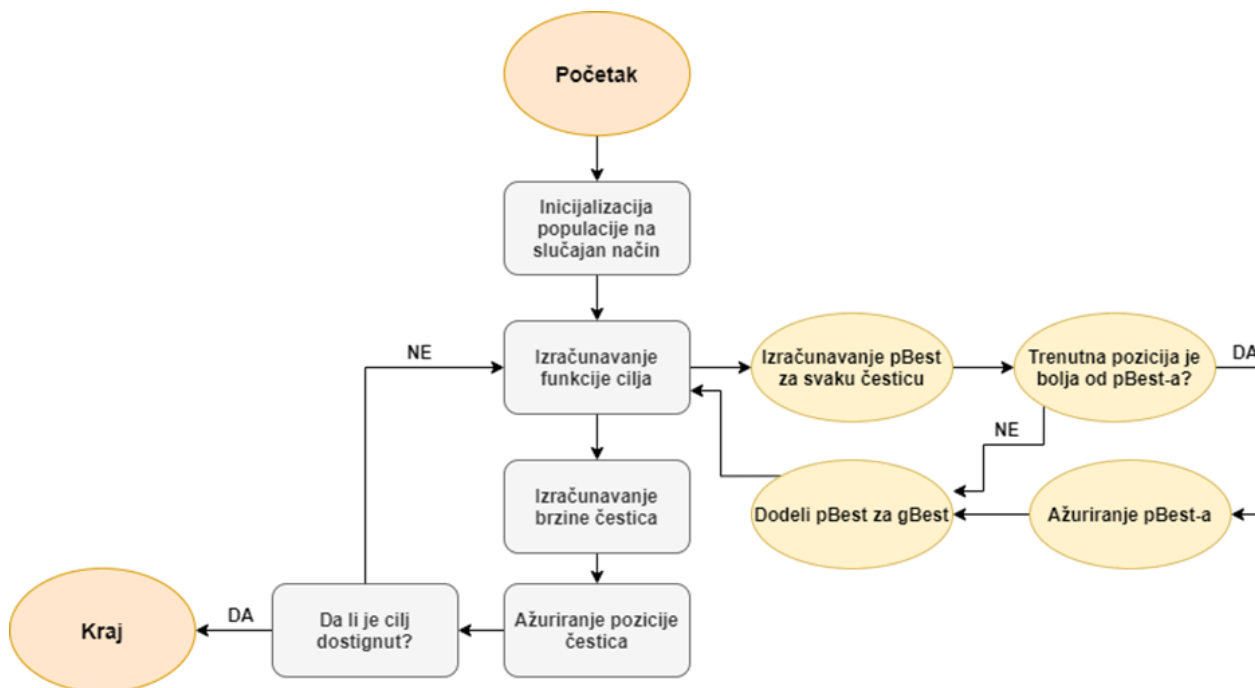
Slika 5.20: ANFIS algoritam učenja

Algoritam 1 iterativno prolazi kroz celi trenažni skup u svakoj epohi i ažurira korespondentne Z_i parametre 10 najkompatibilnijih pravila. Ovde stopa učenja igra ključnu ulogu u konvergenciji algoritma. Ako je vrednost α visoka, brzina konvergencije se smanjuje, ali konvergencija nije zagarantovana. Sa druge strane, za male vrednosti α , iako je konvergencija zagarantovana, stopa brzine učenja se smanjuje i potrebno je dosta vremena da dostigne tačku konvergencije. Drugi važan parametar u Algoritmu 1 je broj pravila koji utiču na predikcije.



Slika 5.21: Algoritam modela sa ulaznim i izlaznim podacima

Kako je algoritam adaptivnog neuro – fuzzy sistema zaključivanja već prikazan na slici 5.20, ostaje da se objasni deo optimizacije rojem čestica sa slike 5.21. Ovaj algoritam je jako sličan svim ostalim iz grupe metaheurističkih algoritama (npr. optimizacije bazirane na ponašanju kitova WOA ili vukova GWO). Nakon inicijalizacije početne grupe čestica određuju se njihove lokalne (pbest) i globalne (gbest) najbolje pozicije, pri čemu druga predstavlja najbolju poziciju u odnosu na sve druge čestice. U slučaju da je cilj dostignut algoritam dolazi do kraja. U suprotnom, vraća se na početak. Detaljniji prikaz je dat na slici 5.22 ispod i na Matlab kodu sa slike 5.23. Ovakav algoritam omogućava operacije sa velikom količinom ulaznih (a samim tim i izlaznih) podataka, što ga čini robusnim.



Slika 5.22: Dijagram za PSO metaheuristički algoritam

```

load('D.mat');
D(:,1:end-1) = (D(:,1:end-1)-min(D(:,1:end-1))) ./ (max(D(:,1:end-1))-min(D(:,1:end-1)));
% Normalization
test_ratio = 0.3;
idx = randperm(size(D,1));
train_size = floor((1-test_ratio)*length(idx));
X_train = D(idx(1:train_size),1:end-1);
Y_train = D(idx(1:train_size),end);
X_test = D(idx(train_size+1:end),1:end-1);
Y_test = D(idx(train_size+1:end),end);
% PSO
num_particles = 20;
dim = 12;
lower_bound = 1;
upper_bound = 25;
bounds_1 = [lower_bound, upper_bound];
bounds_2 = [0, 150];
max_iter = 20;
load('Best_test.mat')
global mf_type
mf_type = 'Gaussinan';
numRules = 1500;
[~,C_train] = kmeans([X_train,Y_train], numRules);
X_train = C_train(:,1:end-1);
Y_train = C_train(:,end);
for i=1:size(X_test,1)
    xt = [X_test(i,:),Y_test(i)];
    dist = sum((C_train(:,1:end) - xt).^2,2);
    [~,ind] = min(dist);
    X_test(i,:) = C_train(ind,1:end-1);

```

```

end

[~, C] = kmeans(X_train,num_cluster);
all_mf = get_all_mf_values_2(X_train,C);
all_mf_test = get_all_mf_values_2(X_test,C);

numSampleInFitness = 5;

% generate population

Rules = [];

%=====

stopper = 0;
while(size(X_train,1)>1 )
    if stopper > 100
        break;
    end
    for i = 1:num_particles
        temp = randi([lower_bound, upper_bound], 1,dim-1);
        temp(end+1) = randi(30);
        particle{i}.pos = temp;
        particle{i}.best_pos = temp;
        particle{i}.velocity = unifrnd(-(upper_bound-lower_bound),upper_bound-lower_bound,[1,dim]);
        particle{i}.comGrades = get_all_comGrade_2(X_train, particle{i}.pos(1:end-1), all_mf);
        particle{i}.fitness = pso_fitness(particle{i}, X_train, Y_train, numSampleInFitness);
        particle{i}.best_fitness = particle{i}.fitness;
    end
    swarm_best_particle.pos = [];
    swarm_best_particle.fitness = 1000;
    best_selected_idx = [];
    stopper = stopper+1;
    disp(['Curent train-size is:',num2str(size(X_train,1))])
    for epoch=1:max_iter
        swarm_best_particle.fitness

```

```

for i = 1:num_particles
    if ((particle{i}.fitness < swarm_best_particle.fitness) | (swarm_best_particle.fitness==1000))
        swarm_best_particle.fitness = particle{i}.fitness;
        swarm_best_particle.pos = particle{i}.pos;
        swarm_best_particle.comGrades = particle{i}.comGrades;
    end
end
for i = 1:num_particles
    particle{i}.velocity = update_velocity(particle{i}, swarm_best_particle);
    particle{i}.pos = update_position(particle{i}, bounds_1, bounds_2);
    particle{i}.comGrades = get_all_comGrade_2(X_train, particle{i}.pos(1:end-1), all_mf);
    [particle{i}.fitness,selected_idx] = pso_fitness(particle{i}, X_train, Y_train, numSampleInFitness);
    if particle{i}.fitness < particle{i}.best_fitness
        particle{i}.best_fitness = particle{i}.fitness;
        particle{i}.best_pos = particle{i}.pos;
        best_selected_idx = selected_idx;
    end
end
if swarm_best_particle.fitness<1
    break;
end
end
Rules = [Rules;swarm_best_particle.pos];
X_train(best_selected_idx,:) = [];
Y_train(best_selected_idx,:) = [];

```

```
end

numRuleInPrediction = 2;

[Y_hat,mse_test,normalized_norm_test]=test_anfis_2(X_test,Y_test,Rules, all_mf_test,
all_comGrade_test, numRuleInPrediction);

disp(['****ANFIS Results: TestMSE: ',num2str(mse_test)', Normalized norm of Test errors:
',num2str(normalized_norm_test)])
```

Slika 5.23: Matlab kod za učitavanje podataka i primenu PSO algoritma

6 PRIMENA MODELA ZA UPRAVLJANJE CIRKULACIJOM – STUDIJA SLUČAJA ZA NAFTNA POLJA AGHAJARI I GADVAN

6.1 Eksperimenti i rezultati

Ovo poglavlje izlaže dobijene rezultate predviđanja predložene ANFIS metode i poredi ih sa druga dva popularna metoda regresije, odnosno stablo odlučivanja i algoritam k-najbližih suseda.

6.2 Metrike procena

Da bi se procenile prediktivne performanse ANFIS modela, korišće se sledeće metrike koje se često koriste u problemima regresije.

Srednja kvadratna greška:

$$MSE\ddagger = \frac{1}{2M} \sum_{m=1}^M (y_i - \tilde{y}_i)^2 \quad (4-1)$$

Normalizovana greška (*Normalized Norm Of Errors*):

$$NME = \frac{1}{M} \left(\sum_{m=1}^M (y_i - \tilde{y}_i)^2 \right)^{\frac{1}{2}} \quad (4-2)$$

Metrike evaluacije prikazane u jednačinama (4-1 i 4-2) su slične jedna drugoj iako izračunavaju prosečnu grešku predikcije na dva različita načina. U jednačinama, M , y_i , \tilde{y}_i je ukupan broj uzoraka, prava y -vrednost i -tog uzorka i procenjena vrednost, redom.

6.3 Rezultati


Skup podataka je podeljen na skup vrednosti treninga i test skup u proporciji 70% - 30%, redom. Skup za trening se koristi za optimizaciju ANFIS parametara, a test skup se koristi za ispitivanje performansi ANFIS-a. U tabeli 6.1 (u Prilogu) prikazan je skup podataka prikupljenih na 100 različitih dubina na bušotini Gadvan, radi ilustracije. Ukupno je u ovom istraživanju prikupljeno 12270 takvih skupova podataka koji su korišćeni u optimizaciji modela.

Tabela 6.2 prikazuje dobijene rezultate testova predloženog ANFIS metoda i poredi ih sa dve popularne metode regresije u mašinskom učenju. Kako pokazuju rezultati, ANFIS radi mnogo bolje i njegove predikcione performance su superiornije u poređenju sa ostalim metodama.

Tabela 6.1: Rezultati predikcija dobijenih preko test skupa podataka

Metoda	MSE	Normalizovana greška
k-NN	56.23±68.7	0.2353±0.1821
Stablo odlučivanja	26.56±33.15	0.1706±0.1141
ANFIS	6.5±1.0	0.08±0.05

Nakon učitavanja, ulazni podaci su razdvojeni na grupu za obučavanje i grupu za testiranje. Pronađene su greške stabla za odlučivanje (eng. decision tree) i k- najbližih suseda (eng. kNN algorithm). Zatim su podešeni parametri mreže, stopa obučavanja, odabir tipa funkcije pripadnosti i broj funkcija pripadnosti. Rezultat rada koda prikazan je na slici 6.1, ispod. Da bi se bolje prikazale performanse predloženog ANFIS modela, slika 6.1 prikazuje predikcioni dijagram ANFIS-a za skup podataka za testiranje sa njegovim pravim vrednostima. Kao što je prikazano, ANFIS pokazuje dobro predikciono ponašanje.



Slika 6.1: Dijagram predikcija ANFIS-a za skup podataka za testiranje

6.4 Novi problem

Iako je rezultat predloženog ANFIS modela superiorniji od ostala dva metoda, i dalje ne daje dobre rezultate na polju predikcija ozbiljnih i kompletnih gubitaka. Ovo može biti rezultat loše distribucije podataka. Loša distribucija podataka nije tako redak slučaj u istraživanjima u praksi i njen uzrok može biti različit. Raspodela skupa podataka predstvalja samo sredstvo do cilja, a ne sam cilj zadatka, pa upravo zbog ovoga ona i nije od prevelike važnosti i predstavlja početni korak. Neki od mogućih uzroka loše distribucije su: ekstremne vrednosti, preklapanje procesa, nedostatka broja podataka ili veliki broj podataka čije su vrednosti blizu nula ili nekih granica koje su zapravo gornji i donji opseg te veličine, procesa...

Distribucija tj. raspodela podataka jeste veličina iz verovatnoće i statistike. Česti oblici raspodele podataka su: uniformna, normalna (Gausova) koje je u obliku zvonaste krive, trougaona, bimodalna... Takve situacije se dešavaju ređe nego curenje i parcijalni gubici pa samim tim postoji manje podataka za takve slučajeve. Stoga, da bi napravili ANFIS model sa visokom tačnošću i alatom za predviđanje svih tipova gubitaka cirkulacije i u slučajevima oskudnih baza podataka, izvršena je modifikacija ANFIS modela.

6.5 Rešenje

U cilju rešavanja gore pomenutog problema, pokušana je modifikacija različitih delova modela i najbolji rezultati su dobijeni kada je pokušana modifikacija dela modela koji generiše pravila. Umesto ANFIS modela, dozvoljeno je PSO da generiše pravila, uneli ih nazad u ANFIS model i pustili ga da izvrši predikciju.

Kod za poboljšanje performansi PSO, istraživači su modifikovali PSO na više načina.

Pseudo kod PSO i analitički opis je:

Initialize the population randomly

While (Population Size)

{

Loop

Calculate fitness

If fitness value is better from the best fitness value (pbest) in history then

Update pbest with the new pbest

End loop

}

Select the particle with the best fitness value from all particles as gbest

While maximum iterations or minimum error criteria is not attained

{

For each particle

Calculate particle velocity by equation (1)

Update particle position according to equation (2)

Next

}

}



Slika 6.2: Prikaz dijagrama toka PSO

6.6 Rezultati

Skup podataka je podeljen na skup za obučavanje i test skup u proporciji 70% i 30% respektivno kao najcelishodnijem pristupu ocenjivanja, po uzoru na ranije primere primene ANFIS modela u predviđanju ponašanja različitih sistema (Babarinde T.O. i sar., 2020; Sada S.O. i sar., 2021). Trenažni skup podataka je korišćen za optimizaciju ANFIS i PSO_ANFIS parametara a test skup za istraživanje performansi ANFIS-a. Tabela 6.3 pokazuje dobijene rezultate testova predloženih metoda i poredi ih sa dve popularne metode regresije u mašinskom učenju (stablo odlučivanja i algoritam k-najbližih suseda).

Kao što rezultati pokazuju, PSO_ANFIS ostvaruje bolje rezultate u poređenju sa ostalim metodama i njegove performanse predviđanja su daleko superiornije.

Tabela 6.2: Dobijeni rezultati predikcija preko skupa podataka za testiranje


Metod	MSE	Normalizovana greška
k-NN	56.23±68.7	0.2353±0.1821
Stablo odlučivanja	26.56±33.15	0.1706±0.1141
ANFIS	6.5±1.0	0.08±0.05
PSO+ANFIS	0.92±0.78	0.022±0.01

U svrhu poboljšanja korišćenog algoritma, on je modifikovan i nadograđen metodom odabrane optimizacije – PSO algoritmom. Nakon učitavanja ulaznih podataka i njihove normalizacije podaci su ponovo podeljeni na jednu grupu za obučavanje i drugu za test. Prvu grupu čini matrica od 1500x11 ulaznih i 1500x1 izlaznih podataka, a drugu grupu za test čak 3673x11 ulaznih i 3673x1 izlaznih podataka za koje je napomenuto da predstavljaju poslovnu i državnu tajnu i koji su na raspolaganju članovima komisije na uvid.


Nakon odabira funkcije pripadnosti iz prethodnih poglavlja vrši se optimizacija postojeće mreže, biraju se trenutna i globalna najbolja pozicija, kao što je objašnjeno u prethodnom poglavlju gde je prikazan i pseudo kod PSO algoritma. Za svaku česticu iz roja se ažurira pozicija u svim iteracijama. Najbolja pozicija se bira za pravila (promenljiva rules u kodu u prilogu). Kodovi su pokretani više puta tako da su najbolji rezultati zadržani. Najbolji rezultati dobijaju se za trougaonu

funkciju pripadnosti, stopu učenja od 0,9, pri čemu se obučava na 70% postojećih podataka, a testira na 30%. Što se tiče fuzzy logike, korišćeno je 10 pravila u predviđanju, a broj funkcija pripadnosti po obeležju je 25.

Za bolji pregled performansi predloženog ANFIS kao i PSO_ANFIS modela, slika 6.3 i slika 6.4 respektivno prikazuju njihove dijagrame predikcija za skup podataka za testiranje. Kao što je prikazano, oba predložena metoda rade dobro i obezbeđuju dobre predikcije ponašanja.



Slika 6.3: PSO_ANFIS dijagram predikcija skupa podataka za testiranje.



Slika 6.4: PSO_ANFIS dijagram predikcija skupa podataka za testiranje.

Matematički model koji je prikazan u ovom poglavlju definisan je u cilju procene promenljivih u toku procesa bušenja. Zasniva se na generisanju velikog broja ulaznih podataka koji su kategorisani u manje grupe podataka, što je od posebne važnosti za dobijanje boljih predikcija. Posebna pažnja posvećena je selekciji promenljivih i problema koji u ovom postupku mogu da se pojave, a koji imaju bitan uticaj na kvalitet eksperimenta. Samom ANFIS modelu potrebno je nekoliko parametara za rad, kao što su funkcije pripadnosti, broj funkcija pripadnosti definisanih za svaku karakteristiku, stopa učenja, broj pravila u skladu sa predikcijama i broj epoha učenja koji su svi detaljno objašnjeni.

Izbor odgovarajuće funkcije pripadnosti izvršen je na osnovu algoritma sa najnižom srednjom kvadratnom greškom na osnovu svih definisanih funkcija pripadnosti definisanih u radu. Na osnovu MSE i sume kvadrata reziduala određen je optimalni broj funkcija pripadnosti. Stope učenja, optimalan broj epoha i optimalan broj pravila koji utiču na rezultat predikcije određeni su na osnovu analize različitih vrednosti datih veličina u cilju odabira najbolje vrednosti parametra. Izbor podataka, kreiranje pravila i proces učenja koji su detaljno objašnjeni imaju za cilj smanjivanje pojave greške u predviđanju.

U radu su data dva primera validacije opisanih modela. Osnovni ANFIS model upoređen je sa metodama regresije u mašinskom učenju. Rezultati validacije modela potvrđuju da se ANFIS model pokazao mnogo kvalitetnijim i da su njegove mogućnosti predikcije bolje u odnosu na one sa kojima je poređen, čime se opravdava njegova primena. I pored ovih kvalitetnih rezultata, uočeno je tokom istraživanja da ANFIS model ne daje dobre rezultate na polju predikcija ozbiljnih i kompletnih gubitaka, što se može pojaviti kao rezultat loše distribucije podataka.

Iako se ovakve situacije ređe dešavaju, u cilju složenije analize i traženja ne samo optimalnog nego i rešenja sa najboljim performansama, definisan je model sa visokom tačnošću i alatom za predviđanje svih tipova gubitaka cirkulacije čak i u onim slučajevima kada je baza

podataka nedovoljna za osnovnu analizu. U cilju ove optimizacije primenjena je PSO tehnika, koja je detaljno objašnjena, i integracijom sa osnovnim modelom formiran je PSO_ANFIS unapređen model. Validacija modela je primenjena na dva skupa podataka: trenažni na koji je primenjen ANFIS model i PSO_ANFIS skup podataka, a rezultati su takođe upoređeni sa metodama regresije u mašinskom učenju.

Rezultati istraživanja pokazuju da se unapređeni PSO_ANFIS model ponaša daleko kvalitetnije u odnosu na sve i standardne modele i osnovni ANFIS model, zatim da obezbeđuje bolje predikcije ponašanja, čak i slučaju nepotpunih skupova podataka, čime su svi ciljevi istraživanja u ovom radu ispunjeni. Rezultati istraživanja pokazuju da se prikazani ANFIS i PSO_ANFIS model mogu kvalitetno koristiti u slučajevima prevencije gubitka isplake.

7 ZAKLJUČAK

- Cirkulacija isplake predstavlja neodvojivi proces pri bušenju u inženjerstvu nafte i gasa. Gubici isplake su neminovni, često nepredvidivi po intenzitetu i vremenu nastanka. U disertaciji je dat predlog za korišćenjem veštačke inteligencije, odnosno fuzzy logike za modeliranje procesa gubitaka isplake u cirkulaciji a u kojima dominira neizvesnost i subjektivnost kod definisanja parametara koji opisuju cirkulaciju, kao i neuronskih mreža za predikciju parametara koji definišu intenzitet cirkulacije.
- Razvijeni je adaptivni neuro fuzzy model zaključivanja ANFIS (eng. Adaptive Neuro Fuzzy Inference System) za predikciju količine gubitaka cirkulacije isplake u naftnoj i gasnoj industriji. Predloženi model obezbeđuje bolje predikcije ponašanja nego uobičajeni kNN (eng. k-nearest neighbors) i metode stabla odlučivanja (MSO). Iako je ulazni skup podataka nestabilan za određene vrednosti gubitaka, predloženi adaptivni neuro fuzzy sistem zaključivanja PSO_ANFIS (eng. Particle Swarm Optimization Adaptive Neuro Fuzzy Inference System) pokazuje dobro ponašanje i sa takvim vrednostima.
- Hipoteze na kojima je baziran naučni rad, izložen u disertaciji, zasnivaju se na činjenici da ne postoje standardizovani modeli kojima se strukturno i konceptijski definiše gubitak isplake tokom procesa bušenja. Identifikacijom svih relevantnih parcijalnih parametara koji utiču na proces bušenja, formiran je model predviđanja koji je primenljiv za sve uslove bušenja, uz ostvarivanje visokog stepena pouzdanosti, i konačno smanjenja troškova procesa bušenja.
- Gubitak isplake tokom procesa bušenja je složen problem na koji utiču mnogi parametri, a koji su identifikovani u radu. Pored promene pritiska u formaciji, karakteristika fluida, parametri bušenja, vremena bušenja i dubine bušenja, takođe su identifikovani parametri koji utiču na gubitak isplake. Ranija istraživanja na ovu temu bila su vezana na sprečavanje gubitka isplake, a mali ili skoro beznačajan uticaj se davao prevenciji samog problema, što se u naftnoj industriji tokom poslednjih decenija pokazalo kao ozbiljan faktor koji utiče na produktivnost. Neuro fuzzy sistemi zaključivanja, posebno razvijeni ANFIS model pokazao se kao dobar za primenu u naftnoj industriji upravo zbog mogućnosti poboljšanja parametara bušenja i kategorizacije ležišta. Adaptivne mreže koje u sebi integrišu neuronske mreže i fuzzy logiku i povezuju ulazne i obrađene podatke, posebno su interesatne i nalaze dobru primenu u ovoj oblasti. Osnova ovakvog koncepta leži u mapiranju ulaznog skupa podataka sa odgovarajućim komponentama izlaznog skupa. U samom radu, detaljno je objašnjena procedura fuzzy logike i osnovna pravila na kojima se ona zasniva: fuzzy skupovi, funkcije pripadnosti, logički operatori i pravila ako-onda, sa datim primerima, radi boljeg tumačenja problematike. Razrađeni su i fuzzy sistemi zaključivanja, koji su pokazali visoku sposobnost za predviđanje i procenu sposobnosti naftnih nalazišta. Takođe je precizno opisana tehnika adaptivni neuro fuzzy sistem zaključivanja ANFIS, karakteristike modela i način na koji ovaj model može da se poveže sa modelima gubitka isplake. Sve ovo podrazumeva detaljnu analizu neuronskih mreža, prikaz osnovne strukture mreže, procese i algoritme učenja sa posebnim akcentom na adaptivne mreže koje su primenjene u istraživanju.
- U radu je formiran adaptivni neuro fuzzy sistem zaključivanja ANFIS model hibridne strukture za analizu značajnih parametara bušenja sa posebnim akcentom na gubitak ispirog fluida. Metoda je primenjena uzimajući u obzir parcijalne pokazatelje, predviđanje njihovog kretanja i dimenziju optimizacije u odnosu na indikatore povezane sa geološkim karakteristikama izbušenih formacija, fizička svojstva spirog fluida, režimom rada bušačih postrojenja i tehničkih karakteristika postrojenja. Parcijalni pokazatelji su medjusoom

nekoherentni i nekonzistentni. Zbog toga je izvršena identifikacija korišćenjem fuzzy logike, fazi skupova i funkcija pripadnosti. Razmatrana je i mogućnost sinteze analiziranih parametara nakon definisanja strukture njihove nezavisnosti.

- Performanse adaptivnog neuro fuzzy sistema zaključivanja ANFIS i predviđanja upoređene su sa performansama neuronskih mreža (eng. Neural networks NN) i proširenog Kalmanovog filtera predviđanja (eng. extended Kalman filter EKF) (Poglavlje 5.) u cilju verifikacije kvaliteta novo postavljenog modela. Prednost ANFIS-a nalazi se u činjenici da je projektovan da optimizuje arhitekturu koja daje najbolju efikasnost u predviđanju. Skup podataka koji je korišćen u prikazanom modelu dobijen je iz dnevnih izveštaja sa bušotina, izveštaja o bušaćem fluidu iz 73 bušotine, čime je obezbeđen kvalitet prikazanih rezultata i njihova merodavnost.
- Rezultati istraživanja u ovoj disertaciji su pokazali da se primenjeni adaptivni neuro fuzzy sistem zaključivanja ANFIS i PSO_ANFIS modeli mogu kvalitetno koristiti u slučajevima prevencije gubitka isplake, odnosno za upravljanje tehno ekonomskim parametrima bušenja.

LITERATURA

1. Alamgro S. P. B., Frates C., Garand J., Meyer A., Sealing fractures: Advances in lost circulation control treatments, *Oilfield Review* 26(3):4-13, 2014
2. Aghanabati A., Geological Survey of Iran, Geological Survey of Iran, p. 586, 2004
3. Alkinani M., Al-Hameedi A., Dunn-Norman S., Flori R., Hilgedick S., Alkhamis M., Alshawi Y., Al-Maliki M., Alsaba M., Amer A., Investigation of the relationship between rate of penetration and mud weight based on the hardness of the rock, SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition, SPE-192401-MS, 2018
4. Alkinani M., Al-Hameedi A., Flori R., Dunn-Norman S., Hilgedick S., Amer A., Drilling Strategies to Control Lost Circulation in Basra Oil Fields, Iraq, Conference AADE-18-FTCE-059, 2018
5. Alvarado M., Sheremetov L., Cantu F., Autonomous Agents and Operational: The Future of AI Applications in Petroleum Industry, *Expert Syst. Appl.* 26, 3-8, 2004
6. Babarinde T.O., Akinlabi S.A., Madyira D.M., Ekundayo F.M., Adedeji P.A., Dataset of experimental and adaptive neuro-fuzzy inference system (ANFIS) model prediction of R600a/MWCNT nanolubricant in a vapour compression system, *Data in Brief* 32: 106316, 2020
7. Behnoud far P., Hosseini P., Estimation of lost circulation amount occurs during under balanced drilling using drilling data and neural network, *Egypt. J. Petrol.* 26 (3) (2017) 627-634
8. Bello O., Teodoriu C., Yaqoob T., Oppelt J., Holzmann J., Obiwanne A., Application of Artificial Intelligence Techniques in Drilling System Desing and Operations: A State of the Art Review and Future Reserch Pathways, SPE-184320-MS, 2016
9. Carrasco E.F., Rodriguez J., Punal A., Roca E., Lema J.M., Rule-based diagnostic and supervision of a pilot-scale wastewater treatment plant using fuzzy logic techniques, *Expert Syst. Appl.* 22, 11–20, 2002
10. Chen P., Rahman M.M., Sarma H.K., Interaction Between Hydraulic Fracture and Natural Fracture-A New Prediction Model by Adaptive Neuro-Fuzzy Inference System (ANFIS)", SPE, 171927-MS, 2014
11. Chiu S.L., Fuzzy Model Identification Based on Cluster Estimation, *Inteligent Fuzzy Systems*, 2: 234-244, 1994
12. Delhommelle J., Machine learning, *Molecular Simulation*, 44:11, 865, 2018
13. Devereux S., *Drilling for Oil & Gas: A Nontechnical Guide*, Pennwell Corporation, Pages 283-290, 1999

14. Dragović I., Konzistentan neuro-fuzzy sistem zaključivanja, Doktorska disertacija, Univerzitet u Beogradu, Fakultet organizacionih nauka, Beograd, 2016
15. Dupriest F.E., Fracture Closure Stress (FCS) and Lost Returns Practices, SPE 92192, SPE/IADC Drilling Conferences, Amsterdam, Netherlands, 23-25 February 2005
16. EI-Shal S.M., Morris A.S., Fuzzy expert system for fault detection in statistical process control of industrial processes, IEEE Trans. Syst., Man Cybernet., Part C: Appl. Rev. 30, 281–289, 2000
17. Esogbue, A.O., Kacprzk, J., Fuzzy dynamic programming: a survey of main development and applications, Arch. Control Sci., Vol. 5(XLI, 1-2): 39-59. 1996
18. Feng Y., Gray K.E., Modeling Lost Circulation Through Drilling-Induced Fractures, Spe Journal, 1 – 19, 2017
19. Ghazanfari M., Rezaei M., An Introduction to the Theory of Fuzzy Collections, Publications of the University of Science and Technology of Iran, 2014
20. Hashemi S., Soleimani B., Naseri F., Investigation of the Problems of Convection Tubes and Zone Adjustment Pressure Changes in Section 7 of Gachsaran Formation in Maroon Oilfield", Oil Research, No. 40, Winter 2013
21. Howard C.G., Scott P.P., An Analysis and the Control of Lost Circulation, AIME, Vol. 192, 1951
22. Ivan, C., Bruton, J., Bloys, B., How we can best manage lost circulation, AADE03-NTCE-38, AADE National Technology Conference "Practical Solutions for Drilling Challenges", Houston, Texas, 2003
23. Jang J.S., ANFIS: adaptive-network-based fuzzy inference system, IEEE Transactions on Systems, Man and Cybernetics 23, 1993
24. Jang J.S., Sun C.T., Mizutauai E., Neuro-fuzzy and soft computing", Prentice-Hall international Inc, 1997
25. Jovanović R.Ž., Fazi logika, modelovanje i upravljanje, Mašinski fakultet Univerziteta u Beogradu, 2020
26. Kasabov N., Decision support systems and expert systems, in: M. Arbib (Ed.), Handbook of Brain Study and Neural Networks, MIT Press, 2002
27. Kia S.M., Fuzzy Logic in Matlab, Fourth Edition, Kian University Press, 2014
28. Kovandžić M., Optimalno prepoznavanje izvora zvuka veštačke inteligencije i lokalizacija primenom metoda veštačke inteligencije, Doktorska disertacija, Univerzitet u Nišu, Mašinski fakultet, 2020.
29. Lababidi H.M.S., Garrouch A.A., Fahim M., A fuzzy heuristic approach for predicting asphaltene precipitation potential, Energy Fuels 18, 242–250, 2004

30. Li Z., Chen M., Jin Y., Lu Y., Wang H., Geng Z., Wei S., Study on Intelligent Prediction for Risk Level of Lost Circulation While Drilling Based on Machine Learning, 52nd U.S. Rock Mechanics/Geomechanics Symposium, Seattle, Washington, 2018
31. Medsker L.R., Hybrid Intelligent System, Kluwer Academic Publisher, 1995
32. Mendel, J.M., Introduction To Type-2 Fuzzy Sets and Systems. California: University of Southern California, 2010
33. Moazzeni A.R., Nabaei M., Ghadami S.J., Prediction of Lost Circulation Using Virtual Intelligence in one of the Iranian Oilfields”, SPE, 136992, 2010
34. Mohaghegh, S.D., Recent Developments in Application of Artificial Intelligence in Petroleum Engineering, J. Pet. Technol, 86-91, 2005
35. Murchison, W.J., Lost Circulation for the Man on the Rig, Murchison Drilling Schools, Inc., 2006
36. Nikravesh M., Aminzadeh F., Zadeh L. (Eds), Soft Computing and Intelligent Data analysis in Oil Exploration, Elsevier Science, 2002
37. Petrović D.V, Tanasijević M., Milić V., Lilić N., Stojadinović S., Svrkota I., Risk assessment model of mining equipment failure based on fuzzy logic, Expert Systems with Applications, 41(18), 8157-8164, 2014
38. Poli R., Kennedy J., Blackwell T., Particle swarm optimization -An Overview, Swarm Intelligence, 1: 33–57, 2007
39. Ramezani R., Maadi M., Khatami S. M., A novel hybrid intelligent system with missing value imputation for diabetes diagnosis, Alexandria Engineering Journal 57 (3): 1883 – 1891, 2018
40. Razeghi S. A., Mitrovic V., Marfo S. A., The influence of steam injection for Enhanced Oil Recovery (EOR) on the quality of crude oil, Petroleum Science And Technology 35 (13): 1334 – 1342, 2017
41. Sada S.O., Ikpeseni S.C., Evaluation of ANN and ANFIS modeling ability in the prediction of AISI 1050 steel machining performance, Heliyon 7: e06136, 2021
42. Sheremetov L., Batyrsgin I., Filatov D., Fuzzy Expert System for Solving Lost Circulation Problem, Elsevier, Applied soft computing 8, 14-29, 2008
43. Simonović B., Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja, Doktorska disertacija, Univerzitet u Nišu, Mašinski fakultet, 2016.
44. Wang L.X., A course in fuzzy system and control, Prentice-Hall international Inc, 1997
45. Yildiz A., Alpaslan Yarar A., Yurdagül Kumcu S., Ihsan Marti A., Numerical and ANFIS modeling of flow over an ogee-crested spillway, Applied Water Science (2020) 10:90

46. Zadeh, L.A., Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic, *Fuzzy Sets and Systems, Int. J. Soft Comput. Intelligence*, 90(2): 111-127, 1997

47. Zhang Z., Zhang Ch. (Eds.), *Agent-Based Hybrid Intelligent Systems: An Agent-Based Framework for Complex Problem Solving*, *Lecture Notes in Artificial Intelligence 2938*, Springer Verlag, 2004

PRILOG

Tabela 6.1: Ulazni podaci na bušotini Gadvan, prikupljeni na 100 različitih dubina. Oznake kolona imaju sledeća značenja: (1) dubina, m (2) brzina bušenja, m/h (3) opterećenje na dleto, kN (4) pritisak pumpe, kPa (5) brzina protoka fluida, l/min (6) gustina fluida za bušenje, g/cm³ * 10 (7) d-eksponent (8) broj časova rada dleta, h (9) prečnik bušotine, cm (10) gubitak isplake, 158 * dm³ / h

1	2	3	4	5	6	7	8	9	10	11
4368	0.47	3.2	96	2744.9	215	81.09	1.751	40.1	8.375	0
4369	0.42	5.2	98	2757.7	217	81.26	1.983	42.5	8.375	0
4370	0.99	3.3	98	2803.6	218	81.16	1.614	43.5	8.375	0
4371	0.45	4.1	98	2796.6	217	80.25	1.859	45.7	8.375	0
4372	6.12	22.9	81	2791.3	218	79.40	2.017	45.9	8.375	0
4373	0.50	39.7	90	2669.4	214	80.56	3.725	0.0	8.375	0
4374	0.14	17.3	136	2424.7	233	80.47	3.267	6.9	8.375	0
4375	2.85	11.6	94	2654.5	208	80.15	1.881	7.3	8.375	0
4376	3.77	26.5	78	2619.0	209	80.31	2.302	7.6	8.375	0
4377	3.75	8.9	102	2678.0	205	80.29	1.691	7.8	8.375	0
4378	3.85	22.9	82	2612.3	211	80.26	2.189	8.1	8.375	0
4379	2.58	30.2	78	2599.9	210	80.73	2.582	8.5	8.375	0
4380	2.58	27.6	79	2584.2	211	80.57	2.494	8.9	8.375	0
4381	6.37	29.9	78	2547.7	210	80.73	2.206	9.0	8.375	0
4382	13.42	19.8	79	2554.6	211	81.19	1.628	9.1	8.375	0
4383	5.52	32.1	78	2603.1	209	80.76	2.328	9.3	8.375	0
4384	3.08	26.1	77	2636.7	207	80.44	2.364	9.6	8.375	0
4385	7.27	27.9	77	2639.9	207	80.45	2.087	9.7	8.375	0
4386	3.27	10.9	97	2628.5	208	80.63	1.816	10.0	8.375	0
4387	2.62	1.5	103	2616.7	208	80.69	1.206	10.4	8.375	0
4388	2.31	1.8	101	2608.8	209	80.73	1.268	10.9	8.375	0
4389	3.00	1.2	98	2294.7	197	80.73	1.123	11.2	8.375	0
4390	3.40	2.6	106	2603.0	208	80.84	1.297	11.6	8.375	0
4391	3.43	1.4	105	2599.4	208	80.91	1.141	11.8	8.375	0
4392	3.13	1.7	106	2637.5	209	80.94	1.213	12.1	8.375	0
4393	2.12	1.7	106	2630.1	210	81.04	1.276	12.6	8.375	0
4394	1.48	8.2	96	2631.7	212	80.86	1.889	13.3	8.375	0
4395	4.33	26.2	80	2657.6	214	80.88	2.248	13.5	8.375	0
4396	3.00	26.4	79	2664.3	212	81.07	2.394	13.8	8.375	0
4397	8.35	28.3	79	2634.2	213	81.16	2.054	14.0	8.375	0
4398	5.36	31.2	79	2663.9	211	81.25	2.316	14.1	8.375	0
4399	1.86	2.4	108	2603.2	209	80.73	1.402	14.9	8.375	0
4400	2.10	2.4	108	2605.9	208	80.62	1.371	15.4	8.375	0
4401	2.11	2.3	108	2611.6	208	80.57	1.357	15.8	8.375	0
4402	2.71	26.3	80	2584.0	212	80.56	2.436	16.2	8.375	0
4403	3.35	32.3	78	2659.6	208	80.49	2.541	16.5	8.375	0
4404	3.14	32.0	79	2596.6	210	80.48	2.564	16.8	8.375	0
4405	5.33	28.7	77	2644.1	206	80.15	2.232	17.0	8.375	0

4406	4.17	33.0	77	2643.3	206	79.97	2.470	17.3	8.375	0
4407	4.62	32.6	75	2679.9	202	80.00	2.404	17.5	8.375	0
4408	3.64	23.7	83	2628.9	206	80.17	2.246	17.8	8.375	0
4409	1.39	1.8	107	2594.4	209	80.19	1.374	18.5	8.375	0
4410	8.27	23.2	79	2595.4	211	80.28	1.903	18.6	8.375	0
4411	4.84	37.7	77	2640.1	206	80.41	2.550	18.8	8.375	0
4412	4.36	21.6	73	2349.3	195	75.08	2.056	19.0	8.375	0
4413	2.88	28.6	78	2561.9	210	80.89	2.482	19.4	8.375	0
4414	2.67	20.8	79	2546.5	210	80.81	2.231	19.8	8.375	1
4415	6.58	27.7	78	2552.4	208	81.12	2.120	19.9	8.375	1
4416	7.58	28.6	78	2530.7	209	81.04	2.095	20.1	8.375	1
4417	6.13	28.7	77	2560.0	206	81.11	2.174	20.2	8.375	1
4418	0.28	19.4	113	2641.5	224	80.70	3.085	23.9	8.375	1
4419	0.11	10.2	129	2281.4	220	80.21	2.825	33.0	8.375	1
4420	2.38	7.2	84	2427.1	190	76.13	1.669	0.0	8.375	1
4421	2.98	20.5	75	2575.8	202	80.81	2.166	0.3	8.375	1
4422	4.81	20.5	76	2573.1	202	80.87	1.998	0.5	8.375	1
4423	2.27	20.5	75	2583.9	201	81.03	2.261	1.0	8.375	1
4424	2.36	18.7	75	2580.3	200	81.28	2.174	1.4	8.375	1
4425	3.09	22.2	75	2570.4	201	81.29	2.215	1.7	8.375	1
4426	2.64	11.6	90	2570.7	201	81.54	1.888	2.1	8.375	1
4427	3.69	2.4	106	2603.7	200	81.69	1.256	2.4	8.375	1
4428	1.24	1.1	106	2574.6	203	81.73	1.286	3.2	8.375	1
4429	1.42	1.1	105	2580.7	203	81.81	1.250	3.9	8.375	1
4430	4.94	17.8	76	2454.8	202	81.82	1.895	4.1	8.375	1
4431	2.21	20.1	75	2495.2	201	81.44	2.255	4.5	8.375	1
4432	2.47	20.1	74	2518.2	199	80.42	2.209	4.9	8.375	1
4433	1.72	9.2	96	2539.0	200	80.36	1.906	5.5	8.375	1
4434	3.32	2.3	103	2578.8	199	80.25	1.259	5.8	8.375	1
4435	3.73	2.2	103	2587.3	198	80.07	1.223	6.1	8.375	1
4436	3.64	2.1	103	2586.4	198	80.15	1.222	6.4	8.375	1
4437	2.13	2.8	105	2543.6	201	79.96	1.407	7.0	8.375	1
4438	1.80	2.5	105	2541.5	198	80.00	1.412	7.6	8.375	1
4439	1.31	3.2	106	2568.5	202	79.71	1.551	8.3	8.375	1
4440	3.39	2.3	105	2609.9	199	79.56	1.265	8.6	8.375	1
4441	4.65	1.5	105	2617.8	199	79.52	1.102	8.8	8.375	1
4442	3.03	1.9	105	2606.5	200	79.69	1.232	9.2	8.375	1
4443	2.95	2.1	105	2606.5	200	79.83	1.267	9.5	8.375	1
4444	4.32	2.7	104	2626.0	198	79.75	1.249	9.7	8.375	1
4445	3.44	20.0	77	2534.6	206	79.55	2.104	10.0	8.375	1
4446	2.99	24.2	77	2502.4	205	79.80	2.303	10.4	8.375	1
4447	3.28	25.9	75	2531.7	202	80.42	2.322	10.7	8.375	1
4448	4.63	23.4	77	2500.3	205	80.52	2.114	10.9	8.375	1
4449	5.74	26.5	77	2508.7	205	80.52	2.132	11.1	8.375	1
4450	3.58	24.2	77	2514.3	204	80.69	2.238	11.3	8.375	1
4451	3.46	22.5	77	2509.1	204	80.82	2.193	11.6	8.375	1

4452	9.14	19.0	76	2520.4	203	80.79	1.727	11.7	8.375	1
4453	2.02	3.3	105	2595.4	199	81.20	1.473	12.2	8.375	1
4454	4.64	20.7	79	2507.7	202	81.26	2.033	12.5	8.375	1
4455	6.32	20.6	79	2517.6	202	80.29	1.922	12.6	8.375	1
4456	1.44	8.6	96	2508.3	200	80.01	1.917	13.3	8.375	1
4457	2.70	0.8	94	2275.0	192	79.40	1.071	13.7	8.375	1
4458	1.60	1.0	103	2414.2	191	79.30	1.204	14.3	8.375	1
4459	4.40	17.4	82	2481.9	202	79.13	1.947	14.6	8.375	1
4460	6.59	26.1	76	2497.5	205	79.21	2.067	14.7	8.375	1
4461	3.56	23.1	76	2482.8	204	79.64	2.199	15.0	8.375	1
4462	11.28	21.3	75	2362.2	200	79.83	1.716	15.4	8.375	1
4463	9.18	21.4	76	2485.7	204	79.83	1.799	15.5	8.375	1
4464	7.33	26.4	76	2496.7	204	80.10	2.032	15.7	8.375	1
4465	2.94	29.1	76	2505.6	204	80.18	2.479	16.0	8.375	1
4466	1.38	12.9	94	2573.4	206	79.17	2.161	16.8	8.375	1
4467	1.81	26.3	77	2512.8	205	79.10	2.572	17.3	8.375	1
4468	2.26	25.4	77	2529.5	206	79.57	2.454	17.8	8.375	1

Spisak tabela

Tabela 2.1: Materijali za sprečavanje gubitka cirkulacije za različite vrste gubitka isplake (Alkinani i sar., 2018b)

Tabela 5.1: Ulazni parametri za proračun

Tabela 5.2: Rezultati eksperimenta za različite stope učenja uz primenu Bell-shape funkcije pripadnosti. Oznake u kolonama imaju sledeće značenje: R^2 = suma kvadrata reziduala; AE = prosečna greška (average error); MEAN-SE = srednja kvadratna greška (mean square error); MED-E = srednja greška (median error); MEAN-AE = srednja absolutna greška (mean absolute error); MED-AE = srednja absolutna greška (median absolute error)

Tabela 5.3: Rezultati eksperimenta za različite stope učenja uz primenu Gausove funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3

Tabela 5.4: Rezultati eksperimenta za različite stope učenja uz primenu Pi funkcije pripadnosti (Pimf). Oznake u kolonama imaju značenja opisana u tabeli 5.3

Tabela 5.5: Rezultati eksperimenta za različite stope učenja uz primenu Sigma funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3

Tabela 5.6: Rezultati eksperimenta za različite stope učenja uz primenu Trapezoidne funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3

Tabela 5.7: Rezultati eksperimenta za različite stope učenja uz primenu Trouglaaste funkcije pripadnosti. Oznake u kolonama imaju značenja opisana u tabeli 5.3

Tabela 5.8: Izabrani ANFIS parametri

Tabela 6.1: Rezultati predikcija dobijenih preko test skupa podataka

Tabela 6.2: Dobijeni rezultati predikcija preko skupa podataka za testiranje

Spisak slika

Slika 2.1: Gubitak isplake u zavisnosti od karakteristika formacije (Alkinani i sar., 2018b)

Slika 2.2: Efekat gustine bušaćeg fluida na gubitak cirkulacije isplake (Alhameedi i sar., 2017)

Slika 2.3: Zavisnost između gustine različitih vrsta materijala za sprečavanje gubitka cirkulacije i veličine frakture (Caenn i sar., 2017)

Slika 2.4: Najčešće strategije za rešavanje problema gubitka isplake (Alhameedi, 2018)

Slika 3.1: Mesto nadgledanog mašinskog učenja u odnosu na veštačku inteligenciju (Duarte i sar., 2018)

Slika 3.2: Primeri funkcija pripadnosti (Kovandžić N., 2020)

Slika 3.3: Ilustracija termina skupa Godine preko Gausove funkcije pripadnosti (Kovandžić N., 2020).

Slika 3.4: Koraci u fuzzy sistemu zaključivanja (Foroozandeh i sar., 2018)

Slika 3.5: Šema biološkog neurona (Simonović B., 2016)

Slika 3.6: Matematički neuron (Simonović B., 2016)

Slika 3.7: Osnovna struktura neuronske mreže (Simonović B., 2016)

Slika 3.8: Linearna aktivaciona funkcija

Slika 3.9: Sigmoidalna aktivaciona funkcija

Slika 3.10: Adaptivna mreža

Slika 3.11: ANFIS struktura sa dve ulazne vrednosti x_1 , x_2 i jednom izlaznom vrednošću, f

Slika 3.12: Osnovna arhitektura ANFIS-a

Slika 3.13: Struktura ANFIS-a sa devet pravila (Ramezani, R. i sar, 2017)

Slika 4.1: Šematski prikaz glinene obloge na zidu bušotine

Slika 5.1: Vrste gubitaka: 1. malo curenje (160 – 320 l/č), 2. srednje curenje (320 – 800 l/č), 3. jako curenje (800 – 1600 l/č), 4. mali delimični gubici (1600 – 2400 l/č), 5. srednji delimični gubici (2400 – 4000 l/č), 6. jaki delimični gubici (4000 – 8000 l/č), 7. jaki gubici (8000 – 12800 l/č) i 8. totalni gubici (>12800 l/č)

Slika 5.2: Prikaz histograma promenljive odziva za različite opsege gubitka cirkulacije: a) 160 – 320; b) 320 – 800; c) 800 – 1600; d) 1600 – 2400; e) 2400 – 4000; f) 4000 – 8000; g) 8000 – 12800; h) potpuni gubitak

Slika 5.3: Dijagram efekata različitih promenljivih

Slika 5.4: Funkcije pripadnosti

Slika 5.5: Broj funkcija pripadnosti

Slika 5.6: Brzina učenja

Slika 5.7: Broj epoha

Slika 5.8: Broj razmatranih pravila

Slika 5.9: Vizualizacija funkcije pripadnosti komponente Dubina bušotine

Slika 5.10: Vizualizacija funkcije pripadnosti komponente Broj obrtaja dleta (ROP)

Slika 5.11: Vizualizacija funkcije pripadnosti komponente Opterećenje na dleto (WOB)

Slika 5.12: Vizualizacija funkcije pripadnosti komponente Kapacitet pumpe

Slika 5.13: Vizualizacija funkcije pripadnosti komponente Pritisak pumpe

Slika 5.14: Vizualizacija funkcije pripadnosti komponente Protok bušaćeg fluida

Slika 5.15: Vizualizacija funkcije pripadnosti komponente Gustina isplake

Slika 5.16: Vizualizacija funkcije pripadnosti komponente Korigovani d-eksponent

Slika 5.17: Vizualizacija funkcije pripadnosti komponente Broj časova rada dleta

Slika 5.18: Vizualizacija funkcije pripadnosti komponente Prečnik bušotine

Slika 5.19: Vizualizacija funkcije pripadnosti komponente Gubitak isplake

Slika 5.20: ANFIS algoritam učenja

Slika 5.21: Algoritam modela sa ulaznim i izlaznim podacima

Slika 5.22: Dijagram za PSO metaheuristički algoritam

Slika 5.23: Matlab kod za učitavanje podataka i primenu PSO algoritma

Slika 6.1: Dijagram predikcija ANFIS-a za skup podataka za testiranje

Slika 6.2: Prikaz dijagrama toka PSO

Slika 6.3: PSO_ANFIS dijagram predikcija skupa podataka za testiranje

Slika 6.4: PSO_ANFIS dijagram predikcija skupa podataka za testiranje

Biografija

Kandidat Seyed Ali Razeghi je rođen u 10.05.1988. u Teheranu, Republika Iran. Osnovnu i srednju školu je završio u Teheranu. Osnovne studije na Industrijskom odseku Koledža za inženjerstvo Azada u Teheranu je upisao 2006.god., gde je stekao zvanje diplomiranog industrijskog inženjera 2010. godine. Master akademske studije je upisao na odseku za Industrijsko inženjerstvo na Mašinskom fakultetu Univerziteta u Beogradu 2011. godine i završio ih 2013. godine sa prosečnom ocenom 8,93. U okviru programa naučno-tehničke saradnje „Svet u Srbiji“ upisao je 2013. godine doktorske akademske studije Rudarsko inženjerstvo na Rudarsko-geološkom fakultetu Univerziteta u Beogradu.

Kandidat je položio sve predmete predviđene programom Rudarsko inženjerstvo Doktorskih studija Rudarsko-geološkog fakulteta Univerziteta u Beogradu. Ostvario je ukupno 175 ESPB (od 180) tokom studija i prosečnu ocenu 9,00.

Stečeno naučnoistraživačko iskustvo Kandidat je do sada kao koautor publikovao 1 rad u časopisu međunarodnog značaja – SCI lista:

Seyed Ali Razeghi, Vladimir Mitrovic & Solomon Adjei Marfo: „The influence of steam injection for Enhanced Oil Recovery (EOR) on the quality of crude oil“, Petroleum Science and Technology, 35(13): 1334-1342, 2017, ISSN: 1091-6466

Kandidat Seyed Ali Razeghi je svojim dosadašnjim aktivnostima ispoljio nadarenost za naučnoistraživački i stručni rad.

Poseduje odgovarajuće stručno i naučno obrazovanje iz oblasti rudarstva, stečeno na Rudarsko-geološkom fakultetu Univerziteta u Beogradu; Pokazuje izrazit smisao za dalje stručno i naučno usavršavanje kroz doktorske studije, kroz pisanje naučnih i stručnih radova i seminarima, stručnim diskusijama.

Publikovani rad u časopisu međunarodnog značaja, ukazuju da kandidat poseduje smisao se bavi teorijskim i eksperimentalnim istraživanjima. Objavljeni rad i istraživačka interesovanja kandidata su suštinski povezani sa naučnom oblašću kojoj pripada tema predložene doktorske disertacije.

Изјава о ауторству

Име и презиме аутора _____ Сеуед Али С. Разегхи _____

број индекса _____ Р710/13 _____

Изјављујем

да је докторска дисертација под насловом

Развој модела управљања циркулацијом у поступку бушења коришћењем
неуро фази система закључивања

- резултат сопственог истраживачког рада,
- да предложена дисертација у целини ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

У Београду, _____

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора _____ Сеуед Али С. Разегхи _____

Број индекса _____ Р710/13 _____

Студијски програм _____ Рударско инжењерство _____

Наслов рада _____ Развој модела управљања циркулацијом у поступку бушења коришћењем неуро фази система закључивања _____

Ментор _____ Др Милош Танасијевић, редовни професор _____

_____ Др Бранко Лековић, редовни професор _____

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла за објављивање на порталу **Дигиталног репозиторијума Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис докторанда

У Београду, _____

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Развој модела управљања циркулацијом у поступку бушења коришћењем
неуро фази система закључивања

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигитални репозиторијум Универзитета у Београду могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство
2. Ауторство - некомерцијално
3. Ауторство – некомерцијално – без прераде
4. Ауторство – некомерцијално – делити под истим условима
5. Ауторство – без прераде
6. Ауторство – делити под истим условима

(Молимо да заокружите само једну од шест понуђених лиценци, кратак опис лиценци дат је на полеђини листа).

Потпис докторанда

У Београду, _____

1. Ауторство - Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. Ауторство – некомерцијално. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. Ауторство - некомерцијално – без прераде. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. Ауторство - некомерцијално – делити под истим условима. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. Ауторство – без прераде. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. Ауторство - делити под истим условима. Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.