

Suvremeni pristup vrednovanju poduzeća naftne i plinske industrije temeljen na računalnoj inteligenciji

Brlečić Valčić, Sonja

Doctoral thesis / Disertacija

2014

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Economics / Sveučilište u Rijeci, Ekonomski fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:192:788560>

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

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



SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Economics and Business - FECRI Repository](#)



**SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET**

Sonja Brlečić Valčić

**SUVREMENI PRISTUP VREDNOVANJU
PODUZEĆA NAFTNE I PLINSKE
INDUSTRIJE TEMELJEN NA
RAČUNALNOJ INTELIGENCIJI**

DOKTORSKI RAD

Rijeka, 2014.

**SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET**

Sonja Brlečić Valčić

**SUVREMENI PRISTUP VREDNOVANJU
PODUZEĆA NAFTNE I PLINSKE
INDUSTRIJE TEMELJEN NA
RAČUNALNOJ INTELIGENCIJI**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Branka Crnković-Stumpf

Rijeka, 2014.

**UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS**

Sonja Brlečić Valčić

**MODERN APPROACH TO BUSINESS
VALUATION OF OIL AND GAS
COMPANIES BASED ON
COMPUTATIONAL INTELLIGENCE**

DOCTORAL THESIS

Supervisor: Branka Crnković-Stumpf, PhD, Full professor

Rijeka, 2014.

Mentor rada: Prof. dr. sc. Branka Crnković-Stumpf

Doktorski rad obranjen je dana _____ na Ekonomskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom:

1. Prof. dr. sc. Josipa Mrša, predsjednik
2. Prof. dr. sc. Branka Crnković-Stumpf, mentor, član
3. Prof. dr. sc. Vinko Belak, član
(Ekonomski fakultet Sveučilišta u Zagrebu)

Mojoj obitelji

SUVREMENI PRISTUP VREDNOVANJU PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE TEMELJEN NA RAČUNALNOJ INTELIGENCIJI

Sažetak

Vrednovanje poduzeća naftne i plinske industrije po mnogim je čimbenicima specifično i teško izvedivo postojećom metodologijom i trenutno korištenim pristupima vrednovanju. Identifikacija i ocjena čimbenika koji stvaraju i pokreću vrijednost poduzeća naftne i plinske industrije temelji se na složenim izračunima koji uključuju mnoge varijable. Međuovisnost tih varijabli prekompleksna je da bi se izrazila jednostavnom formulom. Iz tih se razloga kod vrednovanja ovakvih poduzeća postojeće metode vrednovanja moraju prilagođavati čime se u konačnici brojni kvalitativni, pa čak i kvantitativni čimbenici uopće ne uzimaju u obzir. Pred ekonomske stručnjake i znanstvenike s područja vrednovanja postavljaju se tako novi izazovi u determiniranju odgovarajuće metodologije i pristupa kojima će se moći otkloniti navedeni nedostaci. U ovom doktorskom radu predložen je suvremeni pristup vrednovanju poduzeća naftne i plinske industrije na osnovi računalne inteligencije. Takav pristup temeljen je na korištenju i prilagodbi brojnih financijskih i nefinancijskih pokazatelja pomoću umjetnih neuronskih mreža i neizrazite logike.

Ključne riječi: vrednovanje poduzeća, računalna inteligencija, naftna i plinska industrija, suvremeni pristup vrednovanju, neuronske mreže, neizrazita logika

MODERN APPROACH TO BUSINESS VALUATION OF OIL AND GAS COMPANIES BASED ON COMPUTATIONAL INTELLIGENCE

Abstract

Business valuation of oil and gas companies can be described as specific and difficult in many aspects within existing methodology and currently used approaches in appraisal process. Identification and evaluation of the significant factors that create and determine enterprise value in oil and gas industry is based on complex calculations involving many variables. Regardless of this reason, existing business valuation methods for such companies have to be improved with taking into account a numerous qualitative and even additional quantitative factors. Therefore, economic experts and scientists in the field of business valuation are confronted with new challenges in determination of appropriate approaches that should be able to eliminate the disadvantages of existing valuation methods. In this doctoral thesis, a modern approach to business valuation of oil and gas companies based on computational intelligence has been suggested. This approach includes application and adaption of selected financial and non-financial indicators by means of artificial neural networks and fuzzy logic.

Keywords: business valuation, computational intelligence, oil and gas industry, a modern approach to business valuation, neural networks, fuzzy logic

Sažetak	i
Abstract	ii
1. UVOD	1
1.1. Problem, predmet i objekt istraživanja	3
1.2. Znanstvena hipoteza i pomoćne hipoteze	5
1.3. Svrha i ciljevi istraživanja	8
1.4. Ocjena dosadašnjih istraživanja	8
1.5. Znanstvene metode	12
1.6. Struktura doktorske disertacije	14
2. ANALIZA TEORIJSKE OSNOVE PRISTUPA PROCJENI VRIJEDNOSTI PODUZEĆA	17
2.1. Standardni pristup procjeni vrijednosti poduzeća	18
2.1.1. Teorijski aspekt vrijednosti poduzeća kao cjeline u uporabi i njegove fer tržišne vrijednosti	20
2.1.2. Pojam i karakteristike imovinskog pristupa vrednovanju poduzeća	23
2.1.3. Značaj i odrednice tržišnog pristupa vrednovanju poduzeća	27
2.1.4. Fundamentalna teorija prihodovnog pristupa vrednovanju poduzeća	30
2.2. Kvantitativno-matematički pristup vrednovanju poduzeća	37
2.2.1. Definiranje međuovisnosti parametara unutar financijskih izvještaja matematičkim modeliranjem novčanog toka	38
2.2.2. Metode regresijske analize u funkciji vrednovanja poduzeća	43

3. IDENTIFIKACIJA SPECIFIČNOSTI POSLOVANJA PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE	51
3.1. Karakteristike poslovanja poduzeća naftne i plinske industrije	52
3.1.1. Rezerve nafte i prirodnog plina	52
3.1.2. Ovisnost kretanja cijena nafte i plina o političkim i ekonomskim čimbenicima	55
3.1.3. Obilježja poduzeća naftno-plinskog sektora	61
3.2. Računovodstvene specifičnosti poduzeća naftne i plinske industrije	65
3.2.1. Računovodstveni tretman operativnih troškova koji se odnose na istraživanje novih rezervi nafte i plina	66
3.2.2. Računovodstveni tretman imovine poduzeća naftne i plinske industrije	67
3.2.3. Amortizacija imovine poduzeća naftne i plinske industrije	68
3.2.4. Računovodstvene specifičnosti proizvodnih aktivnosti	70
3.3. Financijske specifičnosti poduzeća naftne i plinske industrije	71
3.3.1. Specifičnosti radnog kapitala poduzeća naftne i plinske industrije	72
3.3.2. Specifičnosti novčanog toka poduzeća naftne i plinske industrije	74
3.3.3. Potreba korištenja pokazatelja <i>EBITDAX</i>	74
3.3.4. Ostale financijske specifičnosti poduzeća naftne i plinske industrije	75
4. OCJENA FINANCIJSKIH I NEFINANCIJSKIH POKAZATELJA U FUNKCIJI POSTAVLJANJA KRITERIJA ZA VREDNOVANJE PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE	77
4.1. Analiza osnovnih financijskih pokazatelja za poduzeća naftne i plinske industrije	77
4.1.1. Analiza likvidnosti	78

4.1.2.	Analiza profitabilnosti	79
4.1.3.	Analiza aktivnosti	80
4.1.4.	Analiza pokazatelja stvaranja vrijednosti	81
4.1.5.	Analiza poslovne izvrsnosti	82
4.1.6.	Rezultati analize osnovnih financijskih pokazatelja za pojedine sektore naftne i plinske industrije	84
4.2.	Karakteristične financijske analize za poduzeća naftne i plinske industrije	89
4.3.	Identifikacija nefinancijskih pokazatelja u funkciji stvaranja i akumulacije vrijednosti poduzeća naftne i plinske industrije	91
5.	RAČUNALNA INTELIGENCIJA KAO SUVREMENI ALAT U RJEŠAVANJU PROBLEMA MODERNE EKONOMIJE	96
5.1.	Umjetne neuronske mreže	96
5.1.1.	Unaprijedna neuronska mreža s povratnim rasprostiranjem pogreške	98
5.1.2.	Generalizirana regresijska neuronska mreža	102
5.1.3.	Samoorganizirajuća neuronska mreža	104
5.2.	Neizrazita logika	106
5.2.1.	Pojam neizrazitog skupa i neizrazitih relacija	108
5.2.2.	Tip-1 neizraziti sustav zaključivanja	110
5.3.	Primjena računalne inteligencije u ekonomiji	112
6.	IZBOR I KVANTIFICIRANJE PARAMETARA ZA PRIJEDLOG SUVREMENOG PRISTUPA VREDNOVANJU PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE	116
6.1.	Analiza odgovarajućeg skupa parametara o kojima ovisi vrijednost poduzeća	116
6.1.1.	Analiza na osnovi ekspertnih mišljenja	119
6.1.2.	Analiza međuovisnosti parametara i njihovog utjecaja na vrijednost poduzeća na osnovi neuronskih mreža	121

6.2. Izbor odabranih parametara i kvantifikacija njihovog utjecaja na vrijednost poduzeća	130
6.2.1. Izbor i kvantifikacija financijskih parametara	130
6.2.2. Izbor i kvantifikacija nefinancijskih parametara	131
7. PRIJEDLOG MODELA ZA VREDNOVANJE PODUZEĆA NA OSNOVI RAČUNALNE INTELIGENCIJE S OBZIROM NA SPECIFIČNOSTI NAFTNE I PLINSKE INDUSTRIJE	134
7.1. Priprema podataka	138
7.2. Model suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije	139
7.3. Pretpostavke modela	142
8. PRIMJENA I OGRANIČENJA PREDLOŽENOG MODELA	146
8.1. Ispitivanje predloženog modela i interpretacija dobivenih rezultata	146
8.2. Komparativna analiza predloženog modela i postojećih standardnih pristupa za vrednovanje poduzeća naftne i plinske industrije	161
8.3. Ograničenja predloženog modela i preporuke za budući rad	168
9. ZAKLJUČAK	169
LITERATURA	175
POPIS TABLICA	181
POPIS SLIKA	183
Prilog 1. Popis analiziranih poduzeća za potrebe analize osnovnih financijskih pokazatelja po pojedinim sektorima naftne i plinske industrije	185
Prilog 2. Vrijednosti poduzeća za sektore <i>E&P</i> , <i>R&M</i> , <i>OFS</i> i <i>T&S</i> temeljene na klasičnom i ekspertnom pristupu	190
Prilog 3. Vrijednosti multiplikatora <i>multTR</i> , <i>multVP</i> i <i>multUP</i> za poduzeća iz sektora <i>E&P</i> , <i>R&M</i> , <i>OFS</i> i <i>T&S</i>	196

Prilog 4.	Vrijednosti ulaznih parametara za FIS1 i FIS2 za odabrana poduzeća iz sektora <i>E&P</i>, <i>R&M</i>, <i>OFS</i> i <i>T&S</i>	202
Prilog 5.	Vrijednosti multiplikatora <i>multΔVP₁</i>, <i>multΔVP₂</i> i <i>multΔVP</i> i korigirane vrijednosti poduzeća za sektore <i>E&P</i>, <i>R&M</i>, <i>OFS</i> i <i>T&S</i>	208
Prilog 6.	Vrijednosti odabranih parametara za treniranje, validaciju i testiranje unaprijedne neuronske mreže	214

1. UVOD

Potreba za procjenom vrijednosti poduzeća u današnje vrijeme u rastućem je trendu, a proizlazi iz same biti vrednovanja poduzeća, odnosno činjenice da se ono poput svake druge imovine može kupiti i prodati na tržištu. Koncept vrednovanja poduzeća, ovisno o svrsi vrednovanja, može biti promatran na nekoliko različitih načina. Tako će vrednovanje i vrijednost koja se procjenom dobiva, u filozofskom i numeričkom smislu, biti potpuno različita s perspektive investicijskih bankara, računovođa, dioničara, menadžmenta, regulatornih agencija te kupaca i prodavača poduzeća.

Prema predviđanju porasta populacije na 8,3 milijardi ljudi do 2030. godine, te sukladno tome razvitku životnog standarda i industrije koja će to pratiti, energetska potrošnja projektirana je godišnjim porastom od 1,6 %, odnosno globalna potrošnja energije 2030. godine biti će 36 % veća u odnosu na 2011. (Energy Outlook 2030. BP p.l.c., 2013.). Prema istom izvoru, sukladno energetskej potražnji, predviđa se porast energetske proizvodnje od čega nafte za 116,26 % (s 3995,6 miliona tona u 2011. na 4645,5 miliona tona 2030. godine), a prirodnog plina za 144,87 % (s 2954,8 miliona tona u 2011. na 4280,7 miliona tona 2030. godine). Navedeno objašnjava važnost naftne i plinske industrije u globalnim industrijskim kretanjima skore budućnosti.

Poduzeća naftne i plinske industrije se konstantno razvijaju, šire, udružuju, kupuju, spajaju, što vrednovanje ovakvih poduzeća čini jednim od najaktualnijih, najzanimljivijih, ali ujedno i najkompleksnijih područja za financijske analitičare današnjice. Značaj vrednovanja poduzeća naftne i plinske industrije najbolje ilustrira prosjek od čak četiri kupoprodajne transakcije takvih poduzeća dnevno, tj. 1616 transakcija u 2012. godini s ukupnom vrijednošću od 402 milijardi USD, s tendencijom porasta broja i vrijednosti transakcija u idućim godinama (Global Oil and Gas Transactions Review 2012., 2013.). Spajanja i akvizicije u naftno plinskoj industriji, bilo da se kupuju cijela poduzeća, dijelovi poduzeća ili individualna imovina, primarno se odvijaju iz razloga potrage za dodatnim izvorima nafte i plina, a sekundarno zbog jačanja položaja na globalnom tržištu i prisutnosti na pojedinačnim tržištima, te pristupu sve zahtjevnijoj modernoj tehnologiji u realizaciji velikih i zahtjevnih projekata kao i znanju potrebnom za njihovu realizaciju (*know-how*).

Nekoliko osnovnih sektora definira naftno plinsku industriju, a svaki od njih fokusiran je na karakteristične procese u vrijednosnom lancu. Kako je ova izuzetno aktivna industrija obilježena značajnim kompleksnostima, mnoga poduzeća fokusiraju se na samo jedan od njih. O specifičnostima svakog pojedinog sektora naftno plinske industrije ovisi projektiranje budućih troškova i prihoda, a što utječe na utvrđivanje vrijednosti poduzeća. Naftno plinska industrija je vrlo ciklična i u ovisnosti je o cijenama robe, iz čega i proizlaze najveće različitosti u odnosu na ostale tipove poduzeća. Jedna od najčešćih obilježja eksploatacijsko proizvodnih poduzeća, ali nerijetko prisutna i u ostalim naftno plinskim segmentima, odnosi se na nemogućnost kontrole prihoda. Nadalje, ovakva su poduzeća u visokom stupnju ovisna o imovini, pa će kod eksploatacijsko proizvodnih poduzeća prihodi ovisiti o rezervama nafte i plina, a kod poduzeća iz drugih naftno plinskih skupina o tehnologijama koje podupiru ovu industriju. Navedeno se očituje u proizvodnim procesima, proizvodnoj opremi i operativnom poslovanju.

Sve su to razlozi koji upućuju na to da alati za procjenu vrijednosti poduzeća nisu primjenjivi kod naftno plinske industrije bez određene prilagodbe i dodatnih analiza potrebnih za modeliranje kretanja troškova i prihoda u budućim razdobljima.

Nadalje, vrednovanje bilo kojom od metoda unutar standardnih pristupa rezultirati će različitim vrijednostima poduzeća. Gotovo je uobičajeno zbog toga da procjenitelji kod svake procjene koriste najmanje dvije metode iz različitih pristupa (ovisno o karakteristikama poduzeća koje se vrednuje i grane unutar koje posluje) uz dubinsko snimanje svih parametara koji utječu na poslovanje vrednovanog poduzeća.

Osim toga, u determiniranju vrijednosti poduzeća nameće se filozofija fer vrijednosti poduzeća kao cjeline. Pri tome se koncept vrijednosti u uporabi kod vrednovanja poduzeća odnosi na sadašnju vrijednost procijenjenih budućih novčanih tokova za koje se očekuje da će biti generirani tijekom nastavka poslovanja poduzeća do kraja vijeka trajanja njegovog poslovanja, a koncept vrijednosti u razmjeni odnosi se na vrijednost o kojoj su se dogovorili upoznati voljni kupac i upoznati voljni prodavatelj u transakciji pred realizacijom.

Približavanje kategorija uporabne i tržišne vrijednosti, u okviru koncepta fer vrijednosti, trebalo bi približiti subjektivna očekivanja kupca s realnim procjenama razvojnih mogućnosti poduzeća.

Posljednjih nekoliko godina istraživanja su se u vrednovanju poduzeća okrenula drugačijem pristupu, temeljenom na definiranju odnosa između određenih financijskih i ostalih pokazatelja unutar promatranog poduzeća ili industrije. Napredak informacijske i računalne tehnologije doprinio je progresivnom rastu metodološkog spektra raspoloživog u različitim područjima i za rješavanje mnogih problema. Osim statističkih metoda i metoda operacijskih istraživanja, modeli računalne inteligencije temeljeni na teoriji učenja, unaprijedili su mogućnost korištenja prethodnog znanja (kroz ekspertne sustave) i podataka (kroz neuronske mreže) u cilju donošenja učinkovitih odluka. Osim toga, potreba za integracijom financijskih, strateških, menadžerskih i ostalih aspekata kvantitativne i kvalitativne prirode, koji predstavljaju pokretače i akumulatore vrijednosti poduzeća navela je istraživače na primjenu ekspertnih i neizrazitih pristupa u vrednovanju poduzeća.

Razlozi zbog kojih je nastala potreba istraživanja i pisanja rada pod naslovom **Suvremeni pristup vrednovanju poduzeća naftno plinske industrije temeljen na računalnoj inteligenciji** u nastavku se pobliže definiraju kroz: 1) **Problem, predmet i objekt istraživanja**, 2) **Znanstvenu hipotezu i pomoćne hipoteze**, 3) **Svrhu i ciljeve istraživanja**, 4) **Ocjenu dosadašnjih istraživanja**, 5) **Znanstvene metode** i 6) **Kompoziciju rada**.

1.1. Problem, predmet i objekt istraživanja

U kontekstu navedene problematike istraživanja definira se **znanstveni problem istraživanja**:

Iako u današnje vrijeme postoje mnoge metode za procjenu vrijednosti poduzeća, a osim standardnih financijskih analiza sve se više koriste modeli na osnovi moderne statistike, još uvijek se nameće pitanje kako napraviti što bolji model utvrđivanja vrijednosti poduzeća što objektivnije. Kako bi se pomoću takvog pristupa zaista i mogla preciznije utvrditi vrijednost pojedinog poduzeća, uz već poznate čimbenike-parametre, posebna se pažnja posvećuje određivanju dodatnih ključnih čimbenika-parametara, o kojima također ovisi vrijednost poduzeća, kao i određivanju njihove međuovisnosti. To je razlog da

se konzistentno analizira, istražuje i primjereno definira mogućnost primjene suvremenog pristupa procjeni vrijednosti poduzeća naftne i plinske industrije temeljenog na računalnoj inteligenciji uzimajući u obzir sve karakteristične specifičnosti te industrije.

Takvu problematiku i problem opravdavaju sljedeća **obilježja** procjene vrijednosti poduzeća:

- 1) **Informacije dobivene standardnim pristupom vrednovanja nisu prihvatljive različitim korisnicima za različite namjene, a rezultati dobiveni upotrebom različitih metoda nisu isti, pa su procjenitelji često primorani na procjenu vrijednosti s nekoliko metoda i različitih pristupa, a procijenjene vrijednosti se postavljaju u određenom rangui (od-do).**
- 2) **Postojeći modeli vrednovanja imaju različite učinke u različitim okolnostima i tipovima donošenja odluka, što se ponajprije očituje u složenim i kompleksnim industrijama poput naftne i plinske, pa se njene specifičnosti mogu koristiti kao osnova suvremenijem pristupu vrednovanja.** Vrednovanje poduzeća naftne i plinske industrije uvijek se smatralo kompleksnim, upravo iz razloga nemogućnosti primjene ni jedne postojeće metode bez određene prilagodbe. Često se kod složenijih poduzeća pojedini njihovi dijelovi (eksploatacija, prerada i proizvodnja, transport) vrednuju zasebno, svaki drugačijom metodologijom, pa se na kraju tri vrijednosti zbroje u jednu ukupnu vrijednost.
- 3) **Odlučivanje na osnovi procjene vrijednosti poduzeća, bilo da se radi o kupoprodaji ili upravljanju poduzećem, težak je zadatak za donositelja odluke ako informacije nisu objektivne i pouzdane.** Posebno se to odnosi na nemogućnost identifikacije točne vrijednosti imovine zabilježene u bilanci, kao i određivanju budućih novčanih tokova kod najpopularnije DCF metode, zbog neizvjesnosti i nesigurnih globalnih ekonomskih uvjeta današnjice.
- 4) **Kao osnovni problem nameće se izbor skupa ključnih čimbenika-parametara o kojima ponajviše ovisi vrijednost poduzeća, pokretača i akumulatora vrijednosti koje je potrebno identificirati među financijskim i nefinancijskim čimbenicima.**

- 5) **Međuviznost parametara koji utječu na procjenu vrijednosti poduzeća vrlo je teško prikazati standardnim metodama procjene, pa i suvremenim statističkim metodama.** Problem postaje još izraženiji jer pojedini čimbenici koji predstavljaju pokretače i akumulatore vrijednosti nisu kvantitativno izraženi, niti zabilježeni u financijskim izvještajima kao ni drugim dokumentima poduzeća koje se promatra. Integracija kvantitativnih i kvalitativnih segmenata, zahtijeva primjenu modernijih alata i suvremenijeg pristupa.
- 6) **Projektiranje budućnosti te procjena rizika i uvrštavanje faktora rizika u klasične modele problem je koji se teško i često neadekvatno rješava standardnim metodama,** posebno u današnjoj neizvjesnosti i nepredvidivoj budućnosti.
- 7) **Analiza nedostatnih podataka, podataka sa smetnjama, problema koji nemaju jasno jednostrano rješenje i nedostataka neadaptivnih standardnih metoda bez učenja na prošlim podacima, često su izazovi koji se pojavljuju u procjeni vrijednosti poduzeća.** Takve izazove moguće je riješiti samo suvremenijim pristupom, modelima računalne inteligencije pomoću ekspertnih i neizrazitih sustava te neuronskih mreža.

Iz takve problematike i problema istraživanja determiniran je i **predmet znanstvenog istraživanja:**

Analizirati, elaborirati, istražiti i konzistentno utvrditi relevantne značajke i čimbenike koji utječu na vrijednost poduzeća naftne i plinske industrije u sadašnjosti i na predviđanje poslovanja u budućnosti, te predložiti model vrednovanja poduzeća na osnovi računalne inteligencije, kao i mjere i aktivnosti za njegovu provedbu u suvremenom pristupu vrednovanju.

Znanstveni problem i predmet znanstvenog istraživanja se odnosi na dva primarna **objekta znanstvenog istraživanja**, a to su: **vrednovanje poduzeća i specifičnosti poslovanja poduzeća naftne i plinske industrije.**

1.2. Znanstvena hipoteza i pomoćne hipoteze

Sukladno determiniranom znanstvenom problemu istraživanja, predmetu znanstvenog istraživanja i objektima znanstvenoga istraživanja postavljena je i **temeljna znanstvena hipoteza:**

Znanstveno utemeljenim spoznajama o bitnim čimbenicima koji utječu na stvaranje i akumuliranje vrijednosti poduzeća naftne i plinske industrije te njihovoj međuovisnosti i stupnju pojedinačnog utjecaja na procijenjenu vrijednost, moguće je primjenom računalne inteligencije predložiti model vrednovanja u sustavu utvrđivanja fer vrijednosti, u kojem će razlika vrijednosti u uporabi i tržišne vrijednosti poduzeća biti minimalna.

Tako postavljena temeljna znanstvena hipoteza, implicira više **pomoćnih hipoteza**:

P.H.1 U sustavu utvrđivanja fer vrijednosti osnovni pristupi vrednovanju su pristup utvrđivanja vrijednosti u razmjeni i utvrđivanja vrijednosti u uporabi.

P.H.2 Vrijednost u uporabi i vrijednost u razmjeni mogu se približiti ili biti značajno različite.

P.H.3 Potreba za suvremenim pristupom vrednovanju poduzeća proizlazi iz nedostataka i ograničenosti standardnih pristupa i metoda vrednovanja te se stoga nameće filozofija fer vrijednosti kao i nužnosti uvažavanja kvantitativnih i kvalitativnih čimbenika u modele vrednovanja.

P.H.4 Poslovanje poduzeća naftne i plinske industrije obilježavaju brojne specifičnosti što implicira kompleksnost vrednovanja ovakvih poduzeća jednom ili kombinacijom više standardnih metoda za procjenu vrijednosti.

P.H.5 Kriterije izbora parametara za vrednovanje poduzeća naftne i plinske industrije moguće je odrediti ocjenom i analizom financijskih pokazatelja i njihove međuovisnosti u stvaranju vrijednosti.

P.H.6 Primjena računalne inteligencije u suvremenom pristupu vrednovanju poduzeća će omogućiti sinergijski učinak postojećih standardnih metoda procjene uzimajući u obzir i čimbenike koji se u tim metodama ne koriste.

Brojni argumenti podupiru postavljenu temeljnu hipotezu i njezine pomoćne hipoteze, a navode se samo oni najvažniji:

- Sasvim je jasno da dosadašnji pristupi vrednovanja poduzeća ne obuhvaćaju neke iznimno bitne i značajne stavke, a što se posebno ističe kod pojedinih industrija i njihovih specifičnosti te se stoga nameće potreba za

integriranjem tih stavki u modele za vrednovanje poduzeća kako bi sama procjena bila što realnija.

- Čak i metode za procjenu vrijednosti poduzeća temeljene na kvantitativnom pristupu imaju smanjenu mogućnost adaptacije na značajne promjene vrijednosti čimbenika te se stoga ne mogu na zadovoljavajući način riješiti problemi manjka podataka ili smetnji na podacima, pa samim time ne mogu ni adekvatno iskoristiti podatke iz prošlih mjerenja, što primjenu suvremenijeg pristupa vrednovanju čini neophodnom za rješanje ovakvih problema.

- Budući da su ekonomske teorije koje analiziraju poduzeće kao cjelinu, njegove životne cikluse i unutarnje i/ili vanjske čimbenike koji na njega utječu, dostigle visoki stupanj, moguće je odrediti i bitne parametre koji utječu na njegovu vrijednost.

- Jedan od problema kod identifikacije parametara koji utječu na vrijednost poduzeća je i taj što mnogi od njih nisu zabilježeni u financijskim izvještajima, te što su kvalitativne prirode, pa je potrebno pronaći adekvatan način za njihovu kvantifikaciju.

- Na temelju brojnih dosadašnjih provedenih istraživanja i s obzirom na iznimno veliki broj objavljenih znanstvenih i stručnih radova o primjenama računalne inteligencije u različitim znanstvenim disciplinama, pa tako i u ekonomskim znanostima, sasvim je opravdano očekivati da će suvremeni pristup procjeni vrijednosti poduzeća uz pomoć metoda računalne inteligencije također dati izvrsne rezultate.

- Računalna inteligencija dokazano može uvelike pomoći kada je riječ o identifikaciji parametara nekog sustava kao i identifikaciji njihovih međuovisnosti, ali i kada je riječ o fuziji potpuno različitih i uobičajeno nespojivih informacija, a s razlogom da se ocijeni njihov utjecaj na konačnu, unaprijed nepoznatu, informaciju. Također je vrlo bitan pristup u kvantifikaciji kvalitativnih informacija pomoću neizrazite logike, koja se kao alat u rješavanju ovakvih problema sve češće koristi u suvremenim pristupima vrednovanju poduzeća što dokazuju istraživanja iz tog područja.

1.3. Svrha i ciljevi istraživanja

U izravnoj vezi sa znanstvenim problemom, predmetom i objektima znanstvenog istraživanja i postavljene znanstvene hipoteze, determinirani su **svrha i ciljevi istraživanja**:

Istražiti i analizirati u okviru ekonomskih znanosti spoznaje o bitnim čimbenicima kvantitativne i kvalitativne prirode koji utječu na vrijednost poduzeća i na temelju objektivnih znanstvenih činjenica i primijenjenih teorijskih i praktičnih spoznaja o procjeni vrijednosti poduzeća i specifičnostima u poslovanju poduzeća naftne i plinske industrije formulirati rezultate istraživanja te u okviru suvremenog pristupa vrednovanju poduzeća predložiti model temeljen na računalnoj inteligenciji, koji će uključivati i čimbenike koji se do sada nisu koristili u svrhu procjene vrijednosti poduzeća te izvršiti njegovo testiranje i predložiti smjernice za daljnja istraživanja.

1.4. Ocjena dosadašnjih istraživanja

Posljednjih nekoliko desetljeća u ekonomskoj teoriji i praksi razvijaju se modeli i metode vrednovanja poduzeća. Shvaćanje važnosti procjene vrijednosti poduzeća kao i razvoj struke procjenitelja vrijednosti poduzeća započinje sedamdesetih godina prošlog stoljeća u SAD-u. Naime, prilikom kupoprodaje, poduzeća su se do tada procjenjivala temeljem njihove materijalne imovine, a sve više je dolazila do izražaja i potreba za procjenom nematerijalne imovine, te postepeno za vrednovanjem poduzeća kao cjeline. Začetnikom same struke procjenitelja poduzeća smatra se Ray Miles, koji je još 1978. godine osnovao prvi institut procjene vrijednosti poduzeća, te se smatra pioninom edukacije za profesionalne procjenitelje. Prva pisana djela iz ovog područja pojavljuju se početkom osamdesetih godina prošlog stoljeća (Miles, 1980.; Pratt, 1981.), a od onda do danas o toj temi napisano je na stotine knjiga i znanstvenih radova.

U početnom razvoju shvaćanja da vrijednost poduzeća nije vrijednost njegove imovine najveća pozornost posvećivana je tzv. P/E (*Price-to-Earnings*) omjerima koji se izračunavaju stavljanjem u odnos cijene po dionici i godišnje zarade po dionici.

Kako je utjecaj spajanja i akvizicija rapidno rastao u razdoblju između kasnih 70-tih do ranih 90-tih godina prošlog stoljeća, perspektiva vrijednosti poduzeća sve

više je prelazila na nezavisnu procjenu kapitalne strukture, naglašavajući dobit prije poreza i amortizacije i dobit prije poreza (EBITDA, EBIT) kao glavne referentne točke vrednovanja. Tu započinje razdoblje prihodovnog pristupa vrednovanju poduzeća.

Razvoj ovog pristupa najviše je obilježio početak korištenja diskontiranog novčanog toka poznatog i kao DCF metode koja se počela koristiti kao posljedica razvoja računalne podrške, poslovnih modela i projekcija budućnosti poslovanja poduzeća. Povijest korištenja diskontiranja novčanih tokova seže u razdoblje nakon 1929. godine, a počelo se koristiti nakon sloma američkih burzi kao vrlo popularna metoda vrednovanja dionica u suvremenim ekonomskim uvjetima (Fisher, 1930.; Williams, 1938.). DCF metoda danas predstavlja najčešće korištenu metodu vrednovanja poduzeća (Tham i Vélez-Pareja, 2004.).

Podupirući razvoj modernih tokova predviđanja poslovanja u budućnosti, razvoj vrednovanja poduzeća se kreće prema predviđanju troškova kapitala (French, 2002.; Pratt, 2003.; Pratt i Grabowski, 2008.), kao posljedica rješavanja izazova cjenovne dimenzije vrednovanja i nadopuna zaključivanju po analogiji. Tako se počinje primjenjivati CAPM (*Capital Asset Pricing Model*) model, kao alat u determiniranju teoretski prikladne stope povrata imovine, a sa svrhom utvrđivanja međuovisnosti rizika i prihoda od investicija. Sam model predstavljen je još 60-tih godina (Treynor, 1961.; Treynor, 1962.; Sharpe 1964.; Lintner, 1965.; Mossin, 1966.) kao nadogradnja moderne portfolio teorije (Markowitz, 1970.). Osim CAPM, termin WACC (*Weighted Average Cost of Capital*) kao minimum povrata koje poduzeće mora zaraditi s postojećom imovinom kako bi zadovoljilo potrebe kreditora, vlasnika i ostalih davatelja kapitala (Miles i Ezzell, 1980.), postaje uobičajeni čimbenik i pokazatelj u vrednovanju poduzeća.

S razvojem financijskog računovodstva i proces izvještavanja zahtjeva sve veće prilagodbe modernim tržišnim uvjetima. Tako je tzv. *fer vrijednost* (FASB, 2006.) posebno u području *goodwill*a i nematerijalne imovine (Moser i Goddar, 2009.), postala značajno područje interesa i kod vrednovanja poduzeća.

Posljednjih godina, a zbog sve većeg shvaćanja potrebe drugačijeg pristupa samom vrednovanju poduzeća, nastala je i potreba za promatranjem poduzeća kao žive i jedinstvene cjeline kao i njegovih specifičnosti (Tichy, 2009.).

U Hrvatskoj je ova tematika nedovoljno proučavana, što zbog nedostatka većeg broja akvizicija i kupoprodaja poduzeća, kao i zbog nedovoljne razvijenosti tržišta kapitala. Naglasak je stavljen na opis metodologije utvrđivanja vrijednosti (Orsag, 1997.), vrijednost poduzeća kao pretpostavke upravljanja ekonomijom poduzeća (Crnković-Stumpf, 1996.), aspekte fer vrijednosti materijalne i nematerijalne imovine (Kolačević i Hreljac, 2009.) te u novije vrijeme nadogradnjom DCF metode uzimajući u obzir makroekonomske cikluse i granske determinante (Vukas, 2012.).

Specifičnosti poslovanja naftne i plinske industrije očituju se u proizvodnim procesima, proizvodnoj opremi i operativnom poslovanju (Raymond i Laffer, 2006.), a rezultiraju ponajprije računovodstvenim specifičnostima (Wright i Gallun, 2008.) kao i financijskim specifičnostima (Johnston, 2006.; Cormier i Magnan, 2002.). Kretanje stanja cijena nafte i plina kao i rizika koji prate ovu industriju uvelike utječe na financijske rezultate ovih poduzeća (Basher, 2012.; Adelman, 2005.), a što uz navedene specifičnosti vrednovanje poduzeća iz ove industrije čini karakterističnim (Osmundsen i sur., 2006.; Misund i sur., 2008.).

Doseg se malobrojnih znanstvenih radova iz vrednovanja poduzeća naftne i plinske industrije tako odnosi uglavnom na specifične vještine potrebne za vrednovanje ovakvih poduzeća kao i primjenu specifičnih alata za vrednovanje, jer postojeće metode ne zadovoljavaju potrebe procjenitelja, a vrednovanje se temelji na kombinaciji triju konvencionalnih pristupa, tj. na tržišnom, prihodovnom i imovinskom pristupu (Howard i Harp, 2009.). Analize financijskih izvještaja kod ovakvih poduzeća zahtijevaju uključivanje povijesnih proizvodnih volumena kao i prosjeke cijena nafte i plina za promatrana razdoblja, kako bi se došlo do zaključka nastaje li povećanje prihoda povećanjem proizvodnje ili povećanjem cijena nafte i plina na tržištu. Specifičnosti također zahtijevaju prilagodbu određenih pokazatelja poslovanja, pa se tako umjesto pokazatelja dobiti prije poreza (EBITDA) primjenjuje pokazatelj EBITDAX koji predstavlja EBITDA prije eksploatacijskih troškova, te se njime zaobilaze različitosti u financijskim rezultatima koji nastaju s obzirom na dvije različite dopuštene metode bilježenja rezervi u financijskim izvještajima (Howard i Harp, 2009.). Naftna i plinska industrija spada u industriju bez direktnog utjecaja na cijenu koju će postići prodajom nafte i plina. Tako svoju proizvodnju i kapitalne investicije moraju temeljiti na rezervama i trenutnim cijenama nafte i plina kao i na predikcijama kretanja cijene nafte i plina u budućnosti. Stoga se prihodovni

pristup vrednovanja poduzeća rijetko samostalno koristi (najčešće se koristi u procjeni dijelova poslovanja). Inicijalno vrednovanje poduzeća naftne i plinske industrije uvijek polazi od tržišnog pristupa. Imovinski se pak pristup koristi kod procjena naftnih i plinskih rezervi. Nedostaci najpopularnije DCF metode u vrednovanju poduzeća naftne i plinske industrije, zbog specifičnosti pojava u novčanim tijekovima čine ovu metodu gotovo neprimjenjivu kao samostalnu (Misund i Osmundsen, 2008.). Tako se uz kombinaciju standardnih metoda vrednovanja koje se prilagođavaju ovoj industriji najčešće koristi pokazatelj ROACE (Osmundsen i sur., 2006.).

Istraživanja vrednovanja poduzeća ovakvih karakterističnih industrija uvelike ukazuju na nedostatak standardne metodologije i pristupa vrednovanju (Hitchner, 2006.; Chakraborty, 2011.), te potrebu dodatnih alata poput kvantitativnih metoda (Abrams, 2001.; Burton, 2011.), kao i analize financijskih izvještaja (Helefert, 2005.; Žager, 2008.; Aralica, 2005.), kao temelje analize međuovisnosti određenih financijskih pokazatelja i vrijednosti poduzeća.

Upravo zbog nepostojanja adekvatne i pouzdane metodologije vrednovanja poduzeća naftne i plinske industrije, potrebno se usredotočiti na istraživanja koja su okrenuta suvremenijim rješenjima vrednovanja, poput neizrazitog pristupa, i to ponajprije iz razloga što se navedeni neizraziti pristup pokazao primjenjivim u vrednovanju unutar nesigurnih i nestabilnih uvjeta poslovanja (Ho i Liao, 2011., Yao i sur., 2005.).

Osim navedenog, istraživanja iz ovog područja naglašavaju potrebu uvrštavanja i ostalih čimbenika stvaranja vrijednosti kvantitativne (Abadie, 2011.) i kvalitativne prirode, što također zahtjeva suvremeni i drugačiji pristup vrednovanju poduzeća kao i moderne alate za obradu i kvantificiranje podataka.

Razvoj informacijske i računalne tehnologije doprinosi konstantnom rastu metodološkog spektra koji imaju na raspolaganju donositelji odluka iz mnogih područja, pa tako i ekonomije.

Neuronske mreže, kao jedna od metoda računalne inteligencije, strukturirane prema ljudskom mozgu, počinju se razvijati još davne 1940. godine (McCulloch i Pits, 1943.). Od tada do danas konstantno se razvijaju, pa je računalna inteligencija temeljena na teoriji učenja unaprijedila mogućnost korištenja prethodnog znanja (kroz ekspertne sustave) i podataka (kroz neuronske mreže) za složenu obradu

informacija (Zahedi, 1993.) u cilju donošenja učinkovitih odluka. Često se ovakvi modeli koriste za predviđanje bankrota (Zhang, 1999.; Yang, 1999.) i kretanje stanja na tržištu dionica, ali područje se širi i na financijske analize, proučavanje međuovisnosti određenih pokazatelja, optimizaciju poslovanja, a sve više i u određivanju vrijednosti poduzeća (Smith i Gupta, 2002.). Financije i ulaganja najčešće su poslovno područje nakon proizvodnje i operacija po učestalosti korištenja računalne inteligencije u ekonomiji (Wong i Laib, 2011.), jer su se novi algoritmi pokazali izvrsni u predviđanju i klasifikaciji budućih povrata (Zekić-Sušac, 1999.).

Upravo ovakvi alati omogućili su i suvremeni pristup vrednovanju poduzeća (Seng, 2010.), a poglavito integriranje financijskih (Sevastjanov i sur., 2006.), strateških (McIvor i sur., 2004.), menadžerskih (Chen i Lin, 2003.) i drugih informacija kvantitativne i kvalitativne prirode (Karsak i Tolga, 2001.) kao pokretača vrijednosti, te neizrazitom logikom (Malagoli i Magni, 2005.; Ho i Liao, 2011.; Yao i sur., 2005.; Gil-Lafuente i sur., 2012.), čime se još više ukazalo na nedostatke standardnog procesa vrednovanja poduzeća, kao i nužnosti aplikacije drugačijih metoda i analitičkih tehnika (Tillman Cassone, 2005.).

Istraživanja u korištenju novih alata i suvremenijeg pristupa cjelovitom vrednovanju poduzeća naftne i plinske industrije još uvijek nisu objavljivana. Rijetka se bave korištenjem neuronskih mreža u procjeni naftnih i plinskih rezervi (Pan i He, 2010.), što također ukazuje na aktualnost ovog područja za istraživanje.

1.5. Znanstvene metode

U znanstvenom istraživanju, formuliranju i prezentiranju rezultata istraživanja doktorske disertacije korištena je kombinacija klasičnih znanstvenih metoda u parovima i samostalnih klasičnih znanstvenih metoda.

Klasične znanstvene metode u parovima korištene su kako slijedi:

- Induktivno-deduktivna metoda kao temeljna metoda u parovima korištena je tijekom cijelog procesa izrade doktorske disertacije, od preliminarnog istraživanja i uočavanja znanstvenog problema preko teorijskog i analitičkog dijela do samih zaključnih razmatranja, jer se na temelju pojedinačnih ili posebnih zaključaka dolazi do zaključka o općem sudu, a iz općih postavki do konkretnih pojedinačnih zaključaka. Tako se kroz teorijske dijelove disertacije objašnjavaju

utvrđene spoznaje o pristupu vrednovanju poduzeća i specifičnostima poslovanja poduzeća naftne i plinske industrije, a kroz analitičke i eksperimentalne otkrivaju nove spoznaje i zakonitosti, dokazuju postavljene teze, provjeravaju temeljna hipoteza te predviđaju budući događaji.

- Analitičko-sintetička metoda korištena je s obzirom na predmet istraživanja te se analizom tj. postupkom raščlanjivanja složenih misaonih tvorevina na njihove jednostavne, sastavne dijelove, istražuju i elaboriraju relevantne značajke i čimbenici koji utječu na vrijednost poduzeća naftne i plinske industrije u sadašnjosti i predviđanje budućnosti, dok se sintezom putem spajanja i sastavljanja jednostavnih misaonih tvorevina u složene, povezuju u jedinstvenu cjelinu te se predlaže model za procjenu poduzeća temeljen na suvremenom pristupu i zaključna razmatranja.

- Metoda apstrakcije i konkretizacije primjenjuju se na način da se sposobnošću razlikovanja bitnih od nebitnih elemenata, vrednovanju poduzeća i poslovanju poduzeća naftne i plinske industrije prvo pristupi apstraktno apsolutnom koncentracijom na predmet istraživanja i zanemarivanjem ostalih svojstava, a zatim se konkretizacijom sintetiziraju opća mišljenja i saznanja ka posebnom i pojedinačnom predloženim modelom temeljem suvremenog pristupa vrednovanju poduzeća.

- Metoda generalizacije i specijalizacije koristi se na način da se generalizacijom ili poopćavanjem s obzirom na postavljene objekte istraživanja *pristup vrednovanju poduzeća i specifičnosti poslovanja poduzeća naftne i plinske industrije* kroz teorijske dijelove izlažu njihova temeljna obilježja i pripadnosti određenim nad skupovima, dok se specijalizacijom kroz analitički dio disertacije izložena razmatranja razvrstavaju u određene pod skupove i ispituju njihove osobine i međuovisnosti.

- Metode dokazivanja i opovrgavanja koriste se kroz izvođenje istinitosti pojedinih stavova na temelju znanstvenog istraživanja kroz izradu doktorske disertacije. Metoda dokazivanja koristi se u svrhu dokazivanja postavljene znanstvene hipoteze, dok se metoda opovrgavanja ne koristi, ali je spomenuta kao dio metoda koje dolaze u parovima.

Samostalne klasične znanstvene metode primijenjene su kako slijedi:

- Metoda deskripcije tj. postupak jednostavnog opisivanja ili ocrtavanja činjenica, procesa i predmeta, te njihovih empirijskih potvrđivanja odnosa i veza, bez znanstvenog tumačenja i objašnjavanja, koristi se u teorijskom dijelu rada kroz izlaganje teorijske osnove pristupa vrednovanju poduzeća i specifičnosti poslovanja poduzeća naftne i plinske industrije, kao i u uvodnim razmatranjima svih dijelova rada.

- Komparativna metoda kao postupak uspoređivanja istih ili srodnih činjenica, pojava, procesa i odnosa, odnosno utvrđivanja njihove sličnosti u ponašanju i intenzitetu razlika među njima ponajviše se koristiti u analitičkom dijelu rada u kojem će se uspoređivati međusobni odnosi i djelovanja određenih pokazatelja koji utječu na vrijednost poduzeća.

- Metoda kompilacije koristi se u radu radi potrebe preuzimanja tuđih spoznaja i znanstvenoistraživačkih rezultata koji će biti citirani, a potrebno ih je spomenuti kako bi se na temelju njih došlo do novih spoznaja.

- Metoda intervjuiranja korištena je u preliminarnom istraživanju pojava i procesa koje u većoj ili manjoj mjeri utječu na vrijednost poduzeća, na način da su intervjuirani stručnjaci različitih profila iz naftne i plinske industrije (kvaliteta, komercijalni sektor, inženjerija, kadrovski menadžment, pravni poslovi), a temeljem čijeg mišljenja se dolazi do zaključaka o pokretačima i generatorima vrijednosti naftne i plinske industrije i njihovoj međuovisnosti.

Također, u doktorskoj disertaciji za izradu i ocjenu modela za procjenu vrijednosti poduzeća korišteni su osnovni koncepti računalne inteligencije, tj. neizrazita logika i umjetne neuronske mreže.

U okviru računalne podrške za izradu modela, korišten je programski paket MATLAB.

1.6. Struktura doktorske disertacije

Rezultati istraživanja prezentirani su u doktorskoj disertaciji u devet međusobno povezanih dijelova.

U prvom dijelu *Uvodu*, definirani su problem, predmet i objekti istraživanja, postavljena je znanstvena hipoteza i pomoćne hipoteze, određena je svrha i ciljevi istraživanja, dana je ocjena dosadašnjih istraživanja, navedene su najvažnije

znanstvene metode koje su korištene u znanstvenom istraživanju i prezentiranju rezultata istraživanja, te je obrazložena struktura rada.

U drugom dijelu s naslovom *Analiza teorijske osnove pristupa procjeni vrijednosti poduzeća* pojašnjavaju se teorijske odrednice standardnog pristupa vrednovanju poduzeća s aspekta imovinskog, prihodovnog i usporednog tržišnog pristupa procjene vrijednosti te razlozi zbog kojih se pojedinačno ili u paru koriste tokom vrednovanja poduzeća, kao i njihove prednosti i nedostaci. Isto tako izložen je i kvantitativni matematički pristup vrednovanju koji se koristi kako bi se nadopunili nedostaci standardnog pristupa vrednovanju te došlo do preciznijeg izračuna vrijednosti.

Identifikacija specifičnosti poslovanja poduzeća naftne i plinske industrije naslov je trećeg dijela u kojem se ukratko opisuju karakteristike i temeljna obilježja poslovanja poduzeća naftne i plinske industrije. Na osnovu toga definiraju se bitne odrednice poduzeća koje se nadalje promatraju kao parametri klasterizirani po odgovarajućim skupinama bitnim za vrijednost poduzeća. Isto tako u ovom dijelu izlažu se računovodstvene i financijske specifičnosti poduzeća naftne i plinske industrije, a temeljem kojih je identificirana potreba za drugačijim (suvremenijim) pristupom vrednovanju poduzeća.

Naslov četvrtog dijela rada *Ocjena financijskih i nefinancijskih pokazatelja u funkciji postavljanja kriterija za vrednovanje poduzeća naftne i plinske industrije* označava početak analitičkog dijela rada, u kojem se kroz identifikaciju samih parametara koji utječu na vrijednost poduzeća, njihovu ocjenu i međuovisnosti postavljaju kriteriji za vrednovanje poduzeća naftne i plinske industrije suvremenim pristupom. U ovom dijelu koriste se realni podaci poduzeća naftne i plinske industrije različitih veličina i sa različitih tržišta poslovanja, financijske i nefinancijske prirode, kako bi se kriteriji postavili što objektivnije i točnije.

Analitički dio nastavlja se kroz peti dio pod naslovom *Računalna inteligencija kao suvremeni alat u rješavanju problema moderne ekonomije* u kojem se pojašnjavaju bitne odrednice za razumijevanje alata i metoda računalne inteligencije, a koje su korištene za kvantifikaciju i klasterizaciju parametara kao i za izradu samog modela suvremenog pristupa vrednovanju poduzeća. Također, ukazuje se na područja u kojima se računalna inteligencija najčešće primjenjuje u ekonomiji.

Posebna pozornost posvećena je šestom dijelu s naslovom *Izbor i kvantificiranje parametara za prijedlog suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije* u kojem će se temeljem zaključaka analitičkih dijelova rada kvantificirati parametri bitni za izradu modela procjene vrijednosti naftne i plinske industrije suvremenim pristupom. U ovom dijelu kvantificiraju se i parametri kvalitativne prirode i nefinancijskog karaktera koji su bitni za stvaranje i akumulaciju vrijednosti poduzeća te određuju kriteriji vrednovanja bitni za model.

Prijedlog modela za vrednovanje poduzeća na osnovi neizrazite logike s obzirom na specifičnosti naftne i plinske industrije naslov je sedmog, najvažnijeg dijela. U njemu se sintetiziraju svi prethodno identificirani i kvantificirani dijelovi bitni za utvrđivanje vrijednosti poduzeća u suvremeni model pomoću neizrazite logike.

U osmom dijelu s naslovom *Primjena i ograničenja predloženog modela* vrši se ispitivanje predloženog modela te interpretiraju dobiveni rezultati. Također se vršiti i komparativna analiza predloženog modela i postojećih standardnih pristupa za vrednovanje poduzeća uz prijedloge mogućih primjena razvijenog modela.

U posljednjem dijelu, *Zaključku*, sustavno i koncizno su formulirani i prezentirani najvažniji rezultati do kojih se došlo istraživanjem, opširnije elaborirani u radu, a temeljem kojih se dokazala postavljena hipoteza.

2. ANALIZA TEORIJSKE OSNOVE PRISTUPA PROCJENI VRIJEDNOSTI PODUZEĆA

Poduzeće kao predmet procjene vrijednosti, predstavlja sastavnicu cjeline učinaka gospodarskih dobara, kako materijalnih tako i nematerijalnih, podređenih ostvarivanju cilja postojanja poduzeća, pa se njegova vrijednost zapravo ne promatra kao suma pojedinačnih vrijednosti, već kao ukupna vrijednost skupa učinaka (Tichy, 2009.). Bit je takve vrijednosti opstanak i budućnost poslovanja kroz mogućnost stvaranja budućih poslovnih rezultata, a može se definirati kroz očekivani razvoj poslovanja od datuma procjene. Ona je usko vezana na teorijska načela vrednovanja prema kojima je jedan predmet vrijedniji od drugoga samo onda kada raste njegova korisnost za čovjeka. U tom kontekstu, objektivnu vrijednost, kao stvarnu neovisnu interpretacijsku vrijednost, moguće je oblikovati na osnovi vrijednosti supstance ili reproduksijske vrijednosti. Radi se o vrijednosti poduzeća na dugi rok kada prosječni poslovni troškovi postanu poslovno opravdani i određuju vrijednost učinka (Koletnik, 1991.).

Stoga i u najjednostavnijem smislu, teorija koja okružuje vrijednosne interese u poslovanju ovisi o budućim koristima koje će pristići vlasniku tih interesa. U tom kontekstu vrednovanje poduzeća može se promatrati kao procjena budućih koristi koje poduzeće kao imovina može proizvesti svom vlasniku i potrebne stope povrata kojom se ta buduća korist diskontira na sadašnju vrijednost.

Ovisno o svrsi, vrednovanje poduzeća usko je povezano s mnoštvom unutarnjih (pravno uređenje, vrsta djelatnosti, lokacija, organizacijska struktura, itd.) i vanjskih čimbenika (društveno-ekonomski sustav, zakonski okviri, mjesto i značenje na tržištu, itd.), a okosnicu svake procjene čine računovodstvene informacije zabilježene u financijskim izvještajima (Brlečić Valčić, 2012.).

Analitičari koriste široki spektar modela i metoda za procjenu vrijednosti poduzeća, od jednostavnih do vrlo sofisticiranih. Različiti modeli polaze od različitih pretpostavki za vrednovanje, a po nekim zajedničkim karakteristikama i pretpostavkama mogu se klasificirati i svrstati u određene kategorije.

Bez obzira na korišteni model vrednovanja, vrijednost poduzeća pod izravnim je utjecajem specifičnosti poslovanja promatranog poduzeća i grane u kojoj posluje, te svakako tržišnim specifičnostima te specifičnostima makroekonomskih uvjeta i globalnog stanja ekonomije.

Stupanj preciznosti procjene najčešće ovisi o samom poduzeću koje se vrednuje, pa su tako procjene preciznije kod dobro uhodanih poduzeća s dugogodišnjom tradicijom poslovanja, dugogodišnjim povijesnim zapisima financijskih izvještaja i ostalih potrebnih informacija iz grana poslovanja za koje postoje informacije za usporedbu na različitim tržištima. S druge strane, kod poduzeća u nastajanju ili poduzeća kratkog poslovnog vijeka predviđanje poslovanja u budućnosti je znatno teže.

U slučaju sigurnosti i dugogodišnje konstante ili rasta u novčanim tokovima i rezultatima poslovanja, uz kvalitetne prethodne analize poslovanja primjenjiv je standardni pristup vrednovanju poduzeća. Međutim, zbog sve veće nesigurnosti u poslovnom okruženju nastaje potreba uvrštavanja sve većeg broja parametara u modele. Zbog nemogućnosti definiranja određenih ovisnosti među pokazateljima, tj. parametrima, dolazi do sve veće potrebe nadopune standardnog principa vrednovanja složenim matematičkim modelima uz primjenu ekonometrije i moderne statistike.

Analiza teorijske osnove pristupa procjeni vrijednosti poduzeća može se elaborirati i prezentirati kroz: **1) Standardni pristup procjeni vrijednosti poduzeća i 2) Kvantitativno–matematički pristup procjeni vrijednosti poduzeća.**

2.1. Standardni pristup procjeni vrijednosti poduzeća

Financijski analitičari, procjenitelji i teoretičari vrijednosti poduzeća često se pozivaju na staru uzrečicu Oscara Wildea koja cinika opisuje kao osobu koja zna cijenu svega, ali vrijednost ničega. Pri tom se osvrću na investitore, ali i analitičare, koji zagovaraju investicijsku teoriju "veće budale" prema kojoj je stvarna vrijednost imovine irelevantna sve dok postoji "veća budala" koja ju je voljna kupiti. Prema takvim teorijama, svaka cijena za imovinu može biti opravdana ako postoje investitori koji su je voljni platiti. Ovakve percepcije vrednovanja možda mogu vrijediti za procjenu slika ili skulptura, ali investiranje u poduzeća nije, odnosno ne bi trebalo biti, povezano uz estetske ili emocionalne razloge (Damodaran, 2012.).

Shvaćanje vrednovanja poduzeća se kroz povijest konceptualno mijenjalo, a danas pod pretpostavkom nastavka poslovanja uglavnom predstavlja procjenu budućih zarada koje će poduzeće za svog vlasnika generirati, kao i procjenu nivoa

očekivanog rasta budućih zarada u okvirima koncepta vrijednosti u uporabi i vrijednosti u razmjeni.

Kada je riječ o poduzećima naftno plinske industrije, postojeći postupci u procjeni vrijednosti temelje se na kombinaciji tri osnovna pristupa vrednovanju:

- *imovinskom pristupu* u kojem se procjenjuje vrijednost imovine temeljem njene sposobnosti stvaranja prihoda,
- *tržišnom pristupu* u kojem se uspoređuje tržišna vrijednost (vrijednost već realizirane transakcije) sličnih poduzeća iz industrije s poduzećem kojem se želi utvrditi vrijednost, i
- *prihodovnom pristupu* kojim se predviđa stvaranje budućih novčanih tokova te se diskontiranjem istih na sadašnju vrijednost utvrđuje vrijednost poduzeća.

Većina izazova u postojećim postupcima vrednovanja poduzeća naftno plinske industrije odnose se na (Brlečić Valčić i sur., 2013.):

- predviđanje cijena nafte i plina modeliranjem različitih makro i mikro-ekonomskih scenarija,
- nedostatak objavljenih specifičnih informacija koje se odnose na svaki pojedinačni segment poslovanja, a korisne su za detaljno predviđanje budućih prihoda i rashoda, pa se projekcije često rade na temelju iskustva i osjećaja o proizvodnim kapacitetima i sposobnostima, tehnologijama rafiniranja, tehnološkim mogućnostima izvedbe složenih projekata (poglavito u odobalnom sektoru) i *know-how-a*,
- normaliziranje računovodstvenih stavaka pogotovo u smislu rezervi koje su zabilježene po različitim standardima (*Successful Efforts* - SE or *Full Cost* - FC), jer da bi poduzeća bila usporediva, potrebno je pobrinuti se da imaju potpuno ujednačene stavke na temelju istih računovodstvenih principa,
- precizno određivanje fokusa eksploatacijsko proizvodnih poduzeća, s tim da su neke više fokusirane na naftu, neke više na plin, neke podjednako na oba izvora, i
- potrebu detaljne analize postotka stvaranja prihoda i rashoda od različitih djelatnosti unutar naftno plinske industrije kod integriranih poduzeća.

U tom kontekstu, značajne karakteristike standardnog pristupa vrednovanju poduzeća potrebno je promatrati kroz: **1) Teorijski aspekt vrijednosti poduzeća**

kao cjeline u uporabi i njegove fer tržišne vrijednosti, 2) Pojam i karakteristike imovinskog pristupa vrednovanju poduzeća, 3) Značaj i odrednice tržišnog pristupa vrednovanju poduzeća te 4) Fundamentalnu teoriju prihodovnog pristupa vrednovanju poduzeća.

2.1.1. Teorijski aspekt vrijednosti poduzeća kao cjeline u uporabi i njegove fer tržišne vrijednosti

Vrijednost koristi koju kroz poslovanje poduzeće donosi njegovim vlasnicima u smislu ostvarivanja poslovnih rezultata, a temeljem koje se može odrediti kvaliteta poslovanja, predstavlja uporabnu vrijednost, tj. vrijednost u uporabi. U filozofskom smislu, ona uvijek predstavlja tzv. *going concern* koncept prema kojem se pretpostavlja vremenski neograničen nastavak poslovanja bez prekida. Koncept vrijednosti u uporabi poduzeća kao cjeline može se promatrati na nekoliko načina. Prvi od njih preuzet je iz koncepta Međunarodnog računovodstvenog standarda 36, prema kojem se vrijednost u uporabi definira kao sadašnja vrijednost budućih novčanih tokova za koje se očekuje da će pritjecati od imovine ili jedinice koja stvara novac (IAS 36, 2012.). Poduzeće u cjelini se u ovom kontekstu promatra kao imovina (Brlečić Valčić i Crnković-Stumpf, 2013.). Prema istom računovodstvenom konceptu, utvrđivanje vrijednosti u upotrebi trebala bi se odraziti na sljedeće elemente:

- procjenu budućih novčanih tokova koji se očekuju od neprekinute upotrebe imovine,
- očekivanje mogućih odstupanja u iznosima ili vremenu nastanka budućih novčanih tokova,
- vremensku vrijednost novca,
- cijenu prisutnog rizika koje nosi imovina, i
- ostale čimbenike, kao što je primjerice nelikvidnost koja može utjecati na određivanje očekivanih budućih novčanih tokova koje stvara neprekinuta upotreba imovine.

Promatranjem novčanih tokova kao i ostalih poslovnih rezultata kroz određeno višegodišnje razdoblje, a temeljem toga i projekcijom budućih rezultata, donose se zaključci o korisnostima koje određeno poduzeće kroz svoje poslovanje donosi vlasnicima, čime je moguće odrediti kvalitetu poslovanja. Vodeći se u filozofskom

smislu vrednovanja *going-concern* konceptom, veću uporabnu vrijednost imati će kvalitetnije poduzeće s boljim poslovnim rezultatima.

Drugi koncept utvrđivanja vrijednosti u uporabi poduzeća kao cjeline može se promatrati kroz utvrđivanje vrijednosti supstance poduzeća što označava utvrđivanje njegove reproduksijske vrijednosti. Ovim se postupkom utvrđuje sposobnost poduzeća, odnosno imovine koju posjeduje, za ostvarivanjem poslovnih zadataka i postizanjem poslovnih rezultata. Supstancom se dakle ostvaruje poslovni cilj poduzeća koji proizlazi iz poslovne aktivnosti i prodaje poslovnih učinaka. Reprodukcijska sposobnost poduzeća definira se kao sposobnost poslovnog subjekta da stalno održava tok poslovanja na određenom nivou, a može se sagledati kao (Crnković-Stumpf, 1991.):

- sposobnost jednostavne reprodukcije, odnosno sposobnost održavanja poslovanja na istom nivou, tako da svaki slijedeći ciklus reprodukcije uključuje iste količine potrebnih elemenata poslovanja,
- sposobnost sužene reprodukcije, tj. obnavljanje poslovanja iz prethodnog ciklusa na smanjenom nivou, ili
- sposobnost proširene reprodukcije kada se obujam poslovanja u odnosu na prethodni ciklus povećava iz dva moguća razloga:
 - povećanog stupnja korištenja kapaciteta, ili
 - proširenih ili usklađenijih kapaciteta, ostvarenih dodatnim investiranjem.

Treći koncept utvrđivanja vrijednosti u uporabi poduzeća kao cjeline može se promatrati kroz utvrđivanje dodane ekonomske vrijednosti (*Economic Value Added, EVA*), odnosno kroz koncept koji omogućava fokusiranje na aktivnosti u svakodnevnom poslovanju koje vode kreiranju vrijednosti poduzeća. Ovaj koncept bazira se na pretpostavci da se dodana vrijednost kreira jedino u slučaju kad poduzeće zarađuje svoj trošak uloženog kapitala. *EVA* predstavlja neto operativni profit poduzeća nakon plaćenog poreza, a definira se kao razlika neto prihoda od poslovanja i cijene kapitala potrebnog da se taj prihod ostvari. Ta razlika predstavlja preostali dobitak koji se javlja kada se od dobitka odbiju troškovi kapitala korištenog pri njegovom stvaranju.

U determiniranju vrijednosti poduzeća kao cjeline, nameće se i filozofija fer tržišne vrijednosti. Naime, ako se promatra poduzeće kao cjelina u kontekstu kupoprodaje, te da se ono može kupiti i prodati na tržištu kao i svaka druga imovina, tada se njegova vrijednost može definirati kao cijena koja bi se mogla

ostvariti njegovom prodajom u uobičajenoj transakciji između neutralnih učesnika na tržištu na dan mjerenja vrijednosti po tekućim tržišnim uvjetima.

Vodeći se filozofijom razvijenih računovodstvenih standarda, obilježja ovako definirane fer vrijednosti mogu se iskazati kroz (Mrša i Miljak, 2012.; IFRS 13, 2012.):

- izlaznu cijenu,
- cijenu koja bi se ostvarila za prodanu imovinu ili platila za podmirenje obveze,
- mjeru vrijednosti za određenu imovinu ili obvezu,
- hipotetičnu vrijednost transakcije koja podrazumijeva normalni položaj na tržištu i provedene uobičajene marketinške aktivnosti prije dana mjerenja,
- vrijednost na određeni dan,


pri čemu se moraju uzeti u obzir posebna obilježja imovine i obveza. Ovako definirana fer vrijednost u sebi već sadrži kategoriju uporabne vrijednosti te se može podijeliti na:

- vrijednost u uporabi (prethodno definirana), i
- vrijednost u razmjeni, odnosno ona koja se promatrano kroz monetarnu komponentu može postići razmjenom na tržištu.

Problem utvrđivanja fer tržišne vrijednosti poduzeća kao cjeline očituje se u činjenici da, za razliku od ostalih roba i usluga, ne postoje definirana tržišta za kupoprodaju poduzeća, već svaka kupoprodaja predstavlja specifičan slučaj koji se ne može u potpunosti usporediti ni sa kojim drugim slučajem. Osim toga, struktura vrijednosti poduzeća kod kupoprodaje u visokom je stupnju ovisnosti o predodžbama poslovnih performansi tog poduzeća, kao i interesa ugovornih strana. Iz navedenih razloga, standardi razvijeni za procjenu vrijednosti poduzeća definiraju samu procjenu kao postupak određivanja "objektivne" vrijednosti, odnosno vrijednosti koja pripada samom poduzeću neovisno o danim tržišnim uvjetima, kao i posebnim okolnostima i uvjetima ponuđača i kupaca. Takva se procjena ne bavi utjecajima ponuđača i kupaca na konačnu vrijednost poduzeća, kao ni njihovim interesima, a upravo oni određuju konačnu tržišnu vrijednost.

Na osnovi navedenog, komponente vrijednosti sadržane u kategoriji fer tržišne vrijednosti poduzeća kao cjeline prikazane su na slici 1., a mogu se definirati kao:

- uporabna vrijednost, odnosno vrijednost procijenjena imovinskim ili prihodovnim pristupom procjeni,
- akvizicijska vrijednost, odnosno uporabna vrijednost uvećana za kupovnu premiju, i
- vrijednost uvećana za sinergijske učinke, odnosno očekivana dodana vrijednost koja će nastati prilikom spajanja poduzeća.



Slika 1. Komponente fer tržišne vrijednosti poduzeća

Očito je da će raspon vrijednosti između uporabne i fer tržišne vrijednosti sadržavati komponentu subjektivnih očekivanja kupca.

2.1.2. Pojam i karakteristike imovinskog pristupa vrednovanju poduzeća

U međunarodnom rječniku terminologije vrednovanja poduzeća, imovinski pristup vrednovanju definira se kao opći način utvrđivanja vrijednosnih indikatora poslovanja, poslovno-vlasničkih interesa ili vrijednosnica, korištenjem jedne ili više metoda temeljenih na vrijednosti imovine umanjene za vrijednost obveza (Hitchner, 2006.).

Osnovni financijski izvještaj za analizu kod imovinskog pristupa vrednovanju poduzeća je bilanca na kraju nekog obračunskog razdoblja koja služi kao početna

točka promatranja. Vrednovanje imovinskim pristupom provodi se na način da se bilanca promatranog poduzeća s kraja posljednjeg obračunskog razdoblja prilagođava ponovnim vrednovanjem po svim stavkama, a u obzir se uzimaju samo značajne stavke te se po potrebi dodaju stavke koje u početnoj bilanci nisu ni postojale, poput stavki nematerijalne imovine i izvanbilančne pasive, tj. potencijalnih obveza na temelju izdanih garancija. Ako postoje razvijeni standardi vrednovanja poduzeća, stavke se ponovno vrednuju po tim standardima. Za značajne imovinske stavke često se koriste usluge ovlaštenih procjenitelja što ovu metodu čini iznimno skupom.

Iz navedenog proizlaze temeljna pravila imovinskog pristupa koja glase:

(a) Fundamentalni računovodstveni princip

- Knjigovodstvena vrijednost imovine umanjena za knjigovodstvenu vrijednost obveza jednaka je knjigovodstvenoj vrijednosti vlasničkog kapitala;

(b) Fundamentalni princip vrednovanja poduzeća prema imovinskom pristupu

- Tekuća vrijednost imovine umanjena za tekuću vrijednost obveza jednaka je tekućoj vrijednosti vlasničkog kapitala (Pratt, 2008.).

Potreba za imovinskim pristupom vrednovanja poduzeća nastaje zbog činjenice da se većina stavaka u bilanci i dalje bilježi po povijesnim troškovima. Kako je već spomenuto, standardi za utvrđivanjem fer vrijednosti tih stavaka postoje i razvijaju se već dugi niz godina, tj. knjigovodstvena vrijednost kapitala zabilježena u financijskim izvještajima ne predstavlja njegovu fer tržišnu vrijednost. Na taj se način utvrđuje stvarna fer tržišna vrijednost imovine, obveza, a samim time i kapitala na datum vrednovanja. U slučaju da su stavke u bilanci već vrednovane po fer vrijednosti, analitičari koji vrše procjenu poduzeća moraju biti izvrsni poznavatelji računovodstvenih standarda. Iako na prvi pogled vrlo jednostavan, imovinski pristup vrednovanja zahtijeva veliko, prvenstveno računovodstveno, znanje i iskustvo.

Kao najznačajnije metode vrednovanja poduzeća unutar imovinskog pristupa procjeni vrijednosti mogu se istaknuti (Pratt, 2008.):

- zajednička reevaluacija svih stavaka imovine i obveza promatranog poduzeća koja se obično izvodi uz pomoću aplikacije metode kapitaliziranog viška zarada, i

- pojedinačna reevaluacija svih stavaka imovine i obveza po takozvanoj imovinsko akumulacijskoj metodi.

Vrednovanje unutar bilo koje od navedenih metoda imovinskog pristupa trebalo bi rezultirati istim ili približno istim vrijednostima, a izbor metode ovisi ponajprije o iskustvu i prosudbi analitičara, kvaliteti i kvantiteti raspoloživih podataka, namjeni i cilju vrednovanja, te obujmu, budžetu i vremenskoj raspoloživosti samog zadatka procjene vrijednosti poduzeća.

Imovinsko akumulacijska metoda, ako je pravilno izvedena, predstavlja jednu od najkompleksnijih analiza vrednovanja poduzeća. Obuhvaća odvojenu identifikaciju i pojedinačnu reevaluaciju sljedećih stavaka (Pratt, 2008.):

- računovodstvene kategorije financijske imovine (novac, potraživanja, unaprijed plaćeni troškovi, zalihe),
- materijalna imovina (postrojenja i oprema, namještaj, instalacije i pripadajući dio opreme, kamioni, osobna vozila),
- nekretnina (zemljište i ulaganja u zemljište, zgrade i ulaganja u zgrade),
- nematerijalne realne imovine (najmovni interesi, služnosti, mineralno eksploatacijska prava, zračna i vodna prava, razvojna prava, itd.),
- nematerijalne osobne imovine (patenti, tržišne marke, autorska prava, računalni programi, trgovačke tajne, odnosi s kupcima, vrijednost nastavka poslovanja, *goodwill*, itd.),
- računovodstvene kategorije tekućih obveza (obveze prema dobavljačima, porezne obveze, obveze prema zaposlenima, predviđene obveze, itd.),
- računovodstvene kategorije dugoročnih obveza (obveznice, zabilješke, hipoteke, plative zadužnice, itd.),
- potencijalne obveze (otvorena moguća porezna dugovanja, eventualna dugovanja iz otvorenih parničnih sporova, mogući troškovi iz područja zaštite okoliša, itd.),
- posebne obveze (mirovinske obveze, neprikazani neiskorišteni godišnji odmori i ostala odsustva, zaposleničko-vlasnički dioničarski plan, repo obveze, itd.).

Metodom kapitaliziranog viška zarada (Howe i sur., 2007.), procjenjuje se skupna vrijednost imovine kao nematerijalne vrijednosti poduzeća, pa iako poneki autori svrstavaju njenu pripadnost u prihodovni pristup procjene, ona je zbog svoje

osnove, tj. ponovnog vrednovanja imovine, najbliža imovinskom pristupu procjene.

Da bi se ovom metodom procijenila vrijednost poduzeća, potrebno je razviti četiri ključne varijable:

- neto vrijednost materijalne imovine,
- bazu zarade koja mora biti kapitalizirana,
- razumnu stopu povrata na neto materijalnu imovinu, i
- direktnu stopu kapitalizacije koja treba biti primijenjena na višak zarade.

Postupak procjene kod ove metode može se svesti na pet ključnih koraka kako slijedi (Howe i sur., 2007.):

- (1) Utvrditi prosjek neto dobiti na temelju razdoblja od najmanje pet godina, uz izuzetak razumne kompenzacije vlasnika ili partnera. Neuobičajene godine, u kojima rezultati poslovanja odskakuju od prosjeka, treba izuzeti iz promatranja, čime se dobiva normalizirana dobit.
- (2) Utvrditi prosjek godišnje vrijednosti stalne imovine korištene u poslovanju za reprezentativan broj godina prije datuma vrednovanja.
- (3) Utvrditi fer povrat na stalnu imovinu koji može biti industrijski prosjek ili se može koristiti stopa od 8 do 10 %.
- (4) Oduzeti stavku (3) od stavke (1), čime se dobiva prosjek zarada pripisanih *goodwillu* ili višak zarade.
- (5) Kapitalizirati prosjek zarada pripisanih *goodwillu* s prikladnom stopom kapitalizacije koja bi trebala iznositi između 15% i 20%.

Kontrolni postotak koji se dobiva dijeljenjem normalizirane dobiti i na ovaj način procijenjene vrijednosti poduzeća treba predstavljati realnu vaganu prosječnu stopu kapitala (*Weighted Average Cost of Capital, WACC*) za poduzeće koje se vrednuje (Howe i sur., 2007.). Iz navedenog slijedi da se vrijednost poduzeća može odrediti dijeljenjem normalizirane dobiti i vagane prosječne stope kapitala.

Kombinacijom ove dvije metode unutar imovinskog pristupa procjenitelji se koriste kada imaju mogućnost u obzir uzeti imovinu i obveze koje je jednostavno reevaluirati te je procjenjuju po imovinsko akumulacijskoj metodi, a ostalu imovinu procjenjuju metodom kapitaliziranog viška zarada.

Prednosti imovinskog pristupa vrednovanju poduzeća su ponajprije jednostavnost u prezentiranju dobivenih rezultata, poglavito u slučaju primjene imovinsko akumulacijske metode, jer se rezultati dobiveni reevaluacijom pojedinih stavaka iz bilance prikazuju ponovno u bilančnom obliku, pa su jednostavni i razumljivi svakom tko se ikad susreo s financijskim izvještajima. Na taj način imovinsko akumulacijska metoda identificira i prikazuje imovinu koja stvara ekonomsku vrijednost poduzeća, i u kojem opsegu. Zbog jednostavnosti prikaza, ova metoda pogodna je u prezentaciji unutar pregovora o prodaji poduzeća.

Nedostaci ove metode odnose se na visoke troškove procjenitelja i stručnjaka za procjenu pojedinih stavaka imovine i obveza, poglavito u slučaju vrednovanja velikih kompleksnih poduzeća, te na nemogućnost mjerenja i uvrštavanja pojedinih kvalitativnih stavaka u imovinu poduzeća.

Imovinski pristup u eksploatacijsko proizvodnom sektoru naftno plinske industrije koristi se uglavnom kod procjene vrijednosti rezervi nafte i plina te njihovoj mogućnosti stvaranja prihoda u budućnosti s obzirom na tretman samih rezervi.

U ostalim sektorima, imovinski pristup odnosi se na složene studije procjene imovine u tehnološkom smislu i u smislu procjene njihovog korisnog vijeka trajanja, studije procjene troškova zamjene određene imovine novom, te procjene mogućnosti stvaranja prihoda pojedinih imovinskih sektora, bilo da se radi o pojedinačnoj imovini ili cijelom postrojenju.

2.1.3. Značaj i odrednice tržišnog pristupa vrednovanju poduzeća

Tržišni pristup vrednovanju poduzeća svodi se na komparativnu analizu između poduzeća koje se procjenjuje i nekog sličnog poduzeća iz iste industrijske grane koje je već ranije prodano na tržištu. Kod analize sličnosti ova dva poduzeća, koriste se različiti usporedivi financijski i nefinancijski pokazatelji o kojima ovisi vrijednost poduzeća. Na ovaj način se mogu procijeniti i različiti vrijednosni interesi, kao i imovina.

Ostvarene realne tržišne transakcije osiguravaju empirijsku evidenciju vrednovanja poduzeća. Ovakve evidencije zabilježene su u raznim bazama podataka koje predstavljaju okosnicu za vrednovanje poduzeća na osnovu ovog pristupa. Različite baze podataka koriste se kao vjerodostojni izvori u pružanju

financijskih i ostalih informacija za određene industrijske grane na temelju kojih se postavljaju takozvane industrijske norme. Upravo takvi podaci korisni su za izravno vrednovanje poduzeća temeljem tržišnog pristupa u slučaju kada su osnovne vrijednosti poduzeća koje se vrednuje poznate.

Metode iz ovog pristupa često se koriste u kombinaciji s drugim metodama vrednovanja poduzeća, a mogu se primijeniti i kao polazna točka u vrednovanju. Pri tome analitičari mogu objektivno postaviti određene ciljeve za izračun vrijednosti koja bi bila jednaka ili slična onoj usporedivoj.

Kako iznos plaćen za određeno poduzeće predstavlja očekivanja investitora, tržišni pristup često služi za procjenu poduzeća bez duge povijesti poslovanja ili onog koje je tek na početku poslovanja (*start-up*).

Kada su prodajne transakcije temelj utvrđivanja vrijednosti poduzeća, takve vrijednosti općenito predstavljaju kontrolne utržive vrijednosti. Kontrolnog su karaktera jer se baziraju na akvizicijama cijelih poduzeća, a utržive su jer transakcija predstavlja prodaju privatnih poslovnih entiteta za koje postoji kupac, ali ne postoji neposredno i spremno tržište (Hitchner, 2006.).

Formula za izračun vrijednosti poduzeća tržišnim pristupom može se izraziti kao

$$\text{vrijednost}_{pp} = \left(\frac{\text{cijena}}{\text{parametar}} \right)_{up} \times (\text{parametar})_{pp} - (\text{dugovanja})_{pp} \quad (2.1)$$

pri čemu se indeks *pp* odnosi na promatrano poduzeće koje se procjenjuje, indeks *up* na usporedno poduzeće s kojim se provodi komparacija, "parametar" predstavlja veličinu koja se uspoređuje, a to može biti prodaja, neto dobit, knjigovodstvena vrijednost, itd. Izraz "cijena/parametar" tako označava primjerice omjer cijene i neto dobiti ili omjer cijene i knjigovodstvene vrijednosti usporedivih poduzeća.

Kao najčešće korištena metoda za vrednovanje unutar ovog pristupa može se izdvojiti *usmjereno usporedna metoda* za poduzeća kojima se javno trguje (*Guidline Publicly Traded Company Method*). Kapitalizirana stopa za promatranu varijablu koja se uspoređuje predstavlja reciprocitet cjenovnog multiplikatora. Kao najčešće korištene varijable za razvijanje multiplikatora usporedbom s drugim poduzećima mogu se izdvojiti (Pratt, 2008.):

- neto prodaja,

- bruto novčani tok, tj. neto dobit uvećana za nenovčane promjene,
- *EBIT*,
- neto novčani tok, tj. bruto novčani tok prilagođen s kapitalnim ulaganjima, promjenama u radnom kapitalu, ponekad uključuje i promjene u dugovanjima,
- dobit prije poreza,
- dobit nakon poreza,
- dividende ili sposobnost (kapacitet) plaćanja dividendi.

Kod metode tržišne vrijednosti investiranog kapitala (*Marked Value of Invested Capital, MVIC*), promatrane varijable za usporedbu najčešće su:

- prihodi od prodaje,
- bruto dobit,
- *EBIT*,
- *EBITDA*,
- diskrecijska zarada (*EBITDA* + vlasnička naknada),
- knjigovodstvena vrijednost (*KV*) investiranog kapitala.

Prednosti tržišnog pristupa vrednovanju su:

- jednostavnost u razumijevanju i primjeni,
- korištenje aktualnih podataka,
- uključivanje vrijednosti ukupne poslovno operativne imovine,
- ne oslanja se na eksplicitna predviđanja budućnosti.

Nedostaci ovog pristupa očituju se u sljedećem:

- rijetko postoji uistinu prikladno poduzeće ili transakcija za usporedbu, i
- mnoge pretpostavke za procjenu su skrivene.

Kod primjene tržišnog pristupa u vrednovanju poduzeća naftno plinske industrije, najčešće korištenom metodom *Comparable Public Companies & Precedent Transactions* (Breaking into Wall Street, 2013.), postoje određene razlike u određivanju parametara koji se uspoređuju od onih uobičajenih u drugim industrijama, poglavito u eksploatacijsko proizvodnom sektoru i dijelu integriranih poduzeća koji se odnosi na eksploataciju i proizvodnju, a mogu se izraziti kao:

- umjesto usporedbe po vrsti prihoda ili *EBITDA*, usporedba se vrši selekcijom koja je temeljena na odobrenim rezervama ili dnevnoj proizvodnji kao dodatak uobičajenim geografskim i industrijskim kriterijima,
- umjesto tradicionalnih mjera poput prihoda ili *EPS* (*Earnings Per Share*), lista pokazatelja i multiplikatora bazira se na *EBITDAX* (*Earnings Before Interest, Taxes, Depreciation, Depletion, Amortization and Exploration Expenses*), odobrenim rezervama, dnevnoj proizvodnji, omjeru prihoda ostvarenom vađenjem nafte ili plina i ostalim mjerama.

2.1.4. Fundamentalna teorija prihodovnog pristupa vrednovanju poduzeća

Prihodovni pristup vrednovanju poduzeća najčešće je korišteni pristup vrednovanja. Koristi se u gotovo svakoj procjeni u kojoj ga je moguće koristiti samostalno ili u kombinaciji s nekom od metoda ostalih pristupa. Sam termin "*prihodovni pristup*" proizlazi iz srži ekonomske definicije prihoda kao određenog priljeva u gospodarsku jedinicu u zamjenu za robu, usluge ili kapital, a orijentiran je na buduća kretanja poslovanja, tj. vrijednost iskazana u trenutku vrednovanja, odraz je predviđanja budućih rezultata poslovanja diskontiranih na dan vrednovanja.

Premisa vrijednosti poduzeća temeljena na ovom pristupu zasniva se na pretpostavci da je vrijednost vlasničkog interesa jednaka sumi sadašnjih vrijednosti i očekivanih budućih koristi od posjedovanja tih interesa (Hitchner, 2006.).

Vrednovanje poduzeća ovim pristupom predstavlja matematičku frakciju budućih isplata ulaganja i kvantifikacije rizika i neizvjesnosti od tih budućih ulaganja. Protok budućih ekonomskih koristi označava očekivane buduće koristi koje mogu biti izražene preko novčanih tokova ili neke druge veličine. Tako se često u modelima koriste veličine poput dobiti prije poreza i amortizacije (*EBITDA*) ili dobiti prije poreza (*EBIT*).

Stopa povrata potrebna za ostvarivanje određenog interesa (oportunitetni trošak ili trošak kapitala) odraz je investitorovih očekivanja budućih ekonomskih koristi. Sastavljena je od nekoliko elemenata kao što su:

- očekivani iznos novca koji se očekuje da bi se investitori odlučili na takvu investiciju, umjesto nekog manje rizičnog ulaganja,

- očekivana stopa inflacije i prikaz njenog utjecaja na investiciju u razdoblju u kojem se želi investirati,
- stopa rizika koja je odraz nesigurnosti u količinu novčanih ekvivalenata i dobiti koja će biti ostvarena u određenom razdoblju potrebnom za isplativost investicije,

s tim da se najčešće korištene i analizirane veličine u ovom pristupu:

- razne isplate (dividende, kamate, vrijednosni papiri, partnerske isplate),
- novčani tok (često mjeren kao neto novčani tok),
- neke od računovodstvenih veličina zarade (dobit, neto operativni prihod).

Problem česte upotrebe dobiti prije poreza i amortizacije (*EBITDA*) u prihodovnom pristupu vrednovanju poduzeća dvojakog je karaktera. S jedne strane ova se problematika može razmatrati u kontekstu upotrebe odnosa izračunate vrijednosti i *EBITDA*, a na osnovu čega se vrednovana poduzeća lako uspoređuju s drugim poduzećima. Pozitivna strana usporedivih *EBITDA* multiplikatora je korisnost usporedivosti u međunarodnim razmjerima jer se isključuju iskrivljujući učinci poreznih politika pojedinih zemalja. Također se smatra da su vrijednosni *EBITDA* multiplikatori dobar orijentir u pronalaženju kandidata za preuzimanje.

Ograničenja i upozorenja kod korištenja vrijednosnih *EBITDA* multiplikatora odnose se na njihovu upotrebljivost s obzirom na industrijske grane poslovanja poduzeća. Naime, pokazalo se da su ovakvi multiplikatori korisni samo ako se upotrebljavaju unutar iste industrijske grane, dok se usporedba različitih industrijskih grana ovakvim metodama ne preporuča.

S druge strane, problematika je vezana uz upotrebu *EBITDA* kao grube aproksimacije novčanog toka ili zamjenu za predviđeni novčani tok. Naime, iako se *EBITDA* ne može smatrati savršenom mjerom za procjenu novčanog toka, kod analiza profitabilnosti usporedbom različitih poduzeća unutar različitih industrijskih grana upravo se ova mjera pokazala dobra, jer eliminira efekte odluka o financiranju i primjene različitih računovodstvenih politika što se ponajprije očituje u načinu obračuna amortizacije i utjecaju istog na rezultat.

Neki autori tvrde da je *EBITDA* mjera financijskog zdravlja i vrijednosti poduzeća. U takvim ocjenama treba zadržati mjeru opreznosti. Naime, poduzeća koja bilježe velike iznose amortizacije u pravilu imaju velike kapitalne izdatke i moraju platiti

porez. Stoga se može dogoditi da poduzeće u rezultatima bilježi visoke iznose *EBITDA*, a da istodobno ne raspolaže s dovoljnom količinom novca da financira svoje dugove (Damodaran, 2013.).

Dobit prije odbitka kamata, poreza i amortizacije može se u osnovnom obliku izraziti kao

$$EBITDA = EBIT + \text{Deprecijacija} + \text{Amortizacija} \quad (2.2)$$

i označava operativnu dobit na koju je ponovo dodana deprecijacija i amortizacija.

Logika prilagodbe, tj. normalizacija financijskih izvještaja, kao i kod imovinskog pristupa koristi se i kod predviđanja budućih novčanih tokova, a izvodi se na način da se iz njih izbace stavke koje nemaju utjecaj na buduće novčane tokove ili pak ubace stavke za koje se zna da će nastati i imati utjecaj na njih. Ovakva prilagodba je potrebna kako bi se investicija mogla izjednačiti s budućim koristima diskontiranim na sadašnju vrijednost, a obično se odnosi na vlasničke karakteristike (većinske kontrole nasuprot manjinskim), prilagođavanje stavaka financijskih izvještaja u skladu s računovodstvenim standardima, neuobičajene, nematerijalne (u smislu poslovno beznačajne) i izvanredne stavke, neoperativnu imovinu i obveze koje su u svezi s prihodima i rashodima, porezne prilagodbe, te sinergijske učinke kod spajanja i akvizicija.

Najčešće korištena metoda prihodovnog pristupa, metoda diskontiranog novčanog toka (*Discounted Cash Flow Method, DCF*), polazi od teorijske pretpostavke da je vrijednost operativne imovine ili investicije jednaka sadašnjoj vrijednosti toka budućih ekonomskih koristi.

Osnova *DCF* modela može se izraziti preko izraza (Hitchner, 2006.):

$$PV = \sum_{i=1}^n \frac{E_i}{(1+k)^i}, \quad (2.3)$$

pri čemu je

PV – sadašnja vrijednost

E_i – očekivana ekonomska buduća korist u *i*-tom periodu budućnosti (plaćena na kraju razdoblja),

k – diskontna stopa (trošak kapitala, očekivana stopa povrata raspoloživa na tržištu za ostale investicije usporedivog rizika i ostalih investicijskih karakteristika),

- i – period (obično zadani broj godina) u budućnosti unutar kojeg se očekuje primitak ekonomske koristi,
- n – posljednji period za koji se očekuje ekonomska dobit; n može težiti u beskonačnost ako se od ekonomske koristi očekuje beskonačan rast.

Postupak procjene primjenom ove metode s godinama se mijenjao i nadograđivao, a danas se uglavnom svodi na način koji se ukratko može prikazati kroz deset međusobno povezanih koraka (Brlečić Valčić, 2012.):

(1) Unošenje povijesnih podataka iz godišnjih financijskih izvještaja u model, te izračun određenih pokazatelja kako slijedi:

- Unošenje u model neto prodaje za promatrane godine te izračun postotka rasta prodaje s obzirom na prethodnu promatranu godinu.
- Unošenje ukupnih troškova te izračun postotka troškova u odnosu na prodaju po godinama.
- Izračun *EBITDA* (dobiti prije poreza i amortizacije) te postotak marže po godinama.
- Unošenje amortizacije za promatrane godine, te izračun postotka od prodaje u odnosu na amortizaciju.
- Izračun *EBIT* (bruto dobiti ili zarade prije poreza).
- Izračun poreza na dobit po promatranim godinama.
- Unošenje kapitalnih izdataka (*Capex*), te izračun postotka od prodaje po promatranim godinama. Kapitalni izdaci mogu se preuzeti iz izvještaja o novčanom toku, a ako ne postoje u tom izvještaju računaju se kao razlika vrijednosti u materijalnoj imovini promatrane godine u odnosu na prethodnu godinu.
- Složeni izračun godišnjeg rasta svih navedenih parametara (*Compound Annual Growth Rate CAGR*). *CAGR* predstavlja stopu rasta godinu za godinom, a izračunava se preko izraza

$$CAGR = \left(\frac{\text{završna vrijednost}}{\text{početna vrijednost}} \right)^{1/(\text{broj godina})} - 1 \quad (2.4)$$

(2) Izračun povijesnog radnog kapitala te komparacija parametara u postotku od prodaje kako slijedi:

- Unošenje potraživanja od kupaca, zaliha i unaprijed plaćenih troškova kako bi se izračunala ukupna tekuća imovina po promatranim razdobljima, te usporedba ukupne tekuće imovine u postotku od prodaje.
- Unošenje obveza prema dobavljačima te ostalih tekućih obveza kako bi se izračunale ukupne tekuće obveze, te usporedba ukupnih tekućih obveza u postotku od prodaje.
- Izračun neto radnog kapitala na način da se od ukupne tekuće imovine oduzmu ukupne tekuće obveze po promatranim razdobljima, te usporedba neto radnog kapitala u postotku od prodaje.

(3) Izračun budućih projekcija

- Na temelju povijesnih podataka iz točke (1) predviđaju se rezultati za slijedećih pet godina po kategorijama prodaja, ukupni troškovi, *EBITDA*, *EBIT* i *Capex*, na način da se rezultati posljednje godine uvećavaju stopom prosječnog rasta iz prethodnih godina, koja ne bi trebala biti veća od *CAGR* stope (ili može biti jednaka *CAGR* stopi), a može biti i stopa koju je menadžment usvojio kao stopu rasta za buduće poslovanje.

(4) Izračun budućeg novčanog toka

- Predviđanje rasta ukupne tekuće imovine za sve godine projekcije uz pomoć prosječne stope prodaje u odnosu na ukupnu tekuću imovinu prethodne četiri godine.
- Predviđanje rasta ukupnih obveza za sve godine projekcije uz pomoć prosječne stope prodaje u odnosu na ukupne tekuće obveze.
- Izračun radnog kapitala za godine projekcije.
- Dodavanje razlike (povećanja i smanjenja) u radnom kapitalu promatrano za svaku godinu u odnosu na prethodnu, počevši od posljednje projektirane godine.
- Izračun slobodnog novčanog toka.

(5) Ciljana kapitalna struktura i izračun *bete*

- Struktura kapitala ispituje se na način da se analizira koliko se imovine financira iz vlastitih sredstava, a koliko iz tuđih, pri čemu se normalnom strukturom kapitala smatra odnos obveza i kapitala u pasivi u omjeru 30:70.

- Izračunata *beta* predstavlja mjeru rizika poduzeća i industrije u odnosu na tržište kapitala.

(6) Determiniranje WACC

- WACC predstavlja vagani prosječni trošak kapitala koji odražava faktore rizika investicije kako slijedi:
 - trošak kapitala i duga ponderiraju se idealnim udjelom u financiranju ukupne imovine poduzeća,
 - rizik državnih obveznica odražava rizik države,
 - premija rizika odražava rizik tržišta kapitala,
 - *beta* je mjera rizika poduzeća i industrije u odnosu na tržište kapitala,

(7) Izračun sadašnje vrijednosti budućeg novčanog toka pomoću dobivenog diskontnog faktora za sve godine projekcije

(8) Izračun terminalne (konačne) vrijednosti

- Postupak izračuna prema sljedećim koracima:
 - konačna vrijednost godišnjeg novčanog toka,
 - prosječna godišnja stopa rasta gospodarstva,
 - konačni godišnji *EBITDA*,
 - konačna vrijednost,
 - implementirani multiplikator,
 - diskontirani period,
 - diskontni faktor,
 - sadašnja vrijednost terminalne vrijednosti,
 - izračun postotka od vrijednosti poduzeća.

(9) Opis rezultata vrednovanja poduzeća pomoću *DCF* metode

(10) Analiza osjetljivosti.

Nedostaci *DCF* metode mogu se izraziti kroz sljedeće činjenice:

- Točnost utvrđivanja vrijednosti poduzeća pomoću ove metode u visokom postotku oslanja se na kvalitetu pretpostavljenih (predviđenih) događaja odnosno budućih novčanih tokova, sadašnjoj vrijednosti i diskontnoj stopi.

Kao rezultat toga, procijenjena vrijednost na temelju ove metode obično se izražava u rangui od-do, a ponekad u različitim tipovima scenarija (primjerice u osnovnom slučaju, u optimističnom slučaju ili u pesimističnom slučaju) kako bi se ocijenila osjetljivost vrednovanja na različitim operativnim pretpostavkama.

- Ulazne vrijednosti za metodu prikupljaju se iz različitih izvora, pa moraju biti objektivno promotreni i agregirani prije unošenja podataka u model. Ukupna sadašnja vrijednost poduzeća obično predstavlja veliki postotak iznosa vrijednosti poduzeća dobivene *DCF* metodom.
- Kvaliteta procjene vrijednosti poduzeća u izravnoj je ovisnosti o ulaznim pretpostavkama.
- Ovisno o tome kako će promatrano poduzeće poslovati u budućnosti, te kako će se tržišta razvijati, procjene vrijednosti poduzeća temeljene na *DCF* metodi mogu značajno varirati,
- Predviđanje novčanih tokova za nekoliko godina unaprijed je težak posao, ali predviđanja u beskonačnost (što je neophodan ulaz ovakvih analiza) gotovo je nemoguć pothvat.
- Ovakve procjene posebno su osjetljive ne samo kod predviđanja rasta u beskonačnost, već i kod određivanja diskontnih stopa.
- Model također nije prilagođen kratkoročnom investiranju.
- *DCF* analize zahtijevaju stalne nadogradnje modela.

Kod prihodovnog pristupa vrednovanju poduzeća naftno plinske industrije također se standardno koristi *DCF* metoda. Ključne razlike kod izračuna vrijednosti za poduzeća naftno plinske industrije primjenom *DCF* metode u odnosu na poduzeća drugih industrijskih grana odnose se na (Breaking into Wall Street, 2013.):

- dodatne nenovčane troškove (uz uobičajene), poput amortizacije i kompenzacije temeljem dionica;
- korištenje multiplikatora dnevne proizvodnje, *EBITDA* ili *EBITDAX* umjesto multiplikatora baziranog na slobodnom novčanom toku kao završnih izlaznih multiplikatora;
- kod predviđanja dugoročnog rasta pomoću *Gordon Growth* modela, pretpostavka rasta za eksploatacijsko proizvodna poduzeća je 0 %, jer se

imovina (rezerve nafte i plina) istroši tokom vremena, pa se pretpostavlja da je iznos resursa ispod zemlje s vremenom jednak nuli (potrošen);

- za poduzeća naftno plinske industrije uobičajeno se koristi diskontna stopa industrijskog standarda od 10 % umjesto izračuna vaganog prosječnog troška kapitala (*WACC*);
- kod postavljanja tablica osjetljivosti uobičajeno je u ovoj industriji koristiti cijene nafte i plina umjesto varijabli rasta prihoda ili *EBITDA* margina.

S obzirom na navedeno, nedostaci *DCF* metode u procjeni vrijednosti poduzeća naftno plinske industrije odnose se na:

- dobivena sadašnja vrijednost osjetljiva je na pretpostavke i metodologiju;
- terminalnu vrijednost gotovo je nemoguće izračunati jer ovisi o dugoročnim predviđanjima cijena nafte i plina;
- visoki zahtjevi za kapitalnim ulaganjima koji smanjuju slobodan novčani tok mogu kreirati opadajući ili čak negativni novčani tok;
- kako bi projektirana buduća financijska kretanja bila realna, potrebno ih je promatrati unutar barem jednog cijelog proizvodnog ciklusa u trajanju od 7-10 godina da bi se normalizirala kretanja novčanog toka.

2.2. Kvantitativno-matematički pristup vrednovanju poduzeća

Zbog sve veće kompleksnosti u poslovanju poduzeća u sadašnjosti i definiranju budućih trendova poslovanja u uvjetima nesigurnosti poslovanja na tržištu, u rješavanju problema nedostataka i ograničenosti standardnih pristupa i metoda vrednovanja u utvrđivanju objektivne vrijednosti poduzeća sve više se koristi kvantitativni kao i matematički pristup vrednovanju poduzeća sa svrhom nadopune nedostataka standardnog pristupa vrednovanju te preciznijeg izračuna vrijednosti.

U kontekstu analize teorijske osnove pristupa procjeni vrijednosti poduzeća, kvantitativno-matematički pristup može se promatrati kroz: **1) Definiranje međuovisnosti parametara unutar financijskih izvještaja matematičkim modeliranjem novčanog toka i 2) Ulogu i primjenu kvantitativnih metoda u funkciji vrednovanja poduzeća.**

2.2.1. Definiranje međuvisnosti parametara unutar financijskih izvještaja matematičkim modeliranjem novčanog toka

Značajan dio procjene vrijednosti svakog poduzeća, bilo da se radi o procjeni na osnovi jedne od metoda prihodovnog pristupa ili samo analize financijskih izvještaja, temeljen je na proučavanju povijesnih podataka o generiranju novčanog toka te na predviđanju stvaranja budućih novčanih tokova.

Slobodni novčani tok poduzeća (*Free Cash Flow to Firm, FCFF*) mjera je novčanog toka koji ostaje slobodan nakon zadovoljenja svih nositelja potraživanja prema poduzeću (vjerovnika i kapitalnih investitora), oporezivanja i zadovoljenih potreba za reinvestiranjem u poduzeće. Pozitivan *FCFF* upućuje na to da je poduzeće sposobno platiti sve zahtijevane obveze s osnove dugovanja i kapitala (dividende), dok negativan implicira na deficit u slobodnom novcu koji će se morati rješavati dodatnim zaduživanjem ili izdavanjem novih dionica.

Osnovni zapis slobodnog novčanog toka može se prema Damodaranu (2010.) izraziti kao:

$$FCFF = EBIT \times [1 - (\text{porezna stopa})] - [(\text{kapitalni izdaci}) - (\text{deprecijacija})] - (\text{promjena u nenovčanom radnom kapitalu}). \quad (2.5)$$

Vrijednost poduzeća se u najopćenitijem smislu prihodovnog pristupa vrednovanju može zapisati kao sadašnja vrijednost očekivanih slobodnih novčanih tokova poduzeća.

Kada se vrijednost očekivanih slobodnih novčanih tokova ponderira prosječnim troškom financiranja, vrijednost poduzeća može se zapisati kao (Damodaran, 2010.):

$$\text{Vrijednost poduzeća} = \sum_{j=1}^{\infty} \frac{FCFF_j}{(1+WACC)^j} \quad (2.6)$$

pri čemu je $FCFF_j$ slobodni novčani tok poduzeća u godini j , a $WACC$ predstavlja vagani prosječni trošak kapitala koji se definira kao (Pratt, 2008.)

$$WACC = (\text{trošak vlastitog kapitala}) \times \frac{E}{D+E} + (\text{trošak duga}) \times \frac{D}{D+E} \times (1-t) \quad (2.7)$$

gdje je E tržišna vrijednost kapitala, D je tržišna vrijednost duga, $E/(D+E)$ je postotak financiranja koji se odnosi na kapital, $D/(D+E)$ je postotak financiranja koji se odnosi na dugovanja, t je stopa poreza na dobit.

Sadašnja vrijednost novčanih tokova dobivena diskontiranjem očekivanih novčanih tokova po trošku financiranja mjeri vrijednost samo operativne imovine poduzeća, tj. one koja doprinosi operativnoj dobiti. Bilo koja imovina čija zarada ne pridonosi direktno stvaranju operativne dobiti na ovaj način nije uključena u vrijednost. S obzirom na to, potrebno je izvršiti korekciju vrijednosti na način da se od vrijednosti operativne imovine dođe do vrijednosti kapitala uključivanjem vrijednost neoperativne imovine i nekapitalnih ulaganja (Damodaran, 2010.).

Postupak dodavanja vrijednosti neoperativne imovine, odnosno imovine čije zarade nisu dio operativne dobiti, operativnoj dobiti poduzeća podrazumijeva dodavanje sljedećih stavaka:

- novac i utržive vrijednosnice,
- vrijednost udjela u drugim poduzećima, i
- vrijednost nezaposlene ili neiskorištene imovine.

Da bi se dobila realna vrijednost kapitala, od tako dobivene vrijednosti potrebno je oduzeti sljedeće stavke:

- vrijednost kamatnog duga,
- sadašnju vrijednost obveza po operativnom najmu,
- procijenjenu vrijednost manjinskih udjela u konsolidiranim poduzećima,
- nefinancirane obveze zdravstvene skrbi ili mirovina,
- očekivane obveze po tužbama.

Drugi se problem određivanja slobodnog novčanog toka odnosi na model slobodnog novčanog toka iz kapitala (*Free Cash Flow to Equity, FCFE*) koji zamjenjuje isplate dividendi kako bi se preciznije vrednovao kapital. To pretpostavlja da dioničari imaju pravo na isplatu tako dobivene vrijednosti, te se time kontrolira sustav menadžerskog upravljanja i politike poslovanja poduzeća. U slučaju više vrijednosti izračunate na ovaj način od stvarne isplate dividendi, dioničari ne mogu prisiliti menadžere da im vrate slobodne novčane tokove iz kapitala kao dividende, no moguće je kontrolirati učinkovitost korištenja neisplaćenog viška novca. Slobodni novčani tokovi iz kapitala mogu se izraziti kao (Damodaran, 2010.):

$$FCFE = \text{neto dobit} - (\text{kapitalni izdaci} - \text{deprecijacija}) - \text{promjene u radnom kapitalu} + (\text{novi dug} - \text{otplate}). \quad (2.8)$$

Upotreba omjera zaduživanja u jednadžbi očekivane stope rasta (Damodaran, 2010.)

$$\text{očekivana stopa rasta} = (\text{omjer zaduživanja}) \times (\text{povrat na kapital}) \quad (2.9)$$

može upućivati na to da li je sve što nije isplaćeno kao dividenda reinvestirano u poduzeće. To se još preciznije može provjeriti stopom reinvestiranja kapitala pomoću izraza (Damodaran, 2010.):

$$\text{stopa reinvestiranja kapitala} = \frac{\text{neto kapitalni izdaci} + \text{promjena radnog kapitala} - (\text{novi dug} - \text{otplate})}{\text{neto dobit}}, \quad (2.10)$$

i to kroz mjerenje postotka neto dobiti koja se ponovno ulaže u poduzeće.

Povrat negotovinskih ulaganja može se mjeriti modificiranom inačicom povrata na kapital koja mjeri negotovinske aspekte (Damodaran, 2010.), pri čemu vrijedi

$$\text{negotovinski ROE} = \frac{\text{neto dobit} - \text{dobit nakon poreza od novca i utrživih vrijednosnica}}{KV \text{ kapitala} - \text{novac i utržive vrijednosnice}}, \quad (2.11)$$

gdje KV označava knjigovodstvenu vrijednost.

Produkt stope reinvestiranog kapitala i modificiranog ROE, rezultirati će očekivanom stopom rasta $FCFE$ što se može zapisati kao (Damodaran, 2010.):

$$\text{očekivani rast } FCFE = (\text{stopa reinvestiranog kapitala}) \times (\text{negotovinski ROE}). \quad (2.12)$$

Dodavanje novca i utrživih vrijednosnica ovom broju rezultirati će ukupnom vrijednošću kapitala poduzeća. Pod pretpostavkom stabilnog budućeg rasta i reinvesticijskih potreba, procjena budućih novčanih tokova iz kapitala može se zapisati kao (Damodaran, 2010.)


$$\left\{ \begin{array}{l} \text{vrijednost kapitala} \\ \text{na dan procjene} \end{array} \right\} = \frac{\text{očekivani } FCFE \text{ u sljedećoj godini}}{\text{trošak kapitala poduzeća} - \text{stopa rasta za } FCFE}. \quad (2.13)$$

Trošak kapitala predstavlja stopu koju poduzeće mora nadići ako želi generirati vrijednost. S druge strane, trošak vlastitog kapitala (*Cost of Equity, COE*) puno je zahtjevnija veličina jer je to stopa povrata koju dioničari očekuju od poduzeća te nikada nije tako jasno određena kao trošak kapitala. To je naknada koju tržište očekuje u zamjenu za vlasništvo imovine i sa sobom nosi rizik vlasništva. Može se definirati na više načina, ovisno o veličini i vlasničkoj strukturi poduzeća, o stopi

rizika države u kojoj poduzeće posluje, i sl. Primjerice, za dionička društva, COE se uobičajeno definira kao (Damodaran, 2010.)

$$COE = \frac{\text{očekivana dividenda po dionici}}{\text{trenutna vrijednost dionice}} + \text{očekivana stopa rasta.} \quad (2.14)$$

Poveznica ove dvije kategorije služi za determiniranje načina na koji slobodni novčani tokovi pridonose kvaliteti investiranja u poduzeća što je vidljivo na slici 2.



Slika 2. Poveznica troška kapitala i troška vlastitog kapitala

Izvor: Izradila doktorandica prema (Damodaran, 2011.)

Trošak kapitala ovisi o povratu na kapital koji je kvocijent operativne dobiti nakon poreza i kapitala investiranog u imovinu. Ovisnost povrata na kapital i troška kapitala ispituje se pomoću sljedeća dva pokazatelja:

- (1) Raspona povrata u slučaju troška kapitala (tk)

$$(\text{raspon povrata})_{tk} = ROC - WACC, \quad (2.15)$$

- (2) Ekonomske dodane vrijednosti (*Economic Value Added*, EVA)

$$EVA = (ROC - WACC) \times (\text{Investirani kapital}), \quad (2.16)$$

pri čemu se povratom na kapital (*Return on Capital, ROC*) mjeri povrat na ulaganje, tj. ukazuje se na efektivnost kojim poduzeće kapital pretvara u zarade. Izražava se kao (Damodaran, 2010.)

$$ROC = \frac{EBIT \times (1 - t)}{KV \text{ dugova} + KV \text{ vlastitog kapitala}}. \quad (2.17)$$

Povrat na vlastiti kapital kvocijent je neto dobiti i vlastitog kapitala investiranog u imovinu. Raspon povrata i ekonomska dodana vrijednost se kod ove kategorije definiraju kao:

(3) Raspon povrata u slučaju troška vlastitog kapitala (*tvk*)

$$(\text{raspon povrata})_{tvk} = ROE - COE, \quad (2.18)$$

(4) Ekonomska dodana vrijednost vlastitog kapitala

$$EVA \text{ vl. kap.} = (ROE - COE) \times (\text{Investirani vlastiti kapital}), \quad (2.19)$$

pri čemu se povrat na vlastiti kapital (*Return on Equity, ROE*) definira kao (Pratt, 2008.)

$$ROE = \frac{\text{dobit nakon poreza}}{\text{vlastiti kapital}}. \quad (2.20)$$

Iz navedenih poveznica može se zaključiti sljedeće:

- minimalna stopa povrata trebala bi odražavati rizike investiranja i pravilan omjer duga i kapitala u financiranju,
- povrat bi trebao odražavati opseg i vremensku domenu novčanih tokova kao i sve popratne pojave,
- optimalna struktura vlastitih i tuđih sredstava u financiranju maksimizira vrijednost poduzeća,
- pravilna struktura dugova oslikava strukturu imovine,
- o tekućim i potencijalnim investicijskim prilikama ovisi koliko novčanih tokova poduzeće može povratiti,
- ako se ne može investirati s minimalno prihvatljivom stopom povrata, zarade je bolje isplatiti dioničarima.

2.2.2. Metode regresijske analize u funkciji vrednovanja poduzeća

Kao i u mnogim drugim područjima ekonomije, regresijska analiza, koja se bavi opisivanjem ovisnosti jedne varijable o nekoj drugoj ili više drugih varijabli, odnosno predviđanjem matematičke ovisnosti između zavisne varijable od primarnog interesa i nezavisnih varijabli kojima se objašnjavaju varijacije zavisne varijable, često nalazi svoju primjenu i u funkciji vrednovanja poduzeća.

U pojedinim fazama cjelovitog postupka vrednovanja poduzeća, često se koristi kvantitativna metoda jednostavne linearne regresije kojom se određuje veza između zavisne varijable y i nezavisne varijable x , pri čemu vrijedi

$$E(y) = \alpha + \beta x. \quad (2.21)$$

Matematičko očekivanje $E(y)$ se razlikuje od stvarne vrijednosti zavisne varijable y za neku slučajnu pogrešku e , tj. vrijedi

$$y - E(y) = e \Rightarrow y = \alpha + \beta x + e. \quad (2.22)$$

Za uzorak nekih N analiziranih podataka (x_i, y_i) , $i = 1, \dots, N$, jednadžba (2.22) poprima oblik

$$y_i = \alpha + \beta x_i + e_i. \quad (2.23)$$

S obzirom da ih je za N podataka nemoguće izraziti jednoznačno, nepoznati regresijski koeficijenti α i β se određuju nekom optimizacijskom metodom. U tu se svrhu najčešće koristi metoda najmanjih kvadrata kojom se traže 'najbolje' procjene nepoznatih parametara $\hat{\alpha}$ i $\hat{\beta}$, a koji pak minimiziraju sumu kvadrata odstupanja između stvarnih vrijednosti zavisne varijable (y_i) i onih koje leže na regresijskom pravcu $(\hat{\alpha} + \hat{\beta}x_i)$. Drugim riječima, minimizira se funkcija cilja

$$L = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - \hat{\alpha} - \hat{\beta}x_i)^2, \quad (2.24)$$

na način da se riješi sustav linearnih jednadžbi koji proizlazi iz sljedeća dva uvjeta:

$$\left. \frac{\partial L}{\partial \hat{\alpha}} \right|_{\hat{\beta}} = 0 \quad \text{i} \quad \left. \frac{\partial L}{\partial \hat{\beta}} \right|_{\hat{\alpha}} = 0. \quad (2.25)$$

Određivanjem parcijalnih derivacija u (2.25) i rješavanjem dobivenog sustava linearnih jednadžbi po $\hat{\alpha}$ i $\hat{\beta}$, može se pokazati da procijenjeni regresijski koeficijenti poprimaju sljedeće vrijednosti

$$\hat{\beta} = \frac{S_{xy}}{S_{xx}} \quad \text{i} \quad \hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}, \quad (2.26)$$

pri čemu je

$$S_{xy} = \sum_{i=1}^N (x_i y_i) - \frac{1}{N} \left(\sum_{i=1}^N x_i \right) \left(\sum_{i=1}^N y_i \right), \quad S_{xx} = \sum_{i=1}^N x_i^2 - \frac{1}{N} \left(\sum_{i=1}^N x_i \right)^2, \quad (2.27)$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i, \quad \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (2.28)$$

Konačno, jednostavni regresijski model se može zapisati u obliku

$$\hat{y} = \hat{\alpha} + \hat{\beta}x, \quad (2.29)$$

pri čemu je $\hat{y}$ regresijskim modelom procijenjena vrijednost zavisne varijable.

Za praktične primjene postoje brojni računalni programi koji podržavaju linearnu regresiju (Statistica, SPSS, MATLAB, i sl.), te osim same regresije nude izračun i brojnih statističkih pokazatelja koji su temelj za analizu varijance (ANOVA), testiranje značajnosti parametara i sl.

Od značajnijih statističkih pokazatelja, za potrebe ovog rada izdvojiti će se sljedeći:

- Koeficijent determinacije R^2 , izračunava se prema izrazu

$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2}. \quad (2.30)$$

Ovaj pokazatelj poprima vrijednosti na intervalu [0,1], a promatrani je model to reprezentativniji što je koeficijent determinacije bliži jedinici.

- Srednje kvadratno odstupanje MSE , izračunava se kao

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (2.31)$$

Predstavlja aritmetičku sredinu kvadrata odstupanja promatranih vrijednosti y_i od procijenjenih regresijskih vrijednosti $\hat{y}_i$. Model je to reprezentativniji što je ova vrijednost bliža nuli.

- Standardna devijacija σ , izračunava se prema izrazu

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad \sigma_y = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2}. \quad (2.32)$$

Označava mjeru raspršenosti podataka u promatranom skupu, a interpretira se kao prosječno odstupanje svakog pojedinog podatka od aritmetičke sredine svih podataka. Odstupanje je apsolutnog karaktera.

- Varijanca V , izračunava se prema izrazu

$$V(x) = \sigma_x^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2, \quad V(y) = \sigma_y^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2. \quad (2.33)$$

Najčešća područja primjene regresijske analize u okviru vrednovanja poduzeća su (Abrams, 2010.):

- predviđanje opsega prodaje kod analiza diskontiranog novčanog toka,
- predviđanje troškova u analizama diskontiranog novčanog toka, i
- mjerenje odnosa između tržišne kapitalizacije, tj. fer tržišne vrijednosti kao zavisne varijable, i nekoliko mogućih nezavisnih varijabli kod tržišnog pristupa vrednovanju poduzeća.

U analizama povijesnih podataka u svrhu predviđanja budućih novčanih tokova najčešće se promatraju i predviđaju veličine poput prodaje, troškova i bilančnih promjena koje utječu na promjene u novčanim tokovima. U tu svrhu računaju se određeni trendovi kao i omjeri troškova u postotnim udjelima prodaje.

Značajni nedostaci ovakve metodologije očituju se u čestom zanemarivanju komponente fiksnih troškova, što u periodima dobrih poslovnih rezultata dovodi do ispod prosječne procijenjene vrijednosti, ali i mogućnosti procjene iznad prosječne vrijednosti u vremenima lošijih poslovnih rezultata. Ako se pak svi troškovi tretiraju kao varijabilni, u periodima dobrih poslovnih rezultata, analitičari će predviđati ubrzani rast prodaje, pa iako bi fiksni troškovi i u takvim vremenima trebali ostati fiksni, vrlo je vjerojatno da će se njihov rast predviđati proporcionalno s rastom prodaje.

U tom kontekstu, jednostavna regresija temeljena na metodi najmanjih kvadrata, pokazala se kao dobar alat u predviđanju prilagođenih troškova baziranih na njihovom povijesnom odnosu u odnosu na prodaju (Abrams, 2010.). Time se može odrediti statistička procjena fiksne i varijabilne komponente troškova koje su potrebne za učinkovito planiranje i predviđanje. Sama regresija dodatno pruža i povratne informacije koje se mogu koristiti u ocjeni robusnosti međusobnog odnosa između prodaje i troškova.

Upotrebi regresije kod predviđanja troškova u analizama diskontiranog novčanog toka prethodi analiza i prilagodba promatranih stavki na način da se utvrđuje njihova značajnost u operativnom poslovanju u prošlosti. Na osnovu toga može se predvidjeti i poslovanje u budućnosti. Slično je i kod klasičnog prihodovnog pristupa. Svrha spomenute prilagodbe je ispitivanje dugotrajnosti financijskih trendova bez uplitanja zastarjelih informacija iz prošlosti za koje se očekuje da neće imati značajan utjecaj na buduće rezultate. Ukoliko dođe do pojave neuobičajenih periodičnih stavaka u novčanim tokovima, mogu se krajem ili sredinom poslovne godine koristiti i tzv. trajni periodični faktori (*periodic perpetuity factors, PPF*) kojima se podaci dodatno prilagođavaju ovisno o nastaloj periodičnoj stavki izvan promatranog perioda (Abrams, 2010.).

Nakon prilagođavanja podataka pristupa se regresijskoj analizi, tj. jednostavnoj linearnoj regresiji na temelju koje se u ovom slučaju obično povezuju prilagođeni troškovi kao zavisna varijabla s prodajom kao nezavisnom varijablom. Drugim riječima, može se prema (2.29) pisati

$$\text{prilagođeni troškovi} = \hat{\alpha} + \hat{\beta} \times \text{prodaja}, \quad (2.34)$$

pri čemu je $\hat{\alpha}$ predstavlja fiksne troškove, a $\hat{\beta}$ promjenjive troškove.

S obzirom da su fiksni i promjenjivi troškovi u modelu (2.34) nemjerljivog karaktera, treba ih ocijeniti metodom najmanjih kvadrata. Upravo zato se $\hat{\alpha}$ i $\hat{\beta}$ često nazivaju procijenjeni fiksni i procijenjeni promjenjivi troškovi koji se određuju na temelju povijesnih podataka. Geometrijski gledano, $\hat{\alpha}$ predstavlja predviđenu vrijednost po prilagođenim troškovima (odrezak na ordinati), a $\hat{\beta}$ predstavlja predviđeni nagib pravca koji ukazuje na brzinu promjene prilagođenih troškova (ordinata) u odnosu na prodaju (apscisa).

Koeficijent determinacije R^2 iz (2.30) mjeri postotak varijacije u zavisnoj varijabli, tj. u ovom slučaju postotak varijacije u prilagođenim troškovima kojeg objašnjava nezavisna varijabla, tj. prodaja. Drugim riječima, može se reći da prodaja objašnjava R^2 (%) varijabilnosti prodaje. Ovo je jedan od najznačajnijih i najčešće korištenih pokazatelja koji govori koliko je regresijski model zaista pouzdan i dobar. Mogu se koristiti i mnogi drugi pokazatelji poput srednjeg kvadratnog odstupanja (*MSE*) iz (2.31), koeficijenta korelacije, i sl.

Pomoću regresijskog modela (2.34) mogu se procjenjivati budući troškovi. U slučajevima kod kojih se u rezultatima javljaju nelogičnosti, poput negativnih fiksnih troškova ili jako malih vrijednosti fiksnih troškova, podaci se prilagođavaju.

Iako se procjene budućih pokazatelja poslovanja uobičajeno vrše na osnovu podataka prošlih pet godina poslovanja, takve odluke mogu biti pogrešne. Naime, procjenitelji period manji od pet godina smatraju nedovoljnim s obzirom na relevantnost raspoloživih podataka, a u periodu iznad pet godina često završe podaci koji nisu ni aktualni ni vjerodostojni. No, procjenu o odabiru ovog perioda ipak bi trebalo temeljiti na nekom pouzdanom pokazatelju. U tu se svrhu najčešće koriste varijance predviđenih fiksnih i promjenjivih troškova koje se definiraju kao (Abrams, 2010.):

$$V(\hat{\alpha}) = \frac{\sigma^2}{n} \quad \text{i} \quad V(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (2.35)$$

pri čemu je σ^2 varijanca cijelog uzorka oko regresijskog pravca, a n broj promatranja, u ovom slučaju i broj godina.

Sasvim je jasno da varijanca procjene fiksnih troškova opada s brojem godina promatranih podataka. Tako primjerice desetogodišnji period promatranja podataka iz prošlosti smanjuje standardnu devijaciju procijenjenih fiksnih troškova, pa se može zaključiti da veći broj godina promatranja povećava pouzdanost statističke procjene fiksnih troškova. Ovo naravno vrijedi samo ukoliko povijesni podaci nisu više aktualni iz bilo kojeg razloga.

Na varijancu promjenjivih troškova $V(\hat{\beta})$, koja u ovom slučaju predstavlja prodaju svake godine umanjene za prosjek prodaje u analiziranom periodu, može se utjecati samo djelovanjem na izraz u nazivniku, jer je brojnik nemjerljivog karaktera. No, u ovom slučaju nije sigurno da će povećanje promatranog perioda smanjiti varijancu, pa se preporučuje testiranje za različite vremenske periode uz istovremenu analizu uspješnosti pojedinih regresijskih modela. Dobiveni pokazatelji poput koeficijenta determinacije, srednjeg kvadratnog odstupanja, odgovarajućih statističkih testova, i sl., predstavljaju neke od statističkih mjera koje treba koristiti za odabir optimalnog vremenskog perioda uz uvjet minimalne varijance promjenjivih troškova.

Preporučeni intervali povjerenja unutar kojih se nalaze procijenjeni parametri $\hat{\alpha}$ i $\hat{\beta}$ su 95 %-tni, no to je ionako najčešće preddefinirana vrijednost većine statističkih programa. Ovako definirani intervali povjerenja govore da se sa sigurnošću od 95 % može tvrditi da su stvarne (nepoznate) vrijednosti od α i β zaista u tako odabranim intervalima, a središte tih intervala predstavljaju upravo procijenjeni $\hat{\alpha}$ i $\hat{\beta}$.

Regresijska analiza je također vrlo iskoristiva i u tržišnom pristupu vrednovanju poduzeća kod kojeg je težište stavljanje na usmjereno-usporedne metode (*Guideline Company Methods*, GC). Neovisno da li se analiziraju dionička društva (GPCM metoda) ili društva s ograničenom odgovornošću (GMAM metoda), procjena vrijednosti se temelji na uspoređivanju odgovarajućih pokazatelja poduzeća koje je predmet procjene i nekog sličnog već prodanog poduzeća iz istog industrijskog sektora (Pratt i sur., 1996.). Podaci o kupoprodaji poduzeća za izvođenje ovakvih analiza prikupljaju se iz određenih komercijalnih baza podataka (npr. *Pratt's Stats*, *Done Deals*, *the IBA database*, *BizComps*, i sl.) kako bi se pronašlo poduzeće po određenim karakteristikama slično onom koje se vrednuje.

Zavisna varijabla u ovim analizama je vrijednost poduzeća postignuta kupoprodajom (MVIC), a uobičajene nezavisne varijable koje se mogu smatrati kandidatima koji će utjecati na fer tržišnu vrijednost su prihodi od prodaje, bruto dobit, *EBIT*, *EBITDA*, diskrecijska zarada, knjigovodstvena vrijednost investiranog kapitala, i sl. Tako se primjerice regresijski model ovisnosti između MVIC i prihoda od prodaje može zapisati u obliku

$$MVIC = \hat{\alpha} + \hat{\beta} \times (\text{prihodi od prodaje}). \quad (2.36)$$

Slično se MVIC izražava i preko ostalih značajnih nezavisnih varijabli, a uspješnost pojedinog modela se ocjenjuje uobičajeno pokazateljima (2.30), (2.31) i sl.

Regresijska analiza u vrednovanju poduzeća pokazala se kao sofisticirani i u velikoj mjeri iznimno informativni alat, posebno u odnosu na izvođenje ovakvih analiza nekim klasičnijim pristupima. Naime, regresija pruža procjeniteljima statistički utemeljenu povratnu vezu (informacije) o snazi odnosa između odabranih pokazatelja.

Problem koji se može pojaviti u modelima poput (2.36), usko je vezan uz problem predviđanja vrijednosti kod kojeg model može ponuditi MVIC vrijednost koja

nema fizikalno značenje (npr. negativna vrijednost *MVIC*). Ovakav je problem najčešće vezan uz heteroskedastičnost koja se javlja kada je narušena pretpostavka o nepromjenjivosti varijance slučajne pogreške e u (2.22) dobivenog regresijskog modela. Uzrokovan je aditivnošću slučajne pogreške i činjenicom da ona vjerojatno značajno korelira s veličinom poduzeća. Postupci otkrivanja heteroskedastičnosti, te načini kako ovaj problem otkloniti mogu se pronaći u (Abrams, 2010.).

Zanimljivo je uočiti da se umjesto jednog višedimenzionalnog regresijskog modela u praksi uglavnom koristi više jednostavnih regresijskih modela poput (2.36). Razlog tome je prije svega potreba da se odrede pokazatelji od posebnog interesa kao što su

$$\frac{MVIC}{\text{prihodi od prodaje}}, \frac{MVIC}{\text{bruto dobit}}, \frac{MVIC}{EBIT}, \frac{MVIC}{EBITDA}, \text{ i sl.} \quad (2.37)$$

koji su temelj za tržišnu metodu vrednovanja i u uskoj su vezi s regresijskim modelima kao što je (2.36). Upravo dobiveni regresijski modeli, kao i statistički pokazatelji uspješnosti istih, mogu značajno pomoći procjeniteljima u određivanju značaja svih navedenih nezavisnih varijabli koji očito u manjoj ili većoj mjeri utječu na *MVIC*. Konačni *MVIC* se određuje sumiranjem otežanih *MVIC* iz svih odabranih pokazatelja poput onih u (2.37), a samo otežavanje je ovisno upravo o svim dobivenim statističkim pokazateljima koji proizlaze iz regresijske analize, ali nekih dodatnih koji proizlaze iz statističke obrade podataka.

Od ostalih statističkih mjera za analizu nekog niza N brojeva $(x_1, x_2, \dots, x_N)$, u tržišnoj metodi vrednovanja poduzeća najčešće se koriste sljedeće (Pratt's Stats, 2014.):

- 10., 25., 50., 75. i 90. percentil (centil)

P -percentil je vrijednost ispod koje se nalazi P % svih elemenata grupe, pri čemu 10. i 25. percentil pripadaju donjem kvartilu, a 75. i 90. percentil gornjem kvartilu.

- Centralna vrijednost ili medijan (*median*)

Predstavlja vrijednost srednjeg člana $x_{(N+1)/2}$ nekog niza ako je N neparan, tj. $x_{N/2}$ ili $x_{(N/2+1)}$ ako je N paran. Često kod procjenitelja reprezentativnija mjera sredine od aritmetičke sredine.

- Aritmetička sredina (*mean*) A , izračunava se prema

$$A = \mu = \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (2.38)$$

Često nepouzdana zbog kontaminiranja pojedinim vršnim vrijednostima (iznimno velikim ili malim) koje uzrokuju da μ često ne predstavlja reprezentativnu sredinu. Iz navedenih razloga češće se koristi medijan kao polazišna vrijednost bilo kakvih prilagođavanja prema dolje ili prema gore.

- Harmonijska sredina H , izračunava se prema izrazu

$$\frac{1}{H} = \frac{1}{N} \sum_{i=1}^N (1 / x_i). \quad (2.39)$$

Predstavlja znatno reprezentativniju mjeru za usrednjavanje pokazatelja, posebno onih kod kojih je vrijednost poduzeća u brojniku. Dok su u slučaju aritmetičke sredine podaci s većim vrijednostima otežani s većim težinama od onih s manjim vrijednostima, kod harmonijske sredine je svim podacima dana jednaka težina.

- Raspon varijacije R_v , izračunava se preko dvije ekstremne vrijednosti prema izrazu

$$R_v = x_{\max} - x_{\min}. \quad (2.40)$$

- Koeficijent varijacije CV , izračunava se prema izrazu

$$CV = \frac{\sigma}{\mu}. \quad (2.41)$$

Koeficijent varijacije predstavlja mjeru raspršenja u odnosu na aritmetičku sredinu. U teoriji vrednovanja poduzeća smatra se da su pokazatelji s najmanjim CV oni s najmanje raspršenja u odnosu na njihove aritmetičke sredine, a samim time predstavljaju značajnije pokazatelje vrijednosti. Dobivena vrijednost na temelju takvih pokazatelja se može otežati značajno više od one dobivene pokazateljima s velikim CV .

3. IDENTIFIKACIJA SPECIFIČNOSTI POSLOVANJA PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE

Naftni derivati u obliku benzina, mlaznih goriva, dizelskih goriva, lož ulja, asfalta, kao i sirovina korištenih u kemijskoj industriji i industriji plastike, svrstavaju naftu u vodeću robu na svjetskom tržištu. S više od 50 % naftne proizvodnje trguje se na međunarodnoj razini, a taj udio predstavlja aproksimativno 10 % ukupne svjetske robne razmjene (Johnston, 2006.). U opskrbi energetske potrošnje, trgovina naftom i naftnim derivatima sudjeluje s otprilike 40 % (Wall Street Prep, 2010.).

S druge strane, prirodni plin se koristi u industrijskom i komercijalnom sektoru te domaćinstvima kao izvor energije, ali i kao sirovina u kemijskim procesima i procesima rafiniranja. Zbog neutralnog utjecaja na onečišćenje okoliša kroz emisiju štetnih plinova, potražnja za prirodnim plinom postaje sve veća, a s više od 26 % svjetske proizvodnje trguje se na međunarodnoj razini.

Stalni porast globalne potražnje za energijom, naftno-plinsku industriju svrstava u brzorazvijajuću i brzorastuću industriju, koja unatoč velikim naporima u razvoju obnovljivih izvora energije, još uvijek nema odgovarajuću alternativu.

U prošlosti, ova industrija bila je usmjerena snabdijevanju energijom uglavnom zapadnih tržišta, a konkurencija između privatnih poduzeća bila je uvjetovana i usmjerena pristupu postojećim rezervama. Kako se potražnja za energijom povećavala, a pozitivan trend u rastu cijena nafte i plina je pratio trendove potražnje, ova industrija se sukladno tome počela sve više razvijati i rasti. Ovakav trend potražnje pratio je i kontinuirani razvoj novih tehnologija koje omogućuju crpljenje iz donedavno nekonvencionalnih ležišta. Ležišta su se tako proširila na izazovna područja poput dubokih mora, arktičkog pojasa ili politički nesigurnih područja svijeta.

Zbog kompleksnosti izvođenja procesa poslovanja od pronalaska izvora do distribucije nafte i plina krajnjim korisnicima, naftno-plinska industrija oblikovala se u nekoliko sektora. Specifičnosti svakog pojedinog sektora iz ove industrije očituju se u proizvodnim procesima, proizvodnoj opremi i operativnom poslovanju te se zbog prirode posla u velikoj mjeri razlikuju od ostalih industrija, pa čak i onih koje se bave eksploatacijom rudnih bogatstava.

Identifikacija tih specifičnosti može se definirati kroz: **1) Karakteristike poslovanja poduzeća naftne i plinske industrije, 2) Računovodstvene specifičnosti poduzeća naftne i plinske industrije i 3) Financijske specifičnosti poduzeća naftne i plinske industrije.**

3.1. Karakteristike poslovanja poduzeća naftne i plinske industrije

Ukoliko se fokus postavi na procese poslovanja, naftno-plinska industrija može se opisati kroz sljedećih pet osnovnih sektora:

- Eksploatacijsko-proizvodni sektor (*Exploration & Production, E&P*), često se u međunarodnim krugovima navodi kao *Upstream* sektor;
- Sektor transporta i skladištenja nafte i plina (*Transportation & Storage, T&S*), u žargonu industrije poznat i kao *Midstream* sektor;
- Sektor rafiniranja i marketinga (*Refining & Marketing, R&M*), poznat i kao *Downstream* sektor;
- Sektor potpore na naftnim poljima (*Oil Field Services, OFS*);
- Integrirana naftno-plinska poduzeća (*Integrated Majors, IM*).

U širem tehnološkom i operativnom smislu karakteristike poslovanja ovih poduzeća ovise o: **1) Rezervama nafte i plina, 2) Ovisnosti kretanja cijena nafte i plina o političkim i ekonomskim čimbenicima te 3) Obilježjima poduzeća naftno-plinskog sektora.**

3.1.1. Rezerve nafte i prirodnog plina

Nafta i plin, uz ugljen, dva su osnovna oblika fosilnih goriva. Naziv fosilna goriva potječe od vjerovanja da su nastala prije više stotina milijuna godina. Sastav i svojstva sirove nafte usko su povezani, a razlikuju se po mjestu ležišta. U sastavu nafte osnovu čine ugljikovodici, a u primjesama se nalaze spojevi sumpora, dušika, kisika i teških metala (Tireli, 2005.). Do danas je identificirano preko 150 vrsta sirove nafte različitih karakteristika i kvalitete. Općenita klasifikacija vrši se temeljem njene gustoće i udjela sumpora. Zbog velikog utjecaja SAD-a u naftnom gospodarstvu u svijetu, gustoća se obično izražava prema Američkom naftnom institutu (*American Petroleum Institut, API*) u °API. Po definiciji, API-težina govori koliko je puta gustoća (specifična težina) nekog naftnog proizvoda veća u odnosu na vodu. S obzirom na API vrijednost, razlikuje se lagana nafta gustoće iznad 31,1

°API, srednja nafta u rangu od 22,3 do 31,1 °API, teška nafta gradacije od 10 do 22,3 °API, te ekstra teška nafta kod koje je gustoća manja od 10 °API i koja više ne može plivati na vodi. S obzirom na udjel sumpora, visokosumporna nafta sadrži više od 0,7 % udjela sumpora, dok se u niskosumpornu svrstava nafta s udjelom sumpora ispod 0,7% (Wall Street Prep, 2009.). Ove karakteristike su važne iz razloga postizanja određene cijene nafte na tržištu. Tako primjerice nafta okarakterizirana kao laka i niskosumporna postiže veću cijenu od one koja je okarakterizirana kao teška i visokosumporna, jer je kod nje proces rafiniranja jednostavniji, a time i jeftiniji.

Kao jedinica volumena u naftnoj industriji najčešće se koristi barel, pri čemu je 1 barel (oznaka bbl) ekvivalentan 0,1589873 m³. Povijest upotrebe izraza mjerne jedinice barel seže u rane početke naftne industrije, jer se u to vrijeme nafta transportirala u bačvama. Naftne rezerve se iskazuju u tisućama barela (Mbbl) ili u milijunima barela (MMbbl), dok je proizvodnja nafte i naftnih derivata izražena količinski po danu (d), tj. u barelima na dan (bpd), u tisućama barela po danu (Mbpd, Mbbl/d) ili u milijunima barela po danu (MMbpd, MMbbl/d).

Prirodni plin čista je mješavina ugljikovodika bez mirisa i boje, koja se u prirodi pojavljuje u plinovitom stanju. Najčešća ležišta su u blizini postojećih naftnih polja na dubinama od 3.000 do 6.000 metara. Uobičajeni sastav prirodnog plina je (Tireli, 2005.):

- metan: 92 do 99 %,
- dušik: 0,4 do 2,9 %,
- etan: 0,05 do 2,6 %,
- butan i viši ugljikovodici: 0,1 do 0,4 %, i
- ugljični dioksid: 0,05 do 0,09 %.

Prirodni plin koji se karakterizira kao "suhi", sadrži udio metana u postotku većem od 95 %, dok se onaj s udjelom manjim od 95 % karakterizira kao "mokri". Proces prerade nakon vađenja prirodnog plina podrazumijeva destiliranje na vrlo niskim temperaturama kako bi se iz njega odstranio nezapaljivi dušik, a dobio koristan helij, butan, etan i propan, dok je konačan proizvod gotovo čisti metan.

Radi lakšeg transporta plin se hladi na niske temperature te se pretvara u tekuće stanje (*Natural Gas Liquids, NGL*). U tom procesu nastaju plinovi butan i propan od kojih se obično dobiva ukapljeni naftni plin (*Liquefied Petroleum Gas, LPG*). Boce punjene tim plinom koriste se u kućanstvu, a služi i kao gorivo za osobne

automobile, autobuse i druga motorna vozila. Butan i propan koriste se i u kemijskoj industriji za proizvodnju plastike, otapala, sintetičkih vlakana i drugih proizvoda. Prirodni plin koji je gotovo čisti metan, radi transporta se hladi na vrlo niskim temperaturama od $-162\text{ }^{\circ}\text{C}$, i često se naziva ukapljeni prirodni plin (*Liquefied Natural Gas, LNG*).

Za lakšu usporedbu energetske vrijednosti različitih goriva koristi se mjerna jedinica BTU (*British Thermal Unit*), pri čemu 1 BTU (1055,056 J) predstavlja energiju potrebnu da se 1 funta vode (0,4536 kg) zagrije za $1\text{ }^{\circ}\text{F}$, s tim da je promjena temperature od $1\text{ }^{\circ}\text{F}$ ekvivalentna promjeni temperature od $5/9\text{ }^{\circ}\text{C}$. Veća korištena jedinica je MMBTU (MMBtu), a predstavlja 1.000.000 BTU (milijun BTU).

O rezervama prirodnog plina uobičajeno se izvještava u milijardama kubičnih stopa (Bcf), dok se proizvodnja uobičajeno mjeri u tisućama kubičnih stopa (Mcf) ili u milijunima kubičnih stopa (MMcf). Iz navedenog je jasno da je 1 Bcf jednak 1.000 MMcf, odnosno 1.000.000 Mcf, s tim da po definiciji 1 Mcf predstavlja količinu prirodnog plina koja bi zauzela volumen od 1000 kubičnih stopa ($28,317\text{ m}^3$) pri temperaturi od $60\text{ }^{\circ}\text{F}$ ($15,556\text{ }^{\circ}\text{C}$) i tlaku od 15 psi (1,034 bar). Dnevna se pak proizvodnja označava kao Mcf/d ili MMcf/d, dok se energetska konverzija može iskazati na način da energija dobivena iz 1 kubične stope ($0,028317\text{ m}^3$) prirodnog plina odgovara energiji od 1000 BTU (1055,056 kJ), tj. iz količine od tisuću kubičnih stopa (1 Mcf) prirodnog plina može se dobiti ekvivalent od milijun BTU-a (1 MMBtu) energije.

Rezerve nafte i plina u operativnom i tehničkom smislu izravno su osnova poslovanja eksploatacijsko-proizvodnih poduzeća, a neizravno cijele industrije. Iskazane u postotcima temeljenim na vjerojatnosti njihova korištenja i eksploatacije, mogu se podijeliti na:

- odobrene,
- vjerojatne, i
- moguće.

Odobrenim rezervama smatraju se one kod kojih je vjerojatnost eksploatacije veća od 90 %, kod vjerojatnih rezervi postotak mora biti veći od 50 %, dok se one s vjerojatnošću ispod 50 % smatraju mogućim rezervama.

Odobrene rezerve mogu biti odobrene razvijene i odobrene nerazvijene, pri čemu se odobrenim razvijenim smatraju rezerve postojećih naftnih polja i ukazuju na podatak o tome koliko poduzeće može proizvoditi sa 100 %-tnom sigurnošću, dok se odobrenim nerazvijenim predstavljaju rezerve novih polja iz kojih se tek

očekuje eksploatacija i proizvodnja. Dodatno se odobrene razvijene rezerve mogu podijeliti na one iz kojih se trenutno proizvodi (postojeća proizvodnja) i na one iz kojih se trenutno ne proizvodi (vjerojatna proizvodnja u budućnosti).

U ekonomskom smislu postoje različitosti u tretmanima priznavanja različitih tipova rezervi u financijskim izvještajima. Tako je primjerice prema američkim računovodstvenim standardima dozvoljeno priznavanje jedino odobrenih rezervi, dok je po međunarodnim standardima dozvoljeno priznavanje odobrenih i vjerojatnih rezervi.

Prema istraživanjima provedenim u 2013. godini, a temeljem podataka iz 2012. godine (BP Statistical Review of World Energy, 2013.), ukupne svjetske odobrene rezerve nafte iznosile su 1.668,9 milijardi barela od čega se najveće rezerve nalaze na Bliskom istoku što je vidljivo u tablici 1.

Tablica 1. Odobrene rezerve nafte i prirodnog plina na kraju 2012. godine

Regija	Rezerve nafte u milijardama barela (u tisućama MMbbl)	Rezerve prirodnog plina u bilijunima kubičnih stopa (u tisućama Bcf)
Sjeverna Amerika	220,2	10,8
Južna i Srednja Amerika	328,4	7,6
Europa i Euroazija	140,8	58,4
Bliski istok	807,7	80,5
Afrika	130,3	14,5
Azijsko-pacifička regija	41,5	15,5
Ukupno (cijeli svijet)	1.668,9	187,3

Izvor: BP Statistical Review of World Energy, 2013.

Prema istom izvoru, rezerve prirodnog plina procijenjene su na 187,3 bilijuna kubičnih stopa, također s najvećim udjelom na Bliskom istoku (Tablica 1.).

3.1.2. Ovisnost kretanja cijena nafte i plina o političkim i ekonomskim čimbenicima

Kao i kod svake druge robe, struktura tržišta nafte i plina okarakterizirana je odnosom ponude i potražnje. No, za razliku od tržišta ostalih roba, na ponudu i potražnju odnosno ekonomsku strukturu naftno-plinskog tržišta kroz povijest, primjetan je utjecaj političkih čimbenika. Isto tako može se reći da ne postoji ni

jedna druga roba osim nafte i plina od izravnijeg utjecaja na ekonomski i politički razvoj ne samo pojedinačnog već i globalnog gospodarstva. Tome svjedoče brojni naftni šokovi i događaji vezani uz njih.

Kroz dvadeseto stoljeće potražnja za naftom je rasla što je uzrokovalo rastući pritisak na cijene. Zajedno s potražnjom, rapidno je rasla i ponuda, jer su pronađeni i razvijeni novi izvori i nove i jeftinije metode proizvodnje.


Nafta je prvi put u povijesti postala međunarodni politički problem tijekom pedesetih godina prošlog stoljeća. Posljedično, 1960. godine osniva se Organizacija zemalja izvoznica nafte (*Organization of the Petroleum Exporting Countries*, OPEC) koju u početku čine zemlje članice: Irak, Iran, Kuvajt, Saudijska Arabija i Venezuela, a danas se na tom popisu još nalaze i Alžir, Angola, Ekvador, Katar, Libija, Nigerija i Ujedinjeni Arapski Emirati (UAE). Cilj i svrha OPEC-a jest koordinacija i ujednačenje naftne politike zemalja članica kao i pronalaženje najboljih načina da se očuvaju njihovi pojedinačni i kolektivni interesi, i to kroz strategije i sredstva za stabilizaciju cijena na međunarodnim naftnim tržištima. Kako je sve više izvora bilo nacionalizirano od vlada zemalja OPEC-a, tako se sve više zemalja pridruživalo organizaciji. To je omogućilo zadržavanje zaliha zemalja članica u svrhu podizanja cijena nafte. Ovakav razvoj situacije je 1973. godine kulminirao Listopadskim (Yom Kippurskim) ratom u kojem su se sukobile Izrael s jedne strane te Egipat i Sirija s druge strane. Zbog velike američke pomoći Izraelu arapske države udružile su se i prekinule izvoz nafte u zapadne zemlje sa svrhom kažnjavanja zbog potpore Izraelu, što je uzrokovalo neviđeni porast cijena nafte.

Sljedeći naftni šok pojavio se 1979. godine s Iranskom revolucijom, te 1980. godine napadom Irana na Irak. Uskoro nakon toga cijene su pale kao signal visoke potražnje za naftom i privukle razvoj proizvođača iz ostalih zemalja koje nisu članice OPEC-a.

Cijene su ponovo narasle 1991. godine tijekom Zaljevskog rata između Iraka i međunarodne koalicije na čelu s SAD-om, ali su ponovno počele padati s pojavom krize istočno-azijske regije čime se smanjila potražnja za naftom. Kako bi oporavio cijenu nafte, OPEC 1998. godine značajno smanjuje dnevnu proizvodnju do 4,2 milijuna barela nafte po danu. Ova mjera samo privremeno podiže cijenu nafte, jer tek nakon terorističkog napada na SAD, 11. rujna 2001. godine, započinje najveći porast cijene nafte u povijesti. Ovaj rastući trend u periodu od početka 2002. godine do sredine 2008. godine popraćen je s dva značajna i uglavnom politički

motivirana događaja. Riječ je o dvogodišnjem velikom štrajku u državnoj naftnoj kompaniji Venezuele (PDVSA, 2002. - 2003.) tijekom kojeg je Venezuela obustavila proizvodnju i isporuku nafte i prirodnog plina, a na ovaj se događaj nadovezala i vojna intervencija na Irak 2003. godine od strane SAD-a. Posljedično se sve više počela isticati problematika vezana uz postojeće rezerve nafte i prirodnog plina, kao i uz stvaranje zaliha, što je konačno u srpnju 2008. godine dovelo do rekordne cijene nafte u povijesti od 147,27 dolara po barelu, iskazano na dan 11. srpnja 2008. godine.

U prijelazu iz 2008. na 2009. godinu, u veliku recesiju prvo ulazi SAD, a ubrzo nakon toga recesija poprima globalne razmjere, što se na cijenu nafte odražava njenim strmoglavim padom koji samo u nešto više od pet mjeseci rezultira cijenom nafte od 32,40 dolara po barelu, iskazano na dan 19. prosinca 2008. godine. Nakon toga, tijekom 2009. godine ponovno intervenira OPEC značajnim smanjenjem dnevne proizvodnje (do 4,2 milijuna barela po danu) čime se cijena nafte ponovno povećava. Ovaj pozitivan trend je dodatno pojačan gubitkom libijskog tržišta uzrokovanog tamošnjim ratom 2011. godine. Pregled kretanja cijena nafte u \$/bbl prilagođenih inflaciji prikazan je i na Slici 3., i to za period od 1970. godine do ožujka 2014. godine.




Slika 3. Mjesečno kretanje cijena nafte (\$/bbl) prilagođenih inflaciji od 1970. godine

Izvor: Izradila autorica prema (WTRG Economics, 2013.; Macrotrends, 2014.)

Na posljjetku, brzorastuće azijske ekonomije udružene s političkom nestabilnošću srednjeg istoka u posljednjem desetljeću podigle su potražnju za naftom i smanjile su ponudu. Tako su, u posljednjih nekoliko godina, cijene nafte na svjetskom tržištu uz ipak nešto manje oscilacije uravnotežene na relativno visokih 90 do 100 dolara po barelu. Za očekivati je da će ekonomski razvitak gospodarstava Kine i Indije vršiti pritisak na cijenu nafte i plina u bližoj budućnosti. Također, za očekivati je da će aktualni sukob između Ruske Federacije i zemalja Zapadne Europe i SAD-a ostaviti ozbiljan trag i utjecaj kako na raspoložive količine nafte i prirodnog plina, tako i na njihovu cijenu u skoroj budućnosti.

Povijest politike formiranja cijena plina uglavnom je pratila politiku cijena nafte i direktno je bila uvjetovana ponudom i potražnjom. Značajnije oscilacije u cijenama prirodnog plina mogu se također povezati s prije navedenim razlozima koji su utjecali na značajne promjene u cijenama nafte. Iako nije predmet ovog rada, važno je naglasiti da se tek posljednjih godina trend u cijenama prirodnog plina odvaja od trenda cijena nafte, i postaje bliži trendu cijena ugljena. S obzirom da se cijene prirodnog plina formiraju za različite regije, razlikuje se formiranje cijena za distributivna čvorišta kao što su *Henry Hub* u SAD-u, Alberta u Kanadi ili čak i za virtualno čvorište NBP (*National Balancing Point*) u UK. S druge strane se nalaze ugovorima definirane uvozne cijene za Japan i Njemačku, a obuhvaćaju trošak, osiguranje i transport. Pregled kretanja realnih cijena prirodnog plina u \$/MMBtu za distributivno čvorište Henry Hub (SAD) prikazan je na Slici 4, i to za period od 1998. godine do veljače 2014. godine.



Slika 4. Mjesečno kretanje realnih cijena prirodnog plina u \$/MMBtu na Henry Hub distributivnom čvorištu od 1998. godine
Izvor: Izradila autorica prema (U.S. EIA, 2014.)

Iz svega navedenog, može se zaključiti da se kao najznačajniji čimbenici o kojima ovise cijene nafte i plina mogu izdvojiti:

- ponuda,
- zalihe,
- potražnja i
- ostali faktori.

Energetske se potrebe kroz vrijeme mijenjaju s društvenim i tehnološkim razvojem. Zemlje u razvoju koje do sada nisu bile u visokoj ovisnosti o energiji, s vremenom će imati rastuće energetske potrebe. Neizvjesno je stoga, hoće li porast životnog standarda u zemljama u razvoju rezultirati nestašicom resursa u budućnosti i povećanjem cijena te hoće li nove tehnologije i nekonvencionalni izvori energije premostiti praznine u opskrbi energentima.

Međutim, monopol naftne industrije na transportnom tržištu kroz upotrebu nafte i prerađevina kao glavnog pogonskog goriva za vozila polako se smanjuje unatoč činjenici da se očekuje rast u proizvodnji. Automobilska industrija proizvodi sve efikasnija vozila, a biogoriva počinju dobivati svoje mjesto na tržištu kao zamjena za naftne prerađevine. Kao ključni čimbenici gubitka monopola nafte u ulozi ključnog pogonskog goriva mogu se navesti njene visoke cijene i sve utjecajnije politike vlada u ograničenju emisija ugljičnog dioksida i ostalih stakleničkih plinova. Za očekivati je stoga, da će ovakve politike biti u porastu u nadolazećim godinama, što će za posljedicu imati pad upotrebe goriva s visokim emisijama ugljičnog dioksida, poglavito u razvijenim zemljama. U zemljama u razvoju ovaj pad će biti spor i dugotrajan.

Od ostalih čimbenika koji utječu na potražnju nafte i plina bitno je izdvojiti tehnološka poboljšanja vezana uz energetske učinkovitost, sezonske vremenske obrasce, povećanu konkurentnost alternativnih izvora energije uz subvencije i poticaje pojedinih vlada kao i promjene u tehnologijama i potrošačkim sklonostima koji mijenjaju konačan izbor potrošača.

S druge strane, kao čimbenici od najvećeg utjecaja na ponudu mogu se izdvojiti u prvom redu utjecaj, otkrivanje i razvoj novih naftnih i plinskih izvora kao i tehnologija za poboljšanje i oporavak postojećih izvora. Ovi čimbenici imaju tendenciju utjecaja na smanjenje cijena u granicama koje prate povećanje opskrbe uvjetovane porastom potražnje. Isto tako povećanje učinkovitosti u rafinerijskoj

industriji kao i povećanje proizvodnih kapaciteta čimbenici su koji imaju tendenciju smanjenja marže na gotove proizvode.

Uloga organizacije OPEC se u novijoj povijesti također mijenja. Iako se procjenjuje da se na području zemalja članica OPEC-a nalazi oko dvije trećine svjetskih zaliha nafte, a one trenutno pokrivaju oko 40 % svjetskog tržišta nafte, s pojavom sve većeg broja proizvođača iz dosada nekonvencionalnih izvora, poglavito dubokih mora i nepristupačnih područja, a zahvaljujući sve većem tehnološkom napretku, buduće slabosti u kratkoročnoj potražnji neće više biti balansirane samo OPEC-ovim regulatornim mjerama proizvodnje u periodima niskih cijena nafte i plina.

Nedavni događaji vezani uz početak i trajanje posljednje ekonomske krize također uvelike utječu na kretanje cijena nafte i plina. To se posebno očituje u smanjenom rejtingu pojedinih država, odbijanju ili odgađanju plaćanja dospjelih dugovanja, neispunjenju ugovornih obveza, nemogućnosti pristupa novcu potrebnom za kreditiranje, pravnim ograničenjima i krizi likvidnosti. Takvi su događaji pokrenuli procese raspada ili restrukturiranja fiskalnih, monetarnih i političkih sustava. Sve to narušilo je i funkcioniranje financijskih tržišta i institucija.

Na opskrbu naftom i plinom na svjetskoj razini mogu utjecati i ostali čimbenici koji mogu smanjiti raspoloživost postojećih zaliha. Osim što je još uvijek prisutna mogućnost pridržavanja proizvodnih kvota od strane zemalja članica OPEC-a, u ove čimbenike se mogu svrstati moguće ratne situacije, nametanje sankcija i ostalih ograničenja, elementarne nepogode, poremećaji u poslovanju konkurenata i ostalih događaja koji imaju utjecaj na nedostupnost distribucijskih kanala, i sl. Svaki od ovih čimbenika zasebno, kao i više njih u kombinaciji, mogu bitno poremetiti regularnu opskrbu. Svi su oni usko povezani s formiranjem cijena nafte i plina na tržištu.

Potencijalni čimbenici koji također mogu utjecati na cijenu nafte i plina s ekonomskog aspekta u negativnom smislu su inflacija, kamatne stope, tečajne razlike kao i lokalni i regionalni uvjeti na tržištu.

S političkog aspekta najveći utjecaj imaju čimbenici povezani s ograničenjima pristupa ležištima. Naime, pojedine države ne dozvoljavaju ili ograničavaju pristup svojim naftnim i plinskim resursima. Ograničenja stranih ulaganja u naftno-plinskom sektoru uobičajena su u vremenima visokih cijena nafte i plina, tj. u slučaju kada vlade takvih država nemaju veliku potrebu za vanjskim izvorima

kapitala. Također se mogu pojaviti i restrikcije ulaska pojedinih poduzeća iz zemalja sa čijom se politikom vlade zemalja vlasnika izvora ne slažu. To je čest slučaj s ulaskom SAD-a u pojedine države. S druge strane, takve restrikcije mogu omogućiti ulazak pojedinih poduzeća iz drugih država.

Nepostojanje dobro razvijenih pravnih sustava u zemljama u kojima se nalaze izvorišta može uzrokovati brojne probleme poduzećima koja na tim područjima posluju, a što pak utječe na proizvodnju, distribuciju i politiku zaliha. Česte promjene zakonske regulative i uvjeta pod kojim poduzeća u pojedinim zemljama posluju također mogu utjecati na kontrolu cijena. Takve promjene očituju se kroz povećavanje poreza i drugih nameta od strane države u kojoj se nalazi izvorište, promjene u regulativi koje se odnose na očuvanje okoliša i ekološke standarde te ponekad poduzimanje određenih radnji od vlada koje imaju za posljedicu otkazivanje bitnih ugovora, denominaciju službenih valuta ili oduzimanje imovine.

Osim navedenih čimbenika može se izdvojiti i stalna mogućnost terorističkih djelovanja koja uzrokuju velike troškove s obzirom na zadovoljavanje potrebnih sigurnosnih mjera prema poduzećima.

3.1.3. Obilježja poduzeća naftno-plinskog sektora

Naftno-plinska industrija (u nastavku: industrija) je okarakterizirana s tri osnovne organizacijske vrste poduzeća s obzirom na vlasništvo, i to ona u privatnom vlasništvu, dionička društva i nacionalizirana poduzeća. Obilježja poslovanja poduzeća ove industrije u tradicionalno naftno-plinskim izvozno-orijentiranim državama još uvijek ovise o državnom monopolu nad ovakvim poduzećima, ali u posljednje vrijeme sve više malih privatnih poduzeća uključuje se u ovu industriju samostalno ili u smislu suradnje s državno kontroliranim poduzećima. Kako su u većini slučajeva razvoj i strategije poslovanja poduzeća iz ove industrije usko povezani s ovisnošću o vladama zemalja unutar kojih posluju, novija istraživanja pokazuju promjene u intervencijama vlade u poslovanje ovih poduzeća, uglavnom uzrokovane klimatskim promjenama te ekonomskom i fizičkom sigurnošću.

Operativna područja poslovanja odnose se na procese definirane od pronalaska nafte i plina do isporuke istih krajnjim korisnicima, pa je industrija, kako je već prethodno definirano, podijeljena s obzirom na operacije koje izvodi u tim procesima.

Sektor za eksploataciju i proizvodnju najveći je unutar industrije ne samo po veličini poduzeća koja unutar njega posluju, već i po njihovom broju. Uključuje poslovne operacije povezane s pronalaskom i vađenjem nafte i plina. Proces eksploatacije oslanja se na primjenu geoloških znanosti i tehnologije bušenja što zahtijeva visoku stručnost i kvalificiranost zaposlenika poglavito u otkrivanju ispod-površinskih zamki vezanih uz ugljikovodike. Proizvodnja pak podrazumijeva aktivnosti povezane s odstranjivanjem nafte i plina iz izvora i dostavu istih transportnom sektoru. Uobičajeni procesi ovog izrazito kompleksnog i kapitalno intenzivnog sektora mogu se podijeliti na:

- proces povezan s preliminarnim istraživanjima koji se odnose na otkrivanje i razvoj novih izvorišta;
- proces ugovaranja prava na pronalazak i proizvodnju koji podrazumijeva pregovaranje s vlasnicima mineralnih prava i strukturiranje ugovornih odnosa koji uključuju postotke buduće proizvodnje, ali i identifikaciju potrebe za potencijalnim zajedničkim nastupom (*Joint Venture*);
- proces bušenja istraživačkih bušotina;
- razvoj i završetak radova potrebnih da se bušotina stavi u funkciju, što podrazumijeva testiranje zaliha i izradu studija isplativosti;
- konačni razvoj bušotine koji se odnosi na bušenje dodatnih polja i instalaciju površinske opreme za učinkovitu i ekonomičnu proizvodnju;
- proces proizvodnje, koji se odnosi na vađenje i prodaju nafte i plina prema uvjetima diktiranim tlakom u ležištu i učinkovitosti opreme;
- začepljenje i napuštanje bušotine/ležišta nakon završetka crpljenja što podrazumijeva sanacijske radove i premještanje opreme nakon iskorištenja ekonomski isplativih limita ležišta.

Navedeno objašnjava uobičajenu vremensku domenu od 5 do 10 godina potrebnu za početak proizvodnje iz otkrivenih potencijalnih izvora.

Strategije ovakvih poduzeća mogu se oslanjati na jednu ili kombinaciju više navedenih kako slijedi:

- strategija čiste eksploatacije, kod koje je eksploatacija nafte i plina isključivi oslonac za razvoj;
- stjecanje i razvoj, strategija je koja teži razvoju imovine od drugih poduzeća te se u fokus u većoj mjeri stavlja razvoj rezervi nego njihova eksploatacija;

- najčešće korištena strategija eksploatacije, stjecanja i razvijanja pri čemu se kombinacija strategije eksploatacije i razvoja često koristi u vremenima kada su cijene robe (nafte i plina) visoke, a imovina skupa, dok se stjecanje kao strategija najčešće koristi u vremenima nižih cijena robe i imovine;
- strategija korištenja nekonvencionalnih izvora poput naftnih šejlova (glineni škrljavac), izvora u dubokim odobalnim područjima, i sl., koje imaju tendenciju rezervi dužeg vijeka od onih konvencionalnih.

U ekonomskom smislu ovaj sektor okarakteriziran je značajnom nestabilnošću u postizanju krajnje ostvarive cijene robe (nafte i plina) kao i visokim troškovima uključenim u pronalazak nafte i plina, razvoju ležišta i rezervi za proizvodnju, čemu se moraju pridodati i često nesigurne procjene obnovljivih resursa za proizvodnju.

Kako je u prirodi rezervi njihovo trošenje uslijed eksploatacije, ovaj industrijski sektor prisiljen je kontinuirano reinvestirati sredstva u poslovanje u svrhu pronalaska novih resursa za proizvodnju, ali i zamjene istrošenih rezervi i povećanja proizvodnje i održivosti.

Konvencionalne rezerve nafte i plina postale su oskudnije te ih se u novije vrijeme pronalazi u manjim ležištima. Međutim, kao što je već spomenuto, ova industrija u visokom stupnju koristi dobrobiti moderne tehnologije koja se stalno razvija, pa se koristi njome u pronalasku nekonvencionalnih rezervi. Tako se sve više pridodaje pažnja naftnim šejlovima, poglavito u Sjevernoj Americi i Kanadi, te odobalnim izvorima i rezervama u dubokim morima (Brazil, arktički pojas, i sl.).

Eksploatacija u odobalnim područjima zahtijeva više kapitalnih ulaganja po svakom ležištu, pa je stoga izložena većem riziku. S druge strane eksploatacija naftnih šejlova uključuje minimalni eksploatacijski rizik, jer je kao resurs dobro definiran i dugotrajnog je karaktera. No, važno je napomenuti da je postupak vađenja nafte iz naftnih šejlova pomalo i kontroverzan zbog mogućeg negativnog utjecaja na okoliš, posebno onog vezanog uz podzemne vode. Posljednje navedeno predmet je brojnih rasprava.

Sektor transporta i skladištenja nafte i plina predstavlja vitalnu poveznicu između proizvođača i potrošača. Osnovne karakteristike ovog sektora vezane su za skladištenje i transport nafte i plina od ležišta do rafinerija. Nafta i plin transportiraju se pomoću cjevovoda, kamiona cisterni, te posebnih brodova za

prijevoz sirove nafte, tj. ukapljenog prirodnog plina. Postavljanje cjevovoda za prikupljanje i transport nafte i plina čine okosnicu ovog sektora. Posljednjih godina ovakva poduzeća sve više su usredotočena na infrastrukturu i transportna sredstva vezana za dostavu plina.

Sektor rafiniranja i marketinga obuhvaća operacije rafiniranja sirove nafte u petrokemijskim postrojenjima (rafinerijama), kao i distribuciju gotovih proizvoda (benzina, dizela, mlaznih goriva, loživih ulja, asfalta, maziva, sintetičkih guma, plastike, gnojiva, pesticida, antifrizi, butana, propana, prirodnog plina, itd.) do krajnjih korisnika. Rafinirani naftni proizvodi i prirodni plin transportiraju se na različite načine do distribucijskih centara za daljnju potrošnju. Ovaj sektor može se promatrati odvojeno kroz podsektor rafiniranja i podsektor marketinga.

Postupak prerade nafte podrazumijeva odvajanje pojedinih frakcija, tzv. rafinata, odakle i potječu nazivi rafiniranje i rafinerija. Općenito se ti postupci odnose na odvajanje sumpora, dušikovih spojeva i soli iz nafte, a kako bi se postigla bolja kvaliteta. Postupci prerade mogu se okarakterizirati kao primarni i sekundarni, pri čemu (Tireli, 2005.):

- u primarne procese spadaju procesi destilacije, separacije, apsorpcije, adsorpcije i ekstrakcije,
- u prvu podskupinu sekundarnih procesa spadaju procesi s pregradnjom molekula, termičko i katalitičko kreiranje i hidrokreiranje,
- u drugu podskupinu sekundarnih procesa spadaju procesi s pregradnjom molekula i spojeva, reformiranje i izomerizacija,
- treću podskupinu čine procesi u kojima se dograđuju molekule u obliku izopentana i izoheksana, polimerizacija i alkilacija.

Margine i profiti rafinerija ovise o razlici u cijeni sirove nafte i gotovih proizvoda što je usko povezano s kvalitetom nafte i navedenim postupcima koji se izvode pri rafiniranju. Kompleksnije rafinerije u mogućnosti su izvođenja takvih procesa jeftinije pa samim time i ostvarenja većih profita.

Preko podsektora marketinga naftno-plinska industrija predstavlja se javnosti. Kroz reklamu, menadžment kupaca, proizvodni miks, veleprodajnu i maloprodajnu strategiju, promovira se prodaja i brendiranje. Veleprodajne aktivnosti uključuju izbor distribucijskih kanala, menadžment položaja distribucije, kao i ekspanziju proizvoda u trgovinama.

Od krucijalne važnosti za ovaj sektor važno je izdvojiti i skladišne terminale na dobrim pozicijama u svrhu:

- izbjegavanja zemljopisne neuravnoteženosti između rafinerija i potrošača,
- poboljšanja zadovoljenja regulatornih uvjeta vezanih uz kvalitativne specifikacije pojedinih proizvoda, a za koje postoji potreba odvojenog skladištenja,
- povećanja aktivnosti neovisnih trgovaca, i
- utjecaja trgovanja naftom u smislu poštivanja obvezatne regulative vezane uz zalihe.

Naftno-plinska servisna poduzeća (*OFS*) pružaju specijaliziranu opremu i vještine potrebne za eksploataciju, bušenje, testiranje, proizvodnju, održavanje i oporavak ležišta nafte i plina, te projektiranje i izgradnju cjevovoda za transport nafte i plina. Naime, istraživanje naftnih polja i rezervi te proizvodnja i transport nafte i plina složen je proces, u kojem svaki korak u lancu tog procesa zahtijeva specifična znanja i specijaliziranu tehnologiju. Isto tako, otkrivanje ležišta nafte i plina zahtijeva brojna i kompleksna istraživanja, geološka modeliranja, seizmičke studije i istraživačke bušotine. Osim navedenih usluga, poduzeća ovog sektora pružaju i usluge iznajmljivanja opreme potrebne za vađenje ili transport nafte i plina.

Integrirana poduzeća su u svom poslovanju osim na eksploatacijsko-proizvodni sektor orijentirana najmanje na još jedan od spomenutih sektora, najčešće na rafiniranje i marketing, te transportni sektor.

3.2. Računovodstvene specifičnosti poduzeća naftne i plinske industrije

U usporedbi s poduzećima iz ostalih industrija, unutar naftno-plinske industrije pojavljuju se jedinstvene značajke koje rezultiraju računovodstvenim specifičnostima. Poglavitito se to odnosi na eksploatacijsko-proizvodni sektor koji posluje pod visokim stupnjem rizika kod kojeg je teško odrediti korelaciju između troška uloženog u ležište i vrijednosti rezervi unutar ležišta. Osim toga, industriju prati visoki stupanj regulatornih obveza u kombinaciji s kompleksnim poreznim pravilima i nerijetko kompleksnim karakterističnim ugovorima o podjeli troškova. Stoga poduzeća eksploatacijsko-proizvodnog sektora posežu za različitim

izborima računovodstvenih politika, u okviru dozvoljenih, unutar određenih računovodstvenih standarda.

U ostalim sektorima, poglavito *OFS* sektoru, računovodstvene specifičnosti vežu se uglavnom uz kompleksno praćenje troškova po fazama pojedinih projekata, te njihovo sučeljavanje s prihodima po obračunskim razdobljima, a ovisno o stupnju dovršenja.

Specifičnosti koje se odnose na računovodstvene tretmane pojedinih stavaka financijskih izvještaja mogu se promatrati kroz: **1) Računovodstveni tretman operativnih troškova koji se odnose na istraživanje novih rezervi nafte i plina - SE/FC metoda, 2) Računovodstveni tretman imovine poduzeća naftne i plinske industrije, 3) Amortizaciju imovine poduzeća naftne i plinske industrije i 4) Računovodstvene specifičnosti proizvodnih aktivnosti.**

3.2.1. Računovodstveni tretman operativnih troškova koji se odnose na istraživanje novih rezervi nafte i plina

Prema američkim računovodstvenim standardima (US GAAP), računovodstveni tretman operativnih troškova koji se odnose na istraživanje pronalaska novih rezervi nafte i plina moguće je izvesti pomoću dvije metode iz kojih proizlaze različiti rezultati koji se odnose na zarade, povrat na kapital te računovodstvenu vrijednost.

Kako obje metode prate računovodstvene principe i pravila usklađivanja, realizacije i troškova, poduzeća svojim odlukama izabiru metodu koja im se za iskazivanje rezultata čini najprikladnija. Primarno, metode se razlikuju u tretmanu i načinu prikazivanja kapitalnih troškova povezanih s istraživanjem bušotina koji mogu biti ili kapitalizirani ili priznati kao troškovi.

Prema *SE* metodi (*Successful Efforts, SE*) kapitaliziraju se, tj. svrstavaju u dugotrajnu imovinu u bilanci, odnosno amortiziraju se i svrstavaju u izvještaje o dobiti, samo oni troškovi povezani s uspješno lociranim rezervama nafte i prirodnog plina, dok se troškovi neuspješnih bušotina, svrstavaju u operativne troškove i sučeljavaju s prihodima tog razdoblja. Slično se provodi i u drugim industrijama koje imaju potrebu otpisivanja poslovnih neuspjeha.

SE tretman troškova istraživanja bušotina nalik je tretmanu troškova istraživanja i razvoja u drugim industrijama, tj. ako istraživački projekt rezultira održivim

proizvodom, tada se izdaci povezani s projektom kapitaliziraju, u protivnom se svrstavaju u troškove.

Alternativnim pristupom po *FC* metodi (*Full Cost, FC*), dopušta se da se svi operativni troškovi povezani s istraživanjem novih izvora nafte i plina kapitaliziraju, odnosno svrstaju u dugotrajnu imovinu u bilanci i amortiziraju.

Razlike u računovodstvenom tretmanu otkrivenih novih rezervi po *SE* ili *FC* metodi rezultiraju drugačijim rezultatima u računu dobiti i gubitka i izvještaju o novčanom toku. Tako će *SE* tretman rezultirati nižom operativnom dobiti, neto dobiti i nižom vrijednošću nekretnina, postrojenja i opreme. *FC* tretman će s druge strane rezultirati višom operativnom dobiti, neto dobiti i vrijednosti nekretnina, postrojenja i opreme.

Važno je napomenuti da, poduzeća koja primjenjuju *FC* metodu imaju obvezu, nametnutu od institucije *Securities & Exchange Commission*, procjene vrijednosti rezervi u skladu s tržišnim cijenama, te temeljem toga otpis viška vrijednosti u slučaju kada je knjigovodstvena vrijednost veća od procijenjene. Otpisi i umanjenja tako uzrokuju smanjenje operativne i neto dobiti u nadolazećim godinama.

Prema međunarodnim računovodstvenim standardima (*IFRS*) dozvoljena je samo *SE* metoda pa se stoga ona najčešće primjenjuje u velikim međunarodnim poduzećima. S druge strane, primjena *FC* metode često se susreće kod malih poduzeća s kratkom poviješću poslovanja ili na početku poslovanja.

3.2.2. Računovodstveni tretman imovine poduzeća naftne i plinske industrije

Bilanca poduzeća naftno-plinske industrije, poglavito eksploatacijsko-proizvodnih i integriranih poduzeća u pojedinim stavkama razlikuje se od bilance poduzeća iz ostalih industrijskih grana. To se naročito odnosi na stavke prikazane u aktivu bilance kako slijedi:

- Unutar potraživanja postoji mogućnost pojave stavke "neravnoteža u bilanci plina", pod kojom su prikazana potraživanja u vlasništvu partnera iz zajedničkih pothvata, pa čak ponekad i transportnih poduzeća.
- Eksploatacijsko-proizvodna poduzeća koja nemaju svoja spremišta i skladišta ne prepoznaju kao zalihe količine sirove nafte pohranjene u unajmljenim

tankovima. Zalihe sirove nafte su tako neuobičajena stavka kod eksploatacijsko-proizvodnih poduzeća. Isto je i sa zalihama plina.

- Česta je pojava stavke "unaprijed plaćenih troškova", a odnosi se na pretplate osiguranja, najma i sličnih troškova.
- "Nedokazani troškovi stjecanja imovine" odnose se na mineralna prava nerazvijenih i neodobrenih rezervi.
- "Odobreni troškovi stjecanja imovine", s druge strane, reflektiraju troškove i akumuliranu amortizaciju troškova odobrenih mineralnih interesa, tj. svojstva odobrenih rezervi na temelju geoloških i inženjerskih podataka o vjerojatnosti postojanja rezervi.
- "Troškovi odobrenih rezervi i razvoja" stavka je koja se odnosi na troškove i akumuliranu amortizaciju ležišta, proizvodnu opremu i objekte koji pripadaju ležištu.
- Pod stavkom "oprema i sadržaji za podršku eksploataciji" bilježe se kapitalizirani troškovi opreme i sadržaja koji se koriste tijekom operacija eksploatacije nafte i plina, a koji imaju višestruku funkciju unutar procesa stjecanja, eksploatacije, razvoja ili proizvodnje. Tu spadaju kampovi, kamioni, bageri, skladišta, sustavi za električno napajanje i sl.
- "Posao u tijeku" reflektira značajan dio sustava eksploatacijsko-proizvodnih poduzeća kod kojeg se akumuliraju svi troškovi povezani s geološkim i geofizičkim fazama eksploatacije po projektima. Isto se odnosi i na projekte u drugim sektorima industrije, poglavito *OFS* poduzećima koja pružaju najveću potporu eksploatacijsko-proizvodnim poduzećima, naročito u dugotrajnim fazama pronalaska i osposobljavanja bušotine i proizvodnje. Svaki projekt mora biti odobren, a troškovi povezani s njim analizirani i klasificirani. Po završetku projekta, akumulirani iznos uspoređuje se s odobrenjima i prenosi na troškove.

3.2.3. Amortizacija imovine poduzeća naftne i plinske industrije

Kao i kod drugih industrija, imovina naftno-plinskih poduzeća se uobičajeno amortizira po istom principu. Međutim, za razliku od ostalih poduzeća, kod eksploatacijsko-proizvodnih poduzeća, uz međunarodno uobičajene izraze deprecijacija i amortizacija, pojavljuje se i izraz iscrpljenost ležišta, tj. deplecija, pa se govori o deprecijaciji, depleciji i amortizaciji (DD&A). Pri tome deprecijacija označava alokaciju trošenja dugotrajne materijalne imovine tijekom korisnog

vijeka trajanja, amortizacija dugotrajne nematerijalne imovine, a deplecija označava trošenje mineralnih resursa. Za razliku od kategorije pojmova koje opisuju deprecijacija i amortizacija, u smislu odbitka troškova zbog starenja opreme i imovine, deplecija se odnosi na stvarno fizičko trošenje prirodnih resursa. Ova kategorija u računovodstvenom i financijskom smislu namijenjena je što točnijoj identifikaciji vrijednosti imovine u bilanci.

Ovisno o spomenutoj mogućnosti odabira SC ili FC metode, prema američkim računovodstvenim standardima, upravo je kategorija amortizacije stavka koja će zbog različitog tretmana rezervi prouzročiti razliku u financijskim izvještajima kao što je vidljivo iz Tablice 2.

Tablica 2. Razlike u financijskim izvještajima s obzirom na amortizaciju

Pretpostavke:			
Prihodi:	\$ 1.000	Proizvodnja:	150
Stjecanje imovine:	50	Opći i administrativni troškovi:	50
Neuspjela istraživanja (<i>Dry holes</i>):	200	DD&A - SE:	200
Uspješna eksploatacija:	100	DD&A - FC:	300
Razvoj:	200	Porezna stopa:	40%

SE - Račun dobiti i gubitka		FC - Račun dobiti i gubitka	
Prihodi:	\$ 1.000	Prihodi:	\$ 1.000
Troškovi:		Troškovi:	
Proizvodnja:	150	Proizvodnja:	150
Eksploatacija:	200	Eksploatacija:	-
DD&A:	200	DD&A:	300
Opći i administrativni troškovi:	50	Opći i administrativni troškovi:	50
Ukupni troškovi:	600	Ukupni troškovi:	500
Operativna dobit:	\$ 400	Operativna dobit:	\$ 500
Porez na dobit:	160	Porez na dobit:	200
Neto dobit:	\$ 240	Neto dobit:	\$ 300

SE - Bilanca		FC - Bilanca	
Početno stanje		Početno stanje	
Nekretnine, postrojenja i oprema:	\$ -	Nekretnine, postrojenja i oprema:	\$ -
Stjecanje imovine:	50	Stjecanje imovine:	50
Eksploatacija:	100	Eksploatacija:	300
Razvoj:	200	Razvoj:	200
DD&A:	(200)	DD&A:	(300)
Nekretnine, postrojenja i oprema:	\$ 150	Nekretnine, postrojenja i oprema:	\$ 250

Izvor: Izradila autorica prema (Breaking Into Wall Street, 2010.)

Za amortizaciju ostalih sektora naftno-plinske industrije može se reći da predstavlja značajnu stavku u financijskim izvještajima, jer su poduzeća svih sektora imovinski intenzivna, stoga izbor politike obračuna amortizacije igra bitnu ulogu u financijskim rezultatima ovih poduzeća.

3.2.4. Računovodstvene specifičnosti proizvodnih aktivnosti

Proizvodne aktivnosti dio su poduzeća eksploatacijsko-proizvodnog sektora, sektora rafiniranja i marketinga i integriranih poduzeća naftno-plinske industrije.

Kao i u ostalim slučajevima nastajanja najčešćih računovodstvenih specifičnosti, i kod proizvodnih aktivnosti one se ponajprije očituju u eksploatacijsko-proizvodnom sektoru. Već je prethodno spomenut dugačak proces od otkrivanja ležišta do proizvodnje, a taj proces uključuje različite vrste troškova kako slijedi:

- Troškovi stjecanja nastaju u trenutku stjecanja prava za istraživanje, razvoj i proizvodnju, a odnose se na kupnju ili zakup prava na vađenje nafte ili plina iz imovine koja nije u vlasništvu poduzeća. Ovakvi se troškovi kapitaliziraju u potpunosti.
- Troškovi istraživanja odnose se na prikupljanje i analizu geofizičkih i seizmičkih podataka mjesta na kojima bi potencijalno ležište moglo biti identificirano. Također, u ovu fazu spadaju troškovi istraživačkog bušenja koji mogu biti materijalnog i nematerijalnog karaktera. Nematerijalni su oni koji identificiraju pripremu instalacije i opreme za bušenje, dok se kao materijalni mogu povezati s fizičkom instalacijom opreme. Prema *SE* metodi svi nematerijalni troškovi bilježe se u računu dobiti i gubitka kao operativni troškovi razdoblja, dok se materijalni troškovi povezani s bušenjem kod uspješnih otkrića novih rezervi kapitaliziraju, a kod neuspješnih dodaju u operativne troškove razdoblja. Prema *FC* metodi svi troškovi istraživanja bilo materijalnog ili nematerijalnog karaktera kapitaliziraju se i dodaju u stavke dugotrajne imovine u bilanci.
- Troškovi razvoja uključuju pripremu otkrivenih rezervi za proizvodnju, što uključuje izgradnju dodatne infrastrukture u obliku pristupnih putova, dodatnih bušotina, instalaciju pumpi, cjevovoda, tankova i slično. Svi se ovi troškovi kapitaliziraju.
- U troškove proizvodnje spadaju troškovi nastali vađenjem nafte ili plina iz rezervi i spadaju u operativne troškove.

U troškove proizvodnje mogu se svrstati svi troškovi vezani za upravljanje i održavanje bušotina, uključujući amortizaciju i operativne troškove podrške, opreme, objekata i ostalih troškova poslovanja vezanih direktno uz proces vađenja nafte i plina. Priznaju se kao rashod u trenutku nastanka, osim u slučaju (Jennings i sur., 2000.):

- bilježenja zaliha nafte i plina po trošku, ili
- bilježenja odgode troškova proizvodnje povezane s neravnotežom plinskih zaliha pomoću metode prodaje.

Iako je teoretski prirodno da su proizvodni troškovi dio troškova proizvodnje nafte i plina, pa bi samim time i njihova alokacija spadala u zalihe i troškove prodanih proizvoda, kao što je već spomenuto, zalihe nafte i plina rijetka su pojava u bilancama proizvodnih i integriranih poduzeća naftno-plinske industrije.

U proizvodnji, prodaji i isporuci plina nerijetko se događaju neravnoteže u količinskim volumenima. Ovakve neravnoteže odnose se na prodaju ili isporuku veće ili manje količine plina od volumena ispuštenog u cjevovode. Odgovornost i prava za ovakve neravnoteže definiraju se ugovorima između isporučitelja i kupaca, a kontroliraju od institucija nadležnih za kontrolu mineralnih dobara. U računovodstvenom smislu ovakve se neuravnoteženosti usklađuju s ugovorenom vrijednošću, jednom od najčešće korištenih metoda kako slijedi:

- metoda prodaje, koja se izvodi na način da se prihodi priznaju u trenutku proizvodnje i prodaje, te se ne bilježe potraživanja i obveze u vezi neuravnoteženosti, već se prilagođavaju na stavkama odobrenih rezervi,
- metoda ovlaštenosti, prema kojoj se prihodi bilježe na temelju izračuna udjela ukupne mjesečne proizvodnje, te se viškovi iznad prosječne mjesečne proizvodnje balansiraju bilježenjem na strani obveza ili odgođenih prihoda, a manjkovi na strani potraživanja ili prihoda.

3.3. Financijske specifičnosti poduzeća naftne i plinske industrije

Uz računovodstvene specifičnosti, naftno-plinsku industriju prate i financijske specifičnosti koje se očituju kroz: **1) Specifičnosti radnog kapitala poduzeća naftne i plinske industrije, 2) Specifičnosti novčanog toka poduzeća naftne i plinske industrije, 3) Potrebu korištenja pokazatelja EBITDAX i 4) Ostale financijske specifičnosti poduzeća naftne i plinske industrije.**

3.3.1. Specifičnosti radnog kapitala poduzeća naftne i plinske industrije

Radni kapital je mjera koja označava razliku između tekuće aktive i tekućih obveza, a u slučaju poremećaja može značajno utjecati na novčani tok poduzeća. Izazovi u upravljanju radnim kapitalom prate naftno-plinsku industriju posljednjih nekoliko godina, a vezani su uz karakteristične probleme koji vrše značajan utjecaj na novčani tok, financiranje i poslovanje. Glavni uzrok tome je potražnja za sve većom proizvodnjom kako bi se zadovoljile energetske potrebe poglavito tržišta u razvoju. Osim toga, pitanja poput promjenjivosti u cjenovnim trendovima, poglavito u intervalima relativno visokih cijena nafte i plina, skreću pozornost s kvalitetnog upravljanja radnim kapitalom.

Uz veliki utjecaj cjenovnih trendova, jedan od najutjecajnijih čimbenika na radni kapital svakako je razvoj i ekspanzija kapitalnih ulaganja, koji je u ovoj industriji u posljednjih nekoliko godina prijeko potreban i to u svrhu brze reakcije na promjene u tržišnim uvjetima ubrzavanjem, usporavanjem i odgađanjem izvođenja sve kompleksnijih projekata i programa. Stoga, u ovoj industriji postoji trend rasta svijesti o značaju kvalitetnog upravljanja radnim kapitalom, a njegov utjecaj indirektno je povezan i s vrijednošću poduzeća.

U naftno-plinskoj industriji koriste se različite varijante upravljanja radnim kapitalom, a nadovezuju se na oblike poslovno-operativnih modela, odnosa s kupcima, stupnja vertikalne integracije, prirode ugovora nabave i proizvodnje te distribucijske infrastrukture.

Na radni kapital uvelike utječu i kompleksnosti same industrije koje se mogu izraziti kroz:

- zaglađivanje investicijskih ciklusa u razdobljima promjenjivosti cijena,
- rješavanje problema viših eksploatacijskih troškova i troškova razvoja, kao i rizika,
- poslovanje u doba povećanja sve strožih regulatornih propisa, te
- procjenu utjecaja i mogućnosti s pojavom alternativnih izvora energije.

Poboljšanja se u upravljanju radnim kapitalom unutar ove industrije mogu postići kvalitetnijim upravljanjem u područjima zaliha, procjene potražnje, planiranja lanca nabave, naplate potraživanja, postizanja dobrih komercijalnih uvjeta, te kvalitetnim ugovorima s izvođačima radova, prvenstveno u smislu odluka o izvođenju pojedinih segmenata poslovanja od strane vanjskih suradnika.

Istraživanja Ernst & Young-a (EY - Cash in the Barrel, 2011.) upućuju na značajan porast promjena u radnom kapitalu ove industrije u posljednjih nekoliko godina. Značajne promjene uočene su u novčano konverzijskim ciklusima (*Cash Conversation Cycle*, CCC; *Cash-to-Cash*, C2C) koji predstavljaju dane neplaćenih zaliha uvećane za dane neplaćenih potraživanja i umanjene za neplaćene obveze.

U promatranom razdoblju od 2003. do 2009. godine, C2C ove industrije obilježen je porastom od 7,1 dana (s 24,9 na 32,2), što je 29 %-tni porast. Ključni čimbenik ovog porasta nalazi se u razinama zaliha koje su bile u znatnom porastu u razdoblju od 2003. do 2009., što se reflektiralo na utjecaj cijena nafte, vrijednost i sastav ukupnih zaliha kao i višu razinu vrijednosti dionica.

Isti izvor navodi da se očiti paradoks u držanju više fizičkih zaliha u razdoblju visokih cijena nafte može objasniti s tekućom kombinacijom niskih kamatnih stopa i značajne nepostojanosti cijena, jer niske kamatne stope smanjuju troškove skladištenja, a nepostojanost kreira značajni cjenovni diferencijal između trenutnih i cijena očekivanih u budućnosti. U takvoj situaciji poduzeća si mogu dopustiti zadržavanje nafte kroz duže intervale, te isporuku zaliha na unosnija ciljana tržišta.

Upstream sektor ima najniži radni kapital unutar industrije što je posljedica niskih razina zaliha i visokih razina obveza prema dobavljačima. Znatno bolji položaj imaju rafinerije i marketing, kao i integrirana poduzeća, dok je za *OFS* sektor karakteristično po prirodi kompleksno poslovanje zbog dugih ciklusa modela poslovanja koje obilježavaju dugoročni ugovori. Karakterističnost tih ugovora je da u sebi sadrže obvezu značajnih predujmova i progresivne uvjete naplate.

Raširenost poslovanja unutar sektora veća je u servisnom i eksploatacijskom sektoru od rafinerijskog sektora, a veća disperzija kod eksploatacijskog sektora uzrokovana je razlikama u proizvodima i kupcima kao i razinama kapitalnih ulaganja.

S druge strane, kod servisnih je poduzeća ona uvjetovana prirodom podsegmenata koji odrađuju odgovarajuće poslove za naftno-plinsku industriju, jer svaki je projekt unutar ovog sektora vezan za poslove unutar određenog perioda životnog ciklusa rezervi, ali i varijacije u načinu izvođenja kroz različite poslovne strategije.

3.3.2. Specifičnosti novčanog toka poduzeća naftne i plinske industrije

Usko vezano uz karakterističnosti radnog kapitala naftno-plinske industrije, specifičnosti novčanog toka uglavnom se vežu i za (M&I, 2013.):

- masivnu deprecijaciju, depleciju i amortizaciju koja ponekad može biti veća od same neto dobiti;
- ostale nenovčane troškove, koje kao i kod drugih industrija, karakteriziraju nagomilani diskonti u obvezama otpisa amortizirane imovine, dobici i gubici od imovine, partnerstva, autorizirane prodaje, a ponekad i nastanak troškova tzv. neuspjelih istraživanja bušotina (*dry hole expense*),
- investicijske aktivnosti koje se očituju kroz visoka kapitalna ulaganja također znaju prerasti neto dobit, te prodaju imovine od pojedinačne do cijelih naftnih polja i plinskih bušotina, kao i visoki iznosi istraživanja i kupnje imovine,
- visoke financijske zahtjeve koji se vežu uz prirodu posla, pa se uz financiranje iz vlastitog kapitala često susreću visoki iznosi financiranja iz tuđih sredstava koji se konstantno otplaćuju i podižu novi, često u obliku *revolving* kredita.

Sve ove specifičnosti usko su vezane za visoke zahtjeve u tehnološkom i financijskom smislu poglavito kod izvođenja velikih često dugogodišnjih projekata. Visoki zahtjevi za kapitalnim ulaganjima (*CapEx*) poduzeća eksploatacijskog i servisnog sektora, koji smanjuju slobodan novčani tok mogu kreirati opadajući ili čak negativni novčani tok, što je karakteristično za početno razdoblje dugogodišnjih projekata. U rafinerijskom sektoru radi konkurentnosti postoji stalna potreba za novim tehnologijama što također uzrokuje visoke financijske izdatke, a sama oprema kao i u drugim sektorima uzrokuje visoke amortizacijske troškove.

3.3.3. Potreba korištenja pokazatelja *EBITDAX*

Problematika upotrebe zarade prije poreza i amortizacije (*EBITDA*) u vrednovanju poduzeća već je ranije iskazana. Usko vezano uz nju, specifičnosti koje nastaju u financijskim rezultatima eksploatacijsko-proizvodnih poduzeća na osnovi različito iskazanih troškova istraživanja bušotina po *SE* ili *FC* metodi, mogu prouzročiti nerealne procjene pojedinih poduzeća temeljem pogrešnih zaključaka analitičara.

U tu svrhu nastala je potreba prilagodbe ovog pokazatelja za poduzeća eksploatacijskog i integriranog sektora industrije. Prilagodba se izvršila

dodavanjem eksploatacijskih troškova u pokazatelj što je rezultiralo tzv. *EBITDAX* pokazateljem. Efekti takve prilagodbe vidljivi su iz Tablice 3., a očituju se u usporedivosti podataka bez obzira na računovodstvene efekte.

Tablica 3. Efekti prilagodbe pokazatelja *EBITDA* u pokazatelj *EBITDAX*

SE - Račun dobiti i gubitka		FC - Račun dobiti i gubitka	
Prihodi:	\$ 1.000	Prihodi:	\$ 1.000
Troškovi:		Troškovi:	
Proizvodnja:	150	Proizvodnja:	150
Eksploatacija:	200	Eksploatacija:	-
DD&A:	200	DD&A:	300
Opći i administrativni troškovi:	50	Opći i administrativni troškovi:	50
Ukupni troškovi:	600	Ukupni troškovi:	500
Operativna dobit:	\$ 400	Operativna dobit:	\$ 500
Porez na dobit:	160	Porez na dobit:	200
Neto dobit:	\$ 240	Neto dobit:	\$ 300
EBITDA:		EBITDA:	
\$ 600		\$ 800	
EBITDAX:		EBITDAX:	
\$ 800		\$ 800	

Izvor: Izradila autorica prema (*Breaking Into Wall Street*, 2010.)

Unatoč postojanju pokazatelja *EBITDAX*, mnoge banke i energetske grupacije i dalje koriste *EBITDA* pokazatelje za analize proizvodno eksploatacijskih poduzeća industrije, pogotovo ako je utvrđeno da sva analizirana poduzeća koriste istu računovodstvenu metodologiju.

3.3.4. Ostale financijske specifičnosti poduzeća naftne i plinske industrije

Osim navedenih, financijske se specifičnosti poduzeća naftne i plinske industrije najčešće pojavljuju zbog čimbenika povezanih uz karakteristične ugovorne odnose kojima su ova poduzeća podložna, porezne tretmane, te rizike poslovanja vezanih uz industriju.

Karakteristični ugovorni odnosi vezani su uz vlasništvo nad mineralnim pravima, odnosno uz činjenicu da ona mogu biti u privatnom ili državnom vlasništvu, ovisno o državi unutar koje se nalazi ležište.

Poslovanje sektora eksploatacije i proizvodnje tako u velikoj mjeri ovisi o vrsti ugovora s vlasnikom mineralnih prava, a ugovorima se definiraju bonusi,

tantijemi, porezna davanja i podjela proizvodnje, što izravno utječe na visinu prihoda.

Najčešći ugovorni sustavi su:

- sustavi koncesija u kojima države vlasnice naplaćuju naknadu za korištenje mineralnih prava kroz razne vrste nameta poput tantijema i poreza, primjer takvih država su SAD, Velika Britanija, Norveška, Rusija;
- ugovorni sustavi u kojima se s vlasnikom prava ugovara podjela proizvodnje ili prihoda u obliku tzv. ugovora o podjeli proizvodnje (*Production Sharing Contracts, PSC*), a karakteristični su za države Angolu, Katar, Kazahstan.

Iako se oscilacije i promjene koje imaju utjecaj na financijske rezultate mogu javiti kod oba ugovorna sustava, one su ipak češće kod *PSC* ugovora. Naime, rast cijene nafte omogućava poduzećima unutar sustava *PSC* ugovora da brže povrate svoje investicije. S druge strane, porast proizvodnje uzrokuje sve veće udjele vlasničkih prava u proizvodnji što može uzrokovati značajne neplanirane padove u udjelima kod poduzeća. Pod utjecajem takvih događaja pojavljuje se smanjenje rezervi što s vremenom uzrokuje smanjenje proizvodnje i negativnu percepciju investitora.

Kao najčešći čimbenici koji imaju utjecaj na rizike poslovanja, što za posljedicu može imati neuobičajene financijske oscilacije, mogu se izdvojiti (DBRS, 2009):

- ekonomsko okruženje, u smislu utjecaja naftno-plinske industrije na ekonomiju, poslovanje i razvoj industrije;
- pravno i regulatorno okruženje, u smislu čimbenika koji mogu pomoći ili odmoći u odnosu između razvoja poduzeća i industrijskog okruženja i regulatornih pravila, a u svrhu utvrđivanja frekvencija promjena ili stabilnosti u poslovanju;
- tržišna struktura s obzirom na načine i težinu ulaska na pojedina tržišta;
- rizik države u kojoj poduzeće posluje;
- cikličnost industrije koja se očituje u čimbenicima poput potrošnje konzumenata;
- uvjerenost konzumenata u potrebu za proizvodom;
- snaga ekonomije;
- kvaliteta menadžmenta u postizanju poslovnog uspjeha.

4. OCJENA FINANCIJSKIH I NEFINANCIJSKIH POKAZATELJA U FUNKCIJI POSTAVLJANJA KRITERIJA ZA VREDNOVANJE PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE

Kao što je već prethodno izloženo, svaki od navedenih pristupa vrednovanju poduzeća ima svoje nedostatke. Ti nedostaci još više dolaze do izražaja u kompleksnim industrijama poput naftno-plinske, a razlog tome je sve veća neizvjesnost na tržištu. Stoga je vrlo teško predvidjeti buduća kretanja, poglavito resurse i cjenovno kretanje tih resursa, zbog čega se javlja potreba dodatnih kvantitativnih i kvalitativnih analiza u svrhu identifikacije čimbenika koji utječu na stvaranje i akumulaciju vrijednosti. Ispitivanjem međuovisnosti tih čimbenika, pojedinačnih ili u određenim skupinama, s vrijednošću poduzeća, na način da se ispita koji od njih, u kojoj mjeri i po kojim kriterijima utječu na stvaranje i akumulaciju vrijednosti poduzeća, osnova je za vrednovanje poduzeća suvremenim pristupom. Ocjena se financijskih i nefinancijskih pokazatelja u funkciji postavljanja kriterija za vrednovanje poduzeća naftne i plinske industrije stoga promatra kroz: **1) Analizu osnovnih financijskih pokazatelja za poduzeća naftne i plinske industrije, 2) Karakteristične financijske analize za poduzeća naftne i plinske industrije i 3) Identifikaciju nefinancijskih pokazatelja u funkciji stvaranja i akumulacije vrijednosti poduzeća naftne i plinske industrije.**

4.1. Analiza osnovnih financijskih pokazatelja za poduzeća naftne i plinske industrije

Osnovni financijski pokazatelji koji se dobivaju analizama financijskih izvještaja rezultat su mnogobrojnih teorijskih i empirijskih istraživanja posljednjih desetljeća. Temeljeni su stoga na razumijevanju poslovnih modela, ključnih obilježja poslovanja, strategije, očekivanih događaja kao i ocjeni ključnih performansi poslovanja. Na osnovi njih vrši se prosudba o poziciji i vjerojatnosti uspjeha poduzeća koje se promatra, u okolini u kojoj posluje.

Najznačajniji aspekt ovakvih analiza je komunikacija menadžmenta poduzeća s okolinom, prvenstveno investitorima. To se u prvom redu očituje kroz usporedbu sličnih obilježja poduzeća unutar pojedine industrijske grupe kao i analizu odstupanja od industrijske norme za pojedine pokazatelje. Analizama se tako

prognozira održivost stabilnog poslovanja, određuju čimbenici rizika, ali i kvaliteta organizacije i menadžmenta u postizanju osnovnih ciljeva i strategije poslovanja.

Osnovni financijski pokazatelji za poduzeća naftno-plinske industrije u ovom radu promatraju se kroz: **1) Analizu likvidnosti, 2) Analizu profitabilnosti, 3) Analizu aktivnosti, 4) Analizu pokazatelja stvaranja vrijednosti i 5) Analizu poslovne izvrsnosti.**

4.1.1. Analiza likvidnosti

Jedan od načina testiranja stupnja zaštite kreditora fokusiran je na kratkoročno financiranje poslovanja poduzeća iz vlastitih operacija. Ovakva testiranja svrstavaju se u analizu strukturnih pokazatelja kroz ispitivanje likvidnosti i solventnosti.

U svrhu utvrđivanja vrijednosti poduzeća, važno je identificirati sposobnost poduzeća da podmiruje svoje obveze, kao i rizike i negativne posljedice koje mogu nastati u slučaju nedovoljne likvidnosti poduzeća. Analizom likvidnosti utvrđuje se i kvaliteta odnosa s vjerovnicima, kao i sposobnost zaštite od eventualnih velikih gubitaka vrijednosti u slučaju poslovnih neuspjeha.

Likvidnost poslovanja analizira se kroz sredstva koja predstavljaju onu tekuću imovinu koja se brzo i lako može pretvoriti u novac. Izvodi se na način da se u odnos stavljaju skupno ili u pojedinačnim oblicima tekuća imovina i tekuće obveze, a time se utvrđuje sposobnost poduzeća da podmiri svoje tekuće obveze u kratkom periodu. Koeficijent trenutne tekuće likvidnosti *CURR* (*CURrent Ratio*), stavlja u odnos ukupnu tekuću imovinu i ukupne tekuće obveze

$$CURR = \frac{\text{kratkotrajna imovina}}{\text{kratkoročne obveze}}. \quad (3.1)$$

Ovakav odnos smatra se pokazateljem likvidnosti najvišeg stupnja. Iako teorija govori da bi zadovoljavajući odnos ovog pokazatelja trebao biti oko 2, ovakve vrijednosti nisu uobičajene u industrijama koje imaju duže periode naplate potraživanja, kao i obrtaje zaliha (Pratt, 2008.), te se prosječne vrijednosti kreću od 1,30 do 1,40 (Bešvir, 2008.). Vrijednost ovog pokazatelja ispod 1 upućuje na zaključak da analizirano poduzeće nije sposobno podmirivati svoje tekuće obveze iz tekućih sredstava u predviđenom roku.

Osim s koeficijentom tekuće likvidnosti, likvidnost se može promatrati i kroz pokazatelj odnosa radnog kapitala prema ukupnoj aktivi, pri čemu je:

$$ex_3 = \frac{\text{radni kapital}}{\text{ukupna aktiva}}. \quad (3.2)$$

Kod upotrebe navedenog pokazatelja, granična mjera likvidnosti iznosi 25 % radnog kapitala u odnosu na aktivu.

4.1.2. Analiza profitabilnosti

Analizom profitabilnosti procjenjuje se poslovna sposobnost poduzeća da generira zarade u odnosu na stvorene troškove tijekom određenog vremenskog razdoblja. Svrha je ovakvih analiza utvrđivanje menadžerske učinkovitosti kroz pokazatelje povrata na imovinu (*Return On Asset, ROA*), povrata na kapital (*ROE*) i profitne marže (*PM*).

Najčešće korišteni omjer za prikaz povrata ulaganja vlasnika, već je prethodno definiran odnos neto dobiti i kapitala u (2.20), tj. *ROE*. Prosječne vrijednosti ovog pokazatelja za velika poduzeća kojima se javno trguje na burzama su između 11 % i 13 % (Palepu i Healy, 2008.).

S druge strane, povrat na imovinu (Palepu i Healy, 2008.):

$$ROA = \frac{\text{dobit nakon oporezivanja}}{\text{ukupna imovina}}, \quad (3.3)$$

pokazuje učinkovitost menadžmenta u raspolaganju i korištenju imovine. Za postizanje boljih vrijednosti ovog pokazatelja potrebno je upotrijebiti manje imovine u postizanju rezultata, efektivno upravljanje radnim kapitalom i minimiziranje poreza u okviru zakonski dopustivih rješenja (Helfert, 2005.). Zadovoljavajućim se vrijednostima ovog pokazatelja smatraju sve vrijednosti iznad 5 %.

Profitna marža kao odnos neto dobiti i ukupnog prihoda izražena kao:

$$PM = \frac{\text{dobit}}{\text{ukupni prihod}}, \quad (3.4)$$

ukazuje na menadžersku sposobnost učinkovitog poslovanja ne samo u smislu povrata na troškove roba i usluga, operativnih troškova uključujući amortizaciju i

troškova posuđenih sredstava, već i na sposobnost ostavljanja margine razumne naknade vlasnicima, kako ne bi doveli svoj kapital u opasnost (Helfert, 2001.).

Pokazatelj ex_1 predstavlja izvrsnost mjerenu profitabilnošću poslovnih (operativnih) aktivnosti, a definira se kao:

$$ex_1 = \frac{EBIT}{\text{ukupna aktiva}}, \quad (3.5)$$

pri čemu $EBIT$ predstavlja dobit prije kamata i poreza. Poslovna profitabilnost je ukupna poslovna izvrsnost u vremenskom kontinuitetu. Granična vrijednost poslovne profitabilnosti iznosi 6,675 % dobitka u odnosu na aktivu.

4.1.3. Analiza aktivnosti

Analizom aktivnosti uglavnom se mjeri efikasnost korištenja imovine (Pratt, 2008.), tj. efikasnost s kojom menadžment raspolaže imovinom u obavljanju poslovanja. U tom smislu uobičajeno se koristi nekoliko omjera u svrhu prosudbe iskoristivosti resursa (Helfert, 2001.), u obliku obrtaja izraženih u raznim formama, koje u konačnici izražavaju relativnu količinu kapitala korištenog u određenom obujmu obavljenog posla.

Ovakve analize upućuju na poduzeća koja prakticiraju leadersku strategiju rukovođenja troškovima. Takva poduzeća imaju niže vrijednosti bruto marže i više obrtaje imovine od poduzeća koja ne vode leaderske strategije (Palepu i Healy, 2008.). Najčešće se izražavaju omjerima, tj. koeficijentima obrtaja ukupne imovine ($KOUI$), obrtaja dugotrajne imovine ($KODI$), obrtaja kratkotrajne imovine ($KOKI$) i obrtaja kapitala (KOK) kako slijedi:

$$KOUI = \frac{\text{ukupni prihod}}{\text{ukupna imovina}}, \quad (3.6)$$

$$KODI = \frac{\text{ukupni prihod}}{\text{dugotrajna imovina}}, \quad (3.7)$$

$$KOKI = \frac{\text{ukupni prihod}}{\text{kratkotrajna imovina}}, \quad (3.8)$$

$$KOK = \frac{\text{ukupni prihod}}{\text{kapital}}. \quad (3.9)$$

Pomoću njih moguće je dobiti odgovore na sljedeće četiri grupe pitanja (Palepu i Healy, 2008.):

- (1) - Koliko dobro poduzeće upravlja zalihama?
 - Upotrebljava li poduzeće moderne proizvodne tehnike?
 - Ima li poduzeće dobar sustav upravljanja dobavljačima i logističkog menadžmenta?
 - Postoji li nesrazmjer između planirane potražnje i stvarne prodaje?
- (2) - Koliko dobro poduzeće upravlja kreditnim politikama?
 - Podudaraju li se te politike s marketinškim strategijama?
 - Stvara li poduzeće umjetno povećanje prodaje opterećenjem distribucijskih kanala?
- (3) - Uzima li poduzeće prednosti od trgovačkog kreditiranja?
 - Oslanja li se previše na trgovačka kreditiranja?
 - Ako da, koliki su implicitni troškovi?
- (4) - Da li je ulaganje u postrojenja i opremu u skladu s konkurentskom strategijom?
 - Ima li poduzeće politiku preuzimanja i dezinvestiranja?

Naime, ovakve se vrste analiza mogu izvoditi za svaku pojedinu vrstu imovine. Na taj se način mogu preciznije donositi zaključci o strategijama poslovanja iz područja upravljanja radnim kapitalom, zalihama ili pak dugotrajnom imovinom. Kroz usporedbu obrtaja kratkotrajne imovine, prvenstveno zaliha, sa sličnim poduzećima, odnosno poduzećima iz iste grane industrije, moguće je donositi zaključke o proizvodnim tehnikama, kvaliteti upravljanja kupcima i dobavljačima, ponudi i potražnji za proizvodom ili uslugom i slično.

Analiza se pak učinkovitosti i efikasnosti raspoloživih proizvodnih kapaciteta vrši usporedbom koeficijenta obrtaja dugotrajne imovine unutar industrije.

4.1.4. Analiza pokazatelja stvaranja vrijednosti

Poduzeće koje stvara vrijednost može se definirati kao organizacija u kojoj je menadžment sposoban integrirati zahtjeve svih zainteresiranih strana od dioničara, menadžmenta, zaposlenika, kupaca, dobavljača, vjerovnika, ali i cjelokupne zajednice (Helfert, 2001.). Tijekom godina brojni ekonomisti i

istraživači iz područja strategije poslovanja identificirali su nekoliko čimbenika koji imaju utjecaj na sposobnost organizacije da kreira vrijednost unutar korporativnog djelovanja (Palepu i Healy, 2008.). U najjednostavnijem obliku, stvaranje vrijednosti povrat je na kvalitetno upravljanje imovinom i poslovanjem na jedan od sljedećih načina (Palepu i Healy, 2008.):

- povećanjem povrata na postojeću imovinu uz istovremeno minimiziranje potrebnog kapitala u realizaciji tog povrata,
- novim investiranjem uz pažljivu procjenu predanosti novih investicija,
- prodajom imovine u slučaju da se povrati mogu maksimizirati efikasnim ulaganjem u nešto drugo,
- minimiziranjem rizika stavljanjem u fokus ključnih sposobnosti menadžmenta i maksimiziranjem komparativnih prednosti unutar pojedinih regija u koje se investira.

Mjerenje stvaranja vrijednosti pokazateljem ex_2 temelji se na ekonomskom profitu, odnosno dobitku koji prekoračuje cijenu vlastitog kapitala, a definira se kao:

$$ex_2 = \frac{\text{dobit nakon oporezivanja}}{(\text{vlastiti kapital}) \times \text{cijena}}, \quad (3.10)$$

Pri tome se pod cijenom vlastitog kapitala podrazumijeva umnožak vlastitog kapitala i cijene koju bi vlasnici mogli ostvariti iz alternativnih, relativno bezrizičnih ulaganja. Cijena kapitala je aproksimirana stopom kamate na vezanu štednju u bankama (4 %). Ako je ex_2 veći od jedan, poduzeće stvara vrijednost, a ako je manji od jedan poduzeće "jede" svoju supstancu (Belak, 2007.).

4.1.5. Analiza poslovne izvrsnosti

Poslovna izvrsnost je menadžerski sustav i organizacijski proces jačanja, razvoja i poboljšanja performansi poslovanja u svrhu kreiranja vrijednosti za vlasnike. Ovakav sustav okrenut je različitim područjima unutar organizacije poduzeća od vođenja, strategije, fokusa na klijente, kao i upravljanje informacijama, ljudima i procesima poslovanja, u svrhu postizanja superiornih poslovnih rezultata.

U ovom radu poslovna izvrsnost utvrđuje se *BEX* (*Business EXcellence*) indeksom (Belak, 2007.) zbog dokazane kvalitete u područjima:

- brze i jednostavne procjene izvrsnosti,

- sposobnosti trenutne i očekivane procjene izvrsnosti,
- dokazane prognostičke snage.

BEX indeks se definira preko četiri pokazatelja s određenim ponderima utjecaja prema sljedećem izrazu:

$$BEX = 0,388 \times ex_1 + 0,579 \times ex_2 + 0,153 \times ex_3 + 0,316 \times ex_4, \quad (3.11)$$

pri čemu je ex_1 pokazatelj profitabilnosti, ex_2 je pokazatelj stvaranja vrijednosti, ex_3 je pokazatelj likvidnosti, a ex_4 je pokazatelj financijske snage.

Pokazatelji ex_1 , ex_2 i ex_3 već su ranije definirani relacijama (3.5), (3.10) i (3.2), dok se pokazatelj ex_4 temelji na odnosu teorijski slobodnog novca iz svih aktivnosti, što je dobitak uvećan za amortizaciju, deprecijaciju i pokriva svih obveza tim novcem, pa vrijedi izraz:

$$ex_4 = \frac{5 \times (\text{dobitak} + \text{amortizacija} + \text{deprecijacija})}{\text{ukupne obveze}}. \quad (3.12)$$

Standardna mjera pokriva obveza slobodnim novcem iznosi 20 %. Postotak označava najkraći vremenski period od 5 godina u kojem promatrano poduzeće slobodnim novcem mora pokriti dospjele obveze. Ako poduzeće svoje obveze slobodnim novcem pokriva u vremenu kraćem od 5 godina, visina pokazatelja ex_4 progresivno raste, kao i njegov utjecaj na izvrsnost. Ovaj pokazatelj dobiven je na temelju statističkih istraživanja koja su ujedno pokazala da ima najveću prognostičku vrijednost.

Prema vrijednosti *BEX* indeksa, poduzeća se dijele na:

- dobra poduzeća kod kojih je *BEX* indeks veći od 1,
- poduzeća kod kojih su potrebna unaprjeđenja u poslovanju, pri čemu je *BEX* indeks između 0 i 1, i
- poduzeća kojima je ugrožena egzistencija, a na što upućuju vrijednosti *BEX* indeksa manje od 0.

Takva klasifikacija na dobra i loša poduzeća na temelju *BEX* indeksa statistički je potvrđena empirijskim testiranjem povijesnih podataka. Detaljnije rangiranje poslovne izvrsnosti s prognostičkim očekivanjima može se izvesti kako je izloženo u tablici 4.

Tablica 4. Rangovi poslovne izvrsnosti i prognoze za budućnost poslovanja poduzeća temeljeni na BEX indeksu

BEX indeks	RANG POSLOVNE IZVRSNOSTI	PROGNOZA ZA BUDUĆNOST
veći od 6.01	svjetska klasa	Poduzeće posluje s vrhunskim rezultatima, što se može očekivati i u sljedeće 4 godine ako menadžment nastavi s unaprjeđenjima u poslovanju.
4.01 do 6.00	izvrsno	Poduzeće posluje izvrsno, što se može očekivati i u sljedeće 3 godine ako menadžment nastavi s unaprjeđenjima u poslovanju.
2.01 do 4.00	vrlo dobro	Poduzeće posluje vrlo dobro, što se može očekivati i u sljedeće 2 godine ako menadžment nastavi s unaprjeđenjima u poslovanju.
1.01 do 2.00	dobro	Poduzeće posluje dobro, ali se poboljšanje može očekivati samo ako se pristupi unaprjeđenjima u poslovanju.
0.00 do 1.00	granično područje između dobrog i lošeg	Poslovna izvrsnost je pozitivna, ali nije zadovoljavajuća. Potrebno je pristupiti ozbiljnim unaprjeđenjima u poslovanju poduzeća.
manji od 0.00	loše	Ugrožena je egzistencija poduzeća. Potrebno je žurno pristupiti restrukturiranju i unaprjeđenjima kako se loše poslovanje ne bi nastavilo, jer postoji vjerojatnost preko 90 % da će ovakvo poduzeće propasti.

Izvor: (Belak i Aljinović, 2007.)

BEX model može služiti za procjenu ukupne poslovne izvrsnosti ili za utvrđivanje izvrsnosti po pojedinim prethodno definiranim područjima. Na taj se način omogućava poduzimanje mjera u nezadovoljavajućim segmentima poslovanja.

4.1.6. Rezultati analize osnovnih financijskih pokazatelja za pojedine sektore naftne i plinske industrije

Za potrebe ove disertacije u svrhu utvrđivanja industrijskog prosjeka i odstupanja analizirano je 186 poznatih svjetskih poduzeća naftno-plinske industrije, i to: 26 iz integriranog sektora, 40 iz eksploatacijsko-proizvodnog sektora, 40 iz sektora rafiniranja i marketinga, 40 servisnih poduzeća te 40 transportnih poduzeća.

Udio analiziranih poduzeća po svjetskim regijama (Sjeverna Amerika, Južna i Srednja Amerika, Europa i Euroazija, Bliski istok, Afrika, Azijsko-pacifička regija) i sektorima industrije (IM, E&P, R&M, OFS, T&S) prikazan je u Tablici 5. Analizirani podaci odnose se na 2012. godinu, prikupljeni su s brojnih profesionalnih poslovnih internetskih izvora, a u najvećoj mjeri korišten je *Bloomberg Businessweek* servis (Bloomberg Businessweek, 2013.). Detaljan popis analiziranih poduzeća nalazi se u Prilogu 1.

Tablica 5. Pregled rezultata analiza likvidnosti, profitabilnosti, aktivnosti, stvaranja vrijednosti i poslovne izvrsnosti za promatrana poduzeća po sektorima

ANALIZE		SEKTOR NAFTNO-PLINSKE INDUSTRIJE					
		IM	E&P	R&M	OFS	T&S	Ukupno
Broj analiziranih poduzeća po regijama	Sjeverna Amerika	4	7	16	19	18	64
	Juž. i Sr. Amerika	3	0	1	0	0	4
	Europa i Euroazija	14	21	4	12	13	64
	Bliski istok	1	3	5	0	1	10
	Afrika	1	1	0	1	1	4
	Azijsko-pacifička	3	8	14	8	7	40
	Ukupno	26	40	40	40	40	186
Analiza likvidnosti	CURR	0,39/5,60	0,37/9,37	0,68/5,59	0,20/4,39	0,44/8,40	0,42/6,67
		1,51	2,15	1,65	1,88	1,59	1,76
	ex ₂	-0,36/0,22	-0,13/0,52	-0,19/0,41	-0,18/0,66	-0,09/0,50	-0,19/0,46
		0,05	0,09	0,12	0,16	0,05	0,09
Analiza profitabilnosti	ROE	0,03/0,25	-0,06/1,57	-0,33/0,59	-0,06/0,43	-1,41/1,20	-0,37/0,81
		0,13	0,17	0,10	0,10	0,11	0,12
	ROA	0,02/0,15	-0,15/0,42	-0,15/0,28	-0,03/0,31	-0,05/0,40	-0,07/0,31
		0,07	0,07	0,06	0,06	0,05	0,06
	PM	0,03/0,20	-0,13/0,60	-0,02/1,17	-0,47/0,34	-0,31/5,62	-0,18/1,59
		0,11	0,18	0,05	0,05	0,28	0,13
	ex ₁	0,01/0,20	0,01/0,70	-0,01/0,59	-0,03/0,40	0,00/0,14	0,00/0,41
		0,11	0,12	0,12	0,09	0,05	0,10
Analiza aktivnosti	KOUJ	0,14/1,84	0,08/0,96	0,03/7,00	0,06/2,06	0,05/2,67	0,07/2,91
		0,86	0,38	2,98	0,84	0,46	1,10
	KODI	0,21/2,59	0,11/2,53	0,04/13,19	0,06/15,78	0,05/7,75	0,09/8,37
		1,18	0,54	5,75	2,10	0,76	2,07
	KOKI	0,43/8,08	0,32/12,02	0,16/17,90	0,70/4,09	0,31/8,02	0,38/10,02
		3,52	2,43	6,56	1,97	3,05	3,51
	KOK	0,20/3,62	0,08/1,23	0,04/18,30	0,15/5,40	0,05/7,18	0,10/7,15
		1,57	0,61	7,95	1,83	1,27	2,65
Stvaranje vrijednosti	ex ₂	0,63/5,89	-0,64/12,01	-3,48/16,12	-2,26/10,09	0,07/13,05	-1,14/11,43
		2,95	2,80	3,66	2,97	2,51	2,98
Poslovna izvrsnost	ex ₄	0,36/4,86	-0,29/5,83	-0,69/8,96	0,11/5,50	0,10/21,13	-0,69/21,13
		1,55	2,18	1,13	1,28	1,80	1,59
	BEX	0,49/4,54	-7,52/8,78	-16,87/10,45	-1,21/7,84	0,07/26,93	-16,87/26,93
		2,25	2,15	2,08	2,19	2,69	2,27

U svrhu ove analize ispitani su rasponi varijanci (2.40) i prosječne vrijednosti (2.38) svih navedenih koeficijenata (3.1), (3.2), (2.20), (3.3)–(3.12), a njihove izračunate vrijednosti nalaze se u Tablici 5., smještene u dva retka za svaki koeficijent. Tako se općenito za neki koeficijent x , u prvom retku nalazi odnos najmanje i najveće vrijednosti tog koeficijenta ($x_{\min}/x_{\max}$), a drugom retku njegova aritmetička sredina, tj. prosječna vrijednost ($\bar{x}$).

Ove su vrijednosti izračunate za sve koeficijente po pojedinim sektorima industrije, ali i za naftno-plinsku industriju u cjelini. Drugim riječima, provedene su analize likvidnosti, profitabilnosti, aktivnosti, stvaranja vrijednosti i poslovne izvrsnosti za svaki pojedini sektor, kao i za cijelu industriju.

Likvidnost poduzeća naftne i plinske industrije

Ocjena kvalitete menadžmenta u pogledu upravljanja likvidnošću može se odrediti kroz odstupanje od prosjeka sličnih poduzeća industrijskog okruženja. Na osnovi analiza uočeno je da su prosječne vrijednosti koeficijenta tekuće likvidnosti (*CURR*) po sektorima jednake: 1,51 (*IM*), 2,15 (*E&P*), 1,65 (*R&M*), 1,88 (*OFS*) i 1,59 (*T&S*), te da se kreću unutar uobičajenih vrijednosti. Prosjek industrije iznosi 1,76.

S druge strane, prosječne vrijednosti pokazatelja ex_3 iznose: 0,05 (*IM*), 0,09 (*E&P*), 0,12 (*R&M*), 0,16 (*OFS*), 0,05 (*T&S*), te 0,09 za cijelu industriju. Ove su vrijednosti niže od zahtijevanih, što upućuje na već izloženi problem specifičnosti koji se pojavljuje u radnom kapitalu ovih poduzeća. Analize su stoga potvrdile već ranije izloženu potrebu kvalitetnijeg upravljanja radnim kapitalom unutar naftno-plinske industrije.

Sumarno, likvidnost promatrana temeljem oba pokazatelja bilježi prosječne vrijednosti kako slijedi: 0,78 (*IM*), 1,12 (*E&P*), 0,89 (*R&M*), 1,02 (*OFS*) i 0,82 (*T&S*), iz čega slijedi zaključak da su vrijednosti prilično ujednačene unutar svih sektora, a likvidnošću se unutar industrije najbolje upravlja u poduzećima eksploatacijsko-proizvodnog i servisnog sektora.

Profitabilnost poduzeća naftne i plinske industrije

Prosječan povrat na kapital (*ROE*) bilježi po sektorima vrijednosti kako slijedi: 0,13 (*IM*), 0,17 (*E&P*), 0,10 (*R&M*), 0,10 (*OFS*) i 0,11 (*T&S*), što je, promatrano u kontekstu cijele industrije, uglavnom u okviru prosječnih vrijednosti, budući da se

promatranim poduzećima trguje na burzi. Sektor rafinerija i marketinga i servisni sektor bilježe nešto niže vrijednosti od prosječnih.

Analizom povrata na imovinu (ROA) dobivene su vrijednosti: 0,07 (IM), 0,07 (E&P), 0,06 (R&M), 0,06 (OFS) i 0,05 (T&S), što je zadovoljavajuće budući se radi o imovinsko intenzivnoj industriji. Iste vrijednosti ovog pokazatelja bilježe integrirani i eksploatacijsko-proizvodni sektor te sektor rafinerija i marketinga i servisni sektor, a najniže vrijednosti bilježi transportni sektor industrije.

Prosječne vrijednosti profitne marže (PM) po pojedinim sektorima iznose: 0,11 (IM), 0,18 (E&P), 0,05 (R&M), 0,05 (OFS) i 0,28 (T&S). Iz navedenog je vidljivo da najviše profitne marže unutar industrije ostvaruje transportni sektor, a najniže servisni sektor i sektor rafinerija i marketinga.

Analiza profitabilnosti pokazateljem ex_1 rezultirala je prosječnim vrijednostima kako slijedi: 0,11 (IM), 0,12 (E&P), 0,12 (R&M), 0,09 (OFS) i 0,05 (T&S), iz čega je vidljivo da zadovoljavajuće prosječne granične vrijednosti bilježe svi sektori osim transportnog, te da najviše vrijednosti bilježe eksploatacijsko-proizvodni i sektor rafinerija i marketinga.

Sumarno, profitabilnost promatrana temeljem svih navedenih pokazatelja bilježi prosječne vrijednosti kako slijedi: 0,10 (IM), 0,14 (E&P), 0,08 (R&M), 0,08 (OFS) i 0,12 (T&S), iz čega se vidi da najviše prosječne vrijednosti profitabilnosti ima eksploatacijsko-proizvodni sektor, a najniže sektor rafinerija i marketinga i servisni sektor.

Aktivnost poduzeća naftne i plinske industrije

Prosječne vrijednosti koeficijenta obrtaja ukupne imovine (KOUI) po pojedinim sektorima iznose: 0,86 (IM), 0,38 (E&P), 2,98 (R&M), 0,84 (OFS) i 0,46 (T&S), odnosno najviše su u sektoru rafinerija i marketinga, a najniže u eksploatacijsko-proizvodnom sektoru.

S aspekta koeficijenta obrtaja dugotrajne imovine (KODI) analiza su utvrđene sljedeće prosječne vrijednosti: 1,18 (IM), 0,54 (E&P), 5,75 (R&M), 2,10 (OFS) i 0,76 (T&S). Iz navedenog je vidljivo da trend koeficijenta obrtaja dugotrajne imovine prati koeficijent obrtaja ukupne imovine, s razlikom u servisnom sektoru koji se po vrijednostima pokazatelja nalazi ispred sektora integriranih poduzeća.

Trend je potpuno drugačiji kod koeficijenta obrtaja kratkotrajne imovine (*KOKI*) gdje su analizama utvrđene prosječne vrijednosti kako slijedi: 3,52 (*IM*), 2,43 (*E&P*), 6,56 (*R&M*), 1,97 (*OFS*) i 3,05 (*T&S*). Naime, iako po vrijednostima i dalje prednjači sektor rafinerija i marketinga, za razliku od prethodna dva izložena koeficijenta, integrirana poduzeća i poduzeća transportnog sektora bilježe više prosječne vrijednosti od eksploatacijsko-proizvodnog i servisnog sektora. Servisni sektor ima najniže prosječne vrijednosti koeficijenta obrtaja kratkotrajne imovine.

Trend daleko najviših prosječnih vrijednosti uočen je kod sektora rafinerija i marketinga i u analizama obrtaja kapitala (*KOK*), s tim da su po sektorima te vrijednosti jednake: 1,57 (*IM*), 0,61 (*E&P*), 7,95 (*R&M*), 1,83 (*OFS*) i 1,27 (*T&S*). Vrijednosti učinkovitosti korištenja kapitala nemaju veća odstupanja u sektoru integriranih, servisnih i transportnih poduzeća, daleko su najniže u eksploatacijsko-proizvodnom sektoru, a najviše u sektoru rafinerija i marketinga.

Sumarno, aktivnost promatrana temeljem svih navedenih pokazatelja bilježi prosječne vrijednosti kako slijedi: 1,78 (*IM*), 0,99 (*E&P*), 5,81 (*R&M*), 1,69 (*OFS*) i 1,39 (*T&S*), iz čega se zaključuje da su najviše prosječne vrijednosti u sektoru rafinerija i marketinga, a najniže u eksploatacijsko-proizvodnom sektoru.

Stvaranje vrijednosti u poduzećima naftne i plinske industrije

Analizom promatranih poduzeća, prosječne vrijednosti pokazatelja ex_2 utvrđene po segmentima unutar naftno-plinske industrije za 2012. godinu iznose po sektorima kako slijedi: 2,95 (*IM*), 2,80 (*E&P*), 3,66 (*R&M*), 2,97 (*OFS*) i 2,51 (*T&S*). Navedene prosječne vrijednosti upućuju na stvaranje vrijednosti unutar cijele industrije, te da ne postoje značajna odstupanja u sektorima integriranih, eksploatacijsko-proizvodnih, servisnih i transportnih poduzeća. Kod poduzeća sektora rafinerija i marketinga uočene su znatno najviše prosječne vrijednosti, dok su kod transportnih poduzeća najniže.

Prosječne vrijednosti pokazatelja ex_4 po pojedinim sektorima iznose: 1,55 (*IM*), 2,18 (*E&P*), 1,13 (*R&M*), 1,28 (*OFS*) i 1,80 (*T&S*). Prosječne vrijednosti svih promatranih sektora nadilaze zahtijevanu standardnu mjeru pokrića obveza slobodnim novcem. Najviše prosječne vrijednosti su u eksploatacijsko-proizvodnom sektoru, a najniže u sektoru rafinerija i marketinga.

Analizom odabranih poduzeća za 2012. godinu utvrđene su sljedeće prosječne vrijednosti *BEX* indeksa po segmentima naftno-plinske industrije: 2,25 (*IM*), 2,15 (*E&P*), 2,08 (*R&M*), 2,19 (*OFS*) i 2,69 (*T&S*), iz čega je vidljivo da ne postoje značajnija odstupanja u prosjecima po pojedinim sektorima, a poslovanje istih se može okarakterizirati kao vrlo dobro. Jednaki zaključak slijedi i za naftno-plinsku industriju u cijelosti, za koju je prosječna vrijednost *BEX* indeksa jednaka 2,27.

4.2. Karakteristične financijske analize za poduzeća naftne i plinske industrije

Financijske analize koje su karakteristične za poduzeća naftne i plinske industrije najčešće su vezane uz otkrivanje, razvoj i efikasno korištenje rezervi nafte i plina. Iako su specifične za poduzeća iz integriranog i eksploatacijsko-proizvodnog sektora, često su interesantne i poduzećima iz ostalih sektora jer im poslovanje ovisi o ta dva glavna sektora industrije. Potencijalni investitori njima se služe u ocjeni efikasnosti menadžmenta i kod budućih projekcija poslovanja.

U tu svrhu često se izvode:

- analiza životnog vijeka naftnih i plinskih rezervi,
- analiza zamjene proizvodnje,
- analiza troškova rezervi, kao i
- ostale analize karakteristične za poduzeća naftne i plinske industrije.

Analize životnog vijeka naftnih i plinskih rezervi vrlo su važne za integrirana i eksploatacijsko-proizvodna poduzeća naftno-plinske industrije, neovisno izvode li se zbog vrednovanja poduzeća ili iz drugih motiva. Rezultati ovakvih analiza, izraženi u godinama, ukazuju na preostali vijek trajanja odobrenih rezervi s obzirom na određene, obično trenutne, proizvodne kapacitete. Jedan od načina izvođenja ove analize može se izraziti kako slijedi (Wall Street Prep, 2009.):

$$\text{analiza životnog vijeka rezervi} = \frac{\text{rezerve na kraju godine}}{\text{proizvodnja}}. \quad (3.13)$$

S druge strane, analizom zamjene proizvodnje (*Production Replacement Ratio, PRR*) utvrđuje se sposobnost poduzeća da zamjeni rezerve iz kojih crpi naftu ili plin u svrhu prosudbe operativnih performansi poduzeća. Ovakve analize mjere iznos odobrenih rezervi nadodanih već postojećim rezervama. Smatra se da u uvjetima

stabilne potražnje ovaj pokazatelj mora biti najmanje 100 %, kako bi se osiguralo nesmetano, dugoročno poslovanje poduzeća koje se analizira. Izvodi se na dva načina (Wall Street Prep, 2009.):

- kao analiza zamjene proizvodnje uključujući sve izvore, tj. na način da se kvantificira sposobnost poduzeća kroz postojeće izvore, otkrića novih i akvizicijom poduzeća koja imaju svoje rezerve, kroz izraz:

$$PRR = \frac{(\text{ekstenzije i otkrića}) + \text{poboljšana proizvodnja} + \text{revizije} + \text{kupnja/prodaja}}{\text{proizvodnja}} \quad (3.14)$$

- kvantifikacijom sposobnosti poduzeća da proširi svoje rezerve samo u "organskom smislu", bušenjem ili razvojem novih nalazišta, kroz izraz:

$$PRR = \frac{(\text{ekstenzije i otkrića}) + \text{poboljšana proizvodnja} + \text{revizije}}{\text{proizvodnja}}. \quad (3.15)$$

U smislu tehnoloških performansi, efikasnost eksploatacijsko-proizvodnih i integriranih poduzeća ponajprije ovisi o sposobnosti pronalaženja i razvoja novih izvora crpljenja nafte i plina (Wright i Galun, 2008.). Analize troškova rezervi predložuju troškove pronalaska i razvoja rezervi (*Finding and Development, F&D*), a uobičajeno se izražavaju u jedinicama \$/boe, pri čemu je boe (*barrel of oil equivalent*) jedinica za energiju koju pri izgaranju oslobađa količina nafte od jednog barela, i ekvivalentna je energiji koju bi oslobodilo izgaranje 5.658,53 kubnih stopa prirodnog plina (Perić, 2007.). Viša vrijednost ovakvih pokazatelja znači višu efikasnost promatranog poduzeća.

Slično kao i analize zamjene proizvodnje, izvode se na dva načina (Wall Street Prep, 2009.):

- kao analiza troškova proizvodnje uključujući sve izvore kroz izraz:

$$F \& D = \frac{\text{istraživanje} + \text{akvizicije} + \text{troškovi razvoja}}{\text{nove rezerve iz svih izvora}} \quad (3.16)$$

- kao analiza troškova pronalaska i razvoja bez nabave i prodaje kao:

$$F \& D = \frac{\text{istraživanje} + \text{troškovi razvoja}}{\text{nove rezerve iz vlastitih izvora}}. \quad (3.17)$$

Ostale financijske analize karakteristične za poduzeća naftno-plinske industrije izvode se najčešće iz razloga i na način kako slijedi (Breaking Into Wall Street, 2013.):

- zbog utvrđivanja cijene koštanja po jedinici energije MCFE ili boe:

$$\text{proizvodni troškovi po MCFE ili boe} = \frac{\text{ukupni proizvodni troškovi}}{\text{ukupni proizvodni kapacitet}}, \quad (3.18)$$

- zbog utvrđivanja dnevne proizvodnje:

$$\text{dnevna proizvodnja} = \frac{\text{godišnji proizvodni kapacitet}}{\text{broj dana u godini}}, \quad (3.19)$$

- zbog utvrđivanja fokusa na vađenje nafte ili plina:

$$\text{naftno-plinski miks (\%)} = \frac{\text{odobrene naftne rezerve}}{\text{ukupne odobrene rezerve}}, \text{ ili} \quad (3.20)$$

$$\text{naftno-plinski miks (\%)} = \frac{\text{proizvodnja nafte}}{\text{ukupna proizvodnja}}. \quad (3.21)$$

U navedenim analizama Mcfe predstavlja ekvivalent tisuću kubnih stopa prirodnog plina. Općenito je uobičajeno prikazivanje rezervi nafte i plina njihovom konverzijom u plin kao zajedničku jedinicu. Drugi način konverzije rezervi je upotreba nafte kao zajedničke jedinice, tj. preko ranije spomenute jedinice boe (Perić, 2007.).

4.3. Identifikacija nefinancijskih pokazatelja u funkciji stvaranja i akumulacije vrijednosti poduzeća naftne i plinske industrije

Svrha identifikacije kvalitativnih pokazatelja u funkciji stvaranja i akumulacije vrijednosti poduzeća naftne i plinske industrije, u prvom redu je utvrditi vanjske i unutarnje čimbenike koji su povezani s rizicima nastavka i opstanka poslovanja poduzeća, tj. održivog razvoja.

Održivi razvoj i stvaranje vrijednosti u kvalitativnom smislu mogu se promatrati kroz pet ključnih čimbenika (Two Tomorrows, 2010.):

- usklađivanje napora u provođenju održivog razvoja i osnovne poslovne strategije kao i upravljanje osnovnim utjecajima na održivost, prilike i rizike;
- kvaliteta upravljanja najviše razine po pitanju održivosti;
- angažiranost kroz opseg zainteresiranosti razumijevanja i djelovanja dioničara;
- upravljanje utjecajima kroz vrijednosni lanac od dobavljača do distributera, uključujući životni vijek proizvoda;

- učinkovitost napora u razvoju proizvodnje i usluga kroz inovativnost, što uključuje i socijalne i ekološke izazove na profitabilan i prilagodljiv način.

Analizom ekonomskog okruženja u kojima poduzeće posluje ne samo kao pravni entitet, već i s osnove projekata na kojima radi, utvrđuje se važnost industrije ili sektora unutar nje u cjelokupnom ekonomskom okruženju. Na taj se način dolazi do zaključaka koji upućuju na odnos ekonomskih čimbenika poput inflacije, deflacije, ponude i potražnje, kamatnih stopa, tečajnih razlika kao i raspoloživosti potrebne radne snage na poslovanje poduzeća.

U okviru pravnih, regulatornih i političkih analiza utvrđuje se stupanj pravnog i regulatornog uređenja, te može li zakonsko uređenje u zemlji u kojoj poduzeće posluje pomoći ili odmoći u razvoju poslovanja poduzeća ili u izvođenju projekata. Pravno okruženje često utječe na promjene i sigurnost provođenja industrijskih i organizacijskih standarda i pravila koje su u ovoj industriji vrlo značajne.

Natjecateljsko okruženje ispituje se kroz analizu postojanja oligopola i monopola te stupanja konkurentnosti kao i barijera s kojima se poduzeće može susresti s ulaskom na neko novo tržište. Čak i najmanje promjene u natjecateljskom okruženju mogu značajno utjecati na poslovanje poduzeća.

Politički rizici koji utječu na poslovanje poduzeća u pojedinim državama povezani su sa stupnjem interveniranja pojedine vlade u ekonomiju i stupnjem osiguravanja održivih promjena u politici. Ovakvi rizici imaju utjecaj na poslovno nadmetanje, vlasništvo, kontrolu cijena, restrikcije kod pojedinih stranih valuta plaćanja, kapital, uvoz i izvoz i slično. Ovisno o njihovim efektima, donose se odluke o lokacijama na kojima će poduzeća poslovati. Uz to, izvođenje pojedinih velikih projekata u naftno-plinskom sektoru često je uvjetovano otvaranjem ovisnog društva, podružnice ili zajedničkih pothvata (*joint venture*) na području države u kojoj se projekt izvodi.

Stupanj cikličnosti ovisi o tržišnom segmentu unutar kojeg poduzeće posluje. Neciklične industrije sposobnije su prebroditi veće ekonomske promjene. Analiza dugoročnih strategija i poslovanja kroz duži period omogućuje bolje razumijevanje poslovanja u slučaju cikličkih poremećaja.

U smislu navedenog, kvalitativni čimbenici koji utječu na vrijednost poduzeća naftne i plinske industrije mogu se identificirati kroz (BP, 2013.):

- potrebu za energijom, koja se utvrđuje analizom porasta populacije i u svezi toga porastom BDP-a;
- opskrbu naftom i plinom i poslovanje unutar ili van organizacije OECD (*Organization of Economic Cooperation and Development*), a utvrđuje se analizom sjedišta poduzeća i njihovih ovisnih društava i analizom prodaje i kupaca;
- snabdijevanje naftom i plinom proizvođača električne energije posebno u zemljama u rastućem razvoju, a do podataka se dolazi analizom prodaje i kupaca;
- stupanj ulaganja u obnovljive izvore energije;
- poslovanje u većinskom dijelu s poduzećima iz transportnog sektora, do podataka se dolazi analizom djelatnosti kupaca i mjesta poslovanja (unutar ili izvan OECD-a);
- poslovanje kroz matice, ovisna društva i podružnice unutar Europske, Azijsko-pacifičke regije, Bliskog istoka i Sjeverne Amerike, analizom sjedišta poduzeća i njihovih ovisnih društava;
- postotak udjela proizvodnje nafte, plina i ulaganja u obnovljive izvore energije;
- ulaganja u tehnološke inovacije za učinkovitiju eksploataciju i proizvodnju u višem stupnju iskoristivih goriva;
- pravno uređenje pristupa privatnom vlasništvu, uređena financijska tržišta, povoljni fiskalni i regulatorni uvjeti;
- poslovanje unutar ili van OPEC zone;
- proizvodnju biogoriva koja ne zahtijevaju rafiniranje;
- proizvodnju ukapljenog prirodnog plina (LNG).

Analizom ostvarenih transakcija po pojedinim sektorima unutar naftno-plinske industrije, kvalitativni čimbenici koji utječu na vrijednost poduzeća mogu se razvrstati kako slijedi (EY, 2013.):

(1) Integrirana i eksploatacijsko-proizvodna poduzeća

- udio na velikom energetsom tržištu ili u značajnom poduzeću,
- pristup nekonvencionalnim rezervama,
- pristup resursima, tehnologiji, vještinama zaposlenika i transferu znanja,

(2) Rafinerije i marketing

- udio ili očekivana ulaganja u nove distribucijske kanale,

- udio u skladišnim terminalima kojima se:
 - povećava zemljopisni nesrazmjer između rafinerija i konzumenata,
 - omogućava odvojeno skladištenje za proizvode koji moraju na doradu da bi zadovoljili regulatorne uvjete ulaska na pojedina tržišta,
 - povećava aktivnost distribucije,
- usklađenost obveza i zaliha,

(3) Servisna poduzeća (*OFS*)

- posjedovanje ili ulaganje u napredne tehnologije,
- znanje i vještine zaposlenika.

Uz navedeno, potrebno je utvrditi i sposobnost i snagu menadžmenta kao jednog od najvažnijih čimbenika uspješnog poslovanja. Objektivni profil menadžmenta može se ispitati kroz sljedeće čimbenike (DBRS, 2009):

- prikladnost ključnih strategija,
- krutost ključnih politika,
- procesi i praksa poslovanja,
- menadžerske reakcije na problematične situacije,
- volja za rast,
- dodavanje novih segmenata kroz akvizicije,
- sposobnost laganog integriranja akvizicija bez većeg remećenja poslovanja, te
- pisani tragovi o poslovnim rezultatima.

Efektivno korporativno upravljanje zahtijeva zdrave odnose između menadžmenta, uprave i javnosti. Ne postoji unificirani "ispravan" pristup za sva poduzeća. Dobrom upravom može se smatrati ona koja ima veliki utjecaj na zdravi i ispravan održivi rast poslovanja, kao i utjecaj na sprječavanje nastajanja velikih negativnih promjena u poslovanju što pokazuju financijski rezultati kroz duži period. Analiza i procjena menadžmenta trebala bi biti fokusirana na prikladnost kompozicije i strukture uprave (uključujući nezavisnost i stručnost revizijskog tijela) da odobri izvršne mjere i korporativnu strategiju, ali i da nadzire izvršnu funkciju te mogućnosti za upravljanje vlastitim interesima.

U naftno-plinskoj industriji to se očituje kroz (Stevens, 2008.):

- jasno postavljen skup ciljeva, poglavito ciljeva integracije i internacionalnih operacija koji će usmjeravati aktivnosti poduzeća,

- proces donošenja odluka koji stvara sustav poticaja u kojima menadžeri djeluju, a odnosi se na sustave budžetiranja, operacija, stupnjeve diskrecije, razine potpisnih ovlasti kod nabave i rashodovne strane projekata,
- stupanj kapaciteta za izvođenje projekata koji direktno ovisi o menadžmentu i tehničkoj spremi zaposlenika, a ukazuje na poticajni sustav u procesu donošenja odluka i kvalitetu ulaganja u znanje i vještine zaposlenika.

Sve navedene kvalitete menadžmenta moguće je ispitati samo unutar poduzeća, tj. interno. Rijetki vanjski analitičari poput ovlaštenih revizora ili klasifikacijskih društava mogu imati uvid u interne procese i standarde kojima se formira organizacija i menadžment.

Stoga se kvaliteta menadžmenta eksterno ispituje financijskim pokazateljima poput navedenih pokazatelja likvidnosti, profitabilnosti, aktivnosti i poslovne izvrsnosti.

5. RAČUNALNA INTELIGENCIJA KAO SUVREMENI ALAT U RJEŠAVANJU PROBLEMA MODERNE EKONOMIJE

Računalna inteligencija kao suvremeni alat u rješavanju problema moderne ekonomije, za potrebe ovog rada, promatrana je kroz: **1) Umjetne neuronske mreže, 2) Neizrazitu logiku i 3) Primjenu računalne inteligencije u ekonomiji.**


5.1. Umjetne neuronske mreže

Ideja umjetne neuronske mreže je nastala iz niza pokušaja modeliranja fiziologije ljudskog mozga, s ciljem razumijevanja i objašnjenja kako isti funkcionira. Ta ideja podrazumijeva kreiranje modela sposobnog da prihvata, obrađuje, generira, pohranjuje i prenosi informacije, analogno aktivnostima mozga čovjeka. Formalizaciju aktivnosti umjetnog neurona, temeljenoj na tvrdnjama W. Jamesa, dali su McCulloch i Pitts (1943.), predloživši jednostavan model umjetnog neurona koji je i do danas ostao osnova za razvoj novih neuronskih mreža. Pritom se umjetne neuronske mreže međusobno razlikuju po strukturi veza među neuronima, te po metodologiji određivanja intenziteta tih veza, što predstavlja proces učenja mreže. Danas su opće prisutna dva, u biti različita, pristupa modeliranja umjetnih neuronskih mreža. Prvi pristup ima za cilj realizirati modele koji dovoljno točno oponašaju aktivnosti mozga čovjeka, što bi u perspektivi trebalo rezultirati sustavima "prave" umjetne inteligencije. Drugi pristup podrazumijeva razvoj umjetnih neuronskih mreža s velikim računarskim sposobnostima koje bi trebale rješavati konkretne i vrlo precizno definirane praktične probleme (neuroračunala).

Danas se pretpostavlja da će umjetne neuronske mreže moći oponašati funkcije mozga čovjeka. Da bi se to omogućilo, moraju se razumjeti sve funkcije i organizacija rada mozga, što je jedan od najvećih izazova i ciljeva u svijetu znanosti koji vjerojatno neće biti potpuno ostvaren u skoroj budućnosti. Postojeće neuronske mreže se grade na osnovi iznimno pojednostavljenih modela koji ne uzimaju u obzir većinu poznatih funkcija mozga. Razlog tome treba tražiti u nemogućnosti da se poznate kompleksne funkcije mozga transformiraju u odgovarajući matematički model. U tom smislu, pristup preko koncepta neizrazite logike puno obećava već u skoroj budućnosti. Ponajviše se očekuje od kombiniranja genetičkih algoritama, neizrazitih i ekspertnih sustava sa sustavima

koji se temelje na umjetnim neuronskim mrežama. U tom slučaju, riječ je o sustavima računalne inteligencije.

Umjetna neuronska mreža je u pravilu složeni sustav, sastavljen od elemenata, tj. neurona, koji su u određenoj interakciji, međusobno i s okolinom sustava, te na taj način grade funkcionalnu cjelinu. Paralelno složeni skup neurona gradi sloj neuronske mreže, koje mogu biti jednoslojne ili višeslojne. Uobičajeno je da višeslojne mreže imaju ulazni i izlazni sloj, a između njih su tzv. skriveni slojevi. Ako se slojevi mreže povežu tako da signali putuju samo u jednom smjeru, od ulaza prema izlazu mreže, onda je riječ o tzv. unaprijednim (*feedforward*) neuronskim mrežama. Ukoliko postoji barem jedna povratna veza, u kojoj se pojavljuje suprotni smjer signala, riječ je o rekurentnim neuronskim mrežama. Primjer jedne višeslojne neuronske mreže sa n neurona u ulaznom sloju, m neurona u skrivenom sloju, te jednim neuronom u izlaznom sloju prikazan je na slici 5.



Slika 5. Pojednostavljeni prikaz višeslojne umjetne neuronske mreže

Neke se umjetne neuronske mreže nazivaju prema metodama koje se koriste za njihovo učenje, a mogu se također i podijeliti s obzirom na način njihova učenja. Tako se najčešće razlikuju mreže s učiteljem kod kojih "učitelj" promatra ponašanje mreže korigirajući istu dok se ne dobije željeno ponašanje, te mreže bez učitelja kod kojih se neuronska mreža sama organizira.

Umjetne neuronske mreže se u današnje vrijeme ponajviše koriste za rješavanje problema kao što su primjerice:

- aproksimacija funkcije,
- prepoznavanje uzoraka,
- klasterizacija podataka,
- analiza vremenskih nizova.

Bez obzira na odabranu primjenu, obrada podataka i postupak kreiranja modela temeljenog na umjetnoj neuronskoj mreži se svodi na sljedeće korake:

- odabir odgovarajuće neuronske mreže s obzirom na vrstu problema;
- prikupljanje, priprema i obrada podataka;
- kreiranje mreže;
- konfiguriranje mreže;
- inicijalizacija težinskih koeficijenata i praga (*biasa*);
- treniranje (učenje) mreže;
- validacija i testiranje mreže;
- korištenje mreže.

U ovom su radu, ovisno o namjeni, korištene sljedeće neuronske mreže:

- Aproksimacijske neuronske mreže s učiteljem
 - unaprijedna neuronska mreža s povratnim rasprostiranjem pogreške (FFBPNN);
 - generalizirana regresijska neuronska mreža (GRNN);
- Klasifikacijska neuronska mreža bez učitelja
 - Kohonenova samoorganizirajuća neuronska mreža (SOM).

5.1.1. Unaprijedna neuronska mreža s povratnim rasprostiranjem pogreške

Kako bi se ostvarila struktura neuronske mreže, njezine osnovne elemente, tj. neurone, potrebno je organizirati u slojeve koji se međusobno povezuju vezama koje su opterećene težinskim koeficijentima. Ulazni i izlazni slojevi mreže su u interakciji s okolinom, a sloj koji nema te interakcije naziva se skriveni sloj.

Broj ulaznih i izlaznih neurona je definiran problemom koji se želi riješiti i to na način da će broj ulaznih neurona biti jednak broju nezavisnih varijabli, a broj izlaznih neurona će odgovarati broju zavisnih varijabli. Broj neurona u skrivenom sloju, kao i broj takvih slojeva nije točno određen. Međutim, dokazano je da se svaka kontinuirana funkcija može dobro aproksimirati već s jednim skrivenim slojem neurona, a broj neurona u tom sloju mora biti dovoljno velik. Odgovarajući broj neurona ovisi o složenosti funkcije koju se želi aproksimirati, te ga je potrebno ispitati na zadanom slučaju.

Da bi se učenje neuronske mreže uopće moglo odvijati, svaki neuron koji sudjeluje u procesu učenja ima poseban ulaz jedinične vrijednosti, a on se u strukturi mreže

ostvaruje vezom sa zasebnim neuronom oznake *bias* ili *b* koji je konstantnog izlaza jednakog jedinici.


Za prijenosnu funkciju u skrivenom sloju obično se odabire neka od monotono rastućih funkcija sa zasićenjem. Na slici 6. prikazana je hiperbolična tangenta sigmoidna prijenosna funkcija oblika

$$y = \frac{2}{1 + e^{-x}} - 1 \quad (5.1)$$


koja se najčešće koristi u aproksimacijskim problemima.

Kod neuronske mreže s jednim skrivenim slojem, izlazi iz tog skrivenog sloja predstavljaju ulaze u izlazni sloj. Kod unaprijednih neuronskih mreža najčešće korištena prijenosna funkcija u izlaznom sloju je linearna funkcija (Slika 7.) oblika

$$y = x. \quad (5.2)$$



Slika 6. Hiperbolična tangenta sigmoidna prijenosna funkcija



Slika 7. Linearna prijenosna funkcija

Struktura unaprijedne neuronske mreže koja se koristi za aproksimaciju neke funkcije više varijabli oblika


$$y = f(x_1, x_2, \dots, x_n) \quad (5.3)$$

ima n neurona u ulaznom i jedan neuron u izlaznom sloju. Kako je već ranije spomenuto, broj neurona m u skrivenom sloju može varirati od slučaja do slučaja. Shematski prikaz strukture takve mreže prikazan je na slici 8.

Ukoliko se unaprijednoj neuronskoj mreži na ulaz dovede ulazni vektor $\mathbf{p}_{n \times 1}^1$, izlaz $\mathbf{a}_{m \times 1}^1$ iz skrivenog sloja se određuje prema izrazu

$$\mathbf{a}_{m \times 1}^1 = \text{tansig}(\mathbf{IW}_{m \times n} \cdot \mathbf{p}_{n \times 1}^1 + \mathbf{b}_{m \times 1}^1), \quad (5.4)$$

pri čemu je $\mathbf{IW}_{m \times n}$ matrica težinskih koeficijenata skrivenog sloja, a $\mathbf{b}_{n \times 1}^1$ vektor *biasa* za svaki pojedini skriveni neuron u skrivenom sloju.



Slika 8. Dijagram slojeva unaprijedne neuronske mreže

Kada se izlaz iz skrivenog sloja $\mathbf{a}_{m \times 1}^1$ dovede na ulaz izlaznog sloja, izračunava se konačni izlaz $\mathbf{a}_{1 \times 1}^2 = \mathbf{y}$ iz neuronske mreže prema izrazu

$$\mathbf{y} = \mathbf{a}_{1 \times 1}^2 = \text{purelin}(\mathbf{LW}_{1 \times m} \cdot \mathbf{a}_{m \times 1}^1 + \mathbf{b}_{1 \times 1}^1), \quad (5.5)$$

pri čemu je $\mathbf{LW}_{1 \times m}$ matrica težinskih koeficijenata u izlaznom sloju, a $\mathbf{b}_{1 \times 1}^1$ vektor *biasa* izlaznog neurona.


U unaprijednoj fazi učenja iz skupa za učenje uzimaju se vrijednosti ulaznog vektora, te se pomoću njih izračunavaju komponente izlaznog vektora. Za taj je proračun potrebno postaviti početne vrijednosti težinskih koeficijenata u matricama $\mathbf{IW}$ i $\mathbf{LW}$. Za skriveni se sloj te vrijednosti određuju generatorom slučajnih brojeva. Težine izlaznog sloja se također mogu odrediti na spomenuti način, iako se time ne osigurava brzi početak učenja neuronske mreže.

U povratnoj fazi učenja umjetne neuronske mreže, na temelju izračunatih izlaza mreže (O) i željenih (ciljnih) izlaza (T), izračunavaju se pogreške učenja (E). Na temelju tih pogrešaka korigiraju se vrijednosti težinskih koeficijenata veza između pojedinih slojeva neurona. Čitav postupak se iteracijski ponavlja za svaku $(n + 1)$ -torku od ukupno N ulazno-izlaznih podataka iz skupa za učenje, sve dok se ne postigne pogreška koja je manja ili jednaka od dozvoljene pogreške. U ovom kontekstu, dozvoljena pogreška predstavlja dozvoljeno odstupanje između odziva neuronske mreže i željenog (ciljnog) izlaza. Cijeli ovaj postupak je pojednostavljeno vizualiziran na slici 9.

Uobičajena statistička metoda regresijske analize, suma kvadrata odstupanja

$$E = \frac{1}{2} \sum_{n=1}^N (T_n - O_n)^2, \quad (5.6)$$

kao mjera odstupanja između ciljne vrijednosti izlaza i odziva mreže, najčešće je korištena funkcija cilja tijekom optimizacijskog postupka podešavanja težinskih koeficijenata, tj. tijekom procesa učenja mreže.



Slika 9. Shematski prikaz procesa učenja neuronske mreže

Na temelju odabrane funkcije cilja, vrijednosti težinskih koeficijenata se mijenjaju, tj. prilagođavaju, pomoću nekog od algoritama nelinearnog programiranja. Za potrebe ovog istraživanja bio je korišten isključivo Levenberg-Marquardt algoritam kao jedan od najboljih i najčešće korištenih algoritama učenja neuronskih mreža s povratnim rasprostiranjem pogreške. Detalji vezani uz ovaj algoritam mogu se pronaći u (Hagan i sur., 1996.).

Oblik u kojem su ulazni podaci predstavljeni ulaznim neuronima umjetne neuronske mreže ima vrlo važan utjecaj na uspješnost učenja i na sposobnost generalizacije neuronske mreže. Osim toga, oblik ulaznih podataka utječe na vrijeme potrebno za izračun težinskih koeficijenata do zadane razine točnosti.

Postupak prilagodbe ulaznih i/ili izlaznih podataka za neuronsku mrežu naziva se normiranje podataka i najčešće se svodi na transformaciju vrijednosti svih ulaznih i/ili izlaznih parametara na interval $[-1,1]$ ili $[0,1]$. Ukoliko se za prijenosnu funkciju neurona u izlaznom sloju neuronske mreže odabere neka od monotono rastućih funkcija sa zasićenjem, izlazne je podatke nužno normirati unutar područja vrijednosti koje ta funkcija poprima. Stoga, kako bi se u fazi učenja neuronske mreže mogle ispravno izračunavati razlike između izračunatih izlaza mreže O_n i ciljnih izlaza R_n , nužno je i ciljne izlaze normirati u skup vrijednosti koje poprimaju izračunati izlazi mreže.

Za ocjenu točnosti algoritma učenja, tj. uspješnosti neuronske mreže u rješavanju postavljenog zadatka, najčešće se koriste koeficijent determinacije R^2 i srednje kvadratno odstupanje MSE , tj. pokazatelji uspješnosti analogni (2.30) i (2.31). Dodatno se koristi i koeficijent korelacije R , kojim se ispituje koliko dobro međusobno koreliraju odzivi mreže i ciljne vrijednosti.


5.1.2. Generalizirana regresijska neuronska mreža

Neuronske mreže s radijalnim baznim funkcijama (RB, RBF) spadaju u novije umjetne neuronske mreže i sve se češće primjenjuju, ponajviše u rješavanju problema interpolacije i aproksimacije kontinuiranih viševarijabilnih funkcija, ali i u rješavanju problema klasifikacije. Ovim mrežama je potreban veći broj neurona nego primjerice klasičnim unaprijednim neuronskim mrežama s povratnim rasprostiranjem pogreške, ali vrijeme potrebno da se ova mreža pripremi za simuliranje predstavlja tek manji dio vremena koje je potrebno unaprijednoj mreži samo za treniranje, tj. učenje. Uz iznimno kvalitetne rezultate koje postiže u aproksimaciji viševarijabilnih funkcija, to je još jedna njena vrlo važna prednost pred ostalim mrežama.

Radijalna bazna funkcija (*radbas*) oblika

$$y = e^{-x^2} \quad (5.7)$$

predstavlja prijenosnu funkciju neurona u skrivenom sloju. Grafički prikaz RB funkcije oblika $a = \text{radbas}(n)$ prikazan je na slici 10. Važno je istaknuti da RB funkcija poprima maksimalnu vrijednost 1 kada je ulaz jednak nuli.




Slika 10. Radijalna bazna funkcija

Generalizirana regresijska neuronska mreža (GRNN) je jedna od najčešće korištenih mreža u svrhu aproksimacije funkcija. Također je temeljena na radijalnim baznim funkcijama. Sastoji se od četiri sloja. Ulazni sloj ima n neurona, prvi skriveni radijalni bazni i drugi skriveni posebni linearni sloj imaju po m

neurona, dok je u izlaznom samo jedan neuron. Iznimno kratko vrijeme potrebno za njeno kreiranje čini je posebno pogodnom. Shematski prikaz strukture GRNN mreže prikazan je na slici 11.

Nakon što se mreži prezentira ulazna matrica $\mathbf{P}_{m \times n}$ i ciljna matrica $\mathbf{T}_{m \times 1}$, formiraju se matrica težinskih koeficijenata radijalnog baznog sloja $\mathbf{IW}_{m \times n}$ i matrica ciljeva posebnog linearnog sloja $\mathbf{LW}_{m \times m}$. Na taj se način formira po m neurona u oba skrivena sloja.



Slika 11. Dijagram slojeva generalizirane regresijske neuronske mreže

Prezentira li se GRNN mreži neki uzorak $\mathbf{p}_{n \times 1}$, u radijalnom baznom sloju formira se najprije vektor $\mathbf{n}^1_{m \times 1}$ čije koordinate oblika

$$n_i^1 = \left\| \mathbf{IW}_{1 \times n}^i - \mathbf{p}_{n \times 1} \right\|_{m \times 1} \cdot b_i^1 \quad (5.8)$$

predstavljaju Euklidsku udaljenost prezentiranog uzorka $\mathbf{p}_{n \times 1}$ od svih uzoraka iz skupa za učenje (matrica $\mathbf{IW}_{m \times n}$) pomnoženu faktorom $\mathbf{b}^1_{m \times 1}$. Izraz (5.8) predstavlja operaciju s obzirom na i -ti redak matrice $\mathbf{IW}_{m \times n}$ i vektora $\mathbf{b}^1_{m \times 1}$, pri čemu je $i = 1, \dots, m$, a operator $\cdot$ predstavlja tzv. množenje vektora po načelu element-po-element.

Ako je za neki neuron $b=1$, prijenosna funkcija će dati vrijednost 0,5 za sve uzorke udaljene za 0,833 od težinskog vektora tog neurona. Povećanjem praga b povećava se i udaljenost uzorka od težinskog vektora neurona i obratno. Veća vrijednost b raspršuje uzorke. Raspršenje s je u izravnoj vezi s pragom b , i to prema izrazu $b = 0,833 / s$.

Izlaz iz prvog skrivenog sloja je vektor $\mathbf{a}^1_{m \times 1}$ čije koordinate

$$a_i^1 = \text{radbas}(n_i^1) \quad (5.9)$$

predstavljaju mjeru udaljenosti uzorka $\mathbf{p}_{n \times 1}$ od svakog uzorka iz skupa za učenje, pri čemu vrijedi: ukoliko je neka vrijednost bliža 1, uzorak $\mathbf{p}_{n \times 1}$ bliži je pripadnom težinskom vektoru, tj. uzorku iz skupa za učenje, a ukoliko je bliži nuli onda je udaljeniji.

Koordinate vektora $\mathbf{a}_{m \times 1}^1$ su ulazni podaci drugog skrivenog posebnog linearnog sloja u kojem se određuje aproksimirana vrijednost funkcije y koju mreža pridružuje ulaznom uzorku $\mathbf{p}_{n \times 1}$. Koordinate vektora $\mathbf{n}_{m \times 1}^2$ se određuju pomoću normalizacijske težinske funkcije $nprod$ prema izrazu

$$n_i^2 = \frac{\mathbf{a}_{m \times 1}^1 \cdot \mathbf{LW}_{1 \times m}^i}{\sum_{i=1}^m a_i^1} \quad (5.10)$$

pri čemu je $\mathbf{LW}_{1 \times m}^i$ i -ti redak matrice težinskih koeficijenata $\mathbf{LW}_{m \times m}$ linearnog sloja. Dobiveni vektor $\mathbf{n}_{m \times 1}^2$ prijenosna funkcija linearnog sloja (*purelin*) prenosi u izlazni sloj GRNN mreže prema

$$\mathbf{a}_{m \times 1}^2 = \text{purelin}(\mathbf{n}_{m \times 1}^2) \quad (5.11)$$

čime se u konačnici dobiva vrijednost izlaznog vektora $\mathbf{y}_{m \times 1} = \mathbf{a}_{m \times 1}^2$.

5.1.3. Samoorganizirajuća neuronska mreža

Sve veća primjena neuronskih mreža u rješavanju problema klasifikacije i prepoznavanja uzoraka ukazuje na činjenicu da su se pokazale kao jako dobar alat kod rješavanja raznih vrsta problema kod kojih se ispituje odnos ulaznih i izlaznih varijabli, bez obzira na stupanj složenosti te veze. Vezano za probleme klasifikacije, tj. klasterizacije podataka, razvili su se i alati koji rješavaju probleme grupiranja podataka.

Klasterizacija podataka predstavlja proces njihovog grupiranja u odgovarajuće skupine, takozvane klastere, prema njihovoj sličnosti, tj. prema nekim njihovim svojstvima. Klasterizacija je izrazita ako svaki uzorak pripada jednom i samo jednom klasteru. Drugim riječima, u ovom se slučaju radi o particiji skupa svih uzoraka. Ako pak svaki uzorak pripada nekom klasteru s određenim stupnjem pripadnosti, klasterizacija je neizrazita. Pri mješovitoj klasterizaciji svaki uzorak pripada određenom klasteru prema vjerojatnosti u distribuciji skupa uzoraka.

Samoorganizirajuća Kohonenova neuronska mreža (*Self-Organizing Map*, SOM) je jedna od najčešće korištenih klasifikacijskih neuronskih mreža za rješavanje problema vezanih uz klasterizaciju. Razlog tome nije samo u izvrsnim klasterizacijskim karakteristikama ove mreže već i u činjenici da je razvijeno više izvrsnih vizualizacijskih alata koji omogućuju vrlo jednostavnu i učinkovitu analizu dobivenih klastera.


Uz ulazni i izlazni sloj ova mreža ima i jedan skriveni, takozvani natjecateljski samoorganizirajući sloj u kojem su neuroni razmješteni u odgovarajuću mrežu koja određuje tzv. topologiju SOM-a. Za potrebe ovog rada korištena je pravokutna 2D topologija mreže s tim da je važno istaknuti da unaprijed definirani broj neurona m u skrivenom sloju definira topologiju pravokutne mreže formata $m \times m$. Ovakva topologija omogućuje da skriveni sloj formira vizualizaciju raspodjele i dvodimenzionalne aproksimacije topologije ulaznog skupa vektora. Od posebnog je značaja vizualizacija težinskih koeficijenata u tzv. težinskoj ravnini kojih ima onoliko koliko ima parametara u ulaznoj matrici. Ovakav grafički prikaz vizualizira težine koje povezuju svaki ulazni neuron (ulazni parametar) sa svakim od neurona u skrivenom samoorganizirajućem sloju. Svjetlije nijanse predstavljaju veće, a tamnije nijanse manje težine. Ukoliko su uzorci težina neka dva promatrana parametra vrlo slična, može se pretpostaviti snažna međusobna korelacija tih parametara.

Samoorganizirajuća neuronska mreža jest mreža bez učitelja tj. bez ciljnog vektora. Klasterizacija se provodi na način da se skup ulaznih vektora klasificira u onoliko klasa koliko natjecateljski sloj ima neurona. Pri tome se postupak klasterizacije provodi po kriteriju udaljenosti uzoraka, tj. uzorci čiji su parametri bliži u navedenom smislu udaljenosti, svrstani su u isti klaster. Karakteristike mreže se podešavaju tako da se postigne optimalna klasterizacija, tj. da udaljenosti uzoraka unutar istog klastera budu minimalne, a udaljenosti između klastera maksimalne. Samoorganizirajuća neuronska mreža se najčešće "trenira", tj. (samo)organizira pomoću takozvanog SOM *batch* algoritma (Hagan i sur., 1996.). Pojednostavljeni prikaz arhitekture SOM mreže prikazan je na slici 12.

U skrivenom samoorganizirajućem sloju prvo se formira vektor $\mathbf{n}_{m \times 1}^1$ čije koordinate oblika

$$n_i^1 = -\left\| \mathbf{I} \mathbf{W}_{1 \times n}^i - \mathbf{p}_{n \times 1} \right\| \quad (5.12)$$

predstavljaju negativne ($ndist$) Euklidske udaljenosti između prezentiranog vektora $\mathbf{p}_{n \times 1}$ i vektora $\mathbf{IW}_{1 \times n}^i$ koji predstavlja i -ti redak matrice težinskih koeficijenata $\mathbf{IW}_{m \times n}$.



Slika 12. Dijagram slojeva samoorganizirajuće neuronske mreže (SOM)

Natjecateljska prijenosna funkcija (*compet*) u skrivenom sloju prima na ulaz vektor $\mathbf{n}_{m \times 1}^1$ i na izlazu prema izrazu

$$\mathbf{a}_{m \times 1}^1 = \text{compet}(\mathbf{n}_{m \times 1}^1) \quad (5.13)$$

vraća nulu za sve izlazne neurone osim za "pobjednički" neuron koji je pridružen najvećem (pozitivnom) elementu vektora $\mathbf{n}_{m \times 1}^1$. Izlaz pobjedničkog neurona je jednak jedinici.

Detalji o različitim topologijama SOM mreže, te različitim pristupima za podešavanje težinskih koeficijenata mogu se pronaći u (Hagan i sur., 1996.) i (Kohonen, 1987.).

5.2. Neizrazita logika

Ljudsko razmišljanje, poglavito ono u svrhu znanstvenog istraživanja, iako je obilježeno visokim stupnjem subjektivnosti konstantno teži objektivnosti. U tom procesu traženja objektivnosti znanstvena se misao oblikovala tokom povijesti (Gil-Lafuente, 2005.). Rješavanje ekonomskih problema zahtijeva uz mjerenja i praćenja određenih pojava u određenom vremenu i mišljenje temeljeno na iskustvu različite vrste eksperata. Stoga se u traženju i oblikovanju modela za rješavanje problema ekonomske prirode logična rješenja pronalaze ne samo kombinacijom informacija numeričke i nenumeričke prirode već i modelima prilagođenim ljudskom načinu razmišljanja. Upravo iz takvih razloga nastala je

matematička teorija neizrazitih (*fuzzy*) pod skupova i omogućila uključivanje subjektivnosti i/ili nesigurnosti u traženje objektivnosti.

Posljednjih godina neizrazita logika je našla svoju primjenu u različitim područjima, od tehničkih (klima uređaji, perilice rublja, kamere, mikrovalne pećnice, medicinski instrumenti, i sl.) do operativnih sustava koji podupiru odlučivanje u različitim područjima poslovanja. Dva su različita značenja neizrazite logike. U užem smislu ona je logički sustav koji je proširenje binarne logike, dok u širem smislu ona predstavlja gotovo sinonim teorije neizrazitih skupova. Polazna točka neizrazite logike je preslikavanje ulaznog prostora na izlazni prostor (The MathWorks, 2010a). Odgovori na neka tipična pitanja zašto uopće koristiti neizrazitu logiku, mogu se kroz opća zapažanja izraziti kako slijedi:

- Neizrazita logika je konceptualno lako razumljiva, odnosno matematički koncepti u pozadini neizrazitog zaključivanja su relativno jednostavni. Neizrazita logika je više intuitivni pristup bez ispitivanja dalekosežne složenosti.
- Neizrazita logika je fleksibilna, što znači da se u svakom sustavu korisnik može osloniti na veću funkcionalnost, bez ponovnog započinjanja od nule.
- Neizrazita logika tolerantna je na manje precizne podatke što se nadovezuje uz činjenicu da ništa nije dovoljno precizno, čak i kod pažljive provjere ili mjerenja.
- Neizrazita logika može modelirati nelinearne funkcije proizvoljne složenosti, tj. neizraziti sustav zaključivanja može se kreirati na način da se poveže bilo koji skup ulazno-izlaznih podataka.
- Modeli kreirani uz pomoć neizrazite logike mogu biti izgrađeni na osnovi vrhunskog iskustva eksperata iz nekog područja. Za razliku od neuronskih mreža koje trebaju treniranje pomoću velike količine podataka na temelju kojih generiraju gotovo nerazumljive modele, neizrazita logika dopušta oslonac na ekspertna mišljenja. Time je jedan od najboljih izbora za modeliranje i kvantifikaciju ekspertnog znanja.
- Temeljena je na prirodnom jeziku. Naime, osnova neizrazite logike je osnova međuljudske komunikacije. Lakoća korištenja očituje se upravo u strukturi kvalitativnih opisa korištenih u svakodnevnom govoru (AKO-ONDA pravila).

U svrhu vrednovanja poduzeća, potreba za integracijom finansijskih, stratezijskih, menadžerskih i ostalih aspekata kvantitativne i kvalitativne prirode, koji predstavljaju pokretače i akumulatore vrijednosti poduzeća, navela je istraživače na primjenu neizrazitih pristupa.

Navedeno se očituje kroz: **1) Pojam neizrazitog skupa i neizrazitih relacija i 2) Tip-1 neizraziti sustav zaključivanja.**

5.2.1. Pojam neizrazitog skupa i neizrazitih relacija

Neizraziti skup $A = \{x, \mu_A(x) \mid x \in X\}$ je skup bez jasno i precizno definiranih granica, što znači da može sadržavati i elemente $x \in X$ sa samo djelomičnim stupnjem pripadnosti skupu A . Ova pripadnost opisana je funkcijom pripadnosti (*membership function*, MF) $\mu_A(x)$ koja može poprimati vrijednosti na intervalu $[0,1]$. Drugim riječima, funkcija pripadnosti je krivulja kojom se opisuje način na koji se elementi ulaznog skupa X preslikavaju u određeni stupanj pripadnosti.

Iako je u primjeni veliki broj različitih funkcija pripadnosti, za potrebe ovog rada korištene su dvije vrlo često primjenjivane funkcije pripadnosti (Slika 13.), i to:

- Generalizirana zvonolika funkcija pripadnosti (*gbellmf*) oblika


$$f(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (5.14)$$

ovisna je o koeficijentima a , b i c , pri čemu je obično $b > 0$, a c definira centar krivulje.

- Trokutasta funkcija pripadnosti (*trimf*) oblika

$$f(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (5.15)$$

pri čemu parametri a i c alociraju vrhove trokutaste funkcije na apscisi, a b alocira njezin vrh.



Slika 13. Generalizirana zvonolika (gbellmf) i trokutasta funkcija pripadnosti (trimf)

Neizraziti skupovi predstavljaju osnovu neizrazite teorije. Kod donošenja odluka, najviše se upotrebljavaju za matematički opis procesa s lingvističkim pravilima oblika

$$\text{AKO } (x \text{ je } LVx) \text{ ONDA } (y \text{ je } LVy) \quad (5.16)$$

pri čemu su LVx i LVy vrijednosti lingvističkih varijabli koje su definirane neizrazitim skupovima nad rasponima vrijednosti ulaznih skupova X i Y , respektivno. Raspon vrijednosti nekog ulaznog ili izlaznog parametra definiran je intervalom od njegove najmanje do najveće vrijednosti.

Svaku ulaznu i izlaznu varijablu potrebno je opisati pomoću odgovarajućeg broja lingvističkih varijabli kojima se opisuju svojstva odgovarajuće varijable. Za potrebe ovog rada pretpostavljen je jednak broj lingvističkih varijabli za sve ulazne i izlazne varijable. U tom slučaju, može se reći da lingvističke varijable pripadaju skupu $\{LV_1, LV_2, \dots, LV_m\}$.

Kada se za izradu neizrazitog sustava zaključivanja koristi više ulaznih varijabli, moguće ih je međusobno povezivati različitim neizrazitim operatorima poput I (presjek), ILI (unija), negacije i sl. Ukoliko se pri tome želi AKO-ONDA pravilima međusobno povezati sve moguće kombinacije koje se mogu formirati od n ulaznih varijabli, jedne izlazne varijable i m lingvističkih varijabli onda je uz korištenje isključivo I operatora potrebno realizirati m^n pravila.

U općoj formi, bilo koje AKO-ONDA pravilo neizrazitog sustava zaključivanja s n ulaznih varijabli $(x_1, x_2, \dots, x_n)$, m lingvističkih varijabli i jednom izlaznom varijablom (y), može se zapisati pomoću I operatora na način

$$\text{AKO } (x_1 \text{ je } LV_i) \text{ I } (x_2 \text{ je } LV_j) \text{ I } \dots \text{ I } (x_n \text{ je } LV_k) \text{ ONDA } (y \text{ je } LV_y) \quad (5.17)$$

pri čemu lingvističke varijable LV_i , LV_j i LV_k pripadaju skupu $\{LV_1, LV_2, \dots, LV_m\}$, dok je LV_y lingvistička varijabla koja opisuje neko konkretno stanje izlazne varijable.

Za razliku od klasične Booleove logike, u neizrazitoj teoriji za poopćenje operatora I (presjek) mogu se koristiti brojni različiti postupci kao što su algebarski produkt, algebarska suma, ograničena suma, ograničena razlika, i sl. U ovom modelu, operator I realiziran je postupkom minimuma. Drugim riječima, ukoliko neizrazito pravilo povezuje dva neizrazita skupa A i B pomoću operatora I, stupanj pripadnosti njihovog presjeka C dobiva se prema izrazu

$$\mu_C = \min(\mu_A, \mu_B). \quad (5.18)$$


5.2.2. Tip-1 neizraziti sustav zaključivanja

Neizraziti sustavi zaključivanja (*fuzzy inference system*, FIS) mogu se podijeliti ovisno o karakteru promatrane veličine. Tako razlikujemo Tip-1 i Tip-2 sustave neizrazitog zaključivanja. Kod Tip-1 sustava vrijednost nekog elementa $x \in X$ je izrazita, dok je pripadnost elementa x nekom neizrazitom skupu A neizrazita i opisana je funkcijom pripadnosti $\mu_A(x) \in [0,1]$. Ukoliko bi i vrijednost elementa $x \in X$ bila neizrazitog karaktera, onda bi se govorilo o Tip-2 sustavu neizrazitog zaključivanja. U ovom radu korišten je isključivo Tip-1 Mamdani sustav neizrazitog zaključivanja o kojem se više može pronaći u (The MathWorks, 2010a), (Kahraman, 2008) i (Donlagić i sur., 1994.).

Općenito, razvoj nekog neizrazitog modela predstavlja kreiranje FIS-a. S praktičnog gledišta, cijeli postupak, prikazan i na slici 14., sastoji se od nekoliko koraka:

- odabrati ulazne i izlazne varijable, te definirati njihove nazive i raspone vrijednosti;
- opisati ulazne i izlazne varijable lingvističkim vrijednostima;

- odabrati (vrsta, broj) i modelirati funkcije pripadnosti (MF) za svaku ulaznu i izlaznu varijablu;
- odrediti potrebna neizrazita AKO-ONDA pravila koja povezuju ulazne i izlazne varijable s lingvističkim vrijednostima, primijeniti neizrazite operatore i implikacijske metode;
- provesti izoštravanje (defazifikacija).



Slika 14. Pojednostavljeni prikaz procesa kreiranja neizrazitog sustava zaključivanja uz međusobnu interakciju pojedinih faza procesa

S obzirom da se konačna odluka, tj. izlaz iz neizrazitog sustava zaključivanja, temelji na testiranju svih definiranih AKO-ONDA pravila, ona moraju biti kombinirana i kao takva skupno uzeta u obzir. Ova faza se naziva pridruživanje ili agregacija. Tijekom procesa pridruživanja, neizraziti skupovi koji prezentiraju izlaze svakog pojedinog pravila grupiraju se u jedan skupni neizraziti skup. Postoji više metoda na temelju kojih se može provesti agregacija, a za potrebe ovog rada korištena je metoda maksimuma.

Kako bi se na izlazu iz FIS-a dobile izrazite vrijednosti izlazne varijable, potrebno je izvršiti postupak izoštravanja, tj. defazifikacije. Jedna od najčešće korištenih metoda izoštravanja je tzv. metoda težišta. Ovom metodom se odrede koordinate težišta $T(y_0, \mu_0)$ površine koja se nalazi ispod krivulje agregirane funkcije

pripadnosti $\mu(y)$ u odnosu na raspon izlazne varijable y , pri čemu koordinata y_0 predstavlja traženu izrazitu vrijednost na izlazu.

5.3. Primjena računalne inteligencije u ekonomiji

Iako se posljednjih godina upotreba računalne inteligencije proširila u sva područja ekonomije, pa je tako sve više zastupljena i u rješavanju makroekonomskih problema (modeliranje i suzbijanje inflacije, modeliranje gospodarskog rasta), financije i ulaganja i dalje su jedno od najčešćih područja njene primjene. To se najviše odnosi na predviđanje bankrota, procjenu rizika kod hipotekarnih i drugih zajmova, predviđanja na tržištima dionica, financijske prognoze i sl. (Zekić-Sušac, 1999.). Na temelju brojnih istraživanja svakodnevno se dokazuju prednosti računalne inteligencije u odnosu na klasične metode kojima se dolazi do zaključaka u rješavanju ekonomskih problema. Upotrebom neizrazite logike omogućilo se spajanje različitih, uglavnom teško spojivih ili nespojivih čimbenika/pokazatelja, te se na taj način omogućio razvoj sustava organizacije i menadžmenta kao i ostalih segmenata odlučivanja u ekonomiji (strategijskih i financijskih).

U ekonomskoj teoriji i praksi, primjena računalne inteligencije može se promatrati kroz sljedeće aspekte:

(a) Primjena računalne inteligencije u svrhu predviđanja

Objašnjenje ekonomskih pojava u svrhu predviđanja njihova razvoja osnovni su ciljevi svake ekonomske analize. U tu svrhu utvrđuje se koeficijent osjetljivosti kojim se ispituje kvantitativna međuovisnost između određenih parametara. Jačina veze između određenih parametara i vrijednosti poduzeća ukazuju na njihovu međusobnu osjetljivost izraženu putem veličine promjene jedne varijable uslijed promjene druge varijable. Promatranjem ovih pojava i provođenjem ovakvih analiza za dulje vremensko razdoblje utvrđuje se utjecaj cikličnosti na odnos između dvije ekonomske veličine. Široka je primjena računalne inteligencije u svrhu predviđanja u ekonomiji, a predviđanje je jedno od najčešćih problema koje se ovim alatima u ekonomiji rješava. Pri izboru arhitekture neuronskih mreža kod rješavanja ovakvih problema treba uzeti u obzir vrstu problema, prirodu podataka koji se za model koriste i strategije koje su proizašle iz usporedbe podataka (Zekić-Sušac i Klicek, 2002.). Dokazano je kroz brojne objavljene radove

da su modeli temeljeni na računalnoj inteligenciji bolji u odnosu na klasične regresijske tehnike.

Od područja usko povezanih s utvrđivanjem vrijednosti poduzeća, a u svrhu predviđanja, predlaže se korištenje računalne inteligencije upotrebom neuronskih mreža, neizrazite logike i hibridnih sustava kako slijedi:

- Upotreba neuronskih mreža za:
 - predviđanje kretanja stanja dionica (Zekić-Sušac, 1999.),
 - predviđanje stanja bankrota i financijskih poremećaja (Yang i sur., 1999.; Ko i Lin, 2006.; Zhang i sur., 1999.),
 - financijsko prognoziranje (Kim, 2006.),
 - izvođenje temeljnih tehničkih i financijskih analiza (Lam, 2004.),
 - predviđanje vremenskih nizova (Palit i Popović, 2005.),
- Upotreba neizrazite logike za:
 - predviđanje kretanja stanja dionica (Zarandi i sur., 2009.; Wang, 2003.),
 - procjene vrijednosti poduzeća kao nadopune klasičnim modelima (Yao i sur., 2005.),
 - predviđanje profitabilnosti i solventnosti (Gil-Lafuente, 2005.),
 - predviđanje novčanih tokova na osnovi ekspertnih mišljenja (Gil-Lafuente, 2005.).

(b) Primjena računalne inteligencije u donošenju odluka

Klasična teorija odlučivanja odnosi se na maksimizaciju očekivanih korisnosti na osnovu problema odlučivanja u kojima se svaka posljedica zamjenjuje izgledima za najbolji i najgori ishod. Pri tome donositelj odluke mora prepoznati i rangirati ciljeve odlučivanja kao i sve raspoložive inačice odluke kao i posljedice njenog donošenja. S tim u vezi primjena računalne inteligencije u donošenju odluka namijenjena je smanjenju nesigurnosti u odlučivanju. Obradom podataka dobivenih iz različitih izvora stvaraju se informacije za odlučivanje. Organizacijom, identifikacijom, analizom i transformacijom informacije se pomoću različitih modela računalne inteligencije obrađuju na način da olakšaju donošenje različitih tipova odluka.

Problemi u odlučivanju usko vezani uz utvrđivanje vrijednosti poduzeća, izloženi i analizirani u brojnim radovima, mogu se kategorizirati kao:

- Problemi rješavani upotrebom neuronskih mreža
 - rješavanje računovodstvenih i financijskih problema (Wagner i sur., 2002.),
 - potpora u odlučivanju (Mesarić i sur., 2004.),
 - ocjena, bodovanje i procjena poduzeća (Malagoli i sur., 2005.),
 - ocjena utjecaja menadžerskih odluka na kreiranje vrijednosti poduzeća (Malagoli i sur., 2005.),
 - rješavanje višestrukih kriterija u problemima donošenja odluka (Chen i Lin, 2003.),
 - Problemi rješavani upotrebom neizrazite logike
 - odabir najprikladnijeg sustava uz procjenu ekonomskih, strategijskih i održivih alternativa (Karsak i Tolga, 2001.),
 - planiranje, raspoređivanje i kontrola (Wong i Laib, 2011.),
 - selekcija i ocjena parametara za poboljšanje DCF metode (Tillman Cassone, 2005.),
 - izbor financijskih resursa (Gil-Lafuente, 2005.).
- (c) Primjena računalne inteligencije u kvantifikaciji, identifikaciji i procjeni odabranih ekonomskih pokazatelja

Analiza pokazatelja koji utječu na poslovanje poduzeća i stvaranje njegove vrijednosti zahtijeva kvantifikaciju, identifikaciju i procjenu čimbenika iz okoline i samog poduzeća. Računalna inteligencija u rješavanju ovakvih problema može se promatrati kroz:

- Upotreba neuronskih mreža za:
 - identificiranje čimbenika koji utječu na upravljanje zaradama (Tsai i Chiou, 2009.),
 - ispitivanje financijskih i ekonomskih varijabli koje utječu na povrate dionica (Thawornwong i Enke, 2004.),
 - inteligentno prikupljanje i razvrstavanje podataka korisnih za vrednovanje poduzeća (Seng i Lai, 2010.),
 - procjena podobnosti klijenata (Sarlija i sur., 2006.),
 - analiza rizika i investicijskog menadžmenta (Burrell i Folarin, 1997.),

- Upotreba neizrazite logike za:
 - budžetiranje kapitala (Sevastjanov i sur., 2006.),
 - procjenu budućih novčanih tokova (Sevastjanov i sur., 2006.),
 - identifikaciju troškova kapitala (Gil-Lafuente, 2005.),
 - identifikaciju mogućih strategija u smanjenju zaduženosti u poslovanju (Gil-Lafuente, 2005.),
 - procjenu vrijednosti poduzeća na osnovi čimbenika nesigurnosti (Gil-Lafuente, 2005.).

Kada je pak riječ o primjenama računalne inteligencije u ovom radu, ista je korištena u nekoliko faza procesa vrednovanja poduzeća naftne i plinske industrije kako slijedi:

- Umjetne neuronske mreže korištene su u ovom radu za:
 - ispitivanje utjecaja odabranih financijskih parametara na vrijednost poduzeća (FFBPNN, GRNN);
 - ispitivanje međuovisnosti odabranih financijskih parametara i vrijednosti poduzeća (SOM);
 - ispitivanje mogućnosti da model temeljen na unaprijednim neuronskim mrežama bude alternativa za klasični pristup vrednovanju;
- Neizrazita logika, tj. neizraziti sustavi zaključivanja korišteni su u ovom radu za:
 - kvantifikaciju odabranih kvalitativnih parametara;
 - implementaciju utjecaja pojedinih kvalitativnih parametara na vrijednost poduzeća;
 - za korekciju uporabne i tržišne vrijednosti.

6. IZBOR I KVANTIFICIRANJE PARAMETARA ZA PRIJEDLOG SUVREMENOG PRISTUPA VREDNOVANJU PODUZEĆA NAFTNE I PLINSKE INDUSTRIJE

Suvremeni pristup vrednovanju poduzeća zahtjeva analizu, određivanje i kvantifikaciju značajnih parametara. S obzirom na utvrđene činjenice u teorijskom dijelu rada, kojima se ukazalo na nedostatke svakog pojedinog pristupa vrednovanju, u vrednovanju poduzeća naftne i plinske industrije nametnuta je potreba procjene vrijednosti poduzeća kombinacijom sva tri pristupa, tj. imovinskim, tržišnim i prihodovnim. Potrebno je stoga uvažiti pozitivne strane sva tri pristupa vrednovanja te odrediti pravilnu kombinaciju istih kako bi dobivena vrijednost bila što preciznije određena s ciljem približavanja uporabne i tržišne komponente.

Usporedbom se raznih čimbenika izraženih u kvantitativnom i kvalitativnom obliku, pojedinačnih i u određenim skupinama, određuje u kojoj mjeri i po kojim kriterijima oni utječu na stvaranje i akumulaciju vrijednosti poduzeća.

Izbor i kvantificiranje parametara za prijedlog suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije provodi se kroz: **1) Analizu odgovarajućeg skupa parametara o kojima ovisi vrijednost poduzeća i 2) Izbor i kvantificiranje odabranih parametara za izradu modela.**

6.1. Analiza odgovarajućeg skupa parametara o kojima ovisi vrijednost poduzeća

U okviru provedenog istraživanja, od strane 56 ciljno odabranih stručnjaka iz područja naftno-plinske industrije i područja vrednovanja poduzeća prikupljena su ekspertna mišljenja u svrhu identifikacije parametara za izradu modela vrednovanja poduzeća naftno-plinske industrije suvremenim pristupom.

U istraživanju su bili uključeni eksperti iz cijelog svijeta, a zastupljenost ispitanika po državama navedena je u Tablici 6. Koliko su rezultati ovog istraživanja zaista pouzdani i relevantni s obzirom na profil ispitanika, najbolje ukazuju neki osnovni pokazatelji. Naime, svi ispitanici su vrhunski stručnjaci u svom području, neovisno da li je riječ o naftno-plinskoj industriji ili ostalim važnim sektorima za područje vrednovanja poduzeća.

Tablica 6. Raspodjela ispitanih eksperata po državama

Naziv države	Broj ispitanika
Ujedinjeno Kraljevstvo	11
Hrvatska	7
Ruska Federacija	6
Ujedinjeni Arapski Emirati	5
Indija	4
Singapur	4
Sjedinjene Američke Države	3
Francuska	2
Kazahstan	2
Njemačka	2
Australija	1
Egipat	1
Japan	1
Kostarika	1
Malezija	1
Nizozemska	1
Norveška	1
Oman	1
Slovenija	1
Ukrajina	1

Iz tablice 6. vidljivo je da je najveći broj ispitanika iz Ujedinjenog Kraljevstva u kojem je i inače sjedište brojnih svjetski renomiranih poduzeća kako iz naftno-plinske industrije, tako i iz sektora savjetodavnih financijskih usluga.

Najzastupljeniji akademski stupanj obrazovanja ispitanika je stupanj magistra što se vidi iz tablice 7., a najzastupljenije kategorije prema industrijskoj grani poduzeća ispitanika koji su sudjelovali u ovom istraživanju su naftno-plinska industrija i konzultantske usluge (Tablica 8.).

Tablica 7. Udio ispitanika prema stupnju obrazovanja

Stupanj obrazovanja	Udio (%)
Magistar (MSc)	65,45
Prvostupnik (BSc)	16,36
Profesionalna diploma (MBA, i sl.)	10,91
Doktorat znanosti (PhD)	5,45
Viša škola	1,83

Tablica 8. Udio ispitanika prema industrijskim granama poduzeća u kojima su zaposleni

Industrijska grana poduzeća ispitanika	Udio (%)
Konzultantske usluge	23,89
Investicijsko bankarstvo	19,47
Naftno-plinska industrija, E&P sektor	16,81
Financije/računovodstvo	14,16
Naftno-plinska industrija, OFS sektor	7,97
Naftno-plinska industrija, R&M sektor	4,42
Naftno-plinska industrija, IM sektor	4,42
Naftno-plinska industrija, T&S sektor	3,54
Marketing/prodaja	3,54
Obrazovanje	0,89
Ostalo	0,89

Prema području djelovanja unutar poduzeća u kojima rade, najviši postotak ispitanih stručnjaka je iz područja menadžmenta, procjene vrijednosti poduzeća i savjetovanja (Tablica 9.).

Tablica 9. Udio ispitanika prema poslovnim sektorima

Industrijska grana poduzeća ispitanika	Udio (%)
Menadžment	28,00
Procjena vrijednosti poduzeća	26,00
Savjetovanje	21,00
Računovodstvo/financije	15,00
Projektni menadžment	7,00
Tehnologija/inženjering	1,00
Istraživanje i razvoj	1,00
Predavač	1,00

S obzirom na godine radnog iskustva najveći udio ispitanih stručnjaka ima više od deset godina radnog iskustva što je vidljivo iz tablice 10.

Tablica 10. Udio ispitanika prema duljini radnog iskustva

Godine radnog iskustva	Udio (%)
Preko 10 godina	65,45
6-10 godina	20,00
3-5 godina	10,91
1-2 godine	3,64

Kako suvremeni pristup vrednovanja poduzeća pretpostavlja primjenu ekspertnog znanja i računalne inteligencije, analiza odgovarajućeg skupa parametara o kojima ovisi vrijednost poduzeća provodi se kroz: **1) Analizu na osnovi ekspertnih mišljenja** i **2) Analizu međuovisnosti parametara na osnovi neuronskih mreža**.

6.1.1. Analiza na osnovi ekspertnih mišljenja

Istraživanje na osnovi ekspertnih mišljenja temelj je za ispitivanje međuovisnosti parametara o kojima ovisi vrijednost poduzeća, te za identifikaciju i kvantifikaciju istih u svrhu izrade modela. U prvom redu to se očituje kroz istraživanje utjecaja i otežavanje pojedinog pristupa vrednovanju. Rezultati prikazani u tablici 11. ukazuju na najveći utjecaj prihodovnog pristupa vrednovanju, ali i različitu disperziju pojedinih pristupa po industrijama. Najveći utjecaj imovinski pristup ima u eksploatacijsko-proizvodnom sektoru (*E&P*), a najniži u sektoru potpore naftnim poljima (*OFS*). Prihodovni pristup najveći postotak utjecaja bilježi u *OFS* sektoru, a najniži u *E&P* sektoru. Utjecaj tržišnog pristupa najzastupljeniji je u *OFS* sektoru dok najnižu zastupljenost bilježi u *E&P* sektoru.

Tablica 11. Utjecaj pojedinih pristupa vrednovanju po sektorima industrije

Pristup vrednovanju	Utjecaj po sektorima naftno-plinske industrije				
	<i>IM</i>	<i>E&P</i>	<i>R&M</i>	<i>OFS</i>	<i>T&S</i>
<i>Imovinski</i>	29,00 %	35,76 %	22,70 %	18,21 %	27,64 %
<i>Prihodovni</i>	37,39 %	34,83 %	43,26 %	48,02 %	41,38 %
<i>Tržišni</i>	33,61 %	29,41 %	34,04 %	33,77 %	30,98 %

Na temelju ekspertnih mišljenja otežani su pojedini pristupi vrednovanju te je stvorena vrijednost koja služi kao osnova u ispitivanju međuovisnosti parametara i modela za vrednovanje naftno-plinske industrije suvremenim pristupom.

Osim navedenog, na temelju ekspertnih mišljenja analiziran je i utjecaj nefinancijskih parametara o kojima ovisi vrijednost poduzeća naftne i plinske industrije. Prethodnim istraživanjem utvrđeno je da na stvaranje i generiranje uporabne vrijednosti unutar naftno-plinske industrije u najvećoj mjeri sudjeluju sljedeći parametri:

- održivost poslovanja,
- transparentnost u izvještavanju,
- jasno postavljene ciljeve poslovanja,
- planiranje budućih rizika koji mogu nastati,
- organizacija i menadžment poslovanja,
- upravljanje odnosima s kupcima,
- upravljanje sustavima (lancima) dobavljača,
- distribucijski kanali,
- usklađenost obveza i zaliha,
- kvaliteta i standardi,
- sigurnost,
- tehnologija,
- patenti,
- znanje i iskustvo kadrova,
- istraživanje i razvoj,
- rezerve,
- obnovljivi izvori energije.

U smislu njihovog utjecaja na stvaranje i generiranje uporabne vrijednosti, svaki pojedini parametar je od strane eksperata ocijenjen opisnim ocjenama: nema utjecaja, jako nizak, nizak, srednji, visok i vrlo visok utjecaj. Analiza je pokazala da su svi identificirani parametri značajni za stvaranje uporabne vrijednosti (Tablica 15. u 6.2.2.).

S obzirom na utjecaj pojedinih parametara na stvaranje i generiranje tržišne vrijednosti poduzeća, identificirani su sljedeći parametri:

- potražnja za energijom,
- cijena nafte i plina,
- stjecanje udjela na velikom energetsom tržištu,
- stjecanje udjela u poduzeću koje naftom i plinom snabdijeva potrebe za električnom energijom i proizvodnjom u zemljama u rastućem razvoju,
- stjecanje pristupa nekonvencionalnim rezervama,
- proizvodnja LNG-a,
- proizvodnja biogoriva koja ne zahtijevaju rafiniranje,
- stjecanje pristupa resursima, tehnologiji, vještinama zaposlenika i transfer znanja,

- geopolitičko okruženje (politička stabilnost/nestabilnost),
- poslovanje unutar i van OECD-a (vezano uz potražnju za energijom),
- poslovanje kroz ovisna društva i podružnice unutar Azijsko-pacifičke regije, Bliskog istoka i Sjeverne Amerike,
- potreba za zajedničkim nastupom na tržištu,
- rivalstvo među konkurentima u industrijskom okruženju,
- socijalna odgovornost u društvu (ulaganje u razvoj društva unutar kojeg posluje, školovanje zapošljavanje pripadnika društva unutar kojeg posluje, posebno u zemljama u razvoju),
- dobri ugovorni odnosi sa nacionalnim kompanijama koje upravljaju izvorima nafte i plina,
- poštivanje zakonske regulative,
- poslovanje unutar države koja ima olakšan pristup privatnom vlasništvu zemljišta, uređena financijska tržišta i povoljne fiskalne i regulatorne uvjete,
- smanjenje geografskog disbalansa između rafinerija i konzumenata,
- sigurnost investicije u visoko konkurentnu industriju.

Unutar predloženih čimbenika gotovo svi su identificirani kao značajni, odnosno samo dva su poprimila niske vrijednosti i to proizvodnja biogoriva koja ne zahtijevaju rafiniranje i potreba za zajedničkim nastupom na tržištu (Tablica 16. u 6.2.2.).

6.1.2. Analiza međuovisnosti parametara i njihovog utjecaja na vrijednost poduzeća na osnovi neuronskih mreža

Kako bi se ispitaio utjecaj odabranih financijskih parametara na vrijednost poduzeća, na temelju ekspertnog mišljenja, tj. na temelju rezultata iz tablice 11., definirana je otežana vrijednost poduzeća VP prema sljedećem izrazu

$$VP_i = \alpha_i VP_{i,IM} + \beta_i VP_{i,PR} + \gamma_i VP_{i,TR}, \quad (6.1)$$

pri čemu su α_i , β_i i γ_i postotno izraženi utjecaji po pojedinim sektorima naftno-plinske industrije za imovinski, prihodovni i tržišni pristup, respektivno, s tim da je $i \in \{IM, E \& P, R \& M, OFS, T \& S\}$.

Ukoliko se promatra samo jedan sektor industrije, izraz (6.1) poprima jednostavniji oblik

$$VP = \alpha VP_{IM} + \beta VP_{PR} + \gamma VP_{TR}, \quad (6.2)$$

pri čemu je VP_{IM} vrijednost poduzeća izračunata imovinskim pristupom, VP_{PR} je vrijednost poduzeća dobivena prihodovnim pristupom, dok je VP_{TR} vrijednost poduzeća procijenjena tržišnim pristupom.

Za potrebe ovog rada, vrijednost dobivena imovinskim pristupom temeljena je na kombinaciji imovinskog pristupa po knjigovodstvenoj vrijednosti i metodi kapitalizirane zarade (2.1.2.). Ista se izračunava prema izrazu

$$VP_{IM} = \frac{(\text{imovina} - \text{obveze}) + (\text{normalizirana dobit} / WACC)}{2} \quad (6.3)$$

pri čemu je normalizirana dobit dobivena desetogodišnjim prosjekom neto dobiti.

Vrijednost VP_{PR} dobivena prihodovnim pristupom određena je DCF metodom, dok je vrijednost VP_{TR} po tržišnom pristupu dobivena po tržišnoj vrijednosti emitiranih dionica, budući da su promatrana poduzeća dionička društva. Podaci za vrednovanje većinom su prikupljeni s (Damodaran, 2013.) i (Bloomberg Businessweek, 2013.).

Utjecaj odabranih financijskih parametara na vrijednost poduzeća naftno-plinske industrije ispitan je pomoću umjetnih neuronskih mreža. Promatrani parametri, njih ukupno 35, navedeni su u tablici 12. Ispitan je njihov utjecaj posebno na otežanu vrijednost poduzeća VP , ali i s obzirom na $EBITDA$ multiplikator koji je za potrebe ovog rada definiran prema izrazu

$$multVP = \frac{VP}{EBITDA}. \quad (6.4)$$

Otežana vrijednost poduzeća VP i multiplikator $multVP$ navedeni su u tablici 12. kao 36. i 37. parametar, respektivno.

Rangiranje pojedinih parametara (1.–35.) iz Tablice 12., s obzirom na njihov utjecaj na otežanu vrijednost VP , napravljeno je na temelju rezultata dobivenih pomoću unaprijednih neuronskih mreža (FFBPNN), generalizirane regresijske neuronske mreže (GRNN) i jednostavne linearne regresije (LR). Za ocjenu uspješnosti pojedinih modela korišten je koeficijent determinacije R^2 iz (2.30).

Jednostavna linearna regresija je korištena kako bi se rezultati dobiveni neuronskim mrežama usporedili s nekom klasičnom statističkom metodom, ali i

kako bi se identificirala mjera nelinearnosti u ovisnosti između otežane vrijednosti poduzeća *VP* i odabranih 35 parametara posebno.


Tablica 12. Odabrani financijski parametri za analizu s obzirom na vrijednost poduzeća

R.br.	Naziv parametra	Oznaka
1.	Ukupna imovina	<i>UI</i>
2.	Ukupne obveze	<i>UO</i>
3.	Tekuća imovina	<i>TI</i>
4.	Novac i novčani ekvivalenti	<i>NNE</i>
5.	Tekuće obveze	<i>TO</i>
6.	Knjigovodstvena vrijednost kapitala	<i>KVK</i>
7.	Amortizacija	<i>AM</i>
8.	Radni kapital	<i>RK</i>
9.	Promjene u nenovčanom radnom kapitalu	<i>PNRK</i>
10.	Neto kapitalna ulaganja	<i>NKU</i>
11.	Neto dobit	<i>ND</i>
12.	Ukupni prihodi	<i>UP</i>
13.	<i>EBIT</i>	<i>EBIT</i>
14.	$EBIT \times (1 - t)$	<i>EBIT2</i>
15.	<i>EBITDA</i>	<i>EBITDA</i>
16.	<i>FCFF</i>	<i>FCFF</i>
17.	Investirani kapital	<i>IK</i>
18.	Dividende	<i>DIV</i>
19.	Cijena dionice (31.12.2012.)	<i>CD</i>
20.	Porezna stopa	<i>PS</i>
21.	Koeficijent tekuće likvidnosti	<i>CURR</i>
22.	Koeficijent obrtaja ukupne imovine	<i>KOUI</i>
23.	Koeficijent obrtaja dugotrajne imovine	<i>KODI</i>
24.	Koeficijent obrtaja kratkotrajne imovine	<i>KOKI</i>
25.	Koeficijent obrtaja kapitala	<i>KOK</i>
26.	Povrat na imovinu	<i>ROA</i>
27.	Povrat na kapital	<i>ROE</i>
28.	Neto profitna marža	<i>NPM</i>
29.	$VP_{PR}/EBIT$	<i>multEB</i>
30.	ex_1	<i>ex1</i>
31.	ex_2	<i>ex2</i>
32.	ex_3	<i>ex3</i>
33.	ex_4	<i>ex4</i>
34.	<i>BEX</i>	<i>BEX</i>
35.	Odnos novca i tržišne vrijednosti imovine	<i>NVP</i>
36.	<i>VP</i>	<i>VP</i>
37.	$VP/EBITDA$	<i>multVP</i>

Pri svakom treniranju unaprijednih neuronskih mreža, težinski koeficijenti skrivenog i izlaznog sloja se odabiru slučajno, što znači da svaki put poprimaju neke druge vrijednosti. Upravo je to razlog zašto je odziv dviju unaprijednih neuronskih mreža treniranih na istom skupu za učenje svaki put nešto drugačiji. Kako bi se dobio što pouzdaniji rezultat uspješnosti s obzirom na realne mogućnosti mreža koje se treniraju, uobičajena praksa strojnog učenja nalaže ponavljanje postupka treniranja unaprijedne neuronske mreže 50-60 puta, a rezultate uspješnosti se preporuča temeljiti na prosjecima odabranih pokazatelja.

Iz tog razloga, u primjeni unaprijednih neuronskih mreža, za svaki par ulazno-izlaznih varijabli, treniranje je ponovljeno 50 puta, nakon čega je rangiranje parametara napravljeno posebno prema prosječnom koeficijentu determinacije $\bar{R}^2$ za svih 50 kreiranih modela, a posebno prema najvišem ostvarenom koeficijentu determinacije $R_{\max}^2$ koji odgovara najuspješnijem modelu. Cijeli ovaj postupak je ponovljen u dva slučaja, za 10, odnosno za 20 neurona u skrivenom sloju. Na slici 15. prikazana je struktura mreže s 20 neurona u skrivenom sloju.

Tijekom svih treniranja korištena je hiperbolična tangenta sigmoidna (*tansig*) prijenosna funkcija u skrivenom sloju, te linearna (*purelin*) prijenosna funkcija u izlaznom sloju. Mreže su trenirane pomoću Levenberg-Marquardt algoritma učenja.



Slika 15. Arhitektura unaprijedne neuronske mreže s 20 neurona u skrivenom sloju

Kako je već spomenuto, s obzirom na slučajan odabir pri inicijalizaciji težinskih koeficijenata, odziv svih 3500 istreniranih unaprijednih neuronskih mreža, tj. 50 neuronskih mreža za svaki od 35 ulaznih parametara za 10 i 20 neurona u skrivenom sloju, nešto je drugačiji, pa je samim time prosječni koeficijent determinacije $\bar{R}^2$ zasigurno nešto reprezentativniji od ocjene najuspješnijih modela odabranih prema maksimalnom koeficijentu determinacije $R_{\max}^2$.

Rangiranje pojedinih parametara s obzirom na njihov utjecaj na *VP* i *multVP*, dobiveno primjenom unaprijedne neuronske mreže prema prosječnom i maksimalnom koeficijentu determinacije, posebno za 10 i 20 neurona u skrivenom sloju, prikazano je u tablicama 13. i 14.

Tablica 13. Rangiranje pojedinih parametara s obzirom na njihov utjecaj na vrijednost poduzeća VP

FFBPNN s 10 neurona u skrivenom sloju				FFBPNN s 20 neurona u skrivenom sloju				GRNN		Linearna regresija	
#	$\bar{R}^2$	#	$R_{\max}^2$	#	$\bar{R}^2$	#	$R_{\max}^2$	#	R^2	#	R^2
6	0,9851	15	0,9898	15	0,9879	1	0,9903	1	1,0000	1	0,9393
1	0,9812	6	0,9882	6	0,9877	6	0,9901	2	0,9998	17	0,9199
15	0,9798	1	0,9854	13	0,9839	15	0,9900	6	0,9995	15	0,8870
17	0,9789	17	0,9836	1	0,9830	14	0,9878	12	0,9995	7	0,8862
13	0,9789	14	0,9835	17	0,9824	13	0,9873	3	0,9992	10	0,8803
14	0,9701	13	0,9828	10	0,9795	17	0,9860	15	0,9992	2	0,8689
10	0,9698	10	0,9777	14	0,9773	11	0,9836	13	0,9985	6	0,8674
11	0,9667	11	0,9755	18	0,9755	10	0,9835	10	0,9973	5	0,8304
2	0,9616	18	0,9736	11	0,9734	2	0,9817	14	0,9958	13	0,8292
18	0,9592	2	0,9734	2	0,9661	18	0,9795	17	0,9951	3	0,8058
7	0,9545	7	0,9712	7	0,9655	7	0,9742	11	0,9950	14	0,7930
3	0,9434	3	0,9580	3	0,9506	5	0,9644	5	0,9922	12	0,7887
5	0,9427	5	0,9555	5	0,9481	8	0,9595	7	0,9908	4	0,7865
8	0,9340	8	0,9522	8	0,9466	3	0,9595	18	0,9860	11	0,7859
4	0,9186	12	0,9412	4	0,9281	12	0,9472	8	0,9822	18	0,7747
12	0,9008	4	0,9276	12	0,9253	4	0,9376	4	0,9688	8	0,0711
16	0,8159	16	0,8752	16	0,8473	16	0,8952	16	0,9649	16	0,0551
9	0,7867	9	0,8289	9	0,8087	9	0,8530	9	0,9081	9	0,0208
33	0,3022	33	0,5760	33	0,3291	25	0,6607	19	0,0319	29	0,0185
24	0,2914	22	0,4762	24	0,3072	22	0,6396	29	0,0263	21	0,0107
27	0,2483	25	0,4571	22	0,2997	33	0,6091	25	0,0060	23	0,0089
22	0,2434	24	0,4378	32	0,2718	31	0,4880	23	0,0043	25	0,0077
25	0,2120	31	0,4049	27	0,2525	24	0,4566	31	0,0014	30	0,0056
34	0,1960	34	0,3890	25	0,2474	19	0,3996	24	0,0005	22	0,0053
32	0,1954	27	0,3160	34	0,1740	34	0,3964	21	0,0004	32	0,0025
28	0,1745	21	0,3096	28	0,1692	23	0,3319	34	0,0003	26	0,0019
23	0,1200	19	0,3011	23	0,1625	29	0,3227	22	0,0003	31	0,0010
29	0,1088	28	0,2937	29	0,1623	27	0,3168	33	0,0001	34	0,0006
19	0,0895	29	0,2874	31	0,1477	28	0,3098	28	0,0000	24	0,0006
21	0,0887	23	0,2852	21	0,1313	32	0,3036	30	0,0000	27	0,0005
20	0,0866	32	0,2751	35	0,1252	21	0,2955	32	0,0000	35	0,0004
35	0,0844	35	0,1258	19	0,0933	35	0,1344	27	0,0000	28	0,0003
26	0,0804	26	0,1007	26	0,0929	30	0,1090	26	0,0000	33	0,0002
31	0,0705	20	0,0866	20	0,0866	26	0,1012	35	0,0000	19	0,0002
30	0,0425	30	0,0765	30	0,0739	20	0,0866	20	0,0000	20	0,0000


Tablica 14. Rangiranje pojedinih parametara s obzirom na njihov utjecaj
na multiplikator multVP

FFNN s 10 neurona u skrivenom sloju			FFNN s 20 neurona u skrivenom sloju			GRNN		Linearna regresija			
#	$\bar{R}^2$	#	$R^2_{\max}$	#	$\bar{R}^2$	#	$R^2_{\max}$	#	R^2	#	R^2
29	0,5720	29	0,6500	29	0,6546	29	0,7179	1	0,8645	29	0,1858
24	0,2758	24	0,3986	24	0,3699	24	0,5256	12	0,8581	15	0,0529
22	0,2645	22	0,3425	22	0,2815	22	0,3859	2	0,8344	13	0,0512
23	0,1888	17	0,2739	21	0,2330	17	0,2982	17	0,8186	30	0,0463
15	0,1656	16	0,2681	17	0,2215	21	0,2830	3	0,8017	25	0,0450
25	0,1632	21	0,2378	32	0,2163	16	0,2646	6	0,7443	12	0,0449
16	0,1569	31	0,2211	23	0,1973	32	0,2645	5	0,6098	14	0,0426
21	0,1560	6	0,2187	25	0,1969	25	0,2543	16	0,5826	3	0,0393
9	0,1522	13	0,2140	16	0,1951	31	0,2536	8	0,5081	11	0,0389
32	0,1438	27	0,2135	15	0,1718	6	0,2436	13	0,4612	5	0,0358
8	0,1413	15	0,2017	35	0,1650	23	0,2264	10	0,4439	4	0,0349
20	0,1412	23	0,1998	26	0,1647	5	0,2109	4	0,4284	7	0,0336
26	0,1392	25	0,1992	2	0,1577	27	0,2062	14	0,4273	22	0,0330
12	0,1290	5	0,1840	34	0,1546	18	0,2053	15	0,4205	18	0,0309
27	0,1290	9	0,1839	8	0,1520	15	0,1974	29	0,3778	6	0,0306
13	0,1276	32	0,1806	4	0,1480	13	0,1959	11	0,3592	1	0,0292
5	0,1262	8	0,1768	27	0,1469	8	0,1934	7	0,3106	35	0,0288
17	0,1260	4	0,1701	30	0,1455	2	0,1912	9	0,2808	24	0,0284
4	0,1243	2	0,1667	20	0,1412	4	0,1864	18	0,2537	17	0,0229
33	0,1239	26	0,1586	13	0,1411	34	0,1824	23	0,0516	26	0,0222
30	0,1191	12	0,1569	31	0,1386	33	0,1805	19	0,0381	10	0,0215
35	0,1162	35	0,1521	33	0,1350	26	0,1758	25	0,0236	2	0,0215
14	0,1121	14	0,1480	5	0,1278	35	0,1716	31	0,0137	20	0,0090
34	0,1099	33	0,1423	12	0,1276	9	0,1611	24	0,0046	8	0,0076
7	0,1086	20	0,1412	18	0,1264	30	0,1584	33	0,0039	16	0,0038
31	0,1072	34	0,1405	7	0,1239	14	0,1570	34	0,0037	28	0,0034
10	0,0944	7	0,1375	9	0,1158	12	0,1553	22	0,0016	23	0,0027
3	0,0926	3	0,1369	14	0,1120	3	0,1535	21	0,0000	33	0,0014
19	0,0891	30	0,1351	10	0,1110	1	0,1469	28	0,0000	19	0,0011
2	0,0797	18	0,1348	3	0,1092	10	0,1467	30	0,0000	34	0,0011
18	0,0755	10	0,1216	6	0,1080	20	0,1412	35	0,0000	31	0,0008
6	0,0751	1	0,1210	1	0,1077	7	0,1330	26	0,0000	9	0,0008
11	0,0720	19	0,1115	19	0,0992	11	0,1216	20	0,0000	27	0,0008
1	0,0698	28	0,0990	11	0,0968	19	0,1198	27	0,0000	21	0,0006
28	0,0681	11	0,0743	28	0,0915	28	0,1080	32	0,0000	32	0,0002

U tablicama 13. i 14. također se nalazi i rangiranje napravljeno pomoću generaliziranih regresijskih neuronskih mreža, te linearne regresije. Iz dobivenih rezultata, posebno onih iz tablice 13., jasno je vidljivo koliko su neuronske mreže uspješnije od klasičnog regresijskog pristupa.

U svrhu iste analize izvršena je i klasterizacija parametara pomoću samoorganizirajuće neuronske mreže. Promatrani parametri iz tablice 12. podijeljeni su u dvije skupine. Prvu skupinu čine parametri 1.-19. i 36., tj. klasični financijski pokazatelji iskazani u novčanoj vrijednosti (USD). Drugu skupinu čine parametri 20.-37., tj. financijski omjeri s iznimkom *VP*, definirani u poglavlju 4., koji se često koriste u financijskim analizama. Ove dvije skupine prezentirane su SOM mreži kao ulazne matrice, nakon čega ih je SOM klasterizirao u odgovarajući broj klastera ovisan o broju neurona u skrivenom sloju.


Budući je SOM mreža bez učitelja, pravokutna 2D topologija mreže se samoorganizirala tijekom 200 iteracija. Podešavanje je posebno napravljeno za 10 i 20 neurona u skrivenom sloju. Primjer arhitekture SOM mreže s 20 neurona u skrivenom sloju prikazana je u pojednostavljenom obliku na slici 16.




Slika 16. Arhitektura samoorganizirajuće neuronske mreže s 20 neurona u skrivenom sloju

Nakon treniranja SOM mreže na raspolaganju je cijeli niz grafičkih prikaza dobivenih rezultata. Od posebnog interesa su tzv. vizualizacije težinskih ravnina u kojima su smještene vrijednosti težina koje povezuju ulazni i izlazni sloj. Vrlo slični uzorci težinskih ravnina promatranih parametara od interesa ukazuju na iznimno veliku korelaciju između tih parametara. Na slikama 17. i 18. mogu se vidjeti težinske ravnine za prvu i drugu skupinu parametara. Lako se sa slike 17. može uočiti značajna povezanost između primjerice parametara *VP*, *NKU*, *EBIT*, *EBIT2*, *EBITDA* i sl. Istovremeno, sa slike 18. se lako može zaključiti da nema značajne korelacije između parametra *VP* i bilo kojeg drugog promatranog parametra.

Općenito, na temelju provedenih analiza, može se zaključiti da se parametri 1.-18. iz tablice 12. mogu izravno dovesti u vezu s otežanom vrijednošću poduzeća, dok ostali parametri nisu pokazali visoki stupanj povezanosti. Također je utvrđeno da se osim parametra 29., svi ostali parametri vrlo loše mogu direktno dovesti u odnos s multiplikatorom *multVP*.



Slika 17. Vizualizacija težinskih koeficijenata u težinskoj ravnini SOM-a za parametre 1.-19. i 36. iz tablice 12.



Slika 18. Vizualizacija težinskih koeficijenata u težinskoj ravlini SOM-a za parametre 20.-37. iz tablice 12.

6.2. Izbor odabranih parametara i kvantifikacija njihovog utjecaja na vrijednost poduzeća

Nakon izvršene analize, moguće je pristupiti izboru i kvantifikaciji parametara za izradu modela kroz: **1) Izbor i kvantifikacija financijskih parametara i 2) Izbor i kvantifikacija nefinancijskih parametara.**

6.2.1. Izbor i kvantifikacija financijskih parametara

Analizama provedenim pomoću neuronskih mreža utvrđeni su parametri o kojima vrijednost poduzeća značajno ovisi. Mjera te ovisnosti je u izravnoj vezi s ocjenom uspješnosti pojedinog modela temeljenog na neuronskim mrežama. Upravo je na temelju ocjena tih uspješnosti provedeno rangiranje koje omogućuje jednostavnu identifikaciju najznačajnijih parametara. Tako se s jedne strane može izdvojiti 16 najznačajnijih parametara kako slijedi:

- *EBITDA*,
- knjigovodstvena vrijednost kapitala,
- *EBIT*,
- ukupna imovina,
- investirani kapital,
- neto kapitalna ulaganja,
- $EBIT \times (1 - t)$
- dividende,
- neto dobit,
- ukupne obveze,
- amortizacija,
- tekuća imovina,
- tekuće obveze,
- radni kapital,
- novac i novčani ekvivalenti,
- ukupni prihodi,

dok je s druge strane važno naglasiti da je osim napravljenog rangiranja i izbora parametara, veliki značaj neuronskih mreža i u samoj kvantifikaciji odnosa između pojedinih parametara i otežane vrijednosti poduzeća.

Iako je odabir najznačajnijih parametara napravljen prema rezultatima FFBPNN i GRNN mreža, njihova povezanost s otežanom vrijednošću poduzeća vidljiva je i iz rezultata dobivenih samoorganizirajućim mrežama, tj. sa slike 17.

6.2.2. Izbor i kvantifikacija nefinancijskih parametara

Nefinancijski parametri navedeni u 6.1.1. kvantificirani su prema rezultatima ekspertnih mišljenja za slučaj utjecaja na uporabnu i tržišnu vrijednost. Tijekom ocjenjivanja eksperti su svaki parametar mogli ocijeniti ocjenama prema skali od neprimjenjivog do vrlo visokog. Drugim riječima, raspoložive ocjene su iz skupa $\{0,1,2,3,4,5\}$, pri čemu vrijednost 0 označava da se predloženi parametar uopće ne može povezati s vrijednošću poduzeća, vrijednost 1 označava vrlo niski utjecaj, pa sve do vrijednosti 5 koja označava vrlo visoki utjecaj na vrijednost poduzeća.

Rangiranje parametara koji utječu na uporabnu vrijednost je izloženo u tablici 15., a rangiranje parametara koji utječu na tržišnu vrijednost poduzeća naftne i plinske industrije izloženo je u tablici 16.

Tablica 15. Rangiranje čimbenika koji utječu na stvaranje uporabne vrijednosti

Čimbenici koji utječu na stvaranje uporabne vrijednosti	Ocjena utjecaja		
	μ	σ	V
rezerve	4,57	0,84	0,71
tehnologija	4,26	0,78	0,62
održivost poslovanja	4,12	0,80	0,63
planiranje budućih rizika koji mogu nastati	4,12	0,82	0,67
znanje i iskustvo kadrova	3,91	0,82	0,68
sigurnost	3,86	1,07	1,14
transparentnost u izvještavanju	3,83	1,06	1,13
upravljanje sustavima (lancima) dobavljača	3,72	0,83	0,69
kvaliteta i standardi	3,72	0,85	0,73
jasno postavljeni ciljevi poslovanja	3,71	0,97	0,95
organizacija i menadžment poslovanja	3,69	0,75	0,57
istraživanje i razvoj	3,69	0,96	0,92
patenti	3,55	1,05	1,09
distribucijski kanali	3,50	0,86	0,75
upravljanje odnosima s kupcima	3,31	0,96	0,92
usklađenost obveza i zaliha	3,30	0,96	0,93
obnovljivi izvori energije	3,00	1,18	1,38

Tablica 16. Rangiranje čimbenika koji utječu na stvaranje tržišne vrijednosti

Čimbenici koji utječu na stvaranje tržišne vrijednosti	Ocjena utjecaja		
	μ	σ	V
cijena nafte i plina	4,58	0,66	0,43
potražnja za energijom	4,29	0,74	0,54
geopolitičko okruženje (politička stabilnost/nestabilnost)	4,25	0,84	0,71
poštivanje zakonske regulative	3,96	0,88	0,78
sigurnost investicije u visoko konkurentnu industriju	3,82	0,90	0,82
dobri ugovorni odnosi sa nacionalnim kompanijama	3,74	1,05	1,10
poslovanje unutar države koja ima olakšan pristup privatnom vlasništvu	3,71	0,88	0,77
stjecanje pristupa resursima, tehnologiji, vještinama zaposlenika i transfer znanja	3,67	0,82	0,67
stjecanje udjela na velikom energetsom tržištu	3,55	0,86	0,73
stjecanje pristupa nekonvencionalnim rezervama	3,50	0,88	0,78
poslovanje unutar i van OECD-a	3,42	0,88	0,77
proizvodnja LNG-a	3,30	0,82	0,68
poslovanje kroz ovisna društva i podružnice unutar Azijsko-pac. regije, Bl. istoka i Sj. Amerike	3,28	0,89	0,78
stjecanje udjela u poduzeću	3,19	0,87	0,76
rivalstvo među konkurentima u industrijskom okruženju	3,16	0,88	0,77
smanjenje geografskog disbalansa između rafinerija i konzumenata	3,16	0,96	0,92
socijalna odgovornost u društvu	3,07	0,95	0,90
potreba za zajedničkim nastupom na tržištu	2,94	0,89	0,79
proizvodnja biogoriva koja ne zahtijevaju rafiniranje	2,70	0,99	0,98

Iz skupa svih ocjena svih ispitanika za sve ponuđene parametre isključene su ocjene jednake nuli. Za preostale ocjene izračunate su srednje vrijednosti (μ) za svaki pojedini parametar, i upravo je ova vrijednost korištena pri njihovom rangiranju. Osim srednje vrijednosti, izračunate su i standardna devijacija (σ) i varijanca (V). Srednje vrijednosti ocjena pokazatelja s najmanjom varijancom su

ujedno i indikatori najpouzdanijih ocjena s obzirom na evidentno slaganje među ekspertnim mišljenja. S druge strane, pokazatelji s velikom varijancom među ocjenama parametara ukazuju na značajna razilaženja u ekspertnim mišljenjima.

Prosječna vrijednost svih promatranih čimbenika koji utječu na uporabnu vrijednost je 3,76 pa se sve vrijednosti iznad nje mogu smatrati značajnima. Međutim, prema ocjenama svih parametara ne može se izdvojiti niti jedan od predloženih čimbenika koji nema utjecaj na uporabnu vrijednost poduzeća.

S druge strane, prosječna vrijednost svih promatranih čimbenika koji utječu na tržišnu vrijednost je jednaka 3,54 pa se parametri s prosječnim ocjenama iznad nje mogu smatrati značajnima. Čimbenici "proizvodnja biogoriva koja ne zahtijevaju rafiniranje" i "potreba za zajedničkim nastupom na tržištu" ocijenjeni su niskim ocjenama te se na temelju mišljenja stručnjaka ne mogu smatrati značajnima u generiranju tržišne komponente vrijednosti poduzeća naftno-plinske industrije.

Općenito, s obzirom na raspon varijance, sasvim je jasno da su ocjene čimbenika koji utječu na tržišnu vrijednost dosta mjerodavnije i pouzdanije zbog manjeg razilaženja u mišljenjima eksperata.

7. PRIJEDLOG MODELA ZA VREDNOVANJE PODUZEĆA NA OSNOVI RAČUNALNE INTELIGENCIJE S OBZIROM NA SPECIFIČNOSTI NAFTNE I PLINSKE INDUSTRIJE

Na temelju istraživanja te iznesenih rezultata u teorijskom i analitičkom dijelu rada, stvorene su pretpostavke za prijedlog odgovarajućeg modela za vrednovanje poduzeća naftne i plinske industrije na osnovi računalne inteligencije u okviru suvremenog pristupa vrednovanju.

Konceptualno, takav je model temeljen na kombinaciji klasičnih metoda vrednovanja s implementacijom ekspertnog znanja i odabranih algoritama računalne inteligencije. S obzirom na korištene metode, može ga se sagledati kroz četiri sljedeća pristupa:

- **Klasični pristup** u okviru kojeg se na osnovi poznatih metoda vrednovanja utvrđuje vrijednost poduzeća naftno-plinske industrije, i to:
 - imovinskim pristupom vrijednost poduzeća (VP_{IM}) određuje se kombinacijom knjigovodstvene vrijednosti kapitala i metode kapitaliziranog viška zarade, prema navedenom u 6.1.2.;
 - prihodovnim pristupom vrijednost poduzeća (VP_{PR}) određuje se metodom diskontiranog novčanog toka (DCF), prema navedenom u 6.1.2.;
 - tržišnim pristupom vrijednost poduzeća (VP_{TR}) određuje se izravnim vrednovanjem na temelju produkta cijene dionice i broja emitiranih dionica promatranog poduzeća, prema navedenom u 6.1.2.;
- **Ekspertni pristup** u kojem se:
 - na temelju provedene analize ekspertnih mišljenja, za svaki sektor naftne i plinske industrije, provodi otežavanje pojedinih klasičnih pristupa vrednovanja pomoću težinskih koeficijenata $(\alpha_i, \beta_i, \gamma_i)$, prema navedenom u 6.1.1. i 6.1.2.;
 - određuje otežana srednja vrijednost poduzeća (VP), prema navedenom u 6.1.2.;
 - određuju značajni kvalitativni parametri koji utječu na vrijednost poduzeća, prema navedenom u 6.1.1. i 6.2.2.;

- **Neizraziti pristup** u okviru kojeg se provodi:
 - neizrazita kvantifikacija kvalitativnih parametara odabranih na temelju ekspertnog pristupa (poglavlja 7.2, 7.3, 8.1);
 - definicija multiplikatora $mult\Delta VP_1$ za korekciju uporabne vrijednosti poduzeća naftne i plinske industrije (poglavlja 7.2, 7.3, 8.1);
 - definicija multiplikatora $mult\Delta VP_2$ za korekciju tržišne vrijednosti poduzeća naftne i plinske industrije (poglavlja 7.2, 7.3, 8.1);
 - definicija kumulativnog multiplikatora $mult\Delta VP$ za korekciju otežane vrijednosti s ciljem približavanja uporabne i tržišne vrijednosti poduzeća naftne i plinske industrije (poglavlja 7.2, 7.3, 8.1);
 - definicija korigirane vrijednosti poduzeća (VP_{kor}) temeljena na proširenju otežane vrijednosti korekcijom uporabne i tržišne komponentne (poglavlja 7.2, 8.1);
 - korekcija multiplikatora $multVP$ (6.4) s multiplikatorima $mult\Delta VP_1$ i $mult\Delta VP_2$ (poglavlja 7.2, 7.3, 8.1);
 - određivanje korigirane vrijednosti poduzeća VP_{kor} (poglavlja 7.2, 8.1);
- **Neuro-deterministički pristup** koji služi za:
 - kvantifikaciju ovisnosti i utjecaja odabranih financijskih pokazatelja s obzirom na otežanu vrijednost poduzeća (poglavlje 6.1.2.);
 - izbor značajnih kvantitativnih parametara za potrebe procjene vrijednosti poduzeća suvremenim pristupom (poglavlje 6.1.2. i 6.2.1.);
 - realizaciju alternativnog pristupa procjeni vrijednosti poduzeća (VP , VP_{kor}) koji je temeljen na unaprijednim neuronskim mrežama (poglavlja 7.2, 8.1).

Predloženi koncept modela, ilustriran na slici 19., može se iskazati kroz sljedeće tri faze:

- Inicijalna faza,
- Faza neizrazite korekcije, i
- Neuro-deterministička faza.

Inicijalna faza suvremenog pristupa vrednovanju poduzeća odnosi se na determiniranje i odabir čimbenika koji u okviru određenog industrijskog sektora sudjeluju u stvaranju i akumulaciji vrijednosti. Ova faza se sastoji iz tri dijela:

- odabir svih relevantnih izvora korisnih informacija i poslovnih baza podataka iz kojih se formira odgovarajuća baza znanja,
- pretraživanje i prikupljanje svih relevantnih informacija i podataka unutar promatrane industrije ili pojedinog sektora značajnih za postupak vrednovanja poduzeća naftno-plinske industrije, i
- podjela prikupljenih podataka u dvije osnovne skupine, tj. na kvantitativne i kvalitativne pokazatelje.


Odabir baza podataka potrebno je izvršiti s obzirom na kompleksnost poslovanja promatranog poduzeća unutar neke industrije, a nerijetko postojeće poslovne baze podataka samostalno ne mogu zadovoljiti sve potrebe procjenitelja. Ukaže li se potreba, uz dodatne izvore informacija nužno je koristiti i više poslovnih baza podataka odjednom.

Nakon odabira podataka značajnih za vrednovanje poduzeća unutar pojedinog sektora naftno-plinske industrije, provodi se klasifikacija i analiza odabranih parametara. Analiza se vrši usporedbom s vrijednošću poduzeća koja je određena kombinacijom metoda iz sva tri pristupa vrednovanja. Otežavanje, odnosno određivanje utjecaja pojedinog pristupa vrednovanju temeljeno je na ekspertnom znanju, dok se izbor metode određuje s obzirom na dostupnost podataka za vrednovanje. Tako otežana vrijednost osnova je za izračun multiplikatora *multVP*, koji služi kao osnova za korekciju vrijednosti.

Faza neizrazite korekcije započinje odabirom ulaznih parametara za neizraziti sustav zaključivanja (FIS), te omekšavanjem, tj. fazifikacijom, njihovih utjecaja na vrijednost poduzeća. Najveći izazov u ovoj fazi jest kreiranje neizrazitih pravila koja moraju biti temeljena na:

- determiniranoj međuovisnosti vrijednosti poduzeća i značajnih kvantitativnih i kvalitativnih parametara, te
- ekspertnom znanju poslovnih procjenitelja i teoretičara vrednovanja poduzeća kao i nefinancijskih stručnjaka iz područja poslovanja naftno-plinske industrije.

Na taj način su ispunjene pretpostavke za neizrazitu korekciju uporabne i tržišne vrijednosti.



Slika 19. Koncept modela suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije

Osim odabira funkcija pripadnosti (MF), svakako je bitno istaknuti i važnost odabrane metode izoštravanja, tj. defazifikacije, koja izravno utječe na konačnu "neizrazitu vrijednost poduzeća". Naime, budući da procijenjena vrijednost poduzeća koja se određuje ovakvim suvremenim pristupom, s ciljem objektivnog

vrednovanja, mora težiti približavanju uporabne vrijednosti fer tržišnoj vrijednosti, i odabir metode izoštravanja mora biti napravljen u skladu s tim.

Faza neizrazite korekcije završava izračunom multiplikatora $mult\Delta VP_1$ za korekciju uporabne vrijednosti i multiplikatora $mult\Delta VP_2$ za korekciju tržišne vrijednosti poduzeća. Na temelju ovih vrijednosti određuje se kumulativni multiplikatora $mult\Delta VP$, kao i korigirana vrijednost poduzeća VP_{kor} .

Neuro-deterministička faza se sastoji od:

- kvantifikacije financijskih parametara s obzirom na otežanu vrijednost poduzeća,
- analize međuovisnosti svih odabranih parametara, kao i analize njihovog utjecaja na vrijednost poduzeća,
- selekcije svih relevantnih čimbenika za suvremeni pristup procjeni vrijednosti poduzeća, i
- primjene odabranih neuronskih mreža u alternativnom pristupu procjeni vrijednosti poduzeća.

Analizom međuovisnosti odabranih parametara ne determinira se samo izbor svih značajnih kvantitativnih pokazatelja, već se kvantificira i njihov utjecaj na otežanu vrijednost poduzeća. U ovoj fazi se za potrebe ispitivanja međuovisnosti i klasifikacije parametara koristi samoorganizirajuća neuronska mreža (SOM), a za određivanje utjecaja pojedinih parametara na otežanu vrijednost poduzeća koriste se unaprijedna neuronske mreže s povratnim rasprostiranjem pogreške (FFBPNN) i generalizirana regresijska neuronska mreža (GRNN) temeljena na radijalnim baznim funkcijama.

S obzirom na navedeno, tematika se u nastavku razlaže na: **1) Pripremu podataka, 2) Model suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije i 3) Pretpostavke modela.**

7.1. Priprema podataka

Model suvremenog pristupa zahtijeva detaljnu pripremu podataka kao i nužno definiranje pretpostavki koje se na njega odnose. Priprema parametara i njihova podjela po sektorima industrije kod ekspertno-neizrazitog dijela modela za korekciju otežane vrijednosti VP odnosi se na:

- pripremu ulaznih parametra:
 - izračun vrijednosti poduzeća klasičnim pristupom vrednovanja i to imovinskim (VP_{IM}), prihodovnim (VP_{PR}) i tržišnim (VP_{TR}),
 - priprema težinskih koeficijenata (α, β, γ) analizom ekspertnih mišljenja za svaki pojedini sektor naftno-plinske industrije,
 - odabir kvalitativnih parametra koji utječu na vrijednost poduzeća na temelju istraživanja i ekspertnih mišljenja;
- pripremu izlaznih parametara:
 - izračun korigirane vrijednosti VP_{kor} dobivene neizravnom korekcijom uporabne i tržišne vrijednosti,
- pripremu ostalih važnih parametra modela:
 - izračun vrijednosti $EBITDA$ kao temeljne pretpostavke za izračun multiplikatora,
 - izračun multiplikatora $multVP$, $mult\Delta VP_1$, $mult\Delta VP_2$ i $mult\Delta VP$ prema navedenom u 6.4. i 7.2.


U okviru neuro-determinističke faze, priprema podataka kod alternativnog pristupa određivanju vrijednosti VP i VP_{kor} , temeljenom na umjetnim neuronskim mrežama, odnosi se na odabir i pripremu odabranih kvantitativnih ulaznih parametara za cijelu naftnu i plinsku industriju, i to za:

- Skup ulaznih parametara:
 - Priprema ulazne matrice odabranih kvantitativnih parametara s najvišim stupnjem značaja s obzirom na vrijednost poduzeća, i
- Skup izlaznih parametara:
 - Priprema ciljnih vektora otežane (VP) i korigirane (VP_{kor}) vrijednosti poduzeća.

7.2. Model suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije

Kao što je prethodno istaknuto, približavanjem kategorija uporabne i tržišne vrijednosti trebalo bi približiti subjektivna očekivanja kupca s realnim procjenama

razvojnih mogućnosti poduzeća, što je izvedivo upravo predloženim suvremenim pristupom vrednovanju. Struktura modela za vrednovanje poduzeća naftne i plinske industrije prikazana je na slici 20.



Slika 20. Struktura modela suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije

Vrednovanjem poduzeća kroz sva tri pristupa, te otežavanjem po pojedinim sektorima industrije na temelju ekspertnog pristupa, dobiva se otežana vrijednost poduzeća VP koja predstavlja ulazni parametar modela suvremenog pristupa vrednovanju. Otežana vrijednost poduzeća se dijeli s parametrom $EBITDA$ pripadajućeg poduzeća što rezultira multiplikatorom $multVP$.

Za potrebe ovog rada, uporabna vrijednost poduzeća VP_{UP} definira se kao aritmetička sredina vrijednosti poduzeća dobivenih imovinskim i prihodovnim pristupima opisanima u 6.1.2., pa vrijedi

$$VP_{UP} = \frac{VP_{IM} + VP_{PR}}{2}. \quad (7.1)$$

Na temelju toga, i tržišne vrijednosti poduzeća definirane u 6.1.2., mogu se odrediti multiplikator uporabne vrijednosti $multUP$ kao

$$multUP = \frac{VP_{UP}}{EBITDA}, \quad (7.2)$$

te multiplikator tržišne vrijednosti $multTR$ kao

$$multTR = \frac{VP_{TR}}{EBITDA}. \quad (7.3)$$

Iako bi se moglo očekivati da za multiplikator $multVP$ uvijek vrijedi

$$multTR \leq multVP \leq multUP \quad (7.4)$$

ili

$$multUP \leq multVP \leq multTR \quad (7.5)$$

ovisno o međusobnom odnosu multiplikatora $multUP$ i $multTR$ kojeg pak diktiraju financijski rezultati, odziv tržišta i sl., istraživanja su pokazala da to ne mora biti uvijek tako. U tom slučaju, potrebno je izvršiti korekciju multiplikatora $multVP$ s ciljem približavanja uporabne i tržišne vrijednosti. Međutim, ovo vrijedi čak i slučaju ako su nejednakosti (7.4) ili (7.5) ispunjene.

Korekcija uporabne vrijednosti vrši se pomoću multiplikatora $mult\Delta VP_1$ koji predstavlja izlaznu varijablu prvog sustava neizrazitog zaključivanja (FIS1). Definiranjem ulaznih parametara za FIS1, njihovih raspona vrijednosti, raspona vrijednosti izlazne varijable, lingvističkih varijabli, funkcija pripadnosti kao i ostalih potrebnih značajki neizrazitog sustava zaključivanja, stvaraju se pretpostavke za izračun $mult\Delta VP_1$, tj. za korekciju uporabne komponente vrijednosti.

S druge strane, korekcija tržišne vrijednosti provodi se pomoću multiplikatora $mult\Delta VP_2$ koji pak predstavlja izlaznu varijablu drugog sustava neizrazitog zaključivanja (FIS2). Postavke ovog sustava analogne su onima za FIS1, s razlikom izbora odgovarajućih ulaznih kvantitativnih parametara koji utječu na tržišnu komponentu vrijednosti poduzeća.

Zbrajanjem multiplikatora $multVP$, $mult\Delta VP_1$ i $mult\Delta VP_2$ dobiva se kumulativni multiplikator $mult\Delta VP$ koji je pretpostavka za približavanje uporabne i tržišne vrijednosti. Pri tome dakle vrijedi

$$mult\Delta VP = multVP + mult\Delta VP_1 + mult\Delta VP_2. \quad (7.6)$$

Upravo zbog njegove svrhe približavanja uporabne i tržišne vrijednosti, nastaje potreba za uvođenjem ograničenja, kako multiplikatora $mult\Delta VP_1$ i $mult\Delta VP_2$, tako i multiplikatora $mult\Delta VP$, a sve u svrhu da u konačnici budu ispunjene nejednakosti

$$multTR \leq mult\Delta VP \leq multUP \quad (7.7)$$

ili

$$multUP \leq mult\Delta VP \leq multTR. \quad (7.8)$$

Na izlazu iz dijela modela koji je temeljen na kombinaciji ekspertnog znanja i neizrazitog pristupa, u potpunosti prilagođeni multiplikator $mult\Delta VP$ transformira se u korigiranu vrijednost poduzeća VP_{kor} prema izrazu

$$VP_{kor} = mult\Delta VP \times EBITDA. \quad (7.9)$$

Tako dobivena vrijednost ciljni je vektor zajedno s otežanom vrijednošću poduzeća VP za učenje aproksimacijskih umjetnih neuronskih mreža. Za potrebe ovog rada, u ovom je dijelu modela korištena unaprijedna neuronska mreža opisana u 5.1.1. Ulazna matrica za učenje temelji se na odabranim kvantitativnim parametrima za koje se analizama zaključilo da o njima značajno ovisi vrijednost poduzeća. Sasvim je dovoljno izabrati do 10 parametara.

Na taj način, kreirane neuronske mreže mogu služiti za brzu procjenu vrijednosti poduzeća naftno-plinske industrije, neovisno da li su usmjerene prema otežanoj ili korigiranoj vrijednosti poduzeća. Ukoliko se tako kreirane mreže ažuriraju kroz određeni vremenski period sasvim je sigurno da će i njihova točnost i pouzdanost u procjeni vrijednosti poduzeća s vremenom dodatno rasti.

7.3. Pretpostavke modela

Pretpostavke modela koje moraju biti zadovoljene u svrhu determiniranja vrijednosti u okviru približavanja uporabne i tržišne vrijednosti u uskoj su vezi s ograničenjima definiranim kroz nejednakosti (7.4), odnosno (7.5). Dakle, s obzirom na međusobni odnos multiplikatora $multTR$ i $multUP$, razlikuju se sljedeća tri slučaja:

- I. $multTR < multUP$,
- II. $multUP < multTR$,
- III. $multTR = multUP$.

Sasvim je jasno da u slučaju III. nisu potrebne nikakve daljnje korekcije ni intervencije. No, također je jasno da je mogućnost pojave takvog slučaja u praktičnim primjenama zanemarivo malena. S druge strane, slučajevi I. i II. su podjednako mogući, iako istraživanja ukazuju da je slučaj I. nešto češći. Bez obzira na to, oba slučaja zahtijevaju podjednaku i vrlo sličnu intervenciju, pa je nastavku zbog jednostavnosti detaljno analiziran samo slučaj I.

Za potrebe definiranja odgovarajućih ograničenja izračunatih multiplikatora u dijelu modela temeljenom na neizrazitom pristupu, pretpostavlja se da je nejednakost (7.4) ispunjena.

Pomoću dvije klizne varijable $\delta_1 > 0$ i $\delta_2 > 0$, dvojna nejednakost (7.4) može se transformirati u dvije jednakosti kako slijedi

$$\left. \begin{aligned} multTR &= multVP - \delta_1 \\ multVP + \delta_2 &= multUP \end{aligned} \right\} \quad (7.10)$$

Multiplikator $multVP$ će biti jednako udaljen od multiplikatora $multTR$ i $multUP$ kada su klizne varijable međusobno jednake, tj. kada vrijedi $\delta_1 = \delta_2 = \delta$. U tom slučaju, lako se iz (7.10) dobiva vrijednost klizne varijable δ

$$\delta = \frac{multUP - multTR}{2} \quad (7.11)$$

koja predstavlja mjeru za raspon izlaznih varijabli $mult\Delta VP_1$ i $mult\Delta VP_2$. Drugim riječima, raspon izlaznih varijabli za svaki pojedini sektor definiran je prema intervalu $[-\bar{\delta}, +\bar{\delta}]$, pri čemu je $\bar{\delta} > 0$ izračunat prema izrazu (7.11), ali preko prosječnih vrijednosti multiplikatora $\overline{multTR}$ i $\overline{multUP}$, za svaki pojedini sektor industrije, dobivenih na temelju podataka iz Tablice 18. (Poglavlje 8.1) i Priloga 3. Navedeno se može zapisati kao

$$\bar{\delta} = \frac{\overline{multUP} - \overline{multTR}}{2}. \quad (7.12)$$

Ukoliko s druge strane vrijedi nejednakost (7.5), tj. za slučaj II, raspon se definira prema izrazu

$$\bar{\delta} = \frac{\overline{multTR} - \overline{multUP}}{2}. \quad (7.13)$$

Rasponima u (7.12) i (7.13) nisu pridruženi različiti nazivi/oznake, jer je ionako istovremeno moguć samo jedan od ta dva scenarija.

Kako je već spomenuto ranije, izlazne varijable $mult\Delta VP_1$ i $mult\Delta VP_2$ imaju funkciju korekcije uporabne i tržišne komponente vrijednosti, no pri tome, iako vrlo rijetko, pod određenim uvjetima, tj. odgovarajućim vrijednostima ulaznih varijabli, mogu poprimiti takve vrijednosti kojima se narušava pretpostavka (7.7), odnosno (7.8).

Kako bi se to izbjeglo, uvodi se kaskadno zasićenje, tj. prvo se kontrolira suma izlaznih varijabli iz FIS1 i FIS2, a nakon toga i kumulativni multiplikator $mult\Delta VP$.

U prvoj fazi, tj. na izlazima iz FIS1 i FIS2 (Slika 20.), provodi se zasićenje multiplikatora $mult\Delta VP_1$ i $mult\Delta VP_2$, pri čemu vrijedi

$$|mult\Delta VP_1 + mult\Delta VP_2| \leq \bar{\delta} = \frac{\overline{multUP} - \overline{multTR}}{2}. \quad (7.14)$$

Svakako je važno naglasiti da se vrijednosti $mult\Delta VP_1$ i $mult\Delta VP_2$ odnose na trenutno promatrano poduzeće, a prosječne vrijednosti $\overline{multUP}$ i $\overline{multTR}$ na cijeli promatrani sektor naftno-plinske industrije. S obzirom na apsolutnu vrijednost u (7.14), razlikuju se za slučaj I., ovisno o dobivenim izlaznim vrijednostima iz FIS1 i FIS2, sljedeći podslučajevi zasićenja:

I.1 $|mult\Delta VP_1 + mult\Delta VP_2| \leq \bar{\delta}$

Napomena: Nije potrebno zasićenje!

I.2. $|mult\Delta VP_1 + mult\Delta VP_2| > \bar{\delta}$

Potrebno je zasićenje, razlikuju se slučajevi:

I.2.1 $mult\Delta VP_1 + mult\Delta VP_2 > \bar{\delta}$

I.2.1.1 $mult\Delta VP_1 \leq \bar{\delta} / 2$ i $mult\Delta VP_2 > \bar{\delta} / 2$

Zasićenje: $mult\Delta VP_2 \rightarrow \bar{\delta} - mult\Delta VP_1$

I.2.1.2 $mult\Delta VP_1 > \bar{\delta} / 2$ i $mult\Delta VP_2 \leq \bar{\delta} / 2$

Zasićenje: $mult\Delta VP_1 \rightarrow \bar{\delta} - mult\Delta VP_2$

I.2.1.3 $mult\Delta VP_1 > \bar{\delta} / 2$ i $mult\Delta VP_2 > \bar{\delta} / 2$

Zasićenje: $mult\Delta VP_1 \rightarrow \bar{\delta} / 2$ i $mult\Delta VP_2 \rightarrow \bar{\delta} / 2$

I.2.2 $mult\Delta VP_1 + mult\Delta VP_2 < -\bar{\delta}$

Zasićenja se provode slično kao i u I.2.1.1, I.2.1.2. i I.2.1.3.

U drugoj fazi, tj. na izlazu iz sumatora (Slika 20.), provodi se zasićenje multiplikatora $mult\Delta VP$ prema pretpostavci

$$multTR \leq multVP + mult\Delta VP_1 + mult\Delta VP_2 \leq multUP. \quad (7.15)$$

Potpuna analogija na postupak zasićenja u slučaju I. vrijedi i za zasićenje u slučaju II., pa je ovdje ispušteno detaljno pojašnjenje zasićenja pojedinih multiplikatora u tom slučaju.

8. PRIMJENA I OGRANIČENJA PREDLOŽENOG MODELA

Izloženi model pogodan je za vrednovanje svih pravnih oblika poduzeća naftne i plinske industrije, ali ako poduzeće nije dioničko društvo čijim se dionicama javno trguje, potrebno je izvršiti procjenu tržišnim pristupom na neki od načina izloženih u teorijskom dijelu rada. Model je također pogodan za vrednovanje poduzeća iz svih sektora industrije uz odgovarajuće analize pokretača vrijednosti i ekspertnih mišljenja za otežavanje pojedinog pristupa vrednovanju. Osim za znanstvene analize, struktura modela je prilagođena i za stvaranje gotovih praktičnih programskih rješenja za vrednovanje poduzeća, bilo kao samostalnih aplikacija ili kao potpora postojećim programskim rješenjima.

Testiranje modela prezentiranog u prethodnom poglavlju izvršeno je kroz:

- 1) Ispitivanje predloženog modela i interpretaciju dobivenih rezultata i**
- 2) Komparativnu analizu predloženog modela i postojećih standardnih pristupa za vrednovanje poduzeća naftne i plinske industrije, te su na kraju postavljena i**
- 3) Ograničenja predloženog modela i preporuke za budući rad.**


8.1. Ispitivanje predloženog modela i interpretacija dobivenih rezultata

Ispitivanje predloženog modela izvršeno je na 170 odabranih poduzeća naftno-plinske industrije po sektorima kako slijedi:

- 26 poduzeća integriranog naftno-plinskog sektora (*IM*),
- 38 poduzeća eksploatacijsko-proizvodnog sektora (*E&P*),
- 36 poduzeća iz sektora rafiniranja i marketinga (*R&M*),
- 37 poduzeća iz sektora potpore na naftnim poljima (*OFS*),
- 33 poduzeća iz sektora transporta i skladištenja nafte i plina (*T&S*).

Podaci za vrednovanje prikupljeni su iz (Damodaran, 2013.) i (Bloomberg Businessweek, 2013.), a odnose se na 2012. godinu.

Detaljan shematski prikaz simulacije modela vrednovanja poduzeća suvremenim pristupom prikazan je na slici 21. Svi prethodni izračuni potrebni za simulaciju modela, kao i testiranje samog modela na odabranim poduzećima naftne i plinske industrije provedeni su pomoću programskog sustava MATLAB (The MathWorks, 2010b).



Slika 21. Detaljan prikaz simulacijskog modela za vrednovanje poduzeća naftne i plinske industrije suvremenim pristupom

U klasično-ekspertnom dijelu modela za korekciju VP definirani su ulazni parametri ($A = VP_{IM}$, $B = VP_{PR}$, $C = VP_{TR}$), te je na temelju težinskih koeficijenata (α, β, γ) iz Tablice 11. (Poglavlje 6.1.1.) izračunata otežana vrijednost VP s obzirom na odabrani sektor naftno-plinske industrije. U tablici 17. prikazani su rezultati izračunatih vrijednosti za integrirana poduzeća (IM), dok se rezultati za ostale sektore nalaze u Prilogu 2.

Tablica 17. Vrijednosti poduzeća za sektor IM temeljene na klasičnom i ekspertnom pristupu

R.br.	Naziv poduzeća	Država	Vrijednost poduzeća (mil. USD)			
			VP_{IM}	VP_{PR}	VP_{TR}	VP
1.	Royal Dutch Shell	Nizozemska	238379,99	276051,01	227382,00	248768,76
2.	BP plc	UK	134298,65	187335,99	150693,50	159639,62
3.	Total SA	Francuska	136014,19	168108,72	139103,90	149052,79
4.	Eni SpA	Italija	91473,37	117298,91	87523,70	99802,06
5.	Statoil ASA	Norveška	75112,02	106410,07	76828,10	87391,14
6.	OMV	Austrija	19312,75	18547,86	15675,50	17804,28
7.	BG Group plc	UK	44143,74	93403,23	73275,80	72353,15
8.	Gas Plus S.p.A.	Italija	240,91	420,00	285,90	322,99
9.	Repsol, S.A.	Španjolska	36266,56	54415,59	31226,00	41358,35
10.	Polskie G. Naftowe	Poljska	8296,47	12755,52	10119,20	10576,33
11.	Suncor Energy Inc.	Kanada	55108,73	68648,08	52190,30	59190,21
12.	Imperial Oil Ltd.	Kanada	50051,11	43964,46	37530,70	43567,20
13.	Husky Energy Inc.	Kanada	40716,61	35617,46	31194,60	35609,69
14.	Cenovus Energy Inc.	Kanada	20849,74	28488,37	21628,50	23967,56
15.	Origin Energy Ltd.	Australija	12596,88	20529,47	13857,10	15986,44
16.	PetroChina Co. Ltd.	Kina	309695,52	306607,26	229343,10	281534,37
17.	Gazprom	Rusija	345571,73	124524,20	96908,30	179346,28
18.	LUKOIL	Rusija	109327,65	53300,59	46867,70	67386,34
19.	PTT Public Co.	Tajland	32455,25	35204,44	24856,70	30929,30
20.	Surgutneftgas	Rusija	67692,71	30247,91	30786,90	41288,06
21.	Sasol Ltd.	JAR	25897,57	32202,96	31545,20	30153,32
22.	YPF S.A.	Argentina	6453,78	21405,61	17719,90	15830,81
23.	Petrobras Argentina	Argentina	1444,98	1892,30	1609,20	1667,43
24.	Dana Gas PJSC	UAE	3208,36	2264,70	1635,70	2326,96
25.	Yakutsk Fuel Co.	Rusija	312,20	370,20	289,40	326,22
26.	Ecopetrol SA	Kolumbija	44684,39	84350,30	78956,40	71034,30

Dobivene otežane vrijednosti *VP* svakog pojedinog poduzeća podijeljene su s pripadajućim *EBITDA* čime se dobivaju multiplikatori *multTR* i *multVP*. Multiplikator *multUP* je izračunat na temelju izraza (7.2). Rezultati izračunatih navedenih multiplikatora za integrirana poduzeća (*IM*) prikazani su u tablici 18., dok su za ostale sektore industrije navedeni u Prilogu 3. Vrijednost *EBITDA* je izražena u mil. USD.

Tablica 18. Vrijednosti multiplikatora *multTR*, *multVP* i *multUP* za sektor *IM*

R.br.	Naziv poduzeća	Država	<i>EBITDA</i>	<i>multTR</i>	<i>multVP</i>	<i>multUP</i>
1.	Royal Dutch Shell	Nizozemska	52114	4,36	4,77	4,94
2.	BP plc	UK	28354	5,31	5,63	5,67
3.	Total SA	Francuska	44678	3,11	3,34	3,40
4.	Eni SpA	Italija	36652,4	2,39	2,72	2,85
5.	Statoil ASA	Norveška	44814,5	1,71	1,95	2,03
6.	OMV	Austrija	6955,9	2,25	2,56	2,72
7.	BG Group plc	UK	11045	6,63	6,55	6,23
8.	Gas Plus S.p.A.	Italija	89,4	3,20	3,61	3,70
9.	Repsol, S.A.	Španjolska	8475,2	3,68	4,88	5,35
10.	Polskie G. Naftowe	Poljska	1596,3	6,34	6,63	6,59
11.	Suncor Energy Inc.	Kanada	11338,9	4,60	5,22	5,46
12.	Imperial Oil Ltd.	Kanada	5636,3	6,66	7,73	8,34
13.	Husky Energy Inc.	Kanada	5631,3	5,54	6,32	6,78
14.	Cenovus Energy Inc.	Kanada	4156,5	5,20	5,77	5,94
15.	Origin Energy Ltd.	Australija	1629,5	8,50	9,81	10,16
16.	PetroChina Co. Ltd.	Kina	54291,6	4,22	5,19	5,68
17.	Gazprom	Rusija	51955,6	1,87	3,45	4,52
18.	LUKOIL	Rusija	18872	2,48	3,57	4,31
19.	PTT Public Co.	Tajland	7578,1	3,28	4,08	4,46
20.	Surgutneftegas	Rusija	9155,9	3,36	4,51	5,35
21.	Sasol Ltd.	JAR	5804,5	5,43	5,19	5,00
22.	YPF S.A.	Argentina	3291,4	5,38	4,81	4,23
23.	Petrobras Argentina	Argentina	618,7	2,60	2,70	2,70
24.	Dana Gas PJSC	UAE	401	4,08	5,80	6,82
25.	Yakutsk Fuel Co.	Rusija	43	6,73	7,59	7,93
26.	Ecopetrol SA	Kolumbija	15870	4,98	4,48	4,07

Nakon klasično-ekspertnog dijela kreiran je ekspertno-neizraziti dio modela za korekciju VP .

Za potrebe neizrazitog dijela modela u kojem su kreirana dva neizrazita sustava zaključivanja, korištena su po tri ulazna parametra za korekciju uporabne i tržišne vrijednosti poduzeća. Tako je neizraziti sustav zaključivanja FIS1 korišten za određivanje multiplikatora $mult\Delta VP_1$ koji služi za korekciju uporabne komponente, a sustav FIS2 za određivanje multiplikatora $mult\Delta VP_2$ kojim se korigira tržišna komponenta vrijednosti.

Kvalitativni parametri koji utječu na uporabnu i tržišnu vrijednost poduzeća odabrani su prema mišljenju eksperata iz Tablice 15. (Poglavlje 6.2.2.) i Tablice 16. (Poglavlje 6.2.2.), respektivno.

Za neizraziti sustav zaključivanja FIS1, u svrhu korekcije uporabne vrijednosti, ulazni parametri su:

- Održivost poslovanja (poslovna održivost, PO), koja je iskazana pomoću pokazatelja poslovne izvrsnosti (BEX) definiranog u 4.1.5.;
- Organizacija i menadžment poslovanja (poslovna organizacija i menadžment, $POiM$), koja je ocijenjena preko pokazatelja stvaranja vrijednosti (ex_2) definiranog u 4.1.4.;
- Tehnologija (učinkovito korištenje tehnologije, UKT), koje je ocijenjeno preko koeficijenta obrtaja dugotrajne imovine ($KODI$) definiranog u 4.1.3.

Parametri PO , $POiM$ i UKT odabrani su s obzirom da je varijanca njihovih prosječnih ocjena od strane eksperata najmanja, što ukazuje da su ove ocjene ujedno i najpouzdanije s obzirom na usklađenost mišljenja ispitanika. Izlazni parametar iz FIS1 je multiplikator za korekciju uporabne vrijednosti ($mult\Delta VP_1$).

Za neizraziti sustav zaključivanja FIS2, u svrhu korekcije tržišne vrijednosti, ulazni parametri su:

- Cijena nafte (CN);

S obzirom da je iz praktičnih razloga nemoguće istovremeno promatrati i cijenu nafte i cijenu plina, za potrebe ovog testiranja u obzir je uzeta samo cijena nafte. Iako je model testiran za 2012. godinu, raspon za CN je prilagođen na nešto duži vremenski period kako bi se ovom parametru lakše i objektivnije pridružile vrijednosti lingvističkih varijabli.

- Geopolitičko okruženje (*GPO*),

Parametar *GPO* izražen je kao pokazatelj geopolitičke sigurnosti preko stope rizika države u kojoj se poduzeće nalazi (*country risk premium, CRP*). Vrijednosti za *CRP* obično su u rasponu $[0, 0,15]$, pri čemu 0 predstavlja stopu bez rizika, a 0,15 predstavlja stopu najvećeg rizika. S obzirom da se raspon ulaznih varijabli u pravilu navodi od manje ka višoj vrijednosti lingvističke varijable, *GPO* je za potrebe testiranja ovog modela transformiran u $(1 - CRP)$. Time raspon za *GPO* postaje $[0,85, 1]$, pri čemu $0,85 = 1 - 0,15$ predstavlja stopu najvećeg rizika, tj. vrlo nisku geopolitičku sigurnost, a $1 = 1 - 0$ predstavlja vrlo visoku sigurnost s minimalnim rizikom.

- Sigurnost ulaganja, tj. investicije, u visoko kompetitivnu industriju (*SU*),

Izražena je preko povrata na investirano (*return on investment, ROI*) dobivenog kao omjer neto dobiti i tržišne vrijednosti poduzeća, jer se u ovom slučaju poduzeće u cjelini smatra investicijom;

Iako u tablici 16. (Poglavlje 6.2.2.) postoje i bolje ocijenjeni pokazatelji s manjom varijancom, za potrebe ovog ispitivanja odabrani su uz *CN* parametri *GPO* i *SU*, koji su također visoko ocijenjeni, a istovremeno su i raspoloživi. Razlog zašto se u obzir nije uzela primjerice "potražnja za energijom" leži u činjenici da je i ovaj parametar konstantnog karaktera kao i "cijena nafte", pa bi FIS2 bio kreiran s dva konstantna parametra za sva poduzeća čime bi se značajno izgubilo na reprezentativnosti multiplikatora $mult\Delta VP_2$ koji je ujedno i izlazni parametar iz FIS2 za korekciju tržišne vrijednosti.

U Tablici 19. nalaze se vrijednosti ulaznih parametara za FIS1 (*PO*, *POiM* i *UKT*) i FIS2 (*CN*, *GPO* i *SU*) za integrirani sektor (*IM*). Vrijednosti istih parametara za ostale sektore industrije nalaze se u Prilogu 4.

Prema vrijednostima u Tablici 19. i u Prilogu 4., određeni su rasponi ulaznih varijabli *PO*, *POiM* i *UKT* (Tablica 20.), tj. varijabli *CN*, *GPO* i *SU* (Tablica 21.), za svaki analizirani sektor industrije.

Svaka ulazna i izlazna varijabla opisana je pomoću pet vrijednosti lingvističkih varijabli. Tako su sve ulazne varijable lingvistički opisane vrijednostima iz skupa

{vrlo niska (VN), niska (N), srednja (S), visoka (V), vrlo visoka (VV)},

a sve izlazne varijable vrijednostima iz skupa

{negativni veliki (NV), negativni mali (NM), srednji (S), pozitivni mali (PM), pozitivni veliki (PV)}.

Lingvističke vrijednosti {(VN), (N), (S), (V), (VV)}, tj. {(NV), (NM), (S), (PM), (PV)} odgovaraju numeričkim ekvivalentima {1, 2, 3, 4, 5}, respektivno.

Tablica 19. Vrijednosti ulaznih parametara za FIS1 i FIS2 za sektor IM

R.br.	Naziv poduzeća	FIS1			FIS2		
		PO	POiM	UKT	CN	GPO	SU
1.	Royal Dutch Shell	0,49	0,63	0,21	94,05	0,00	0,02
2.	BP plc	1,21	1,59	0,36	94,05	0,01	0,04
3.	Total SA	1,29	1,64	0,48	94,05	0,01	0,05
4.	Eni SpA	1,36	1,72	0,54	94,05	0,03	0,05
5.	Statoil ASA	1,36	1,75	0,60	94,05	0,00	0,06
6.	OMV	1,53	1,91	0,62	94,05	0,00	0,07
7.	BG Group plc	1,53	2,01	0,68	94,05	0,01	0,07
8.	Gas Plus S.p.A.	1,54	2,21	0,70	94,05	0,03	0,08
9.	Repsol, S.A.	1,55	2,27	0,77	94,05	0,03	0,08
10.	Polskie G. Naftowe	1,77	2,29	0,84	94,05	0,01	0,08
11.	Suncor Energy Inc.	1,81	2,48	0,85	94,05	0,00	0,08
12.	Imperial Oil Ltd.	2,02	2,54	0,95	94,05	0,00	0,08
13.	Husky Energy Inc.	2,15	2,60	1,21	94,05	0,00	0,09
14.	Cenovus Energy Inc.	2,18	2,83	1,27	94,05	0,00	0,09
15.	Origin Energy Ltd.	2,22	3,03	1,27	94,05	0,00	0,10
16.	PetroChina Co. Ltd.	2,30	3,27	1,30	94,05	0,01	0,10
17.	Gazprom	2,34	3,33	1,31	94,05	0,02	0,10
18.	LUKOIL	2,39	3,39	1,36	94,05	0,02	0,11
19.	PTT Public Co.	2,55	3,46	1,62	94,05	0,02	0,12
20.	Surgutneftegas	2,88	3,51	1,68	94,05	0,02	0,12
21.	Sasol Ltd.	3,05	3,51	1,78	94,05	0,02	0,12
22.	YPF S.A.	3,08	3,69	1,86	94,05	0,10	0,14
23.	Petrobras Argentina	3,27	4,29	1,90	94,05	0,10	0,16
24.	Dana Gas PJSC	3,79	5,43	1,95	94,05	0,01	0,19
25.	Yakutsk Fuel Co.	4,24	5,48	1,98	94,05	0,02	0,23
26.	Ecopetrol SA	4,54	5,89	2,59	94,05	0,03	0,40

Tablica 20. Rasponi vrijednosti ulaznih i izlaznih parametara za FIS1 po sektorima

Sektor industrije	Raspon vrijednosti varijabli za FIS1			
	<i>PO</i>	<i>POiM</i>	<i>UKT</i>	<i>multΔVP₁</i>
<i>IM</i>	[0,49 4,54]	[0,63 5,89]	[0,21 2,59]	[-0,41 0,41]
<i>E&P</i>	[-0,18 8,78]	[-0,65 7,39]	[0,11 2,53]	[-0,24 0,24]
<i>R&M</i>	[-2,04 10,45]	[-3,49 10,97]	[0,04 13,19]	[-0,44 0,44]
<i>OFS</i>	[-1,21 7,84]	[-2,26 10,09]	[0,06 7,93]	[-0,30 0,30]
<i>T&S</i>	[0,07 10,16]	[0,07 13,05]	[0,05 7,75]	[-1,14 1,14]

Tablica 21. Rasponi vrijednosti ulaznih i izlaznih parametara za FIS2 po sektorima

Sektor industrije	Raspon vrijednosti varijabli za FIS2			
	<i>CN</i>	<i>GPO</i>	<i>SU</i>	<i>multΔVP₂</i>
<i>IM</i>	[50 130]	[0,85 1]	[0,02 0,40]	[-0,41 0,41]
<i>E&P</i>	[50 130]	[0,85 1]	[-0,21 0,31]	[-0,24 0,24]
<i>R&M</i>	[50 130]	[0,85 1]	[-1,95 0,19]	[-0,44 0,44]
<i>OFS</i>	[50 130]	[0,85 1]	[-0,10 0,13]	[-0,30 0,30]
<i>T&S</i>	[50 130]	[0,85 1]	[-0,26 0,33]	[-1,14 1,14]

Budući je za testiranje ovog modela korišten samo operator I, kako bi se lingvističkim pravilima opisale sve kombinacije triju ulaznih parametara i njihovih pripadnih pet lingvističkih vrijednosti, ukupno je potrebno $5^3 = 125$ AKO-ONDA pravila.

U općoj formi, bilo koje AKO-ONDA pravilo neizrazitog sustava zaključivanja s tri ulazne varijable (x_1, x_2, x_3) i jednom izlaznom varijablom (y), može se zapisati pomoću I operatora na način:

AKO (x_1 je a) I (x_2 je b) I (x_3 je c) ONDA (y je d)

pri čemu lingvističke varijable a, b i c pripadaju skupu {(VN), (N), (S), (V), (VV)}, tj. {1, 2, 3, 4, 5}, dok lingvistička varijabla d pripada skupu {(NV), (NM), (S), (PM), (PV)}, tj. {1, 2, 3, 4, 5}. Ukoliko se prethodno navedeno AKO-ONDA pravilo

dodatno oteža težinskim faktorom e , može ga se zapisati u tzv. indeksiranom obliku:

$$a \ b \ c, d \ (e) : f$$

pri čemu f predstavlja indikator operatora korištenog u AKO-ONDA pravilu. Za potrebe testiranja ovog modela, AKO-ONDA pravila nisu otežavana, tj. za sva pravila vrijedi $e = 1$, a budući je korišten samo I operator, vrijedi $f = 1$.

Ilustracije radi, prvo AKO-ONDA pravilo za FIS1 može se zapisati u obliku

$$\text{AKO } (PO \text{ je } VV) \text{ I } (POiM \text{ je } VV) \text{ I } (UKT \text{ je } VV) \text{ ONDA } (mult\Delta VP_1 \text{ je } PV),$$

tj. kao

$$\text{AKO } (PO \text{ je } 5) \text{ I } (POiM \text{ je } 5) \text{ I } (UKT \text{ je } 5) \text{ ONDA } (mult\Delta VP_1 \text{ je } 5),$$


što pak u indeksiranom obliku poprima formu

$$5 \ 5 \ 5, 5 \ (1) : 1.$$

Svih 125 pravila za FIS1 i FIS2 u indeksiranom obliku navedena su u Tablici 22.

Za potrebe ovog testiranja, pri kreiranju neizrazitih sustava zaključivanja, korištene su generalizirane zvonolike funkcije pripadnosti (5.14) za opisivanje ulaznih varijabli, tj. trokutaste funkcije pripadnosti (5.15) za opisivanje izlaznih varijabli.

Na slikama 22. i 23. prikazana je arhitektura neizrazitih sustava zaključivanja za FIS1 i FIS2 s tri prethodno definirana ulaza, 125 pravila i jednim izlazom.




Sustav FIS1IM: 3 ulaza, 1 izlaz, 125 pravila

Slika 22. Pojednostavljeni prikaz arhitekture neizrazitog sustava zaključivanja FIS1

Tablica 22. Pregled svih 125 AKO-ONDA pravila korištenih za FIS1 i FIS2 u okviru ispitivanja suvremenog modela procjene vrijednosti


#	AKO-ONDA pravilo	#	AKO-ONDA pravilo	#	AKO-ONDA pravilo	#	AKO-ONDA pravilo
1.	5 5 5, 5 (1) : 1	33.	4 4 3, 4 (1) : 1	65.	3 3 1, 2 (1) : 1	97.	2 1 4, 2 (1) : 1
2.	5 5 4, 5 (1) : 1	34.	4 4 2, 3 (1) : 1	66.	3 2 5, 3 (1) : 1	98.	2 1 3, 2 (1) : 1
3.	5 5 3, 4 (1) : 1	35.	4 4 1, 3 (1) : 1	67.	3 2 4, 3 (1) : 1	99.	2 1 2, 2 (1) : 1
4.	5 5 2, 4 (1) : 1	36.	4 3 5, 4 (1) : 1	68.	3 2 3, 3 (1) : 1	100.	2 1 1, 1 (1) : 1
5.	5 5 1, 4 (1) : 1	37.	4 3 4, 4 (1) : 1	69.	3 2 2, 2 (1) : 1	101.	1 5 5, 4 (1) : 1
6.	5 4 5, 5 (1) : 1	38.	4 3 3, 3 (1) : 1	70.	3 2 1, 2 (1) : 1	102.	1 5 4, 3 (1) : 1
7.	5 4 4, 4 (1) : 1	39.	4 3 2, 3 (1) : 1	71.	3 1 5, 3 (1) : 1	103.	1 5 3, 3 (1) : 1
8.	5 4 3, 4 (1) : 1	40.	4 3 1, 3 (1) : 1	72.	3 1 4, 3 (1) : 1	104.	1 5 2, 3 (1) : 1
9.	5 4 2, 4 (1) : 1	41.	4 2 5, 4 (1) : 1	73.	3 1 3, 2 (1) : 1	105.	1 5 1, 2 (1) : 1
10.	5 4 1, 3 (1) : 1	42.	4 2 4, 3 (1) : 1	74.	3 1 2, 2 (1) : 1	106.	1 4 5, 3 (1) : 1
11.	5 3 5, 4 (1) : 1	43.	4 2 3, 3 (1) : 1	75.	3 1 1, 2 (1) : 1	107.	1 4 4, 3 (1) : 1
12.	5 3 4, 4 (1) : 1	44.	4 2 2, 3 (1) : 1	76.	2 5 5, 4 (1) : 1	108.	1 4 3, 3 (1) : 1
13.	5 3 3, 4 (1) : 1	45.	4 2 1, 2 (1) : 1	77.	2 5 4, 4 (1) : 1	109.	1 4 2, 2 (1) : 1
14.	5 3 2, 3 (1) : 1	46.	4 1 5, 3 (1) : 1	78.	2 5 3, 3 (1) : 1	110.	1 4 1, 2 (1) : 1
15.	5 3 1, 3 (1) : 1	47.	4 1 4, 3 (1) : 1	79.	2 5 2, 3 (1) : 1	111.	1 3 5, 3 (1) : 1
16.	5 2 5, 4 (1) : 1	48.	4 1 3, 3 (1) : 1	80.	2 5 1, 3 (1) : 1	112.	1 3 4, 3 (1) : 1
17.	5 2 4, 4 (1) : 1	49.	4 1 2, 2 (1) : 1	81.	2 4 5, 4 (1) : 1	113.	1 3 3, 2 (1) : 1
18.	5 2 3, 3 (1) : 1	50.	4 1 1, 2 (1) : 1	82.	2 4 4, 3 (1) : 1	114.	1 3 2, 2 (1) : 1
19.	5 2 2, 3 (1) : 1	51.	3 5 5, 4 (1) : 1	83.	2 4 3, 3 (1) : 1	115.	1 3 1, 2 (1) : 1
20.	5 2 1, 3 (1) : 1	52.	3 5 4, 4 (1) : 1	84.	2 4 2, 3 (1) : 1	116.	1 2 5, 3 (1) : 1
21.	5 1 5, 4 (1) : 1	53.	3 5 3, 4 (1) : 1	85.	2 4 1, 2 (1) : 1	117.	1 2 4, 2 (1) : 1
22.	5 1 4, 3 (1) : 1	54.	3 5 2, 3 (1) : 1	86.	2 3 5, 3 (1) : 1	118.	1 2 3, 2 (1) : 1
23.	5 1 3, 3 (1) : 1	55.	3 5 1, 3 (1) : 1	87.	2 3 4, 3 (1) : 1	119.	1 2 2, 2 (1) : 1
24.	5 1 2, 3 (1) : 1	56.	3 4 5, 4 (1) : 1	88.	2 3 3, 3 (1) : 1	120.	1 2 1, 1 (1) : 1
25.	5 1 1, 2 (1) : 1	57.	3 4 4, 4 (1) : 1	89.	2 3 2, 2 (1) : 1	121.	1 1 5, 2 (1) : 1
26.	4 5 5, 5 (1) : 1	58.	3 4 3, 3 (1) : 1	90.	2 3 1, 2 (1) : 1	122.	1 1 4, 2 (1) : 1
27.	4 5 4, 4 (1) : 1	59.	3 4 2, 3 (1) : 1	91.	2 2 5, 3 (1) : 1	123.	1 1 3, 2 (1) : 1
28.	4 5 3, 4 (1) : 1	60.	3 4 1, 3 (1) : 1	92.	2 2 4, 3 (1) : 1	124.	1 1 2, 1 (1) : 1
29.	4 5 2, 4 (1) : 1	61.	3 3 5, 4 (1) : 1	93.	2 2 3, 2 (1) : 1	125.	1 1 1, 1 (1) : 1
30.	4 5 1, 3 (1) : 1	62.	3 3 4, 3 (1) : 1	94.	2 2 2, 2 (1) : 1		
31.	4 4 5, 4 (1) : 1	63.	3 3 3, 3 (1) : 1	95.	2 2 1, 2 (1) : 1		
32.	4 4 4, 4 (1) : 1	64.	3 3 2, 3 (1) : 1	96.	2 1 5, 3 (1) : 1		

Geometrija krivulja funkcija kojima su definirani stupnjevi pripadnosti ulaznih i izlaznih varijabli za FIS1 i FIS2, na primjeru IM sektora, prikazani su na slikama 24. i 25.




Sustav FIS2IM: 3 ulaza, 1 izlaz, 125 pravila

Slika 23. Pojednostavljeni prikaz arhitekture neizrazitog sustava zaključivanja FIS2



Slika 24. Funkcije pripadnosti ulaznih i izlaznih varijabli za FIS1




Slika 25. Funkcije pripadnosti ulaznih i izlaznih varijabli za FIS2


Geometrija krivulja funkcija pripadnosti ulaznih varijabli za FIS1 i FIS2 odabrana je na način da se lingvističke varijable što reprezentativnije preslikaju na definirani raspon vrijednosti, posebno kada je riječ o interpretaciji vrijednosti pojedinih ulaznih varijabli. Proces izoštravanja je proveden metodom težišta i za FIS1 i za FIS2.

Kod izlaznih varijabli izvršena je gušća raspodjela funkcija pripadnosti oko srednje vrijednosti multiplikatora $mult\Delta VP_1$, odnosno $mult\Delta VP_2$. Posljedično, poboljšavanje izlaznih vrijednosti u sredini raspona izlaznih varijabli uzrokuje nešto lošije rezultate kod ekstremnih vrijednosti, ali one u ovom kontekstu nisu od posebnog praktičnog značaja. Ovo se najbolje vidi iz vizualizacije 3D plohe koja

prezentira preslikavanje neka dva odabrana ulazna parametra u izlazni parametar. Slike 26. i 27. predstavljaju vizualizaciju preslikavanja definiranih kao $(PO, UKT) \rightarrow mult\Delta VP_1$ i $(SU, GPO) \rightarrow mult\Delta VP_2$ za FIS1 i FIS2, respektivno.



Slika 26. Primjer vizualizacije preslikavanja neizrazitog sustava zaključivanja FIS1



Slika 27. Primjer vizualizacije preslikavanja neizrazitog sustava zaključivanja FIS2

Izračunate, i po potrebi zasićene, vrijednosti multiplikatora $mult\Delta VP_1$, $mult\Delta VP_2$ i $mult\Delta VP$, kao i izračunata korigirana vrijednost poduzeća VP_{kor} iskazana u mil. USD, za sva analizirana poduzeća integriranog sektora (IM) nalaze se u Tablici 23.

Zasićenje multiplikatora je provedeno sukladno opisanom postupku u poglavlju 7.3., što je vidljivo i sa slike 21. Za analizirana poduzeća ostalih sektora naftne i plinske industrije, izračunate vrijednosti navedenih multiplikatora s korigiranom vrijednošću poduzeća nalaze se u Prilogu 5.


Tablica 23. Vrijednosti multiplikatora $mult\Delta VP_1$, $mult\Delta VP_2$ i $mult\Delta VP$ i korigirane vrijednosti poduzeća za IM sektor

R.br.	Naziv poduzeća	$multVP$	$mult\Delta VP_1$	$mult\Delta VP_2$	$mult\Delta VP$	VP_{kor}
1.	Royal Dutch Shell	4,77	-0,32	0,00	4,45	231873,74
2.	BP plc	5,63	-0,14	0,01	5,50	155932,81
3.	Total SA	3,34	-0,14	0,01	3,21	143445,28
4.	Eni SpA	2,72	-0,14	0,00	2,59	94949,90
5.	Statoil ASA	1,95	-0,14	0,02	1,83	82095,76
6.	OMV	2,56	-0,13	0,03	2,46	17127,36
7.	BG Group plc	6,55	-0,13	0,03	6,45	71282,62
8.	Gas Plus S.p.A.	3,61	-0,12	0,04	3,53	315,40
9.	Repsol, S.A.	4,88	-0,12	0,04	4,80	40645,80
10.	Polskie G. Naftowe	6,63	-0,11	0,05	6,57	10482,45
11.	Suncor Energy Inc.	5,22	-0,12	0,05	5,16	58486,56
12.	Imperial Oil Ltd.	7,73	-0,06	0,05	7,73	43557,18
13.	Husky Energy Inc.	6,32	-0,02	0,05	6,36	35809,64
14.	Cenovus Energy Inc.	5,77	-0,01	0,05	5,81	24149,07
15.	Origin Energy Ltd.	9,81	0,00	0,04	9,85	16053,97
16.	PetroChina Co. Ltd.	5,19	0,01	0,04	5,24	284355,91
17.	Gazprom	3,45	0,01	0,04	3,51	182244,71
18.	LUKOIL	3,57	0,03	0,03	3,63	68521,55
19.	PTT Public Co.	4,08	0,07	0,03	4,18	31662,00
20.	Surgutneftegas	4,51	0,09	0,03	4,63	42380,75
21.	Sasol Ltd.	5,19	0,10	0,03	5,32	30900,33
22.	YPF S.A.	4,81	0,12	-0,10	4,83	15894,00
23.	Petrobras Argentina	2,70	0,13	-0,09	2,70	1670,49
24.	Dana Gas PJSC	5,80	0,15	0,10	6,06	2429,70
25.	Yakutsk Fuel Co.	7,59	0,29	0,10	7,93	340,99
26.	Ecopetrol SA	4,48	0,27	0,14	4,89	77559,29

U neuro-determinističkom dijelu modela ispitana je mogućnost da neuronska mreža na temelju odabranih kvantitativnih parametara procjenjuje otežanu (VP) i korigiranu (VP_{kor}) vrijednost poduzeća. U tu svrhu, istrenirana je unaprijedna neuronska mreža s povratnim rasprostiranjem pogreške.

Za formiranje ulazne matrice, odabrani su vektori značajnih parametara kako slijedi: ukupna imovina (UI), ukupne obveze (UO), amortizacija (AM), neto kapitalna ulaganja (NKU), neto dobit (ND), ukupni prihodi (UP), $EBIT \times (1 - t)$ ($EBIT2$), $EBITDA$, investirani kapital (IK) i dividende (DIV). Vrijednosti navedenih parametara za svih 170 analiziranih poduzeća naftno-plinske industrije u cijelosti nalaze se u Prilogu 6.

Struktura obje mreže odabrana je kao na slici 28., tj. sa 10 neurona u ulaznom sloju, 20 neurona u skrivenom sloju i jednim neuronom u izlaznom sloju.



Slika 28. Dijagram slojeva testirane unaprijedne neuronske mreže u neuro-determinističkom dijelu modela

Vrijednosti parametara odabranih poduzeća podijeljeni su u tri skupine: 70 % (118 poduzeća) za treniranje, 15 % (26 poduzeća) za validaciju i 15 % (26 poduzeća) za testiranje. Uspješnost kreiranih modela je ocijenjena koeficijentom korelacije R između stvarnih vrijednosti VP i VP_{kor} u odnosu na procijenjene VP ($nnVP$) i VP_{kor} ($nnVP_{kor}$) koje daje mreža kao odziv (Slika 21.). Dobiveni rezultati prikazani su u tablici 24.

Rezultati prikazani u tablici 13. dobiveni su treniranjem mreža s jednim ulaznim parametrom na uzorku od 170 poduzeća, a rezultati iz tablice 24. treniranjem mreža sa 10 ulaznih parametara na uzorku od 118 poduzeća. Navedeno je razlog zašto se ti rezultati ne mogu izravno usporediti. Međutim, ipak je jasno da što god mreža na raspolaganju ima više značajnih ulaznih parametara, više raspoloživih poduzeća i veći broj neurona u skrivenom sloju, to je odziv takve mreže bolji.


Tablica 24. Ocjena uspješnosti kreiranih unaprijednih neuronskih mreža za procjenu otežane i korigirane vrijednosti poduzeća

Faza	Broj uzoraka	Koeficijent korelacije R	
		(VP, mVP)	(VP_{kor}, mVP_{kor})
<i>Treniranje</i>	118	0,999032	0,999312
<i>Validacija</i>	26	0,998145	0,999754
<i>Testiranje</i>	26	0,997854	0,999153


Rezultati iz tablice 24. dodatno sugeriraju podjednako dobre aproksimacijske mogućnosti unaprijednih neuronskih mreža, neovisno da li na izlazu daju otežanu ili korigiranu vrijednost poduzeća. Općenito, dobiveni rezultati ukazuju na iznimno dobre aproksimacijske mogućnosti kreiranih mreža, na temelju čega se može zaključiti da imaju veliku perspektivu u procjeni vrijednosti poduzeća. Mreža koja iznimno dobro aproksimira VP_{kor} predstavlja moćan alat procjeniteljima, jer kombinira sva tri klasična pristupa vrednovanju, ekspertno mišljenje i neizrazitu korekciju uporabne i tržišne komponente vrijednosti.

8.2. Komparativna analiza predloženog modela i postojećih standardnih pristupa za vrednovanje poduzeća naftne i plinske industrije


Na osnovi provedenog testiranja moguće je izvršiti komparativnu analizu predloženog modela, standardnih pristupa vrednovanju poduzeća i vrijednosti dobivene otežavanjem sva tri pristupa. Zbog velikog broja poduzeća po pojedinoj industriji i ilustracije funkcije predloženog modela, komparativna analiza izvršena je usporedbom multiplikatora $multTR$, $multVP$, $mult\Delta VP$ i $multUP$. Rezultati komparacije po pojedinim sektorima industrije prikazani su na slikama 29. do 33. Iz njih je vidljivo da je korekcija u svim sektorima u većini slučajeva izvršena na način da se uporabna vrijednost spušta prema tržišnoj, iz razloga što je prema analiziranim rezultatima iz 2012. godine tržišna vrijednost u većini slučajeva bila manja od uporabne vrijednosti. Iz slika je također vidljivo da je čak i samo vrednovanje otežanim kombinacijama sva tri pristupa u funkciji postavljene hipoteze, te da postoje slučajevi kada takve vrijednosti nije potrebno korigirati ili su potrebne vrlo male korekcije.




Slika 29. Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća IM sektora (prema Tablici 23.)




Slika 30. Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća E&P sektora (prema Prilogu 5.)



Slika 31. Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća R&M sektora (prema Prilogu 5.)



Slika 32. Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća OFS sektora (prema Prilogu 5.)



Slika 33. Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća T&S sektora (prema Prilogu 5.)

Do prethodnih zaključaka se može doći i sagledavanjem industrijskih prosjeka, tj. prosjeka po sektorima naftne i plinske industrije. U tu svrhu izračunata su srednja kvadratna odstupanja (MSE) između uporabne i tržišne, otežane i uporabne, otežane i tržišne, korigirane i uporabne, korigirane i tržišne, te korigirane i otežane vrijednosti poduzeća za svaki pojedini sektor. Analogno, isto je napravljeno i za multiplikatore prethodno navedenih odnosa vrijednosti poduzeća. Dobiveni rezultati izloženi su u tablicama 25. i 26.

Tablica 25. Srednja kvadratna odstupanja između tržišne, otežane, korigirane i uporabne vrijednosti poduzeća po sektorima

Vrijednosti poduzeća (i, j)	Srednje kvadratno odstupanje $MSE(i, j)$				
	<i>E&P</i>	<i>R&M</i>	<i>OFS</i>	<i>T&S</i>	<i>IM</i>
(VP_{UP}, VP_{TR})	$2,3523 \cdot 10^7$	$2,7149 \cdot 10^6$	$2,9770 \cdot 10^6$	$8,0756 \cdot 10^6$	$1,1246 \cdot 10^9$
(VP, VP_{UP})	$1,9821 \cdot 10^6$	$1,0912 \cdot 10^6$	$1,2369 \cdot 10^6$	$7,0724 \cdot 10^5$	$1,6502 \cdot 10^8$
(VP, VP_{TR})	$1,1851 \cdot 10^7$	$5,9479 \cdot 10^5$	$1,3031 \cdot 10^6$	$7,6855 \cdot 10^6$	$4,3380 \cdot 10^8$
(VP_{kor}, VP_{UP})	$1,9442 \cdot 10^6$	$1,2625 \cdot 10^6$	$1,4558 \cdot 10^6$	$6,8884 \cdot 10^5$	$1,8112 \cdot 10^8$
(VP_{kor}, VP_{TR})	$1,2012 \cdot 10^7$	$5,8948 \cdot 10^5$	$8,1068 \cdot 10^5$	$5,4703 \cdot 10^6$	$4,3529 \cdot 10^8$
(VP_{kor}, VP)	$2,0719 \cdot 10^4$	$5,8429 \cdot 10^4$	$1,0476 \cdot 10^5$	$3,3292 \cdot 10^5$	$1,7209 \cdot 10^7$

Tablica 26. Srednja kvadratna odstupanja između multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti poduzeća po sektorima

Vrijednosti multiplikatora (i, j)	Srednje kvadratno odstupanje $MSE(i, j)$				
	<i>E&P</i>	<i>R&M</i>	<i>OFS</i>	<i>T&S</i>	<i>IM</i>
$(multUP, multTR)$	5,7111	4,0810	12,7890	15,7971	1,6112
$(multVP, multUP)$	0,4816	0,4405	1,7706	1,6634	0,2189
$(multVP, multTR)$	2,8766	2,6697	7,3205	8,5463	0,6680
$(mult\Delta VP, multUP)$	0,4843	0,4330	1,6219	1,8511	0,2161
$(mult\Delta VP, multTR)$	2,9003	2,4357	7,2410	7,6903	0,7321
$(mult\Delta VP, multVP)$	0,0084	0,0468	0,0784	0,1833	0,0237

Iz rezultata prezentiranih u tablici 25. jasno je vidljivo da su u sektoru *E&P* i otežana i korigirana vrijednost bliža uporabnoj, dok je u sektoru *R&M* situacija potpuno obrnuta, tj. otežana i korigirana vrijednost su bliže tržišnoj vrijednosti. U *OFS* sektoru otežana vrijednost je negdje između tržišne i uporabne, dok je korigirana nešto bliža tržišnoj. Za sektore *T&S* i *IM* vrijedi isto kao i kod sektora *E&P*, tj. i kod ovih sektora otežane i korigirane vrijednosti su bliže uporabnoj.

Ukoliko se gledaju srednja kvadratna odstupanja multiplikatora iz tablice 26., može se zaključiti da je na razini prosjeka po svim pojedinim sektorima multiplikator otežane i korigirane vrijednosti bliži multiplikatoru uporabne vrijednosti. No, treba napomenuti da ove rezultate treba uzeti s rezervom zbog značajne nelinearnosti koja karakterizira multiplikatore.

8.3. Ograničenja predloženog modela i preporuke za budući rad

Predloženi model kreiran je i testiran na poduzećima s pozitivnim *EBITDA* vrijednostima te je u okviru postavljene hipoteze predviđen za poduzeća okrenuta stvaranju pozitivnih poslovnih rezultata. U slučaju pojave negativnog *EBITDA* potrebno je uzeti rezultate petogodišnjeg ili desetogodišnjeg prosjeka. U slučaju pojave negativnih rezultata i negativnih *EBITDA* kod višegodišnjih prosjeka, takvo poduzeće preporuča se vrednovati nekom od metoda za utvrđivanje likvidacijske vrijednosti, a ne predloženim modelom.

Kod određivanja raspona vrijednosti multiplikatora za korekciju uporabne i tržišne vrijednosti, bez obzira na parametre kojima će se korigirati, potrebno je izbaciti ona poduzeća koja bitno odskakuju od prosjeka sektora industrije. Rasponi vrijednosti kumulativnog multiplikatora uvijek moraju biti unutar postojećih granica multiplikatora tržišne i uporabne vrijednosti.

Preporuke za budući rad uključuju sljedeće:

- vrednovati poduzeća predloženim modelom na temelju višegodišnjih rezultata, te pomoću njih trenirati neuronsku mrežu;
- u slučaju raspoloživosti internih baza podataka s kvalitativnim parametrima velikih savjetodavnih kuća, ocijeniti odabrane parametre za korekciju uporabne i tržišne komponente na temelju tih podataka;
- testirati model uz odabir drugih važnih parametara za korekciju uporabne i tržišne vrijednosti, a koji u ovom radu nisu uzeti u obzir;
- testirati model na poduzećima drugih industrijskih grana uz pretpostavku detaljne analize promatrane industrije.

9. ZAKLJUČAK

U ovom doktorskom radu predložen je suvremeni pristup vrednovanju poduzeća naftne i plinske industrije. Potreba za istraživanjem nastala je iz nužnosti približavanja kategorija vrijednosti u uporabi i vrijednosti u razmjeni poduzeća kao cjeline, u okviru filozofije fer vrijednosti, odnosno nametnutog pitanja kako u tim okvirima napraviti što bolji model za objektivnije utvrđivanje vrijednosti poduzeća.

Kroz pojašnjavanje teorijskih odrednica standardnog pristupa vrednovanju poduzeća s aspekta imovinskog, prihodovnog i tržišnog pristupa procjeni vrijednosti, utvrđeni su razlozi zbog kojih se ovi pristupi, pojedinačno ili u paru, koriste tokom standardnog vrednovanja poduzeća, te su identificirane njihove prednosti i nedostaci. Poglavito se to odnosi na nedostatke najčešće korištene metode unutar prihodovnog pristupa, DCF metode, koja je osjetljiva na pretpostavke za predviđanje budućih novčanih tokova. Stoga je velika pažnja u klasičnom vrednovanju posvećena modeliranju novčanih tokova i definiranju međuovisnosti parametara koji na njega utječu.

Isto tako, izložena je i primjena regresijske analize u funkciji vrednovanja poduzeća. Upotreba regresijske analize raširena je u vrednovanju poduzeća upravo zbog svoje biti, odnosno utvrđivanja ovisnosti jedne varijable o nekoj drugoj ili više drugih varijabli. Tako se kod vrednovanja prihodovnim pristupom koristi u svrhu što točnijeg predviđanja opsega prodaje ili troškova, kako bi se što preciznije mogli odrediti budući novčani tokovi, dok se u tržišnom pristupu koristi kao mjera odnosa ostvarene vrijednosti prodanog poduzeća kao zavisne varijable i nekoliko mogućih nezavisnih varijabli. Također su istaknuti najčešće korišteni statistički pokazatelji za interpretaciju rezultata analiza.

Razmotreni nedostaci postojećih metoda promotreni su u okviru vrednovanja naftne i plinske industrije, te je istaknuta potreba za suvremenim modelom koji može uvažiti kompleksnosti svakog pojedinog sektora unutar industrije. To se osobito odnosi na karakteristike i temeljna obilježja poslovanja pojedinih sektora poduzeća naftne i plinske industrije. Naime, zbog kompleksnosti procesa poslovanja od pronalaska izvora do distribucije nafte i plina krajnjim korisnicima, ova se industrija formirala kroz pet sektora, tj. kroz eksploatacijsko-proizvodni sektor, sektor transporta i skladištenja, sektor rafiniranja i marketinga, sektor

potpore naftnim poljima i sektor integriranih poduzeća. Specifičnosti svakog pojedinog sektora očituju se u proizvodnim procesima, proizvodnoj opremi i operativnom poslovanju. Na osnovu toga definirane su bitne odrednice poduzeća koje se nadalje promatraju kao parametri klasterizirani po odgovarajućim skupinama bitnim za vrijednost poduzeća.

Bitan čimbenik koji uvelike utječe na poslovanje cijele naftno-plinske industrije je cijena nafte i plina koja se kroz povijest, pod utjecajem raznih vanjskopolitičkih događaja mijenjala. U radu su istaknute okolnosti koje su utjecale na promjene u cijenama, a u svrhu identifikacije rizika koji se mogu pojaviti u poslovanju ovih poduzeća u slučaju većih oscilacija u cjenovnim trendovima nafte i plina.

Također, izložene su i računovodstvene i financijske specifičnosti poduzeća naftne i plinske industrije, čime je dodatno ukazano na potrebu za drugačijim pristupom vrednovanju. One se ponajprije odnose na eksploatacijsko-proizvodna poduzeća i tretman operativnih troškova koji se odnose na istraživanje novih rezervi nafte i plina, a nastaju zbog različitih tretmana unutar pojedinih računovodstvenih standarda. Efekt se ovakvih različitosti očituje u drugačijim rezultatima koji se odnose na zarade, pa ih je potrebno prilagoditi kako bi promatrana poduzeća mogla biti uspoređivana u svrhu analiza. Zbog velikih utjecaja cjenovnih trendova, te česte potrebe za velikim kapitalnim ulaganjima, nastaju specifičnosti u radnom kapitalu naftno-plinske industrije, koje uvelike utječu na novčane tokove. Višegodišnje analize ukazale su na potrebu učinkovitijeg upravljanja radnim kapitalom unutar svih sektora industrije. Osim navedenog, na financijske oscilacije poslovanja ovih poduzeća mogu utjecati razni drugi čimbenici poput ekonomskog i pravno-regulatornog okruženja, tržišna struktura, rizik države u kojoj poduzeće posluje i slično.

Provedenim analizama osnovnih financijskih pokazatelja po sektorima industrije utvrđeni su rangovi likvidnosti, profitabilnosti, aktivnosti, stvaranja vrijednosti i poslovne izvrsnosti. Na taj način izvršena je usporedba svih sektora industrije koja je još jednom dovela do zaključka o različitostima pojedinih sektora i potrebe stvaranja drugačijih kriterija za vrednovanje unutar istih.

Istraživanjem i analizama utvrđene su značajke i čimbenici koji utječu na vrijednost poduzeća naftne i plinske industrije u sadašnjosti, kao i čimbenici koji utječu na predviđanje poslovanja u budućnosti.

Na temelju provedenih analiza i istraživanja definirana je stoga nužnost suvremenog pristupa vrednovanju koji može uzeti u obzir razne kategorije čimbenika koji utječu na stvaranje i akumulaciju vrijednosti poduzeća, te koji s druge strane omogućuje integraciju sva tri pristupa klasične metodologije vrednovanja poduzeća, tj. imovinski, tržišni i prihodovni. Potvrđeno je to analizom ekspertnih mišljenja iz područja vrednovanja poduzeća naftne i plinske industrije, koja je omogućila pravilno otežavanje svakog pojedinog pristupa vrednovanju po sektorima industrije, ali i identifikaciju najznačajnijih kvalitativnih čimbenika koji utječu na stvaranje i akumulaciju vrijednosti u uporabi i tržišne vrijednosti unutar industrije. Temeljem zaključaka iz analitičkih dijelova rada kvantificirati su parametri značajni za izradu suvremenog modela procjene vrijednosti naftne i plinske industrije.

S obzirom na brojna dosadašnja istraživanja i na iznimno veliki broj objavljenih znanstvenih i stručnih radova o primjenama računalne inteligencije u različitim znanstvenim disciplinama, pa tako i u ekonomskim znanostima, za realizaciju suvremenog pristupa procjeni vrijednosti poduzeća odabrane su metode računalne inteligencije koje uključuje ekspertne i neizrazite sustave, te umjetne neuronske mreže.

Istraživanjem je dokazano da računalna inteligencija može uvelike pomoći kada je riječ o identifikaciji parametara nekog sustava kao i u identifikaciji njihovih međuovisnosti, ali i kada je riječ o fuziji potpuno različitih i uobičajeno nespojivih informacija, a s razlogom da se ocijeni njihov utjecaj na konačnu, unaprijed nepoznatu, informaciju. Također je dokazana korisnost pristupa kvantifikaciji kvalitativnih informacija pomoću neizrazite logike. Pri tome su umjetne neuronske mreže korištene za ispitivanje utjecaja i međuovisnosti pojedinih parametara na vrijednost poduzeća, kao i za ispitivanje mogućnosti da model temeljen na umjetnim neuronskim mrežama bude alternativa klasičnom pristupu vrednovanju koji je proširen s ekspertnim znanjem. Neizrazita logika korištena je za korekciju uporabne i tržišne vrijednosti.

Upotrebom računalne inteligencije kroz neuronske mreže i neizrazitu logiku kreiran je model u okviru suvremenog pristupa procjeni, kojim je moguće procijeniti onu vrijednost poduzeća, u okviru filozofije fer vrijednosti, u kojoj su kategorije vrijednosti u uporabi i vrijednosti u razmjeni približene u onoj mjeri da mogu zadovoljiti očekivanja investitora.

Predloženi model prezentiran je konceptualno kroz inicijalnu fazu, fazu neizrazite korekcije i neuro-determinističku fazu. Inicijalna faza pretpostavlja odabir relevantnih izvora podataka uz pretraživanje informacija značajnih za poduzeća naftne i plinske industrije. Također, u ovoj fazi je implementirano ekspertno znanje kroz otežavanje vrijednosti poduzeća dobivenih imovinskim, prihodovnim i tržišnim pristupom, ali i za identifikaciju i ocjenu značaja odabranih kvalitativnih pokazatelja koji stvaraju vrijednost poduzeća. Druga faza neizrazite korekcije zahtjeva odabir ulaznih i izlaznih parametara za neizrazite sustave zaključivanja čija je funkcija korekcija uporabne i tržišne vrijednosti s ciljem njihovog međusobnog približavanja. Pri tome se definirao pojam korigirane vrijednosti koji se odnosi na korigiranu otežanu vrijednost s obzirom na prethodno spomenuti cilj. Završna neuro-deterministička faza se sastoji iz dva dijela. U preliminarnom se dijelu primjenom aproksimacijskih i klasifikacijskih neuronskih mreža ispituje utjecaj pojedinih kvantitativnih parametara na vrijednost poduzeća, kvantificira se taj odnos i ispituje se njihova međuovisnost. U drugom dijelu neuro-determinističke faze ispituju se aproksimacijske mogućnosti unaprijednih neuronskih mreža s ciljem da takvi modeli budu alternativa pri procjeni otežane i korigirane vrijednosti poduzeća. Time ovakvi modeli nisu samo alternativa klasičnim pristupima vrednovanju, već i njihovo značajno proširenje i poboljšanje u sinergijskom smislu.

Model je testiran na ukupno 170 poduzeća svih sektora naftne i plinske industrije, što je omogućilo komparativnu analizu s postojećim metodama vrednovanja, ali i istaknulo važnost upotrebe otežanih vrijednosti sva tri konvencionalna pristupa vrednovanju. Razvijeni neizraziti multiplikatori za korekciju uporabne i tržišne vrijednosti vrlo uspješno korigiraju otežanu vrijednost, pri čemu je značajno istaknuta važnost pravilnog postavljanja njihovih raspona vrijednosti.

Komparativnom analizom utvrđeno je da je na promatranim poduzećima korekcija više vršena u podizanju tržišne vrijednosti prema uporabnoj. Do ovih se zaključaka došlo analizom korekcija po pojedinim poduzećima, ali i na razini cijelih sektora naftne i plinske industrije.

Ostvareni rezultati mogu se iskazati kroz sljedeće:

- znanstveno su utemeljene i određene najvažnije značajke različitih pristupa u vrednovanju poduzeća;
- utvrđene su specifičnosti poslovanja poduzeća naftne i plinske industrije te

je ukazano na potrebu za drugačijim pristupom procjeni vrijednosti poduzeća;

- određeni su najznačajniji pokazatelji financijske i nefinancijske prirode, njihova međuovisnost i utjecaj na vrijednost poduzeća;
- određeni su kriteriji za procjenu vrijednosti suvremenim pristupom;
- istraživanjem je pokazana važnost korištenja suvremenih alata poput umjetnih neuronskih mreža i neizrazite logike u području vrednovanja poduzeća;
- predložen je i na realnim poduzećima testiran model suvremenog pristupa vrednovanju poduzeća s ciljem približavanja uporabne i tržišne vrijednosti;
- kreiranim modelom uspješno su eliminirani nedostaci postojećih pristupa vrednovanju.

Na temelju svih ostvarenih rezultata, potvrđena je postavljena znanstvena hipoteza, odnosno dokazano je da je spoznajama o bitnim čimbenicima koji utječu na stvaranje i akumuliranje vrijednosti poduzeća naftne i plinske industrije te njihovoj međuovisnosti i stupnju pojedinačnog utjecaja na procijenjenu vrijednost, moguće primjenom računalne inteligencije kreirati model vrednovanja u sustavu utvrđivanja fer vrijednosti, u kojem će razlika vrijednosti u uporabi i tržišne vrijednosti poduzeća biti minimalna. Također, potvrđene su i sve pomoćne hipoteze.

Na kraju rada istaknuta su ograničenja i preporuke za budući rad. Ograničenja se uglavnom odnose na poduzeća koja nisu okrenuta *going concern* konceptu te ostvaruju dugogodišnje negativne rezultate. Preporuke se pak odnose na primjenu modela za vrednovanje poduzeća iz drugih industrija, kao i testiranje modela odabirom nekih drugih parametara za korekciju uporabne i tržišne vrijednosti koji nisu u ovom radu bili uzeti u obzir.

Ostvareni izvorni znanstveni doprinos ovog doktorskog rada očituje se u:

- u razvoju znanstvene misli o različitim pristupima vrednovanju poduzeća;
- u razvoju znanstvene misli o poduzeću, osnovnim faktorima koji ga određuju i utječu na njegovu vrijednost, kroz specifičnosti poslovanja poduzeća naftne i plinske industrije;
- u utvrđivanju značajnih kvalitativnih čimbenika koji su od velike važnosti za procjenu vrijednosti poduzeća, a u današnjoj praksi još uvijek nisu uvršteni u financijske izvještaje;

- u važnosti utvrđene međuovisnosti relevantnih financijskih pokazatelja i njihovog utjecaja na vrijednost poduzeća;
- u determiniranju važnosti suvremenijeg pristupa i alata za analizu utjecaja parametara na vrijednost poduzeća i njihovu međuovisnost;
- u prepoznavanju važnosti približavanja uporabne i tržišne vrijednosti poduzeća;
- u ekspertnom otežavanju vrijednosti poduzeća dobivenih klasičnim metodama vrednovanja;
- u definiciji pojma korigirane vrijednosti poduzeća koja se ostvaruje približavanjem uporabne i tržišne komponente;
- u kreiranju neizrazitog sustava zaključivanja za korekciju uporabne i tržišne vrijednosti;
- u razvoju alternativnog pristupa za određivanje otežanih i korigiranih vrijednosti poduzeća na temelju unaprijednih neuronskih mreža.

Vrijednost poduzeća naftno-plinske industrije determinirana pomoću predloženog modela, osim za različita znanstvena istraživanja, s aplikativnog aspekta od iznimnog je značaja i za potencijalne prodavatelje i kupce, procjenitelje vrijednosti, analitičare naftne i plinske industrije, investicijske bankare, kao i ostale subjekte unutar svih sektora industrije.

LITERATURA

- [1] Abrams, J. B.: *Quantitative Business Valuation - A Mathematical Approach for Today's Professional, Second Edition*, John Wiley & Sons, Inc., New Jersey, 2010.
- [2] Abrams, J. B.: *Quantitative Business Valuation - A Mathematical Approach for Today's Professional*, McGraw-Hill, New York, 2001.
- [3] Adelman, M.A., Watkins, G.C.: *U.S. oil and gas reserve prices, 1982-2003*, Energy Economics, Vol. 27, 2005, p. 553-571
- [4] Aralica, Z.: *Povezanost vrijednosti kapitala i odabranih pokazatelja u proizvodnim poduzećima*, Ekonomski pregled, Vol. 56., 2005., p. 1190-1216
- [5] Basher, S.A., Haug, A.A., Sadorsky, P.: *Oil prices, exchange rates and emerging stock markets*, Energy Economics, Vol. 34, 2012, 227-240
- [6] Belak, V., Aljinović Barić, Ž.: *Business excellence (bex) indeks - za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj*, Računovodstvo, revizija i financije, Vol. 10, 2007., p. 15-25
- [7] Bešvir, B.: *Kako čitati i analizirati financijske izvještaje*, RRIF plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, 2008.
- [8] Bloomberg Businessweek, [Online] dostupno na: <http://www.businessweek.com/> (2013.)
- [9] BP Statistical Review of World Energy, [Online] Available: www.bp.com/content/dam/bp/pdf/statistical-review (June 2013)
- [10] Brlečić Valčić, S., Crnković-Stumpf, B.: *Potreba za približavanjem uporabne i fer tržišne vrijednosti poduzeća u suvremenom pristupu vrednovanja poduzeća*, Ekonomska misao i praksa, Vol. 2, 2013., p. 379-396
- [11] Brlečić Valčić, S., Crnković-Stumpf, B., Katunar, J.: *Business valuation in Oil&Gas industry: New challenges*, Proceedings of the 36th International Convention on Information & Communication Technology Electronics & Microelectronics MIPRO 2013, Opatija, Croatia, 2013, p. 1489-1494
- [12] Burrell, P. R., Folarin, B. O.: *The Impact of Neural Networks in Finance*, Neural Computing & Applications, Vol. 6, 1997, p. 193-200
- [13] Burton, R.: *The Benefits of Econometric Firm Valuation in International Financial Disputes*, Journal of International Service, Vol.20, 2011, p.103-124
- [14] Chakraborty, K.: *Impact of Assets and Profitability to Improve the Business Valuation: A Study*, Vol. 3, 2011, p. 16-21
- [15] Chen, J., Lin, S.: *An interactive neural network-based approach for solving multiple criteria decision-making problems*, Decision Support Systems, Vol.36, 2003, p. 137-146

- [16] Cormier, D., Magnan, M.: *Performance reporting by oil and gas firms: contractual and value implications*, International Accounting, Auditing and Taxation, Vol. 11, 2002, p. 131-153
- [17] Crnković-Stumpf, B.: *Procjenjivanje vrijednosti poduzeća kao pretpostavka upravljanja ekonomijom poduzeća*, Doktorska disertacija, Ekonomski fakultet Rijeka, Sveučilište u Rijeci, Rijeka, 1996.
- [18] Crnković-Stumpf, B.: *Akumulativna i reproduktivna sposobnost poduzeća*, Gospodarstvo Istre, Vol. 4, No. 1, 1991. p. 54-60
- [19] Damodaran, A.: *Damodaran Online*, [Online] dostupno na: <http://pages.stern.nyu.edu/~adamodar> (2013.)
- [20] Damodaran, A.: *Investment Valuation Tools and Techniques for Determining the Value of Any Asset*, Third Edition, John Wiley & Sons, New Jersey, 2012.
- [21] Damodaran, A.: *Damodaran o valuaciji*, Mate d.o.o, Zagreb, 2010.
- [22] DBRS, *Rating Oil and Gas Companies*, 2009.
- [23] Đonlagić, D., Jurković, F., Tovornik, B.: *Osnove projektiranja neizrazitih (fuzzy) regulacijskih sustava*, KoREMA, Zagreb, 1994.
- [24] Energy Outlook 2030. BP p.l.c., [Online] Available: www.bp.com/energyoutlook (January 2013)
- [25] EY - Cash in the Barrel, *Benchmarking and analysis of working capital management in the oil and gas industry*, [Online] Available: www.ey.com (2013)
- [26] EY - Global oil and gas transactions review 2013, EYGM Limited, [Online] Available: [www.ey.com/oil and gas](http://www.ey.com/oil%20and%20gas) (2013)
- [27] EY - Global oil and gas transactions review 2012, EYGM Limited, [Online] Available: [www.ey.com/oil and gas](http://www.ey.com/oil%20and%20gas) (2012)
- [28] EY - Cash in the Barrel, *Working capital management in the oil and gas industry*, [Online] Available: www.ey.com (2011)
- [29] Gil-Lafuente, A.M., Castillo-Lopez, C., Blanco-Mesa, F.R.: *A Paradigm Shift in Business Valuation Process Using Fuzzy Logic*, Soft Computing in Management and Business Economics, Vol. 287/2012, 2012, p. 177-189
- [30] Gil-Lafuente, A.M.: *Fuzzy Logic in Financial Analysis*, Springer, Berlin – Heidelberg, 2005.
- [31] Hagan, M.T., Demuth, H.B., Beale, M.H.: *Neural Network Design*, Boston, MA: PWS Publishing, 1996.
- [32] Helfert, E.A., *Financial Analysis: Tools and Techniques*, McGraw-Hill, New York, 2005.
- [33] Hitchner, J. R.: *Financial valuation: applications and models*, John Wiley & Sons, New Jersey, 2006.

- [34] Howard, A.W., Harp, A.B.: *Oil and Gas Company Valuations*, Business Valuation Review, Vol. 28, 2009, p. 30-36
- [35] Howe, H., Lewis, E., Lippitt, J.W.: *Estimating Capitalization Rates for the Excess Earnings Method Using Publicly Traded Comparables*, Journal of Business Valuation and Economic Loss Analysis. Volume 2, April 2007, p. 1932-9156,
- [36] IAS 36 - Impairment of Assets, [Online] Available: www.iasplus.com/en/standards/ias/ias36 (2012)
- [37] IFRS 13, IASB: *Fair value measurement*, 2012.
- [38] IFRS 13, IASB: *Fair value measurement*, Illustrative Examples (separate booklet), 2012.
- [39] Jennings, D.R., Feiten, J.B., Bock, H.R.: *Petroleum Accounting*, Professional Development Institute, University of North Texas, 2000.
- [40] Johnston, D. & D.: *Oil Company Financial Analysis*, PennWell Corporation, Tulsa, 2006.
- [41] Kahraman, C.: *Fuzzy Engineering Economics with Applications*, Springer-Verlag, Berlin-Heidelberg, 2008.
- [42] Karsak, E.E., Tolga, E.: *Fuzzy multi-criteria decision-making procedure for evaluating advanced manufacturing system investments*, International Journal of Production Economics, Vol. 69, 2001, p. 49-64
- [43] Kim, K. J.: *Artificial neural networks with evolutionary instance selection for financial forecasting*, Expert Systems with Applications, Vol. 30, 2006, p. 519-526
- [44] Ko, P. C., Lin, P. C.: *An evolution-based approach with modularized evaluations to forecast financial distress*, Knowledge-Based Systems, Vol. 19, 2006, p. 84-91
- [45] Kohonen, T., *Self-Organization and Associative Memory*, 2nd Ed., Berlin: Springer-Verlag, 1987.
- [46] Kolačević, S., Hreljac, B.: *Vrednovanje poduzeća*, TEB poslovno savjetovanje d.o.o., Zagreb, 2009.
- [47] Koletnik, F.: *Koliko vrijedi poduzeće: teorijski i praktični aspekti vrednovanja poduzeća*, Savez računovodstvenih i financijskih radnika Hrvatske, Zagreb, 1991.
- [48] Lam, M.: *Neural network techniques for financial performance prediction: integrating fundamental and technical analysis*, Decision Support Systems, Vol. 37, 2004, p. 567- 581
- [49] M&I, Mergers and Inquisitions, [Online] dostupno na: www.mergersandinquisitions.com/oil-gas-modeling (2013.)

- [50] Malagoli, S., Mastreoleo, G., Magni, C.A.: *The use of fuzzy logic and expert systems for rating and pricing firms: a new perspective on valuation*, University of Modena and Reggio Emilia, MPRA Paper No. 11958, 2005.
- [51] McCulloch, W., Pitts, W.: *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics, Vol. 7, 1943, p. 115 - 133
- [52] McIvor, R.T., McCloskey, A.G., Humphreys, P.K., Maguire, L.P.: *Using a fuzzy approach to support financial analysis in the corporate acquisition process*, Expert Systems with Applications, Vol.27, 2004, p.533-547
- [53] Mesarić, J., Pekić, N., Zekić-Sušac, M.: *Intelligent decision support for small business using expert systems and neural networks*, Proceedings of the 15th International Conference on Information and Intelligent Systems (IIS 2004), B. Aurier, D. Kermek (eds.), University of Zagreb, Faculty of Organization and Informatics Varaždin, 2004, p. 343-354
- [54] Miles, R.C.: *Basic Business Appraisal*, First Edition, John Wiley & Sons, Inc., New Jersey, 1984.
- [55] Misund, B., Asche, F., Osmundsen, P.: *Industry upheaval and valuation: Empirical evidence from the international oil and gas industry*, The international Journal of Accounting, Vol. 43, 2008, p. 398-424
- [56] Moser, U., Goddar, H.: *Fundamental Principles in the Valuation of Intangible Assets, Taking the Valuation of Technologies Protected by Patents as an Example*, Innovation performance accounting, Vol.2, 2009, p. 113-166
- [57] Mrša, J., Miljak, T.: *Realni dometi MSFI-ja 13 - Mjerenje fer vrijednosti*, Zbornik 13. Međunarodnog simpozija Fiskalni okvir i održivi razvoj BiH, Neum, Bosna i Hercegovina, 2012.
- [58] Orsag, S.: *Vrednovanje poduzeća*, Infoinvest, Zagreb, 1997.
- [59] Osmundsen, P., Asche, F., Misund, B., Mohn, K.: *Valuation of International Oil Companies*, The Energy Journal, Vol. 27., 2006., p.49-66
- [60] Palepu, G. K., Healy, M.P.: *Business Analysis & Valuation Using Financial Statements*, 4th edition, Thomson Learning, Inc, 2008.
- [61] Palit, K. A., Popović D.: *Computational Intelligence in Time Series Forecasting*, Springer-Verlag London Limited, 2005.
- [62] Pan, Y.H., He, H.: *Evaluation Techniques for Oil Gas Reservoir Based on Artificial Neural Networks Techniques*, Proceeding BIFE '10 Proceedings of the 2010 Third International Conference on Business Intelligence and Financial Engineering, Washington, p. 28-31
- [63] Perić, M.: *Englesko hrvatski enciklopedijski rječnik istraživanja i proizvodnje nafte plina*, INA Industrija nafte d.d., Sektor korporativnih komunikacija, Zagreb, 2007.
- [64] Pratt, S. P., Grabowski, R. J.: *Cost of capital: applications and examples*, John Wiley & Sons, New Jersey, 2008.

- [65] Pratt, S. P., Niculita, A. V.: *Valuing a Business - The Analysis and Appraisal of Closely Held Companies*, McGraw-Hill, New York, 2008.
- [66] Pratt, S. P., Niculita, A. V., Twitchell, D.: *Business Valuation - Body of Knowledge*, John Wiley & Sons, New Jersey, 2003.
- [67] Pratt's Stats - Private Company Merger and Acquisition (M&A) Transaction Database, 2014, [online] Available: www.bvmarketdata.com (2014)
- [68] Raymond, M.S., Leffer W.L.: *Oil and Gas Production in Nontechnical Language*, PennWell Corporation, Tulsa, 2006.
- [69] Sarlija, N., Bensic, M., Zekic-Susac, M.: *Logistic refression, survival analysis and neural networks in modeling customer credit scoring*, WSEAS Transactions on Business and Economics, Vol 3, 2006
- [70] Seng, J., Lai, J.T.: *An Inteligent information segmentation approach to extract financial data for business valuation*, Expert Systems with Applications, Vol. 37, 2010, p. 6515-6530
- [71] Sevastjanov, P., Dimova, L., Sevastianov, D.: *Fuzzy Capital Budgeting: Investment Project Evaluation and Optimization*, Fuzzy Applications in Industrial Engineering, Vol. 201/2006, 2006, p. 205-228
- [72] Smith, K. A., Gupta, J. N.: *Neural Networks in Business: Techniques and Applications*, IGI Publishing, London, 2002.
- [73] Stevens, P.: *A methodology for assetting the performance of national oil companies*, The World Bank, Washington D.C., 2008.
- [74] Tham, J., Vélez-Pareja, I.: *Principles Of Cash Flow Valuation - An Integrated Market-Based Approach*, Elsevier, London, 2004.
- [75] Thawornwong, S., Enke, D.: *The adaptive selection of financial and economic variables for use with artificial neural networks*, Neurocomputing, Vol. 56, 2004, p. 205-232
- [76] The MathWorks, *Fuzzy Logic Toolbox - Help Documentation*, The MathWorks, Natick, MA, 2010.
- [77] The MathWorks, *MATLAB programski sustav*, [Online] dostupno na: www.mathworks.com (2014.)
- [78] Tichy, E.G.: *Procjena vrijednosti poduzeća - osnove, metode, praksa*, 2. Neizmijenjeno izdanje, Zgombić & Partneri - nakladništvo i informatika d.o.o., Zagreb, 2009.
- [79] Tillman Cassone, D.: *A proces to estimate the value of a company based on operational performance metrics*, doctoral disertation, Kansas State University, Manhattan, Kansas, 2005.
- [80] Tireli, E.: *Goriva i njihova primjena na brodu*, Sveučilište u Rijeci, Pomorski fakultet u Rijeci, 2005.

- [81] Tsai, C. F., Chiou, Y. J.: *Earnings management prediction: A pilot study of combining neural networks and decision trees*, Expert Systems with Applications, Vol. 36, 2009, p. 7183–7191
- [82] Two Tomorrows, *Tomorrow's value Rating of the world's largest oil and gas companies* 2010, [Online] dostupno na: www.tomorrowsvaluerating.com (lipanj 2012.)
- [83] Vukas, J.: *Valuacija nefinancijskih korporacija u Republici Hrvatskoj*, Doktorska disertacija, Ekonomski fakultet, Sveučilište u Splitu, Split, 2012.
- [84] Wagner, W.P., Otto, J., Chung, Q.B.: *Knowledge acquisition for expert systems in accounting and financial problem domains*, Knowledge-Based Systems, Vol. 15, 2002, p. 439-447
- [85] Wall Street Prep, *Oil & Gas Financial & Valuation Modeling Training Program*, Wall Street Prep Financial Training Solutions, 2009.
- [86] Wang, Y. F.: *Mining stock price using fuzzy rough set system*, Expert Systems with Applications, Vol. 24, 2003, p. 13–23
- [87] Wong, B.K., Laib, V.S.: *A survey of application of fuzzy set theory in production and operations management*, International Journal of Production Economics, Vol. 129, 2011, p. 157-168
- [88] Wright, C.J., Gallun, R.A.: *Fundamentals of Oil & Gas Accounting*, 5th edition, PennWell Corporation, Tulsa, 2008.
- [89] Yang, Z. R., Platt, M. B., Platt, H. D.: *Probabilistic Neural Networks in Bankruptcy Prediction*, Journal of Business Research, Vol. 44, 1999, p. 67–74
- [90] Yao, J.S., Chen, M.S., Lin, H.W.: *Valuation by using a fuzzy discounted cash flow model*, Expert Systems with Applications, Vol.28, 2005, p.209-222
- [91] Zarandi, M. H. F., Rezaee, B., Turksen, I. B., Neshat, E.: *A type-2 fuzzy rule-based expert system model for stock price analysis*, Expert Systems with Applications, Vol. 36, 2009, p. 139–154
- [92] Zekic-Susac, M., Klicek, B.: *A Nonlinear Strategy of Selecting NN Architectures for Stock Return Predictions*, Finance, Proceedings from the 50th Anniversary Financial Conference Svishtov, Bulgaria, 11-12 April, 2002., ABAGAR, Veliko Tarnovo, 2002, p. 325–355
- [93] Zekić-Sušac, M.: *Neuronske mreže u predviđanju profitabilnosti ulaganja*, Doktorska disertacija, Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin, 1999.
- [94] Zhang, G., Hu, M. Y., Patuwo, B. E., Indro, D. C.: *Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis*, European Journal of Operational Research, Vol. 116, 1999, p. 16–32
- [95] Žager, L. et al.: *Analiza financijskih izvještaja*, 2. prošireno izdanje, Masmedia, Zagreb, 2008.

POPIS TABLICA

Redni broj i naziv tablice	Stranica
Tablica 1. Odobrene rezerve nafte i prirodnog plina na kraju 2012. godine	55
Tablica 2. Razlike u financijskim izvještajima s obzirom na amortizaciju	69
Tablica 3. Efekti prilagodbe pokazatelja <i>EBITDA</i> u pokazatelj <i>EBITDAX</i>	75
Tablica 4. Rangovi poslovne izvrsnosti i prognoze za budućnost poslovanja poduzeća temeljeni na <i>BEX</i> indeksu	84
Tablica 5. Pregled rezultata analiza likvidnosti, profitabilnosti, aktivnosti, stvaranja vrijednosti i poslovne izvrsnosti za promatrana poduzeća po sektorima	85
Tablica 6. Raspodjela ispitanih eksperata po državama	117
Tablica 7. Udio ispitanika prema stupnju obrazovanja	117
Tablica 8. Udio ispitanika prema industrijskim granama poduzeća u kojima su zaposleni	118
Tablica 9. Udio ispitanika prema poslovnim sektorima	118
Tablica 10. Udio ispitanika prema duljini radnog iskustva	118
Tablica 11. Utjecaj pojedinih pristupa vrednovanju po sektorima industrije	119
Tablica 12. Odabrani financijski parametri za analizu s obzirom na vrijednost poduzeća	123
Tablica 13. Rangiranje pojedinih parametara s obzirom na njihov utjecaj na vrijednost poduzeća <i>VP</i>	125
Tablica 14. Rangiranje pojedinih parametara s obzirom na njihov utjecaj na multiplikator <i>multVP</i>	126
Tablica 15. Rangiranje čimbenika koji utječu na stvaranje uporabne vrijednosti	131
Tablica 16. Rangiranje čimbenika koji utječu na stvaranje tržišne vrijednosti	132
Tablica 17. Vrijednosti poduzeća za sektor <i>IM</i> temeljene na klasičnom i ekspertnom pristupu	148
Tablica 18. Vrijednosti multiplikatora <i>multTR</i> , <i>multVP</i> i <i>multUP</i> za sektor <i>IM</i>	149
Tablica 19. Vrijednosti ulaznih parametara za FIS1 i FIS2 za sektor <i>IM</i>	152

Tablica 20.	Rasponi vrijednosti ulaznih i izlaznih parametara za FIS1 po sektorima	153
Tablica 21.	Rasponi vrijednosti ulaznih i izlaznih parametara za FIS2 po sektorima	153
Tablica 22.	Pregled svih 125 AKO-ONDA pravila korištenih za FIS1 i FIS2 u okviru ispitivanja suvremenog modela procjene vrijednosti	155
Tablica 23.	Vrijednosti multiplikatora $mult\Delta VP_1$, $mult\Delta VP_2$ i $mult\Delta VP$ i korigirane vrijednosti poduzeća za IM sektor	159
Tablica 24.	Ocjena uspješnosti kreiranih unaprijednih neuronskih mreža za procjenu otežane i korigirane vrijednosti poduzeća	161
Tablica 25.	Srednja kvadratna odstupanja između tržišne, otežane, korigirane i uporabne vrijednosti poduzeća po sektorima	167
Tablica 26.	Srednja kvadratna odstupanja između multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti poduzeća po sektorima	167

POPIS SLIKA

Redni broj i naziv slike	Stranica
Slika 1. Komponente fer tržišne vrijednosti poduzeća	23
Slika 2. Poveznica troška kapitala i troška vlastitog kapitala	41
Slika 3. Mjesečno kretanje cijena nafte (\$/bbl) prilagođenih inflaciji od 1970. godine	57
Slika 4. Mjesečno kretanje realnih cijena prirodnog plina u \$/MMBtu na Henry Hub distributivnom čvorištu od 1998. godine	58
Slika 5. Pojednostavljeni prikaz višeslojne umjetne neuronske mreže	97
Slika 6. Hiperbolična tangentna sigmoidna prijenosna funkcija	99
Slika 7. Linearna prijenosna funkcija	99
Slika 8. Dijagram slojeva unaprijedne neuronske mreže	100
Slika 9. Shematski prikaz procesa učenja neuronske mreže	101
Slika 10. Radijalna bazna funkcija	102
Slika 11. Dijagram slojeva generalizirane regresijske neuronske mreže	103
Slika 12. Dijagram slojeva samoorganizirajuće neuronske mreže (SOM)	106
Slika 13. Generalizirana zvonolika (gbellmf) i trokutasta funkcija pripadnosti (trimf)	109
Slika 14. Pojednostavljeni prikaz procesa kreiranja neizrazitog sustava zaključivanja uz međusobnu interakciju pojedinih faza procesa	111
Slika 15. Arhitektura unaprijedne neuronske mreže s 20 neurona u skrivenom sloju	124
Slika 16. Arhitektura samoorganizirajuće neuronske mreže s 20 neurona u skrivenom sloju	127
Slika 17. Vizualizacija težinskih koeficijenata u težinskoj ravnini SOM-a za parametre 1.-19. i 36. iz tablice 12.	128
Slika 18. Vizualizacija težinskih koeficijenata u težinskoj ravnini SOM-a za parametre 20.-37. iz tablice 12.	129
Slika 19. Koncept modela suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije	137
Slika 20. Struktura modela suvremenog pristupa vrednovanju poduzeća naftne i plinske industrije	140

Slika 21.	Detaljan prikaz simulacijskog modela za vrednovanje poduzeća naftne i plinske industrije suvremenim pristupom	147
Slika 22.	Pojednostavljeni prikaz arhitekture neizrazitog sustava zaključivanja FIS1	154
Slika 23.	Pojednostavljeni prikaz arhitekture neizrazitog sustava zaključivanja FIS2	156
Slika 24.	Funkcije pripadnosti ulaznih i izlaznih varijabli za FIS1	156
Slika 25.	Funkcije pripadnosti ulaznih i izlaznih varijabli za FIS2	157
Slika 26.	Primjer vizualizacije preslikavanja neizrazitog sustava zaključivanja FIS1	158
Slika 27.	Primjer vizualizacije preslikavanja neizrazitog sustava zaključivanja FIS2	158
Slika 28.	Dijagram slojeva testirane unaprijedne neuronske mreže u neuro-determinističkom dijelu modela	160
Slika 29.	Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća <i>IM</i> sektora	162
Slika 30.	Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća <i>E&P</i> sektora	163
Slika 31.	Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća <i>R&M</i> sektora	164
Slika 32.	Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća <i>OFS</i> sektora	165
Slika 33.	Komparacija multiplikatora tržišne, otežane, korigirane i uporabne vrijednosti za poduzeća <i>T&S</i> sektora	166

PRILOZI

Prilog 1. Popis analiziranih poduzeća za potrebe analize osnovnih financijskih pokazatelja po pojedinim sektorima naftne i plinske industrije

Sektor industrije: Integrirana naftno-plinska poduzeća (IM)

R.br.	Naziv poduzeća	Država	R.br.	Naziv poduzeća	Država
1.	Royal Dutch Shell	Nizozemska	14.	Cenovus Energy	Kanada
2.	BP plc	UK	15.	Origin Energy Ltd.	Australija
3.	Total SA	Francuska	16.	PetroChina Co. Ltd.	Kina
4.	Eni SpA	Italija	17.	Gazprom	Rusija
5.	Statoil ASA	Norveška	18.	LUKOIL	Rusija
6.	OMV	Austrija	19.	PTT Public Co.	Tajland
7.	BG Group plc	UK	20.	Surgutneftgas	Rusija
8.	Gas Plus S.p.A.	Italija	21.	Sasol Ltd.	JAR
9.	Repsol, S.A.	Španjolska	22.	YPF S.A.	Argentina
10.	Polskie Gornictwo Naftowe	Poljska	23.	Petrobras Argentina	Argentina
11.	Suncor Energy Inc.	Kanada	24.	Dana Gas PJSC	UAE
12.	Imperial Oil Ltd.	Kanada	25.	Yakutsk Fuel and Energy Company	Rusija
13.	Husky Energy Inc.	Kanada	26.	Ecopetrol SA	Kolumbija

Sektor industrije: Eksploatacijsko-proizvodni (E&P)

R.br.	Naziv poduzeća	Država	R.br.	Naziv poduzeća	Država
1.	Tullow Oil plc	UK	21.	Kunlun Energy Company Limited	Kina
2.	Bonheur ASA	Norveška	22.	Total Gabon	Gabon
3.	Afren PLC	UK	23.	Dragon Oil plc	UAE
4.	Premier Oil plc	UK	24.	PT Energi Mega Persada	Indonezija
5.	Lundin Petroleum	Švedska	25.	GeoPark Limited	Bermuda
6.	Fred Olsen Energy	Norveška	26.	RH PetroGas Limited	Singapur
7.	EnQuest PLC	UK	27.	Slavneft-Megionneftegaz	Rusija
8.	Maurel & Prom	Francuska	28.	PetroEnergy Resources Corp.	Filipini
9.	DNO International	Norveška	29.	Canadian Natural Resources Limited	Kanada
10.	Genel Energy plc	UK	30.	Woodside Petroleum	Australija
11.	Ithaca Energy Inc.	UK	31.	Encana Corporation	Kanada
12.	Exillon Energy plc	Otok Man	32.	Talisman Energy Inc.	Kanada
13.	JKX Oil & Gas plc	UK	33.	Pacific Rubiales Energy Corp.	Kanada
14.	Misen Energy AB	Švedska	34.	Canadian Oil Sands Limited	Kanada
15.	Tethys Oil AB	Švedska	35.	Santos Limited	Australija
16.	Circle Oil plc	Ireland	36.	Crescent Point Energy Corp.	Kanada
17.	Urals Energy Public Company Limited	Cipar	37.	Penn West Petroleum Ltd.	Kanada
18.	Global Energy Development plc	UK	38.	New Zealand Oil & Gas Limited	Novi Zeland
19.	CNOOC Ltd.	Kina	39.	Ipek Dogal Enerji	Turska
20.	OAo Novatek	Rusija	40.	Amerisur Resources PLC	UK

Sektor industrije: Sektor rafiniranja i marketinga (R&M)

R.br.	Naziv poduzeća	Država	R.br.	Naziv poduzeća	Država
1.	Neste Oil Corp.	Finska	21.	The New Zealand Refining Company	Novi Zeland
2.	Esso S.A.F.	Francuska	22.	Australijan Renewable Fuels	Australija
3.	Hellenic Petroleum	Grčka	23.	Alon USA Energy	SAD
4.	Motor Oil Hellas Corinth Refineries	Grčka	24.	Calumet Specialty Products L.P	SAD
5.	OMV Petrol Ofisi AS	Turska	25.	CVR Energy Inc	SAD
6.	Turkiye Petrol Rafinerileri A.S.	Turska	26.	Delek US Holdings	SAD
7.	Indian Oil Corporation Ltd.	Indija	27.	HollyFrontier Corp.	SAD
8.	Reliance Industries Limited	Indija	28.	Marathon Petroleum	SAD
9.	Bharat Petroleum Corp. Ltd.	Indija	29.	Northern Tier Energy LP	SAD
10.	Hindustan Petroleum Corp.	Indija	30.	PBF Energy Inc	SAD
11.	Mangalore Refinery and Petrochemicals	Indija	31.	Phillips 66	SAD
12.	Chennai Petroleum Corporation Ltd	Indija	32.	Suncor Energy	SAD
13.	Bangchak Petroleum Public	Tajland	33.	Tesoro Corp.	SAD
14.	Paz Oil Company	Izrael	34.	Valero Energy	SAD
15.	Refineria La Pampilla S.A.A.	Peru	35.	Western Refining Inc	SAD
16.	Petron Malaysia R&M	Malezija	36.	CVR Refining LP	SAD
17.	Strong Petrochemical Holdings	Kina (H.K.)	37.	Turcas Petrol AS	Turska
18.	Caltex Australia Ltd.	Australija	38.	Formosa Petrochemical Corp.	Tajvan
19.	Parkland Fuel Corporation	Kanada	39.	Sinopec Shandong Taishan Petroleum	Kina
20.	Keyera Corp.	Kanada	40.	Saudi Arabia Refineries Company	Saudijska Arabija

Sektor industrije: Sektor potpore na naftnim poljima (OFS)

R.br.	Naziv poduzeća	Država	R.br.	Naziv poduzeća	Država
1.	Saipem SpA	Italija	21.	Petrofac Limited	Kanalski otoci
2.	Weatherford International Ltd.	Švicarska	22.	Ezra Holdings Ltd.	Singapur
3.	Aker Solutions ASA	Norveška	23.	Scomi Group Bhd	Malezija
4.	John Wood Group	UK	24.	Boustead Singapur	Singapur
5.	Subsea 7 SA	UK	25.	Hilong Holding	Kina
6.	SBM Offshore N.V.	Nizozemska	26.	Anton Oilfield Services Group	Kina
7.	Tecnicas Reunidas	Španjolska	27.	Japaul Oil and Maritime Services	Nigerija
8.	CGG	Francuska	28.	Sea Production Ltd.	Bermuda
9.	Kvaerner ASA	Norveška	29.	Atwood Oceanics	SAD
10.	Spectrum ASA	Norveška	30.	Basic Energy Services Inc.	SAD
11.	WorleyParsons	Australija	31.	Diamond Offshore	SAD
12.	Trican Well Service	Kanada	32.	Halliburton Co.	SAD
13.	ShawCor Ltd.	Kanada	33.	Helix Energy Solutions	SAD
14.	Enerflex Ltd.	Kanada	34.	Hornbeck Offshore Services Inc	SAD
15.	Calfrac Well Services	Kanada	35.	ION Geophysical	SAD
16.	Mullen Group Ltd.	Kanada	36.	Key Energy Services	SAD
17.	Pason Systems Inc.	Kanada	37.	Transocean Ltd.	SAD
18.	Total Energy Services Inc.	Kanada	38.	Xinjiang Zhundong Petroleum Technol.	Kina
19.	Zedi Inc.	Kanada	39.	Viking Offshore and Marine Limited	Singapur
20.	Hyduke Energy Services Inc.	Kanada	40.	NXT Energy Solutions Inc	SAD

Sektor industrije: Transport i skladištenje nafte i plina (T&S)

R.br.	Naziv poduzeća	Država	R.br.	Naziv poduzeća	Država
1.	Royal Vopak NV	Nizozemska	21.	Prime Oil Chemical Service Corporation	Tajvan
2.	James Fisher and Sons Public Ltd Co	UK	22.	Phoenix Petroleum Philippines Inc	Filipini
3.	StealthGas, Inc.	Grčka	23.	China Merchants Energy Shipping	Kina
4.	Awilco LNG ASA	Norveška	24.	Hengyang Petrochemical Logistics	Kina
5.	Docks des Petroles d'Ambes SA	Francuska	25.	Golar LNG Ltd.	Bermuda
6.	Exmar NV	Belgija	26.	Enbridge Inc.	SAD
7.	Pan European Terminals PLC	UK	27.	Kinder Morgan Inc.	SAD
8.	Enbridge Inc.	Kanada	28.	ONEOK Inc.	SAD
9.	TransCanada Corp.	Kanada	29.	Pembina Pipeline Corp.	SAD
10.	Gibson Energy Inc.	Kanada	30.	Spectra Energy	SAD
11.	Pembina Pipeline Corporation	Kanada	31.	Williams Cos.	SAD
12.	AltaGas Ltd.	Kanada	32.	Atlas Pipeline Partners L.P.	SAD
13.	SK Gas Co., Ltd.	Južna Koreja	33.	Energy Transfer	SAD
14.	The National Shipping Company	Saudijska Arabija	34.	GasLog Ltd.	Monako
15.	Frontline Ltd.	Bermuda	35.	Veresen Inc.	Kanada
16.	Teekay LNG Partners LP.	Bermuda	36.	Enbridge Income Fund Holdings Inc.	Kanada
17.	Golar LNG Partners Limited Partnership	Bermuda	37.	Fortune Oil plc	Kina (H.K.)
18.	Essar Ports Limited	Indija	38.	Zhejiang Haiyue Co. Ltd.	Kina
19.	Ship Finance International Ltd	Bermuda	39.	NGL Energy Partners LP	SAD
20.	Höegh LNG Holdings Ltd.	Bermuda	40.	EQT Midstream Partners LP	SAD

Prilog 2. Vrijednosti poduzeća za sektore *E&P*, *R&M*, *OFS* i *T&S* temeljene na klasičnom i ekspertnom pristupu

Sektor industrije: Eksploatacijsko-proizvodni (*E&P*)

R.br.	Naziv poduzeća	Država	Vrijednost poduzeća (mil. USD)			
			VP _{IM}	VP _{PR}	VP _{TR}	VP
1.	Tullow Oil plc	UK	7284,18	14583,77	12877,30	11471,56
2.	Bonheur ASA	Norveška	1976,70	2031,14	684,70	1615,68
3.	Afren PLC	UK	2225,75	4097,70	3076,80	3128,04
4.	Premier Oil plc	UK	2913,67	4375,70	2709,60	3362,88
5.	Lundin Petroleum	Švedska	1446,90	6820,10	6046,40	4671,10
6.	Fred Olsen Energy	Norveška	2326,50	3374,14	2695,10	2799,80
7.	EnQuest PLC	UK	3232,13	1848,57	1738,50	2310,96
8.	Maurel & Prom	Francuska	1041,82	2465,20	1937,80	1801,09
9.	DNO International	Norveška	1816,08	4016,39	4027,20	3232,74
10.	Genel Energy plc	UK	2543,21	4124,10	4991,20	3813,79
11.	Ithaca Energy Inc.	UK	992,79	1189,29	809,90	1007,44
12.	Exillon Energy plc	Otok Man	352,27	481,03	449,50	425,71
13.	JKX Oil & Gas plc	UK	565,56	198,31	197,50	329,40
14.	Misen Energy AB	Švedska	341,80	283,46	255,30	296,04
15.	Tethys Oil AB	Švedska	119,08	396,50	373,70	290,59
16.	Circle Oil plc	Ireland	241,44	192,00	185,40	207,74
17.	Urals Energy Public Company Limited	Cipar	55,98	27,74	22,00	36,15
18.	Global Energy Development plc	UK	58,32	66,91	55,10	60,36
19.	CNOOC Ltd.	Kina	105237,29	101137,98	83033,00	97279,22
20.	OAo Novatek	Rusija	16526,62	40859,60	36832,90	30973,87
21.	Kunlun Energy Company Limited	Kina	9545,70	16251,31	14203,90	13251,24
22.	Total Gabon	Gabon	3091,65	2840,60	2884,10	2943,17
23.	Dragon Oil plc	UAE	5607,20	4583,49	4620,10	4960,34
24.	PT Energi Mega Persada	Indonezija	562,66	1233,64	256,20	706,23
25.	GeoPark Limited	Bermuda	315,73	661,59	441,10	473,07

26.	RH PetroGas Limited	Singapur	176,35	380,78	351,50	299,06
27.	Slavneft-Megionneftegaz	Rusija	5422,44	2310,80	1769,60	3264,36
28.	PetroEnergy Resources Corp.	Filipini	45,26	74,20	33,50	51,88
29.	Canadian Natural Resources Limited	Kanada	44128,67	46706,34	36736,70	42852,50
30.	Woodside Petroleum	Australija	29323,90	32100,52	28663,50	30096,77
31.	Encana Corporation	Kanada	42540,44	18058,72	13363,70	25432,58
32.	Talisman Energy Inc.	Kanada	6816,84	18009,55	12038,30	12250,89
33.	Pacific Rubiales Energy Corp.	Kanada	4087,68	7621,38	5602,30	5763,92
34.	Canadian Oil Sands Limited	Kanada	14937,24	9802,60	9113,40	11436,05
35.	Santos Limited	Australija	13372,66	16388,39	12694,40	14223,56
36.	Crescent Point Energy Corp.	Kanada	7361,49	17149,79	15309,90	13108,38
37.	Penn West Petroleum Ltd.	Kanada	6514,78	7494,22	4089,30	6142,58
38.	New Zealand Oil & Gas Limited	Novi Zeland	246,92	157,21	278,40	224,93

Sektor industrije: Sektor rafiniranja i marketinga (R&M)

R.br.	Naziv poduzeća	Država	Vrijednost poduzeća (mil. USD)			
			VP _{IM}	VP _{PR}	VP _{TR}	VP
1.	Neste Oil Corp.	Finska	3216,50	7834,63	5081,10	5848,50
2.	Esso S.A.F.	Francuska	1323,12	1447,30	725,80	1173,44
3.	Hellenic Petroleum	Grčka	2033,75	6678,79	3190,40	4436,60
4.	Motor Oil Hellas Corinth Refineries	Grčka	719,65	2646,29	1254,10	1734,91
5.	OMV Petrol Ofisi AS	Turska	993,38	2834,30	1113,80	1830,64
6.	Turkiye Petrol Rafinerileri A.S.	Turska	3799,87	6273,00	5004,70	5279,37
7.	Indian Oil Corporation Limited	Indija	12816,48	8527,21	8406,20	9458,84
8.	Reliance Industries Limited	Indija	32641,17	46767,10	46767,10	43555,84

9.	Bharat Petroleum Corp. Ltd.	Indija	3304,41	4066,70	4066,70	3893,25
10.	Hindustan Petroleum Corp. Ltd.	Indija	1519,83	1299,20	1299,20	1349,15
11.	Mangalore Refinery and Petrochemicals	Indija	1189,53	2321,50	1199,10	1682,36
12.	Chennai Petroleum Corporation Ltd	Indija	428,07	1316,39	167,30	723,58
13.	Bangchak Petroleum Public	Tajland	1243,23	1885,71	1173,10	1497,18
14.	Paz Oil Company	Izrael	722,78	3402,61	1659,30	2200,70
15.	Refineria La Pampilla S.A.A.	Peru	387,96	894,70	133,50	520,54
16.	Petron Malaysia Refining&Marketing	Malezija	297,72	534,26	247,30	382,86
17.	Strong Petro-chemical Holdings	Kina (H.K.)	309,32	385,94	323,20	347,16
18.	Caltex Australia Ltd.	Australija	2361,90	6133,03	4841,50	4836,86
19.	Parkland Fuel Corporation	Kanada	778,84	1573,57	1243,60	1280,72
20.	Keyera Corp.	Kanada	1321,50	5806,71	4746,20	4427,09
21.	The New Zealand Refining Company	Novi Zeland	621,19	573,09	475,10	550,61
22.	Australijan Renewable Fuels	Australija	23,56	45,20	28,10	34,46
23.	Alon USA Energy	SAD	843,38	1386,40	915,70	1102,82
24.	Calumet Specialty Products L.P	SAD	1777,64	2615,90	1792,50	2145,15
25.	CVR Energy Inc	SAD	3417,64	3294,80	3292,60	3321,61
26.	Delek US Holdings	SAD	2222,17	1541,70	1781,20	1777,51
27.	HollyFrontier Corp.	SAD	14166,01	8062,20	9112,80	9804,48
28.	Marathon Petroleum	SAD	27704,23	24468,10	25967,10	25710,36
29.	Northern Tier Energy LP	SAD	1516,31	2282,30	2272,70	2104,93
30.	PBF Energy Inc	SAD	222,80	1609,80	1165,70	1143,66
31.	Phillips 66	SAD	36985,09	46199,00	42699,00	42911,77
32.	Suncor Energy	SAD	37804,14	61462,00	54830,00	53828,65
33.	Tesoro Corp.	SAD	6989,92	7615,10	7664,10	7489,10
34.	Valero Energy	SAD	22888,80	30175,80	24849,80	26706,20
35.	Western Refining Inc	SAD	3040,12	3121,20	3065,20	3083,43
36.	CVR Refining LP	SAD	4592,05	3901,20	3281,10	3846,61

Sektor industrije: Sektor potpore na naftnim poljima (OFS)

R.br.	Naziv poduzeća	Država	Vrijednost poduzeća (mil. USD)			
			VP _{IM}	VP _{PR}	VP _{TR}	VP
1.	Saipem SpA	Italija	8338,48	16667,10	9445,10	12711,59
2.	Weatherford International Ltd.	Švicarska	6677,44	21862,84	11917,90	15739,17
3.	Aker Solutions ASA	Norveška	3709,95	7763,11	4857,80	6043,91
4.	John Wood Group	UK	3370,23	4775,33	4130,60	4301,74
5.	Subsea 7 SA	UK	4557,43	7763,35	6415,30	6724,32
6.	SBM Offshore N.V.	Nizozemska	1502,21	6711,08	4254,60	4932,99
7.	Tecnicas Reunidas	Španjolska	1146,76	2241,90	2922,20	2272,21
8.	CGG	Francuska	2848,41	6388,95	3050,50	4616,82
9.	Kværner ASA	Norveška	478,96	496,55	509,60	497,75
10.	Spectrum ASA	Norveška	211,63	263,50	256,70	251,76
11.	WorleyParsons	Australija	4470,41	4991,66	3664,00	4448,39
12.	Trican Well Service	Kanada	1450,49	2458,08	1819,50	2058,95
13.	ShawCor Ltd.	Kanada	1561,79	2756,31	2397,60	2417,65
14.	Enerflex Ltd.	Kanada	1054,09	1124,26	1102,00	1103,96
15.	Calfrac Well Services	Kanada	1181,77	1780,19	1350,60	1526,14
16.	Mullen Group Ltd.	Kanada	1443,68	2801,59	2421,20	2425,86
17.	Pason Systems Inc.	Kanada	837,23	1592,31	1777,10	1517,21
18.	Total Energy Services Inc.	Kanada	662,02	653,09	603,50	637,97
19.	Zedi Inc.	Kanada	66,96	115,98	94,70	99,87
20.	Hydruke Energy Services Inc.	Kanada	27,91	21,65	12,10	19,57
21.	Petrofac Limited	Kanalski otoci	4038,43	7533,98	6907,80	6685,98
22.	Ezra Holdings Ltd.	Singapur	1233,04	2792,42	1061,50	1923,93
23.	Scomi Group Bhd	Malezija	241,66	455,50	173,20	321,23
24.	Boustead Singapur	Singapur	613,76	576,47	689,50	621,43
25.	Hilong Holding	Kina	899,12	1547,54	1451,80	1397,13
26.	Anton Oilfield Services Group	Kina	778,15	1370,50	1313,30	1243,32
27.	Japaul Oil and Maritime Services	Nigerija	69,26	101,10	21,10	68,29
28.	Sea Production Ltd.	Bermuda	165,88	76,63	1,63	67,55

29.	Atwood Oceanics	SAD	3138,99	4493,00	3310,50	3847,10
30.	Basic Energy Services Inc.	SAD	321,68	1348,10	599,60	908,42
31.	Diamond Offshore	SAD	6300,82	7852,10	7841,60	7566,07
32.	Halliburton Co.	SAD	21947,56	44338,70	42002,70	39472,41
33.	Helix Energy Solutions	SAD	787,17	2891,60	2309,50	2311,81
34.	Hornbeck Offshore Services Inc	SAD	829,69	2267,90	1755,20	1832,86
35.	ION Geophysical	SAD	601,68	537,50	493,20	534,23
36.	Key Energy Services	SAD	1190,34	1974,20	1171,60	1560,42
37.	Transocean Ltd.	SAD	15526,12	24696,00	17534,00	20607,56

Sektor industrije: Transport i skladištenje nafte i plina (T&S)

R.br.	Naziv poduzeća	Država	Vrijednost poduzeća (mil. USD)			
			VP _{IM}	VP _{PR}	VP _{TR}	VP
1.	Royal Vopak NV	Nizozemska	4510,63	10581,65	7461,90	7937,12
2.	James Fisher and Sons Public Ltd Co	UK	586,92	1227,52	1033,60	990,38
3.	StealthGas, Inc.	Grčka	295,18	471,75	209,40	341,67
4.	Awilco LNG ASA	Norveška	253,86	352,34	207,70	280,31
5.	Docks des Petroles d'Ambes SA	Francuska	43,02	15,72	16,90	23,63
6.	Exmar NV	Belgija	561,52	1735,85	858,80	1139,56
7.	Pan European Terminals PLC	UK	36,08	46,56	35,20	40,14
8.	Enbridge Inc.	Kanada	21612,89	58961,91	36179,30	41580,59
9.	TransCanada Corp.	Kanada	32104,17	55404,23	32303,40	41807,46
10.	Gibson Energy Inc.	Kanada	2578,58	3877,27	3151,00	3293,31
11.	Pembina Pipeline Corporation	Kanada	4420,46	13440,87	11025,00	10199,19
12.	AltaGas Ltd.	Kanada	3141,58	7502,76	4564,00	5386,90
13.	SK Gas Co., Ltd.	Južna Koreja	1599,53	1054,30	598,40	1063,76
14.	The National Shipping Company	Saudijska Arabija	2486,23	3691,00	2368,50	2948,29
15.	Frontline Ltd.	Bermuda	2888,98	1639,61	319,10	1575,84

16.	Teekay LNG Partners LP.	Bermuda	2221,40	5809,03	3021,60	3953,86
17.	Golar LNG Partners Limited Partnership	Bermuda	1652,43	3024,10	1898,70	2296,32
18.	Essar Ports Limited	Indija	727,47	1285,03	427,40	865,23
19.	Ship Finance International Ltd	Bermuda	2782,20	3305,70	1527,60	2610,15
20.	Höegh LNG Holdings Ltd.	Bermuda	374,41	1131,80	540,70	739,34
21.	Prime Oil Chemical Service Corporation	Tajvan	109,31	43,00	60,50	66,75
22.	Phoenix Petroleum Philippines Inc	Filipini	179,04	373,82	145,00	249,09
23.	Kina Merchants Energy Shipping Co.	Kina	2171,57	2810,70	1887,10	2347,91
24.	Hengyang Petro-chemical Logistics	Kina	61,38	102,58	41,70	72,33
25.	Golar LNG Ltd.	Bermuda	2705,44	3281,13	2922,70	3010,97
26.	Enbridge Inc.	SAD	16780,77	53946,90	33805,90	37434,50
27.	Kinder Morgan Inc.	SAD	16854,96	67793,60	34058,60	43263,06
28.	ONEOK Inc.	SAD	4128,81	18855,60	12095,80	12690,93
29.	Pembina Pipeline Corp.	SAD	3944,99	12540,80	10013,70	9382,02
30.	Spectra Energy	SAD	12929,40	35061,40	22322,40	24997,57
31.	Williams Cos.	SAD	8392,23	33364,90	23467,90	23396,36
32.	Atlas Pipeline Partners L.P.	SAD	1420,23	3864,80	2688,30	2824,64
33.	Energy Transfer	SAD	13132,99	35547,20	19807,20	24475,66

Prilog 3. Vrijednosti multiplikatora *multTR*, *multVP* i *multUP* za poduzeća iz sektora *E&P*, *R&M*, *OFS* i *T&S*

Napomena: *EBITDA* je izražen u mil. USD

Sektor industrije: Eksploatacijsko-proizvodni (*E&P*)

R.br.	Naziv poduzeća	Država	<i>EBITDA</i>	<i>multTR</i>	<i>multVP</i>	<i>multUP</i>
1.	Tullow Oil plc	UK	1706,6	7,55	6,72	6,41
2.	Bonheur ASA	Norveška	738,3	0,93	2,19	2,71
3.	Afren PLC	UK	1061	2,90	2,95	2,98
4.	Premier Oil plc	UK	973,6	2,78	3,45	3,74
5.	Lundin Petroleum	Švedska	1116,2	5,42	4,18	3,70
6.	Fred Olsen Energy	Norveška	634,2	4,25	4,41	4,49
7.	EnQuest PLC	UK	628,1	2,77	3,68	4,04
8.	Maurel & Prom	Francuska	430,1	4,51	4,19	4,08
9.	DNO International	Norveška	370,1	10,88	8,73	7,88
10.	Genel Energy plc	UK	272,8	18,30	13,98	12,22
11.	Ithaca Energy Inc.	UK	86,4	9,37	11,66	12,63
12.	Exillon Energy plc	Otok Man	36,9	12,18	11,54	11,29
13.	JKX Oil & Gas plc	UK	126	1,57	2,61	3,03
14.	Misen Energy AB	Švedska	55,4	4,61	5,34	5,64
15.	Tethys Oil AB	Švedska	62,3	6,00	4,66	4,14
16.	Circle Oil plc	Ireland	39,2	4,73	5,30	5,53
17.	Urals Energy Public Company Limited	Cipar	6,53	3,37	5,54	6,41
18.	Global Energy Development plc	UK	11,7	4,71	5,16	5,35
19.	CNOOC Ltd.	Kina	19018,7	4,37	5,11	5,43
20.	OAo Novatek	Rusija	3183,2	11,57	9,73	9,01
21.	Kunlun Energy Company Limited	Kina	1994,7	7,12	6,64	6,47
22.	Total Gabon	Gabon	587,6	4,91	5,01	5,05
23.	Dragon Oil plc	UAE	1002,5	4,61	4,95	5,08
24.	PT Energi Mega Persada	Indonezija	341,5	0,75	2,07	2,63

25.	GeoPark Limited	Bermuda	120,9	3,65	3,91	4,04
26.	RH PetroGas Limited	Singapur	31,6	11,12	9,46	8,82
27.	Slavneft-Megionneftegaz	Rusija	851	2,08	3,84	4,54
28.	PetroEnergy Resources Corp.	Filipini	4,19	8,00	12,38	14,25
29.	Canadian Natural Resources Limited	Kanada	7488,3	4,91	5,72	6,07
30.	Woodside Petroleum	Australija	4462	6,42	6,75	6,88
31.	Encana Corporation	Kanada	2289	5,84	11,11	13,24
32.	Talisman Energy Inc.	Kanada	3495	3,44	3,51	3,55
33.	Pacific Rubiales Energy Corp.	Kanada	1986,9	2,82	2,90	2,95
34.	Canadian Oil Sands Limited	Kanada	1677,5	5,43	6,82	7,37
35.	Santos Limited	Australija	1719,4	7,38	8,27	8,65
36.	Crescent Point Energy Corp.	Kanada	1804,7	8,48	7,26	6,79
37.	Penn West Petroleum Ltd.	Kanada	1623,3	2,52	3,78	4,31
38.	New Zealand Oil & Gas Limited	Novi Zeland	52,7	5,28	4,27	3,83

Sektor industrije: Sektor rafiniranja i marketinga (R&M)

R.br.	Naziv poduzeća	Država	EBITDA	multTR	multVP	multUP
1.	Neste Oil Corp.	Finska	771,3	6,59	7,58	7,16
2.	Esso S.A.F.	Francuska	294,4	2,47	3,99	4,71
3.	Hellenic Petroleum	Grčka	414,7	7,69	10,70	10,50
4.	Motor Oil Hellas Corinth Refineries	Grčka	350,7	3,58	4,95	4,80
5.	OMV Petrol Ofisi AS	Turska	348,8	3,19	5,25	5,49
6.	Turkiye Petrol Rafinerileri A.S.	Turska	745	6,72	7,09	6,76
7.	Indian Oil Corporation Limited	Indija	2899,5	2,90	3,26	3,68
8.	Reliance Industries	Indija	6546,5	7,14	6,65	6,06

	Limited					
9.	Bharat Petroleum Corp. Ltd.	Indija	1474,2	2,76	2,64	2,50
10.	Hindustan Petroleum Corp. Ltd.	Indija	896,5	1,45	1,50	1,57
11.	Mangalore Refinery and Petrochemicals	Indija	154,2	7,78	10,91	11,38
12.	Chennai Petroleum Corporation Ltd	Indija	114,2	1,46	6,34	7,64
13.	Bangchak Petroleum Public	Tajland	208,6	5,62	7,18	7,50
14.	Paz Oil Company	Izrael	170,6	9,73	12,90	12,09
15.	Refineria La Pampilla S.A.A.	Peru	82,9	1,61	6,28	7,74
16.	Petron Malaysia Refining&Marketing	Malezija	70,2	3,52	5,45	5,93
17.	Strong Petro-chemical Holdings	Kina (H.K.)	18,4	17,57	18,87	18,89
18.	Caltex Australia Ltd.	Australija	464,9	10,41	10,40	9,14
19.	Parkland Fuel Corporation	Kanada	193,9	6,41	6,61	6,07
20.	Keyera Corp.	Kanada	336,4	14,11	13,16	10,59
21.	The New Zealand Refining Company	Novi Zeland	93,9	5,06	5,86	6,36
22.	Australijan Renewable Fuels	Australija	6,9	4,07	4,99	4,98
23.	Alon USA Energy	SAD	425,6	2,15	2,59	2,62
24.	Calumet Specialty Products L.P	SAD	394,5	4,54	5,44	5,57
25.	CVR Energy Inc	SAD	1164,9	2,83	2,85	2,88
26.	Delek US Holdings	SAD	555,6	3,21	3,20	3,39
27.	HollyFrontier Corp.	SAD	3127	2,91	3,14	3,55
28.	Marathon Petroleum	SAD	6643	3,91	3,87	3,93
29.	Northern Tier Energy LP	SAD	697,3	3,26	3,02	2,72
30.	PBF Energy Inc	SAD	1010,3	1,15	1,13	0,91
31.	Phillips 66	SAD	19223	2,22	2,23	2,16
32.	Suncor Energy	SAD	11491	4,77	4,68	4,32
33.	Tesoro Corp.	SAD	2118	3,62	3,54	3,45
34.	Valero Energy	SAD	6598	3,77	4,05	4,02
35.	Western Refining Inc	SAD	803,9	3,81	3,84	3,83
36.	CVR Refining LP	SAD	1101,5	2,98	3,49	3,86

Sektor industrije: Sektor potpore na naftnim poljima (OFS)

R.br.	Naziv poduzeća	Država	EBITDA	multTR	multVP	multUP
1.	Saipem SpA	Italija	2902	3,25	4,38	4,31
2.	Weatherford International Ltd.	Švicarska	2445	4,87	6,44	5,84
3.	Aker Solutions ASA	Norveška	753,9	6,44	8,02	7,61
4.	John Wood Group	UK	504,7	8,18	8,52	8,07
5.	Subsea 7 SA	UK	1044,1	6,14	6,44	5,90
6.	SBM Offshore N.V.	Nizozemska	569,6	7,47	8,66	7,21
7.	Tecnicas Reunidas	Španjolska	207,9	14,06	10,93	8,15
8.	CGG	Francuska	1024,1	2,98	4,51	4,51
9.	Kværner ASA	Norveška	85	6,00	5,86	5,74
10.	Spectrum ASA	Norveška	86,2	2,98	2,92	2,76
11.	WorleyParsons	Australija	525,1	6,98	8,47	9,01
12.	Trican Well Service	Kanada	242,9	7,49	8,48	8,05
13.	ShawCor Ltd.	Kanada	258	9,29	9,37	8,37
14.	Enerflex Ltd.	Kanada	156,1	7,06	7,07	6,98
15.	Calfrac Well Services	Kanada	257,9	5,24	5,92	5,74
16.	Mullen Group Ltd.	Kanada	294,8	8,21	8,23	7,20
17.	Pason Systems Inc.	Kanada	165,1	10,76	9,19	7,36
18.	Total Energy Services Inc.	Kanada	89,2	6,77	7,15	7,37
19.	Zedi Inc.	Kanada	12,1	7,83	8,25	7,56
20.	Hydruke Energy Services Inc.	Kanada	3,91	3,09	5,00	6,34
21.	Petrofac Limited	Kanalski otoci	849	8,14	7,88	6,82
22.	Ezra Holdings Ltd.	Singapur	63,8	16,64	30,16	31,55
23.	Scomi Group Bhd	Malezija	64,2	2,70	5,00	5,43
24.	Boustead Singapur	Singapur	67,6	10,20	9,19	8,80
25.	Hilong Holding	Kina	94,6	15,35	14,77	12,93
26.	Anton Oilfield Services Group	Kina	78,6	16,71	15,82	13,67
27.	Japaul Oil and Maritime Services	Nigerija	19,1	1,10	3,58	4,46
28.	Sea Production Ltd.	Bermuda	10,4	0,16	6,50	11,66

29.	Atwood Oceanics	SAD	534,9	6,19	7,19	7,13
30.	Basic Energy Services Inc.	SAD	291,1	2,06	3,12	2,87
31.	Diamond Offshore	SAD	1335,9	5,87	5,66	5,30
32.	Halliburton Co.	SAD	5787	7,26	6,82	5,73
33.	Helix Energy Solutions	SAD	229,8	10,05	10,06	8,00
34.	Hornbeck Offshore Services Inc	SAD	208,8	8,41	8,78	7,42
35.	ION Geophysical	SAD	179,8	2,74	2,97	3,17
36.	Key Energy Services	SAD	421,1	2,78	3,71	3,76
37.	Transocean Ltd.	SAD	3352	5,23	6,15	6,00

Sektor industrije: Transport i skladištenje nafte i plina (T&S)

R.br.	Naziv poduzeća	Država	EBITDA	multTR	multVP	multUP
1.	Royal Vopak NV	Nizozemska	857,9	8,70	9,25	8,80
2.	James Fisher and Sons Public Ltd Co	UK	86	12,02	11,52	10,55
3.	StealthGas, Inc.	Grčka	66,7	3,14	5,12	5,75
4.	Awilco LNG ASA	Norveška	29,3	7,09	9,57	10,34
5.	Docks des Petroles d'Ambes SA	Francuska	7,16	2,36	3,30	4,10
6.	Exmar NV	Belgija	123,7	6,94	9,21	9,29
7.	Pan European Terminals PLC	UK	3,98	8,84	10,09	10,38
8.	Enbridge Inc.	Kanada	2556,3	14,15	16,27	15,76
9.	TransCanada Corp.	Kanada	3959,9	8,16	10,56	11,05
10.	Gibson Energy Inc.	Kanada	295,4	10,67	11,15	10,93
11.	Pembina Pipeline Corporation	Kanada	622	17,73	16,40	14,36
12.	AltaGas Ltd.	Kanada	282,5	16,16	19,07	18,84
13.	SK Gas Co., Ltd.	Južna Koreja	164,9	3,63	6,45	8,05
14.	The National Shipping Company	Saudijska Arabija	225,6	10,50	13,07	13,69
15.	Frontline Ltd.	Bermuda	137,3	2,32	11,48	16,49

16.	Teekay LNG Partners LP.	Bermuda	265,9	11,36	14,87	15,10
17.	Golar LNG Partners Limited Partnership	Bermuda	230	8,26	9,98	10,17
18.	Essar Ports Limited	Indija	210,2	2,03	4,12	4,79
19.	Ship Finance International Ltd	Bermuda	163,7	9,33	15,94	18,59
20.	Höegh LNG Holdings Ltd.	Bermuda	39,2	13,79	18,86	19,21
21.	Prime Oil Chemical Service Corporation	Tajvan	13,9	4,35	4,80	5,48
22.	Phoenix Petroleum Philippines Inc	Filipini	36,7	3,95	6,79	7,53
23.	Kina Merchants Energy Shipping Co.	Kina	112,7	16,74	20,83	22,10
24.	Hengyang Petro-chemical Logistics	Kina	7,71	5,41	9,38	10,63
25.	Golar LNG Ltd.	Bermuda	289,4	10,10	10,40	10,34
26.	Enbridge Inc.	SAD	3380	10,00	11,08	10,46
27.	Kinder Morgan Inc.	SAD	4012	8,49	10,78	10,55
28.	ONEOK Inc.	SAD	1441,9	8,39	8,80	7,97
29.	Pembina Pipeline Corp.	SAD	589,1	17,00	15,93	13,99
30.	Spectra Energy	SAD	2319	9,63	10,78	10,35
31.	Williams Cos.	SAD	2392	9,81	9,78	8,73
32.	Atlas Pipeline Partners L.P.	SAD	170,5	15,77	16,57	15,50
33.	Energy Transfer	SAD	2050	9,66	11,94	11,87

Prilog 4. Vrijednosti ulaznih parametara za FIS1 i FIS2 za odabrana poduzeća iz sektora *E&P*, *R&M*, *OFS* i *T&S*

Sektor industrije: Eksploatacijsko-proizvodni (*E&P*)

R.br.	Naziv poduzeća	FIS1			FIS2		
		<i>PO</i>	<i>POiM</i>	<i>UKT</i>	<i>CN</i>	<i>GPO</i>	<i>SU</i>
1.	Tullow Oil plc	2,41	-0,65	0,29	94,05	0,01	0,05
2.	Bonheur ASA	-0,18	-0,65	0,11	94,05	0,00	-0,21
3.	Afren PLC	-0,18	-0,57	0,20	94,05	0,01	-0,06
4.	Premier Oil plc	0,45	0,34	0,21	94,05	0,01	-0,04
5.	Lundin Petroleum	0,61	0,41	0,21	94,05	0,00	0,01
6.	Fred Olsen Energy	0,64	0,47	0,24	94,05	0,00	0,01
7.	EnQuest PLC	0,69	0,53	0,28	94,05	0,01	0,01
8.	Maurel & Prom	0,72	0,56	0,29	94,05		0,02
9.	DNO International	0,72	0,57	0,31	94,05	0,00	0,02
10.	Genel Energy plc	0,98	0,80	0,34	94,05	0,01	0,03
11.	Ithaca Energy Inc.	0,99	0,84	0,34	94,05	0,01	0,03
12.	Exillon Energy plc	1,01	0,91	0,37	94,05	0,01	0,04
13.	JKX Oil & Gas plc	1,10	1,03	0,37	94,05	0,01	0,04
14.	Misen Energy AB	1,21	1,33	0,37	94,05	0,00	0,04
15.	Tethys Oil AB	1,55	1,81	0,39	94,05	0,00	0,05
16.	Circle Oil plc	1,83	1,91	0,39	94,05	0,04	0,06
17.	Urals Energy Public Company Limited	1,85	2,04	0,40	94,05	0,15	0,06
18.	Global Energy Development plc	2,13	2,18	0,40	94,05	0,01	0,06
19.	CNOOC Ltd.	2,16	2,19	0,41	94,05	0,01	0,07
20.	OAo Novatek	2,19	2,45	0,43	94,05	0,02	0,07
21.	Kunlun Energy Company Limited	2,22	2,73	0,45	94,05	0,01	0,08
22.	Total Gabon	2,25	2,83	0,48	94,05	0,05	0,09
23.	Dragon Oil plc	2,44	2,88	0,50	94,05	0,01	0,09
24.	PT Energi Mega Persada	2,56	3,04	0,51	94,05	0,03	0,10
25.	GeoPark Limited	2,58	3,09	0,51	94,05	0,01	0,10

26.	RH PetroGas Limited	2,93	3,53	0,51	94,05	0,00	0,11
27.	Slavneft-Megionneftegaz	3,00	3,65	0,52	94,05	0,02	0,11
28.	PetroEnergy Resources Corp.	3,44	4,04	0,56	94,05	0,03	0,11
29.	Canadian Natural Resources Limited	3,59	4,75	0,59	94,05	0,00	0,12
30.	Woodside Petroleum	3,59	4,76	0,59	94,05	0,00	0,12
31.	Encana Corporation	3,88	4,93	0,64	94,05	0,00	0,12
32.	Talisman Energy Inc.	4,09	5,37	0,66	94,05	0,00	0,12
33.	Pacific Rubiales Energy Corp.	4,11	5,46	0,76	94,05	0,00	0,13
34.	Canadian Oil Sands Limited	4,14	5,48	0,84	94,05	0,00	0,13
35.	Santos Limited	4,29	5,87	1,00	94,05	0,00	0,14
36.	Crescent Point Energy Corp.	4,59	6,51	1,30	94,05	0,00	0,16
37.	Penn West Petroleum Ltd.	5,72	7,39	1,63	94,05	0,00	0,21
38.	New Zealand Oil & Gas Limited	8,78	7,39	2,53	94,05	0,00	0,31

Sektor industrije: Sektor rafiniranja i marketinga (R&M)

R.br.	Naziv poduzeća	FIS1			FIS2		
		PO	POiM	UKT	CN	GPO	SU
1.	Neste Oil Corp.	1,00	-3,49	3,72	94,05	0,00	0,04
2.	Esso S.A.F.	-2,04	-3,49	0,04	94,05	0,01	-1,95
3.	Hellenic Petroleum	-2,04	0,12	0,05	94,05	0,15	-0,12
4.	Motor Oil Hellas Corinth Refineries	0,24	0,21	0,35	94,05	0,15	0,00
5.	OMV Petrol Ofisi AS	0,39	0,30	0,69	94,05	0,03	0,00
6.	Turkiye Petrol Rafinerileri A.S.	0,40	0,64	1,58	94,05	0,03	0,01
7.	Indian Oil Corporation Limited	0,68	0,89	2,14	94,05	0,03	0,01
8.	Reliance Industries Limited	0,78	0,89	2,23	94,05	0,03	0,02

9.	Bharat Petroleum Corp. Ltd.	0,83	1,00	2,25	94,05	0,03	0,03
10.	Hindustan Petroleum Corp. Ltd.	0,88	1,06	3,28	94,05	0,03	0,03
11.	Mangalore Refinery and Petrochemicals	1,27	1,39	4,20	94,05	0,03	0,05
12.	Chennai Petroleum Corporation Ltd	1,27	1,39	4,63	94,05	0,03	0,06
13.	Bangchak Petroleum Public	1,32	1,45	4,68	94,05	0,02	0,07
14.	Paz Oil Company	1,37	1,77	4,72	94,05	0,01	0,07
15.	Refineria La Pampilla S.A.A.	1,66	1,99	4,94	94,05	0,03	0,08
16.	Petron Malaysia Refining&Marketing	1,86	2,40	5,18	94,05	0,02	0,08
17.	Strong Petro-chemical Holdings	1,90	2,75	5,20	94,05	0,01	0,08
18.	Caltex Australia Ltd.	2,20	3,03	5,44	94,05	0,00	0,09
19.	Parkland Fuel Corporation	2,22	3,18	5,49	94,05	0,00	0,09
20.	Keyera Corp.	2,29	3,29	5,96	94,05	0,00	0,10
21.	The New Zealand Refining Company	2,29	3,38	6,03	94,05	0,00	0,10
22.	Australijan Renewable Fuels	2,39	3,61	6,72	94,05	0,00	0,10
23.	Alon USA Energy	2,93	3,68	6,90	94,05	0,00	0,11
24.	Calumet Specialty Products L.P	3,33	4,37	7,69	94,05	0,00	0,11
25.	CVR Energy Inc	3,35	4,96	8,00	94,05	0,00	0,12
26.	Delek US Holdings	3,54	5,22	8,26	94,05	0,00	0,12
27.	HollyFrontier Corp.	3,69	5,67	8,66	94,05	0,00	0,12
28.	Marathon Petroleum	4,02	5,90	9,65	94,05	0,00	0,13
29.	Northern Tier Energy LP	4,42	6,61	10,16	94,05	0,00	0,13
30.	PBF Energy Inc	4,76	7,13	10,26	94,05	0,00	0,13
31.	Phillips 66	4,85	7,25	10,35	94,05	0,00	0,14
32.	Suncor Energy	5,09	7,58	11,36	94,05	0,00	0,15
33.	Tesoro Corp.	5,12	8,25	11,49	94,05	0,00	0,15
34.	Valero Energy	6,73	10,21	12,85	94,05	0,00	0,16
35.	Western Refining Inc	6,99	10,97	13,19	94,05	0,00	0,19
36.	CVR Refining LP	10,45	10,97	13,19	94,05	0,00	0,19

Sektor industrije: Sektor potpore na naftnim poljima (OFS)

R.br.	Naziv poduzeća	FIS1			FIS2		
		PO	POiM	UKT	CN	GPO	SU
1.	Saipem SpA	2,94	-2,26	1,37	94,05	0,03	0,13
2.	Weatherford International Ltd.	-1,21	-1,28	0,06	94,05	0,00	-0,10
3.	Aker Solutions ASA	-0,66	-1,07	0,27	94,05	0,00	-0,07
4.	John Wood Group	-0,55	0,18	0,32	94,05	0,01	-0,02
5.	Subsea 7 SA	0,27	0,28	0,33	94,05	0,01	0,01
6.	SBM Offshore N.V.	0,34	0,39	0,36	94,05	0,00	0,01
7.	Tecnicas Reunidas	0,49	0,40	0,44	94,05	0,03	0,01
8.	CGG	0,61	0,69	0,59	94,05	0,01	0,02
9.	Kværner ASA	0,62	0,76	0,70	94,05	0,00	0,02
10.	Spectrum ASA	0,69	0,87	0,75	94,05	0,00	0,02
11.	WorleyParsons	0,80	1,01	0,90	94,05	0,00	0,03
12.	Trican Well Service	0,82	1,18	0,94	94,05	0,00	0,03
13.	ShawCor Ltd.	0,97	1,40	1,04	94,05	0,00	0,04
14.	Enerflex Ltd.	1,13	1,79	1,07	94,05	0,00	0,04
15.	Calfrac Well Services	1,39	1,99	1,09	94,05	0,00	0,04
16.	Mullen Group Ltd.	1,52	2,02	1,11	94,05	0,00	0,05
17.	Pason Systems Inc.	1,55	2,02	1,18	94,05	0,00	0,05
18.	Total Energy Services Inc.	1,60	2,73	1,19	94,05	0,00	0,05
19.	Zedi Inc.	1,75	2,83	1,21	94,05	0,00	0,06
20.	Hyduke Energy Services Inc.	2,02	2,99	1,35	94,05	0,00	0,06
21.	Petrofac Limited	2,32	3,17	1,39	94,05	0,01	0,06
22.	Ezra Holdings Ltd.	2,35	3,19	1,41	94,05	0,00	0,07
23.	Scomi Group Bhd	2,36	3,23	1,53	94,05	0,02	0,07
24.	Boustead Singapur	2,42	3,23	1,69	94,05	0,00	0,07
25.	Hilong Holding	2,51	3,48	1,71	94,05	0,01	0,07
26.	Anton Oilfield Services Group	2,74	3,67	1,71	94,05	0,01	0,07
27.	Japaul Oil and Maritime Services	2,75	3,73	1,76	94,05	0,05	0,08
28.	Sea Production Ltd.	2,94	3,97	2,21	94,05	0,01	0,08

29.	Atwood Oceanics	3,03	4,09	2,23	94,05	0,00	0,08
30.	Basic Energy Services Inc.	3,04	4,70	2,57	94,05	0,00	0,09
31.	Diamond Offshore	3,16	4,80	3,16	94,05	0,00	0,09
32.	Halliburton Co.	3,74	4,84	3,20	94,05	0,00	0,09
33.	Helix Energy Solutions	4,08	5,76	3,61	94,05	0,00	0,09
34.	Hornbeck Offshore Services Inc	4,18	6,21	4,78	94,05	0,00	0,10
35.	ION Geophysical	4,27	6,79	5,35	94,05	0,00	0,11
36.	Key Energy Services	4,81	7,38	7,93	94,05	0,00	0,13
37.	Transocean Ltd.	7,84	10,09	7,93	94,05	0,00	0,13

Sektor industrije: Transport i skladištenje nafte i plina (T&S)

R.br.	Naziv poduzeća	FIS1			FIS2		
		PO	POiM	UKT	CN	GPO	SU
1.	Royal Vopak NV	2,95	0,07	0,30	94,05	0,00	0,06
2.	James Fisher and Sons Public Ltd Co	0,07	0,17	0,05	94,05	0,01	-0,26
3.	StealthGas, Inc.	0,21	0,19	0,10	94,05	0,15	0,00
4.	Awilco LNG ASA	0,30	0,48	0,10	94,05	0,00	0,00
5.	Docks des Petroles d'Ambes SA	0,38	0,49	0,11	94,05	0,01	0,01
6.	Exmar NV	0,44	0,58	0,14	94,05	0,01	0,02
7.	Pan European Terminals PLC	0,44	1,03	0,15	94,05	0,01	0,02
8.	Enbridge Inc.	0,71	1,03	0,17	94,05	0,00	0,02
9.	TransCanada Corp.	0,74	1,03	0,18	94,05	0,00	0,02
10.	Gibson Energy Inc.	0,77	1,17	0,18	94,05	0,00	0,02
11.	Pembina Pipeline Corporation	0,81	1,18	0,19	94,05	0,00	0,02
12.	AltaGas Ltd.	0,88	1,22	0,20	94,05	0,00	0,02
13.	SK Gas Co., Ltd.	1,16	1,55	0,21	94,05	0,01	0,03
14.	The National Shipping Company	1,19	1,72	0,21	94,05	0,01	0,03
15.	Frontline Ltd.	1,24	1,77	0,25	94,05	0,01	0,03

16.	Teekay LNG Partners LP.	1,25	1,97	0,29	94,05	0,01	0,03
17.	Golar LNG Partners Limited Partnership	1,41	2,00	0,30	94,05	0,01	0,04
18.	Essar Ports Limited	1,44	2,15	0,33	94,05	0,03	0,04
19.	Ship Finance International Ltd	1,47	2,23	0,35	94,05	0,01	0,04
20.	Höegh LNG Holdings Ltd.	1,60	2,37	0,42	94,05	0,01	0,04
21.	Prime Oil Chemical Service Corporation	1,66	2,62	0,45	94,05	0,01	0,04
22.	Phoenix Petroleum Philippines Inc	1,79	2,74	0,49	94,05	0,03	0,05
23.	Kina Merchants Energy Shipping Co.	2,05	2,93	0,49	94,05	0,01	0,06
24.	Hengyang Petrochemical Logistics	2,07	3,02	0,52	94,05	0,01	0,06
25.	Golar LNG Ltd.	2,24	3,18	0,69	94,05	0,01	0,06
26.	Enbridge Inc.	2,28	3,24	0,69	94,05	0,00	0,07
27.	Kinder Morgan Inc.	2,47	3,66	0,69	94,05	0,00	0,10
28.	ONEOK Inc.	3,53	4,07	0,86	94,05	0,00	0,11
29.	Pembina Pipeline Corp.	4,17	4,56	0,97	94,05	0,00	0,12
30.	Spectra Energy	4,41	5,28	1,24	94,05	0,00	0,14
31.	Williams Cos.	6,42	6,31	1,67	94,05	0,00	0,14
32.	Atlas Pipeline Partners L.P.	9,86	7,18	2,63	94,05	0,00	0,15
33.	Energy Transfer	10,16	13,05	7,75	94,05	0,00	0,33

**Prilog 5. Vrijednosti multiplikatora $mult\Delta VP_1$, $mult\Delta VP_2$ i $mult\Delta VP$
i korigirane vrijednosti poduzeća za sektore *E&P*, *R&M*, *OFS* i *T&S***

Napomena: VP_{kor} je izražen u mil. USD

Sektor industrije: Eksploatacijsko-proizvodni (*E&P*)

R.br.	Naziv poduzeća	$multVP$	$mult\Delta VP_1$	$mult\Delta VP_2$	$mult\Delta VP$	VP_{kor}
1.	Tullow Oil plc	6,72	-0,16	0,07	6,62	11297,69
2.	Bonheur ASA	2,19	-0,20	0,00	1,99	1469,22
3.	Afren PLC	2,95	-0,20	0,02	2,90	3076,90
4.	Premier Oil plc	3,45	-0,18	0,02	3,30	3212,88
5.	Lundin Petroleum	4,18	-0,17	0,06	4,07	4542,93
6.	Fred Olsen Energy	4,41	-0,17	0,06	4,30	2727,06
7.	EnQuest PLC	3,68	-0,16	0,06	3,58	2248,60
8.	Maurel & Prom	4,19	-0,16	0,06	4,09	1759,11
9.	DNO International	8,73	-0,15	0,06	8,64	3197,66
10.	Genel Energy plc	13,98	-0,11	0,06	13,93	3800,10
11.	Ithaca Energy Inc.	11,66	-0,11	0,06	11,61	1003,10
12.	Exillon Energy plc	11,54	-0,11	0,06	11,49	423,98
13.	JKX Oil & Gas plc	2,61	-0,11	0,06	2,57	323,82
14.	Misen Energy AB	5,34	-0,11	0,06	5,30	293,62
15.	Tethys Oil AB	4,66	-0,09	0,07	4,64	289,07
16.	Circle Oil plc	5,30	-0,08	0,02	5,23	205,02
17.	Urals Energy Public Company Limited	5,54	-0,08	-0,06	5,39	35,20
18.	Global Energy Development plc	5,16	-0,08	0,07	5,15	60,26
19.	CNOOC Ltd.	5,11	-0,08	0,07	5,10	96995,37
20.	OAo Novatek	9,73	-0,08	0,06	9,71	30908,87
21.	Kunlun Energy Company Limited	6,64	-0,08	0,07	6,64	13244,81
22.	Total Gabon	5,01	-0,08	0,04	4,97	2920,37
23.	Dragon Oil plc	4,95	-0,07	0,07	4,94	4952,35
24.	PT Energi Mega Persada	2,07	-0,07	0,05	2,04	696,66

25.	GeoPark Limited	3,91	-0,07	0,07	3,91	472,72
26.	RH PetroGas Limited	9,46	-0,06	0,07	9,48	299,57
27.	Slavneft-Megionneftegaz	3,84	-0,06	0,06	3,84	3267,84
28.	PetroEnergy Resources Corp.	12,38	-0,02	0,05	12,41	52,00
29.	Canadian Natural Resources Limited	5,72	-0,01	0,07	5,79	43357,26
30.	Woodside Petroleum	6,75	-0,01	0,07	6,81	30386,22
31.	Encana Corporation	11,11	0,00	0,07	11,18	25591,02
32.	Talisman Energy Inc.	3,51	0,01	0,07	3,55	12407,25
33.	Pacific Rubiales Energy Corp.	2,90	0,02	0,07	2,95	5861,36
34.	Canadian Oil Sands Limited	6,82	0,03	0,07	6,91	11591,53
35.	Santos Limited	8,27	0,05	0,07	8,39	14425,77
36.	Crescent Point Energy Corp.	7,26	0,07	0,07	7,40	13354,78
37.	Penn West Petroleum Ltd.	3,78	0,08	0,09	3,95	6412,04
38.	New Zealand Oil & Gas Limited	4,27	0,16	0,08	4,51	237,68

Sektor industrije: Sektor rafiniranja i marketinga (R&M)

R.br.	Naziv poduzeća	<i>multVP</i>	<i>multΔVP₁</i>	<i>multΔVP₂</i>	<i>multΔVP</i>	<i>VP_{kor}</i>
1.	Neste Oil Corp.	7,58	-0,14	0,14	7,16	5522,51
2.	Esso S.A.F.	3,99	-0,36	0,00	3,62	1067,13
3.	Hellenic Petroleum	10,70	-0,35	0,00	10,35	4291,29
4.	Motor Oil Hellas Corinth Refineries	4,95	-0,31	0,00	4,64	1628,40
5.	OMV Petrol Ofisi AS	5,25	-0,31	0,15	5,09	1774,79
6.	Turkiye Petrol Rafinerileri A.S.	7,09	-0,25	0,15	6,72	5006,40
7.	Indian Oil Corporation Limited	3,26	-0,18	0,15	3,23	9351,45

8.	Reliance Industries Limited	6,65	-0,17	0,15	6,63	43383,99
9.	Bharat Petroleum Corp. Ltd.	2,64	-0,17	0,15	2,62	3857,60
10.	Hindustan Petroleum Corp. Ltd.	1,50	-0,15	0,15	1,51	1350,05
11.	Mangalore Refinery and Petrochemicals	10,91	-0,14	0,15	10,92	1683,76
12.	Chennai Petroleum Corporation Ltd	6,34	-0,14	0,15	6,35	724,63
13.	Bangchak Petroleum Public	7,18	-0,14	0,14	7,18	1498,11
14.	Paz Oil Company	12,90	-0,14	0,14	12,09	2062,55
15.	Refineria La Pampilla S.A.A.	6,28	-0,13	0,15	6,29	521,66
16.	Petron Malaysia Refining&Marketing	5,45	-0,13	0,14	5,47	383,82
17.	Strong Petro-chemical Holdings	18,87	-0,12	0,14	18,88	347,48
18.	Caltex Australia Ltd.	10,40	-0,11	0,14	10,41	4839,61
19.	Parkland Fuel Corporation	6,61	-0,11	0,14	6,41	1242,90
20.	Keyera Corp.	13,16	-0,10	0,14	13,21	4442,32
21.	The New Zealand Refining Company	5,86	-0,09	0,14	5,91	555,23
22.	Australijan Renewable Fuels	4,99	-0,08	0,14	4,98	34,36
23.	Alon USA Energy	2,59	-0,03	0,14	2,62	1115,07
24.	Calumet Specialty Products L.P	5,44	0,00	0,14	5,57	2197,37
25.	CVR Energy Inc	2,85	0,02	0,14	2,88	3354,91
26.	Delek US Holdings	3,20	0,03	0,14	3,37	1872,09
27.	HollyFrontier Corp.	3,14	0,05	0,14	3,33	10405,73
28.	Marathon Petroleum	3,87	0,07	0,14	3,93	26106,99
29.	Northern Tier Energy LP	3,02	0,11	0,14	3,26	2273,20
30.	PBF Energy Inc	1,13	0,13	0,14	1,15	1161,85
31.	Phillips 66	2,23	0,13	0,14	2,22	42675,06
32.	Suncor Energy	4,68	0,14	0,14	4,77	54812,07
33.	Tesoro Corp.	3,54	0,15	0,14	3,62	7667,16

34.	Valero Energy	4,05	0,30	0,14	4,02	26523,96
35.	Western Refining Inc	3,84	0,30	0,14	3,83	3078,94
36.	CVR Refining LP	3,49	0,30	0,14	3,86	4251,79

Sektor industrije: Sektor potpore na naftnim poljima (OFS)

R.br.	Naziv poduzeća	<i>multVP</i>	<i>multΔVP₁</i>	<i>multΔVP₂</i>	<i>multΔVP</i>	<i>VP_{kor}</i>
1.	Saipem SpA	4,38	-0,10	0,10	4,31	12507,62
2.	Weatherford International Ltd.	6,44	-0,24	0,00	5,84	14278,80
3.	Aker Solutions ASA	8,02	-0,23	0,02	7,61	5737,18
4.	John Wood Group	8,52	-0,21	0,04	8,18	4128,45
5.	Subsea 7 SA	6,44	-0,17	0,08	6,14	6410,77
6.	SBM Offshore N.V.	8,66	-0,16	0,08	7,47	4254,91
7.	Tecnicas Reunidas	10,93	-0,14	0,05	10,84	2253,38
8.	CGG	4,51	-0,12	0,08	4,47	4574,76
9.	Kværner ASA	5,86	-0,12	0,08	5,82	494,52
10.	Spectrum ASA	2,92	-0,11	0,08	2,89	249,08
11.	WorleyParsons	8,47	-0,11	0,09	8,44	4434,20
12.	Trican Well Service	8,48	-0,11	0,09	8,05	1955,35
13.	ShawCor Ltd.	9,37	-0,11	0,09	9,29	2396,82
14.	Enerflex Ltd.	7,07	-0,10	0,09	7,06	1102,81
15.	Calfrac Well Services	5,92	-0,09	0,09	5,74	1480,35
16.	Mullen Group Ltd.	8,23	-0,09	0,09	8,21	2420,31
17.	Pason Systems Inc.	9,19	-0,08	0,09	9,19	1517,90
18.	Total Energy Services Inc.	7,15	-0,08	0,09	7,16	638,97
19.	Zedi Inc.	8,25	-0,07	0,09	7,83	94,74
20.	Hyduke Energy Services Inc.	5,00	-0,06	0,09	5,03	19,66
21.	Petrofac Limited	7,88	-0,04	0,09	7,92	6722,85
22.	Ezra Holdings Ltd.	30,16	-0,04	0,09	30,21	1927,38
23.	Scomi Group Bhd	5,00	-0,03	0,09	5,06	324,72
24.	Boustead Singapur	9,19	-0,02	0,09	9,26	626,08

25.	Hilong Holding	14,77	-0,02	0,09	14,84	1403,74
26.	Anton Oilfield Services Group	15,82	-0,01	0,09	15,89	1249,29
27.	Japaul Oil and Maritime Services	3,58	-0,01	0,08	3,64	69,55
28.	Sea Production Ltd.	6,50	0,00	0,10	6,59	68,57
29.	Atwood Oceanics	7,19	0,00	0,11	7,13	3813,84
30.	Basic Energy Services Inc.	3,12	0,00	0,11	2,87	835,46
31.	Diamond Offshore	5,66	0,01	0,11	5,78	7726,22
32.	Halliburton Co.	6,82	0,03	0,11	6,97	40319,39
33.	Helix Energy Solutions	10,06	0,07	0,11	10,05	2309,49
34.	Hornbeck Offshore Services Inc	8,78	0,08	0,10	8,41	1756,01
35.	ION Geophysical	2,97	0,09	0,10	3,16	567,38
36.	Key Energy Services	3,71	0,13	0,10	3,76	1583,34
37.	Transocean Ltd.	6,15	0,20	0,10	6,00	20112,00

Sektor industrije: Transport i skladištenje nafte i plina (T&S)

R.br.	Naziv poduzeća	<i>multVP</i>	<i>multΔVP₁</i>	<i>multΔVP₂</i>	<i>multΔVP</i>	<i>VP_{kor}</i>
1.	Royal Vopak NV	9,25	-0,55	0,32	8,80	7549,52
2.	James Fisher and Sons Public Ltd Co	11,52	-0,88	0,00	10,64	914,93
3.	StealthGas, Inc.	5,12	-0,87	-0,29	3,96	264,04
4.	Awilco LNG ASA	9,57	-0,85	0,28	9,00	263,62
5.	Docks des Petroles d'Ambes SA	3,30	-0,84	0,29	2,75	19,73
6.	Exmar NV	9,21	-0,82	0,30	8,69	1074,90
7.	Pan European Terminals PLC	10,09	-0,78	0,30	9,61	38,24
8.	Enbridge Inc.	16,27	-0,71	0,30	15,76	40287,29
9.	TransCanada Corp.	10,56	-0,70	0,30	10,16	40239,80
10.	Gibson Energy Inc.	11,15	-0,72	0,30	10,73	3170,31
11.	Pembina Pipeline Corporation	16,40	-0,71	0,30	15,99	9947,16

12.	AltaGas Ltd.	19,07	-0,69	0,30	18,68	5277,85
13.	SK Gas Co., Ltd.	6,45	-0,53	0,31	6,23	1027,04
14.	The National Shipping Company	13,07	-0,51	0,31	12,86	2902,06
15.	Frontline Ltd.	11,48	-0,48	0,31	11,30	1551,62
16.	Teekay LNG Partners LP.	14,87	-0,48	0,31	14,70	3908,38
17.	Golar LNG Partners Limited Partnership	9,98	-0,41	0,31	9,89	2274,75
18.	Essar Ports Limited	4,12	-0,40	0,19	3,91	821,78
19.	Ship Finance International Ltd	15,94	-0,39	0,31	15,87	2597,27
20.	Höegh LNG Holdings Ltd.	18,86	-0,39	0,31	18,79	736,51
21.	Prime Oil Chemical Service Corporation	4,80	-0,40	0,31	4,71	65,52
22.	Phoenix Petroleum Philippines Inc	6,79	-0,39	0,19	6,59	241,75
23.	Kina Merchants Energy Shipping Co.	20,83	-0,36	0,32	20,79	2343,07
24.	Hengyang Petrochemical Logistics	9,38	-0,36	0,32	9,34	72,00
25.	Golar LNG Ltd.	10,40	-0,35	0,32	10,34	2992,40
26.	Enbridge Inc.	11,08	-0,35	0,33	10,46	35354,80
27.	Kinder Morgan Inc.	10,78	-0,34	0,34	10,55	42326,60
28.	ONEOK Inc.	8,80	-0,31	0,34	8,39	12097,54
29.	Pembina Pipeline Corp.	15,93	-0,29	0,33	15,97	9406,71
30.	Spectra Energy	10,78	-0,19	0,33	10,35	24001,65
31.	Williams Cos.	9,78	0,01	0,33	9,81	23465,52
32.	Atlas Pipeline Partners L.P.	16,57	0,30	0,33	15,77	2688,79
33.	Energy Transfer	11,94	0,77	0,37	11,87	24333,50

Prilog 6. Vrijednosti odabranih parametara iz Tablice 12. (Poglavlje 6.1.2.) za treniranje, validaciju i testiranje unaprijedne neuronske mreže

#	UI	UO	AM	NKU	ND	UP	EBIT2	EBITDA	IK	DIV
1.	360325,00	170398,00	14458,00	17370,00	26592,00	467153,00	15605,68	52114,00	229075,01	-7222,00
2.	300193,00	180573,00	14990,00	17085,00	11582,00	375580,00	12106,34	28354,00	155818,49	-5292,00
3.	235019,10	133541,60	11011,80	19229,80	14099,80	240357,30	13591,40	44678,00	129442,02	-7255,90
4.	190994,00	105218,30	13315,00	5680,40	10268,30	168473,90	7402,11	36652,40	114513,61	-5344,80
5.	127653,30	26608,00	10350,30	9511,00	12375,60	126755,80	11994,42	44814,50	86032,87	-3574,90
6.	41742,60	21869,20	297,70	3337,60	1847,70	56232,10	3391,68	6955,90	23189,16	-847,20
7.	65247,00	32153,00	2849,00	6134,00	4519,00	18933,00	4166,86	11045,00	54003,43	-921,00
8.	928,80	648,20	40,60	-34,31	21,60	350,30	30,66	89,40	416,10	-13,00
9.	88795,70	51220,90	3107,50	2401,10	2716,10	77690,00	2915,49	8475,20	59123,89	-720,00
10.	15622,40	6739,00	674,60	-741,80	721,20	9267,10	1526,08	1596,30	11603,82	0,00
11.	68945,50	33572,30	3737,40	3929,00	2792,10	38332,60	3939,44	11338,90	56440,28	-965,20
12.	26481,90	11712,30	686,30	6991,98	3778,30	29811,90	3001,47	5636,30	23611,96	-394,70
13.	31691,00	14410,70	2326,80	2147,30	2028,60	22508,20	1779,04	5631,30	23274,86	-1139,20
14.	21839,20	12995,70	1490,80	1512,47	996,20	16896,90	858,11	4156,50	15965,17	-696,00
15.	25688,00	12843,20	603,40	750,70	346,00	13383,10	959,59	1629,50	15297,87	-420,20
16.	358605,30	163380,40	24965,30	28072,80	18501,60	352188,40	23595,15	54291,60	279659,36	-8478,10
17.	350217,40	97711,60	9697,40	28734,70	38722,50	152766,10	35549,98	51955,60	298921,70	-6003,10
18.	98961,00	24773,00	4832,00	13209,00	11004,00	139171,00	10546,57	18872,00	84748,89	-2193,00
19.	49657,40	27385,50	186,70	3114,30	3419,90	91286,80	3366,53	7578,10	34049,64	-996,60
20.	60099,30	7476,00	1373,90	4243,40	5897,50	27351,60	5338,21	9155,90	58847,51	0,00
21.	22499,50	8677,10	1084,90	2083,00	2646,50	18256,00	3124,19	5804,50	16007,86	-1086,40
22.	9980,80	6078,30	1014,80	4018,31	793,60	13661,60	1013,76	3291,40	10706,21	-108,60
23.	2352,90	1033,30	237,90	388,09	125,10	2596,10	154,94	618,70	2250,80	-34,20
24.	3520,00	1103,00	98,00	-156,00	165,00	500,00	180,04	401,00	2836,00	0,00
25.	344,30	161,60	12,30	0,00	25,20	155,00	-9,69	43,00	273,50	-5,79
26.	57087,80	23328,80	2681,40	9711,00	8361,50	38954,50	7644,51	15870,00	40825,60	-4515,10
27.	9381,80	4060,20	1264,10	2087,50	624,30	2344,10	425,77	1706,60	6876,27	-184,50
28.	4824,10	2805,50	320,30	48,80	70,30	1841,70	310,27	738,30	3549,54	-160,70
29.	3584,40	2157,00	394,10	890,60	203,40	1498,80	347,87	1061,00	2346,70	0,00
30.	4843,60	2890,10	530,50	989,40	252,00	1408,70	300,02	973,60	3496,60	-40,20
31.	3293,70	2043,70	595,30	900,10	108,20	1319,50	91,95	1116,20	2008,30	0,00
32.	2576,90	1290,00	220,10	-4,70	326,60	1235,20	311,62	634,20	2054,24	-110,20
33.	2544,80	1250,90	235,00	860,12	362,20	889,50	336,05	628,10	1392,57	0,00
34.	2247,50	1194,60	171,10	232,36	76,60	626,30	147,15	430,10	1459,28	-60,20
35.	1196,30	542,50	100,50	267,51	186,70	510,40	264,50	370,10	797,09	0,00
36.	4156,00	235,90	199,20	1357,50	75,90	333,40	112,90	272,80	3161,90	0,00
37.	933,50	327,90	62,20	476,84	93,40	170,50	51,68	86,40	1190,11	0,00
38.	776,50	208,90	21,00	117,42	12,10	301,90	21,62	36,90	574,73	0,00
39.	586,90	75,00	73,70	56,64	-11,30	202,90	15,39	126,00	494,41	0,00
40.	97,50	42,50	1,50	68,79	40,70	90,10	55,02	55,40	112,86	0,00
41.	213,40	79,80	18,40	56,95	48,20	89,70	54,41	62,30	185,80	0,00
42.	260,90	44,90	11,10	43,87	25,20	73,30	30,09	39,20	237,30	0,00
43.	147,40	39,80	6,40	2,39	2,34	49,90	1,43	6,53	105,84	0,00
44.	131,30	50,80	8,10	8,41	-2,12	44,00	3,27	11,70	93,51	0,00
45.	75406,60	24187,60	5417,70	14981,20	10217,90	39726,50	10189,81	19018,70	69622,88	-2545,50
46.	13440,10	4986,60	333,70	3386,37	2274,30	6907,90	2491,06	3183,20	14409,70	-642,40
47.	13982,40	5972,60	566,80	1548,20	841,00	4251,60	1175,25	1994,70	10612,11	-239,20
48.	3249,80	1102,50	253,00	206,00	329,70	2770,80	246,60	587,60	2215,10	-153,20
49.	3843,10	983,80	211,60	736,40	600,00	1155,10	523,34	1002,50	3003,09	-148,00
50.	2072,40	1381,60	145,30	345,94	15,30	654,60	121,36	341,50	1906,24	0,00
51.	628,00	315,90	80,10	202,00	11,90	250,50	30,66	120,90	572,89	0,00
52.	319,50	138,50	10,80	39,94	6,10	86,40	-5,09	31,60	56,38	0,00
53.	4235,80	1233,50	222,80	0,00	549,70	4077,90	417,65	851,00	3945,20	0,00
54.	91,50	44,30	1,90	35,18	2,56	12,00	1,01	4,19	88,80	-0,94

55.	44241,70	22307,80	4045,90	1850,70	1898,20	14636,60	2049,36	7488,30	34807,54	-488,00
56.	24810,00	8983,00	1503,00	1113,00	2983,00	6348,00	2775,84	4462,00	19135,02	-1061,00
57.	18700,00	13405,00	2009,00	1090,00	-2794,00	5160,00	1223,40	2289,00	8424,02	-509,00
58.	21858,00	11948,00	3050,00	561,00	132,00	7303,00	-61,23	3495,00	14804,25	-278,00
59.	7087,00	3113,40	954,90	1138,10	527,70	3884,80	434,25	1986,90	5992,48	-174,70
60.	9187,50	5109,10	364,00	896,20	984,20	3715,10	891,36	1677,50	5273,40	-659,10
61.	14814,00	6670,00	764,40	3355,10	538,90	3343,20	408,91	1719,40	12756,99	-145,60
62.	10958,50	3142,10	1314,50	1148,70	191,30	2234,00	279,76	1804,70	10014,09	-335,20
63.	13092,60	5075,00	1441,70	-361,60	174,60	2648,60	-242,88	1623,30	9738,82	-395,60
64.	366,80	72,30	30,90	14,60	20,10	76,80	17,06	52,70	155,81	-21,80
65.	10101,70	6575,40	454,20	-263,90	207,00	21632,30	526,48	771,30	6486,33	-131,30
66.	5311,20	3093,30	173,60	-8,10	83,30	23341,60	23,40	294,40	2215,40	-33,40
67.	10135,10	6719,80	1303,60	283,11	111,00	13803,00	-213,14	414,70	6529,19	-69,30
68.	2569,60	1998,70	124,10	93,00	102,90	12765,40	66,29	350,70	2078,99	-45,00
69.	2971,60	2123,30	277,00	110,60	8,65	11320,30	170,96	348,80	1625,50	0,00
70.	7272,80	5194,90	113,80	1283,60	818,60	26392,00	441,20	745,00	3750,20	-477,10
71.	37770,70	27553,60	906,20	757,50	819,40	85050,10	1524,89	2899,50	121,01	-274,80
72.	57578,50	28499,20	2128,10	3417,60	3845,50	73130,50	3362,34	6546,50	0,00	-543,10
73.	12650,90	9812,50	391,60	221,40	346,40	44604,70	640,33	1474,20	0,00	-79,40
74.	14662,60	12502,50	367,90	532,30	92,30	39793,80	288,18	896,50	0,00	-53,00
75.	4232,10	3207,00	95,80	-106,50	-139,40	12099,90	87,60	154,20	2121,50	0,00
76.	2237,80	1916,30	59,20	-63,00	-325,40	7898,20	56,41	114,20	1431,99	0,00
77.	2152,50	1170,50	74,50	189,90	139,60	5399,30	115,15	208,60	1808,81	-66,10
78.	3624,70	2694,40	94,70	203,30	49,00	4968,30	-17,29	170,60	2647,11	0,00
79.	832,23	409,19	23,78	55,17	18,80	4840,70	58,80	82,90	1228,14	-6,64
80.	829,20	543,30	23,30	55,70	32,10	3761,20	31,42	70,20	562,06	-8,70
81.	277,90	132,30	0,30	61,92	39,80	1944,00	43,73	18,40	231,34	-8,33
82.	4698,30	2814,30	103,10	387,50	58,90	24151,90	267,99	464,90	3390,03	-98,90
83.	816,80	497,90	48,00	124,43	85,10	4147,10	85,65	193,90	608,77	-21,50
84.	2421,10	1615,80	87,90	161,62	131,00	2951,90	179,19	336,40	1898,61	-163,70
85.	780,00	309,00	52,10	53,00	26,90	229,90	33,26	93,90	561,19	-15,20
86.	48,30	27,30	1,50	1,93	2,11	53,60	5,02	6,90	39,10	0,00
87.	2223,60	1602,40	121,90	93,90	79,10	8017,70	195,86	425,60	1055,40	14,62
88.	2253,00	1363,30	90,70	57,10	195,00	4657,30	301,69	394,50	1682,70	157,55
89.	3610,90	1950,80	130,00	212,20	403,00	8567,30	669,28	1164,90	1527,40	260,40
90.	2623,70	1545,70	82,60	132,00	272,80	8726,70	305,30	555,60	659,80	35,76
91.	10329,00	3686,30	242,90	335,30	1727,20	20090,70	1820,70	3127,00	5002,40	274,86
92.	27223,00	15118,00	995,00	1369,00	3389,00	76534,00	3658,60	6643,00	10195,00	566,10
93.	1136,80	653,00	33,20	30,90	197,60	4653,90	635,77	697,30	493,40	113,96
94.	4253,70	2530,20	92,20	175,90	2,00	20138,70	916,65	1010,30	863,90	28,32
95.	48073,00	27267,00	913,00	1721,00	4124,00	179460,00	11406,76	19223,00	24275,00	972,66
96.	69083,10	33639,30	3692,30	6959,00	2783,00	38616,00	2782,98	11491,00	45855,00	1218,48
97.	10702,00	5965,00	445,00	529,00	743,00	32974,00	1025,62	2118,00	4202,00	138,40
98.	44477,00	26382,00	1574,00	2931,00	2083,00	138286,00	2819,72	6598,00	23358,00	496,89
99.	2480,40	1571,30	93,90	202,20	398,90	9503,10	458,94	803,90	965,10	76,47
100.	2258,50	1277,70	107,60	120,20	632,80	8281,70	993,90	1101,50	1600,90	0,00
101.	23512,60	15919,40	958,70	292,30	1189,30	17641,20	27,36	2902,00	13550,80	-476,40
102.	22795,00	13977,00	1282,00	1742,00	-778,00	15215,00	613,91	2445,00	14771,94	0,00
103.	6502,00	4565,00	179,50	485,00	404,00	7977,30	302,94	753,90	4992,11	-180,10
104.	4161,10	1925,80	129,00	241,00	257,00	6821,30	309,78	504,70	2913,83	-62,00
105.	10495,10	4126,80	324,90	708,70	830,40	6296,60	444,78	1044,10	5206,15	-202,20
106.	6335,40	4795,60	220,40	986,60	-79,50	3695,20	173,00	569,60	4321,48	0,00
107.	3618,70	3011,90	9,30	-12,20	175,90	3499,40	222,79	207,90	-32,50	-52,57
108.	8332,80	3740,90	678,90	1656,80	74,20	3410,50	384,95	1024,10	4924,15	0,00
109.	978,60	622,50	10,70	16,70	42,70	1930,50	59,62	85,00	184,35	-48,40
110.	186,10	80,70	46,90	25,44	23,10	117,00	33,51	86,20	114,60	-4,15
111.	4441,40	2525,80	61,10	223,96	294,90	8079,40	375,87	525,10	1620,36	-208,40
112.	2167,50	923,10	138,20	175,32	53,80	2220,60	-2,12	242,90	1900,88	-43,10
113.	1743,10	833,50	47,40	-110,90	179,00	1487,70	283,56	258,00	670,81	-30,80
114.	1256,50	454,50	35,70	33,55	72,00	1506,60	70,28	156,10	475,06	-20,40
115.	1379,20	673,00	81,80	191,45	97,50	1600,40	68,57	257,90	1184,29	-31,90

116.	1408,60	659,80	75,70	55,17	131,30	1432,30	160,55	294,80	1019,89	-112,20
117.	442,10	108,30	48,40	2,50	40,00	387,80	93,74	165,10	128,11	-39,90
118.	431,50	154,40	21,50	54,53	47,80	308,70	38,91	89,20	366,35	-5,96
119.	89,60	37,10	5,50	-0,83	4,49	104,60	6,27	12,10	61,58	0,00
120.	52,70	23,80	1,10	0,38	0,80	108,60	-1,12	3,91	38,65	0,00
121.	5332,00	3782,00	123,00	586,00	632,00	6324,00	539,23	849,00	2084,18	-221,00
122.	2733,00	1720,80	52,50	186,60	53,60	1262,10	85,96	63,80	2639,82	-3,90
123.	751,30	496,70	29,10	30,11	-17,30	497,00	22,16	64,20	621,40	0,00
124.	475,20	230,70	4,20	59,73	65,60	413,60	48,45	67,60	150,06	-14,70
125.	668,20	286,90	17,30	61,05	55,30	363,30	71,47	94,60	524,14	-16,60
126.	594,20	250,00	15,20	60,86	48,50	321,60	61,58	78,60	362,50	-16,30
127.	201,00	95,90	13,90	0,00	1,74	78,60	0,69	19,10	187,70	0,00
128.	171,70	104,90	14,80	-12,93	14,70	9,49	-4,54	10,40	138,80	0,00
129.	3657,30	1449,90	117,50	745,20	350,20	1017,90	361,13	534,90	3389,90	0,00
130.	1595,90	1221,70	187,00	171,40	20,90	1374,90	68,18	291,10	1122,70	0,00
131.	7235,30	2658,90	392,90	702,00	720,50	2986,50	740,03	1335,90	4586,90	486,50
132.	29223,00	15608,00	1900,00	3566,00	2577,00	28503,00	2815,10	5787,00	18101,00	557,40
133.	3386,60	1967,20	86,00	323,00	15,40	846,10	132,60	229,80	1975,50	0,00
134.	2631,70	1465,90	87,80	264,10	40,80	512,70	75,30	208,80	1678,50	0,00
135.	820,60	319,40	105,30	160,50	63,30	526,30	54,00	179,80	542,80	0,00
136.	2761,60	1474,30	214,20	447,20	101,20	1960,10	132,75	421,10	2056,40	0,00
137.	34255,00	18525,00	1081,00	1409,00	1251,00	9196,00	1810,53	3352,00	22907,00	805,28
138.	6860,40	4171,20	276,90	568,90	434,70	1732,30	428,79	857,90	5501,85	-145,70
139.	595,80	323,90	26,80	62,92	64,60	590,60	63,99	86,00	449,82	-13,40
140.	713,00	371,00	28,80	72,65	29,00	119,20	31,37	66,70	729,35	0,00
141.	203,00	9,70	7,70	141,78	21,70	56,60	8,39	29,30	339,44	0,00
142.	66,70	22,80	3,30	-1,60	3,02	21,10	2,61	7,16	42,72	-0,64
143.	1370,30	1003,40	72,00	-56,20	54,60	467,50	87,82	123,70	1305,85	0,00
144.	78,90	19,70	0,70	0,62	1,10	33,50	2,29	3,98	50,96	0,00
145.	42622,70	29288,00	1089,80	6836,50	717,30	25388,50	1181,94	2556,30	39694,41	-627,90
146.	43657,30	27095,10	1241,70	3265,20	1358,40	8033,10	2288,84	3959,90	38836,43	-1191,70
147.	2525,50	1345,30	114,30	627,26	116,60	4929,00	163,18	295,40	1337,17	-119,60
148.	7472,70	3612,50	172,80	764,78	225,60	3438,60	394,72	622,00	7231,67	-204,70
149.	5337,10	3531,70	92,40	984,90	117,10	1432,70	137,49	282,50	4637,16	-157,20
150.	2673,90	1771,00	31,60	24,96	90,10	7130,40	108,18	164,90	1449,60	-11,80
151.	2950,00	1423,30	1,60	212,54	134,40	657,10	97,63	225,60	2882,40	-83,50
152.	1688,20	1557,10	114,80	-109,10	-82,80	668,10	41,33	137,30	1275,91	0,00
153.	3785,40	2531,20	86,10	263,20	123,70	392,30	108,64	265,90	4054,83	-173,70
154.	1511,00	1269,40	51,80	13,50	116,40	286,60	172,63	230,00	1530,70	-111,20
155.	1505,70	1073,10	38,40	-42,40	61,10	261,90	139,14	210,20	1070,93	0,00
156.	2973,10	1978,30	55,60	185,00	185,80	265,70	99,90	163,70	2967,30	-139,20
157.	1072,10	728,30	20,70	116,40	8,90	136,50	27,77	39,20	972,00	0,00
158.	37,10	3,00	5,80	2,59	6,88	19,90	4,59	13,90	15,10	-6,07
159.	363,80	264,60	8,40	63,50	15,30	842,90	27,67	36,70	366,68	-2,86
160.	3259,70	1211,20	119,10	153,10	14,60	460,40	-41,85	112,70	2878,01	-4,95
161.	164,30	92,80	3,70	75,23	0,87	17,70	2,24	7,71	165,68	0,00
162.	2414,40	650,10	86,10	353,00	971,30	410,30	45,57	289,40	2218,63	-141,10
163.	42525,10	29220,90	1087,20	5468,00	1269,00	25306,00	1896,55	3380,00	30641,00	1080,80
164.	68185,00	44086,00	1419,00	2022,00	1092,00	9973,00	2324,62	4012,00	47600,00	1698,55
165.	15855,30	11622,80	335,80	1866,20	346,30	12632,60	682,21	1441,90	8889,40	348,33
166.	7457,30	3605,00	172,50	546,80	214,70	3427,40	303,71	589,10	6797,40	498,44
167.	30587,00	20486,00	746,00	2025,00	940,00	5075,00	1161,69	2319,00	21711,00	908,48
168.	24327,00	16900,00	756,00	2529,00	695,00	7486,00	1143,55	2392,00	14649,00	1191,75
169.	3065,60	1459,20	90,00	373,50	62,00	1204,00	80,29	170,50	2684,20	160,21
170.	43230,00	25898,00	656,00	2840,00	736,00	15702,00	1293,98	2050,00	24941,00	1103,49