Usporedba metoda procjene vjerojatnosti geološkog uspjeha na primjeru tipskog potencijalnog ležišta u klastitima

Radoević, Karla

Master's thesis / Diplomski rad

2021

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:169:300018

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-07-15**

Repository / Repozitorij:

Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb

SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
STUDIJ GEOLOGIJE

USPOREDBA METODA PROCJENE VJEROJATNOSTI GEOLOŠKOG USPJEHA NA PRIMJERU TIPSKOG POTENCIJALNOG LEŽIŠTA U KLASTITIMA

Diplomski rad

Karla Radoević

Zagreb, 2021.

Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet

Diplomski rad

USPOREDBA METODA PROCJENE VJEROJATNOSTI G-EOLOŠKOG USPJEHA NA PRIMJERU TIPSKOG POTENCIJALNOG LEŽIŠTA U KLASTITIMA

KARLA RADOEVIĆ

Diplomski rad izrađen: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za mineralogiju, petrologiju i mineralne sirovine
Pierottijeva 6, 10002 Zagreb

Sažetak

Vjerojatnost geološkog uspjeha (engl. *Probability of Geological Success* – PoS) predstavlja metodu kojom se može procijeniti perspektivnost slabo istraženog dijela bazena ili perspektivnost prospekta. Geološki uspjeh predstavlja način procjene rizika koji se najčešće dobije množenjem nekoliko faktora rizika, a najznačajniji su zamka, kvaliteta ležišta, zrelost matičnih stijene, adekvatan izolator, migracija. U ovom radu objašnjene su dvije metode izračuna PoS-a. Jednu metodu predložio je David A. WHITE, a drugu metodu predložio je Alexei V. MILKOV. Iako obje metoda služe za procjenu geološkog faktora rizika, one se dosta razlikuju, ponajprije u načinu određivanja vrijednosti faktora rizika. Metoda prema WHITE subjektivnija je metoda gdje se vrijednosti procjene rizika dodjeljuju na temelju stručnog, ali subjektivnog mišljenja, dok je metoda prema MILKOVU objektivnija, temelji se na algoritmu, odnosno relativno složenim tablicama pomoću koji se definira vrijednost PoS-a. Dvije metode su testirane na pojednostavljenom potencijalnom tipskom ležištu koje je opisano strukturnom kartom po krovini ležišta. Potencijalno tipsko ležište temelji se na jednome od ležišta polja Stružec, a značajke su mu definirane na temelju značajki pješčenjačkih ležišta Savske depresije opisanih u literaturi. Dobiveni rezultati se razlikuju, ali izračun PoS-a prema obje metode rezultirao bi nastavkom istraživanja, kada bi se radilo o stvarnom prospektu, jer je u oba slučaja vrijednost PoS-a je >0,5, odnosno prema WHITE dobivena vrijednost iznosi 0,72, a prema MILKOV 0,52.

Ključne riječi: vjerojatnost geološkog uspjeha, faktor rizika, matične stijene, kolektorske stijene, migracija, antiklinala

Diplomski rad sadrži: 42 stranica, 6 slika, 8 tablica, 34 referenci.

Jezik izvornika: hrvatski

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

Voditelj: doc.dr.sc. Iva Kolenković Močilac

Ocjenjivači: doc.dr.sc. Iva Kolenković Močilac
izv.prof.dr.sc. Bruno Saftić
doc.dr.sc. Marko Cvetković

Datum obrane: 18. veljače 2021.

University of Zagreb
Faculty of Mining, Geology
and Petroleum Engineering

Master's Thesis

COMPARISON OF METHODS FOR ASSESSING THE PROBABILITY OF GEOLOGICAL SUCCESS ON THE EXAMPLE OF A TYPICAL POTENTIAL FIELD IN CLASTIC RESERVOIR

KARLA RADOEVIĆ

Thesis completed in: University of Zagreb
Faculty of Mining, Geology and Petroleum engineering
Institute of Mineralogy, Petrology and Mineral deposits,
Pierottijeva 6, 10 002 Zagreb

Abstract

The probability of geological success (PoS) is a method which helps to assess the perspectives of a underexplored part of petroleum basin or the perspectives of prospects. Geological success is a way of risk assessment that is most often obtained by multiplying several risk factors, and the most important are the trap, the quality of the reservoir, the maturity of the source rocks, adequate seal, migration. In this paper, two methods of PoS calculation are explained. One method was proposed by David A. WHITE and the other method was proposed by Alexei V. MILKOV. Although both methods are used to estimate the geological risk factor, they are quite different, primarily in the way the risk factors are determined. The method according to WHITE is a more subjective method where the risk assessment values are assigned based on expert, but subjective opinion, while the method according to MILKOV is more objective, based on an algorithm or relatively complex tables that define the value of PoS . The methods were tested on a simplified potential reservoir which is described by a top reservoir structural map. The potential type field is based on one of the reservoirs of the Stružec field, and its characteristics are defined on the basis of the characteristics of the sand deposits of the Sava Depression described in the literature. The results obtained by the two methods differ, but both would result in drilling if it was a real prospect, because the value of PoS is> 0.5, ie according to WHITE the obtained value is 0.72, and according to MILKOV 0.52.

Keywords: probability of geological success, risk factor, source rocks, reservoir rock, migration, anticline

Thesis contains: 42 pages, 6 figures, 8 tables, 34 references.

Original in: Croatian

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

Supervisor: PhD doc.dr.sc. Iva Kolenković Močilac, assistant professor, RGNF

Reviewers: PhD Iva Kolenković Močilac, assistant professor, RGNF
PhD Bruno Saftić, associate professor, RGNF
PhD Marko Cvetković, assistant professor, RGNF

Date of defense: February 18th, 2021.

Zahvaljujem se mentorici, doc. dr. sc. Ivi Kolenković Močilac, na velikom razumijevanju, strpljenju, vremenu i pomoći pruženoj prilikom izrade ovog rada.

Zahvaljujem se i članovima komisije, prof. dr. sc. Bruni Saftiću i doc. dr. sc. Marku Cvetkoviću, na konstruktivnim kritikama i savjetima koji su ovaj rad učinili boljim.

Zahvaljujem se i prijateljima Tomislavu, Domagoju, Luki, Mariji i Lei koji su mi bili potpora tijekom studiranja, učinili su studiranje zanimljivijim, a ispite lakšima.

Najviše se zahvaljujem Manueli na pomoći tijekom studiranja, svim savjetima i potpori i podizanju morala kada mi je to najviše trebalo.

Hvala i mojoj obitelji koja je bila uz mene, pružala mi podršku i vjerovala u mene.

Veliko hvala i Antoniju bez čije podrške i ohrabrenja ovaj rad ne bih uspjela napisati.

Sadržaj

1. UVOD 1
2. METODE IZRAČUNA GEOLOŠKOG RIZIKA 2
2.1 Metoda prema WHITE (1993) 2
2.2 Metoda prema MILKOV (2015) 7
2.2.1 Tablica vjerojatnosti postojanja strukture/zamke 8
2.2.2 Tablica vjerojatnosti prisutnosti kolektorskih stijena 10
2.2.3 Tablica vjerojatnosti kvalitete ležišta 12
2.2.4 Tablica vjerojatnosti postojanja adekvatnog izolatora 14
2.2.5 Tablica vjerojatnosti zrelosti matičnih stijena 16
2.2.6 Tablica vjerojatnosti migracije 19
3. GEOLOŠKE ZNAČAJKE ISTRAŽIVANOG PODRUČJA 21
3.1 Strukturno-stratigrafski odnosi hrvatskoga dijela Panonskog bazenskog sustava 22
4. REGIONALNE NAFTNOGEOLOŠKE ZNAČAJKE 27
4.1. Matične stijene Savske depresije 27
4.2. Kolektorske stijene 28
4.3. Migracija 29
4.4. Značajke nafti u Savskoj depresiji 30
5. TIPSKO POTENCIJALNO NAFTNO-PLINSKO LEŽIŠTE 31
6. IZRAČUN VJEROJATNOSTI GEOLOŠKOG USPJEHA 32
6.1. Volumen zamke 32
6.2. Izračun vjerojatnosti geološkog uspjeha prema WHITE (1993) 32
6.3. Izračun vjerojatnosti geološkog uspjeha prema MILKOV (2015) 35
6.3.1. Vjerojatnost postojanja strukture 35
6.3.2. Vjerojatnost prisutnosti kolektorskih stijena 35
6.3.3. Vjerojatnost kvalitete ležišta 35
6.3.4. Vjerojatnost postojanja adekvatnog izolatora 36
6.3.5. Vjerojatnost zrelosti matičnih stijena 36
6.3.6. Vjerojatnost migracije 36
7. DISKUSIJA I ZAKLJUČAK 37
8. LITERATURA 39

POPIS SLIKA

Slika 1. Predložak za izračun šanse adekvatnosti za „play i prospekt“ (WHITE, 1993).….6

Slika 2. Strukturne jedinice u jugozapadnom dijelu Panonskog bazena (PRELOGOVIĆ et al., 1998.; LUČIĆ et al., 2001.; VELIĆ et al., 2011)……...22

Slika 3. Generalizirani taložni stup Savske et alavske depresije (iz KOLENKOVIĆ (2012), modificirano prema SAFTIĆ, 1998)……...……..25

Slika 4. Regionalni geološki profil kroz Savsku depresiju (preuzeto iz KOLENKOVIĆ, 2012 prema PRELOGOVIĆ et al., 1998)…….26

Slika 5. Strukturna karta tipskog potencijalnog ležišta po krovini…….31

Slika 6. Procjena vrijednosti geološkog faktora rizika prema WHITE (1993)…… ……...34

POPIS TABLICA

Tablica 1. Tablica vjerojatnosti prisutnosti strukture/zamke (MILKOV, 2015)……..…9

Tablica 2. Tablica vjerojatnosti prisutnosti kolektorskih stijena (MILKOV, 2015)……..11

Tablica 3. Tablica vjerojatnosti kvalitete ležišta (MILKOV, 2015)……..…13

Tablica 4. Tablica vjerojatnosti prisutnosti izolatora (MILKOV, 2015)…….…….....15

Tablica 5. Tablica vjerojatnosti zrelosti matičnih stijena (MILKOV, 2015)……...…..…18

Tablica 6. Tablica vjerojatnosti migracije (MILKOV, 2015)……..……..……...20

Tablica 7. Svojstva nafte iz ležišta u Savskoj depresiji (VELIĆ, 2007)…….30

Tablica 8. Pregled rezultata određivanja vjerojatnosti geološkog uspjeha prema MILKOV (2015)…… ……...……37

1. UVOD

Od početka istraživanja ležišta ugljikovodika korištene su različite metode za procjenu njihove iskoristivosti. Jedna od tih metoda je metoda izračuna vjerojatnosti geološkog uspjeha, u daljnjem tekstu PoS. Izračun geološkog uspjeha zapravo predstavlja način procjene rizika i jedan je od ključnih podataka za daljnja istraživanja u naftnoj industriji. Geološki rizik najčešće se dobije množenjem nekoliko čimbenika, a najznačajniji su: struktura, kvaliteta ležišta, matične stijene, adekvatan izolator, migracija. Različiti autori koriste različite načine izračuna PoS-a, no svima je zajednički cilj, a to je što preciznije odrediti prisutnost i volumen akumulacije ugljikovodika. U ovom radu odabrane su dvije metode izračuna PoS-a. Prva, koju je predložio David A. WHITE (1993) podložnija je subjektivnoj procjeni istraživača koji procjenjuje vrijednosti čimbenika rizika na temelju dostupnih podataka o geološkoj građi ležišta, a drugu je predložio Alexei V. MILKOV (2015) čija se metoda temelji na algoritmu, odnosno relativno složenim tablicama, te predstavlja objektivniji pristup izračunu. Između ove dvije metode postoje određene razlike u terminologiji te samom izračunu, ali cilj je isti. Za potrebe rada definirano je pojednostavljeno potencijalno tipsko ležište koje je opisano strukturnom kartom po krovini ležišta. Potencijalno tipsko ležište razvijeno je po uzoru na ležište polja Stružec te je za njega izračunat geološki rizik (PoS). Nadalje, opisani su regionalni geološki odnosi hrvatskog dijela Panonskog bazenskog sustava te naftnogeološki odnosi Savske depresije i polja Stružec na kojem je temeljeno pojednostavljeno tipsko ležište.

2. METODE IZRAČUNA GEOLOŠKOG RIZIKA

Vjerojatnost geološkog uspjeha (PoS) je vjerojatnost pronalaska nafte koja je u stanju slobodno i održivo teći prema bušotini (ROSE, 2001). Vrijednost PoS-a je bezdimenzionalna veličina, a može se izraziti kao postotak (ROSE, 2001) ili decimalni broj (MILKOV, 2015; NEWENORP i SCHUYLER, 2000). PoS se najčešće koristi kako bi se izračunao perspektivni rizični volumen. Većina autora koristi četiri do sedam faktora čiji umnožak daje ukupan geološki PoS, a neki autori koriste čak 50 faktora rizika (WATSON, 1998). MALVIĆ (2009) koristi 5 faktora rizika: struktura, matične stijene, kolektorske stijene, migracija te očuvanost ugljikovodika.

Odgovor na pitanje koliko bi se faktora trebalo uzeti u obzir prilikom izračuna PoS-a treba sagledati iz dvije perspektive. Jedna je teoretska koja kaže da je bitno da se samo međusobno neovisni faktori množe te da niti jedan rizičan faktor koji ima utjecaj na geološki uspjeh ne smije biti izostavljen. Ovo je bitno kako bi se zadovoljio matematički smisao izračuna PoS-a množenjem (CCOP, 2000). Druga perspektiva je praktična koja kaže da veća količina rizičnih faktora može rezultirati nižim PoS-om, što za sobom vuče druge posljedice. Jedna od njih je da je teško odobriti bušenje ukoliko je vrijednost izračunatog PoS-a niska, a druga je da niži PoS znači i nižu novčanu vrijednost „playa" te posljedično i prospekta.

U ovom radu odabrane su dvije metode izračuna PoS-a. Jednu je predložio David A. WHITE (1993), a drugu Alexei V. MILKOV (2015). Prva metoda je subjektivnija, temelji se stručnoj procjeni čimbenika rizika na temelju dostupnih podataka o geološkoj građi ležišta, a druga metoda temelji se na relativno kompleksnim tablicama što predstavlja objektivniji pristup izračunu. U nastavku slijedi pregled obje metode.

2.1 Metoda prema WHITE (1993)

Prema WHITE-u (1993), geološka šansa za uspjeh (PoS, autor još naziva i „adekvatnost") je percipirana vjerojatnost postojanja značajnog polja koje je veće od najmanje definirane vrijednosti. Vrijednosti vjerojatnosti se kreću u rasponu od 0,0 do 1,0.

Kako bi se dobio geološki rizik postojanja od maksimalne vrijednosti vjerojatnosti koja iznosi 1,0 oduzima se dobiveni PoS. Rizik pri tom predstavlja vjerojatnost da se neće otkriti značajno polje. Svako polje koje je veličinom manje od preciziranog minimuma ima vrijednost PoS blizu nuli.

Da bi odredili geološku šansu uspjeha prema WHITE-u (1993) prvo moramo odrediti geološku šansu „playa" (ili samo šansa „playa") te uvjetni geološki faktor uspjeha, a određujemo ih pomoću rizičnih faktora: zamka, ležište, matična stijena, migracija te kvaliteta ugljikovodika. Vrijednosti ovih faktora utvrđujemo na temelju podataka iz bušotina, izdanaka, seizmičkih istraživanja, povijesti proizvodnje te drugih podataka.

„Play" je grupa prospekata jednog područja koje ima iste matične stijene, kolektorske stijene, migracijske puteve, izolatore i tip zamki. Geološka šansa „playa" je vjerojatnost da postoji barem jedno polje koje ima potrebnu, minimalnu veličinu unutar „playa". Ova vjerojatnost obuhvaća regionalne, grupne te zavisne i za „play" specifične rizike, što znači da ukoliko jedan prospekt nema akumulacije ugljikovodika, vrlo vjerojatno nemaju ni ostali (WHITE, 1993). To nije slučaj s prosječnom vjerojatnošću uspjeha prospekta koja predstavlja omjer uspjeha „playa" množen s omjerom uspjeha regionalnog „playa" te ona obuhvaća lokalne, za prospekt specifične, individulane te nezavisne rizike, stoga neuspjeh jednog prospekta ne povlači za sobom i neuspjeh drugog prospekta. Procijenjeni omjer uspjeha „playa" pretpostavlja da će „play" biti uspješan ukoliko ima barem jedno polje minimalne veličine.

Prije nego li se krene u određivanje vjerojatnosti geološkog uspjeha prema WHITE-u (1993), potrebno je definirati kritične faktore potrebne za procjenu vjerojatnosti adekvatnosti prospekta. Najprije se definira potrebna minimalna vrijednost geološkog polja, odnosno minimalni volumen geoloških rezervi polja koja se izražava u m^3 ili barelima, odnosno definira se minimalna veličina polja koja se odnosi na sve prospekte jednoga „playa" te utječe na šansu prospekta. Izabrana minimalna veličina jedan je od najvažnijih parametara te ne smije biti zadana premala vrijednost. Minimalna veličina obično je veličine male, ali vidljive strukture. Nadalje, procjenjuju se minimalne, najvjerojantnije te maksimalne vrijednosti za svaki bitan faktor prospekta. Na slici 1. prikazani su faktori rizika koji se trebaju uzeti u obzir prilikom izračuna geološke vjerojatnosti adekvatnosti i za prospekte i za „playeve".

Kako bi došli do procijenjene vjerojatnosti adekvatnosti prospekta, procjenjuje se omjer uspjeha „playa“ (eng. *Play success ratio*). Omjer uspjeha playa je procijenjeni broj budućih polja većih od definiranog minimuma podijeljen s ukupnim brojem netestiranih prospekta koji su dovoljno veliki da sadrže barem jedno ležište barem minimalne veličine Na slici 1. na crtu f unosi se omjer uspjeha „playa”. Ukoliko ne postoji dovoljno podataka za procjenu omjera uspjeha „playa”, može se koristiti omjer uspjeha nekog drugog „playa” koji je sličan istraživanom „playu“. Zatim se procjenjuje grupna šansa za četiri kategorije a, b, c, d na Slici 1. Kako bi odredili šansu „playa“ potrebno je definirati kritične grupne rizike te se moraju zaokružiti samo oni faktori koji, ukoliko su neadekvatni, mogu odbaciti polje minimalne veličine u svakom prospektu u „playu“, ali takvih faktora je vrlo malo. Ne smiju se zaokruživati individualni rizici ili rizici specifični za prospekt. Za svaku kategoriju se treba fokusirati samo na zaokružene parametre, a šansa za zaokružene grupne parametre može varirati od minimalne 0,0 do 1,0. Ukoliko nema zaokruženih rizičnih faktora, vrijednost svake grupe je 1,0, a ukoliko je zaokruženo više faktora unutar jedne grupe, te se vrijednosti međusobno zbrajaju kako bi se dobila vrijednost grupnog faktora. Nakon što su grupne kategorije a, b, c, d izračunate, množe se kako bi se dobila šansa adekvatnosti „playa”, linija e na slici 1. Ovo je procijenjena šansa koja kaže da će unutar neograničenog broja prospekta unutar „playa”, barem jedan prospekt sadržavati barem jedno polje minimalne veličine. U već produktivnim „playevima“, gdje postoji barem jedno polje minimalne veličine, šansa „playa” ostaje 1,0. Nadalje se računa prosječna vjerojatnost uspjeha prospekta, na slici 1. linija g, koja je jednaka umošku omjera uspjeha „playa” (f) i šanse „playa” (e). Ako je šansa „playa” 1,0 onda je prosječna šansa prospekta jednaka omjeru uspjeha.

Nakon što je izračunata šansa „playa” te omjer uspjeha „playa”, pristupa se procjeni prospekta. Prvo se procjenjuju faktori volumena, minimalne, najmanje vjerojatne, te maksimalne vrijednosti za svaki faktor volumena prospekta. Preferirani faktori volumena su ukupni volumen zamke (uključuje geometrijske elemente zamke te ukupnu debljinu kolektora), prosječnu poroznost, efektivnu debljinu, zasićenje ugljikovodicima, naftni i/ili plinski volumni faktor te faktor iskorištenja. Nadalje se procjenjuju uvjetni geološki faktor uspjeha. Ovo je procijenjena šansa da će prospekt sadržavati polje minimalne veličine, ali pod uvjetom da je „play“ bio uspješan gdje se pretpostavlja da je svaki prethodni grupni faktor bio 1,0. Na slici 1. se identificiraju i podcrtavaju individualni rizični faktori. Podcrtavaju se samo oni faktori koji ukoliko su neadekvatni mogu izbrisati polje minimlane

veličine, ali samo na istraživanom području bez da nužno utječu i na druge prospekte. Procjenjuje se individualna šansa adekvatnosti za 4 kategorije, odnosno čimbenika rizika (Slika 1, h, i, j, k) ukoliko je vrijednost na linijama h, i, j, k jednaka 1,0 znači da nema lokalnih rizika i primijenit će se samo regionalna vrijednost. Ukoliko su dvije ili više vrijednosti u svakoj kategoriji podcrtane, treba uzeti vrijednost svake te ih pomnožiti kako bi se dobila vjerojatnost za tu kategoriju. U svrhu lakšeg snalaženja, postoje linije na slici 1., p, q, r, s koje se odnose na šansu adekvatnosti prospekta, kada se uzmu u obzir regionalni i lokalni čimbenici (npr. h x a=p). Množenjem 4 kategorije h, i, j, k dobije se uvjetni faktor uspjeha prospekta (m), no ova vrijednost samo je indikator lokalnih uvjeta i ne uzima se kao mjerilo uspješnosti prospekta. Zatim se množi faktor uspjeha prospekta (m) sa šansom „playa" (e) kako bi se dobila sveukupna šansa adekvatnosti prospekta (t). Množenjem p, q, r, s dobiva se sveukupna šansa adekvatnsoti prospekta (t), što daje procijenjenu šansu da propekt sadrži barem jedno polje minimalne veličine. Najbolja šansa prospekta ne može premašiti šansu „playa" jer je u šansu prospekta uračunata i šansa „playa".

„PLAY“ –_____ PROSPEKT – _____

a. ____ ZAMKA – IZOLATOR – VRIJEME h. ____ x a = ____p.

VOLUMEN ZAMKE (površina i visina zatvaranja, strukturna ili stratografska)

IZOLATOR (gornji, bočni; nema značajnijeg istjecanja duž rasjeda, pukotina)

VRIJEME ZATVARANJA (u odnosu na migraciju)

b. ____ KOLEKTOR – POROZNOST – PROPUSNOST i. ____ x a = ____q.

DEBLJINA KOLEKTORA (nema prekida taloženja, promjene facijesa, isklinjavanja ili rasjedanja; odgovarajuća efektivna debljina)

POROZNOST (primarna ili sekundarna, pore nisu zatvorene ili cementirane)

PROPUSNOST I KONTINUIRANOST

c. ____ MATIČNA STIJENA – ZRELOST – MIGRACIJA j. ____ x a = ____r.

ORGANSKA TVAR (područje prostiranja matičnih stijena, debljina, TOC (eng. *total organic carbon*)) I KVALITETA (tip organske tvari)

ZRELOST (adekvatno vrijeme ,temperatura; nije prezrelo)

MIGRACIJA (primarna ili ekspulzija; sekundarna, migracija od matične stijene do zamke)

d. ____ OČUVANOST – KVALITETA UGLJIKOVOIDKA – ISCRPAK k. ____ x a = ____s.

OČUVANOST (nema ispiranja, biodegradacije, difuzije)

KVALITETA UGLJIKOVODIKA I KONCENTRACIJA (nafta nije previskozna, zasićenje je zadovoljavajuće; ugljikovodične komponente prirodnoga plina nisu previše raspršene ili razrijeđene ;zadovoljavajuća visina stupca nafte ili plina u ležištu)

ISCRPAK (energija ležišta, tlak, dubina)

e. ____ ŠANSA „PLAYA“ = a x b x c d (minimalna veličina polja = _____)

f._____OMJER USPJEHA PLAYA

g. PROSJEČNA ŠANSA PROSPEKTA = e x f = _____

UVJETNI FAKTOR USPJEHA PROSPEKTA = h x i x j x k = _____ m.

ŠANSA ADEKVATNOSTI PROSPEKTA = e x m = p x q x r x s = _____ t.

Slika 1. Predložak za izračun šanse adekvatnosti za “play i prospekt” (WHITE, 1993)

2.2 Metoda prema MILKOV (2015)

Nasuprot pristupu WHITE-a, MILKOV (2015) predlaže izračun PoS-a na temelju detaljnih tablica rizika koji predstavljaju objektivniji pristup procijeni PoS-a. Kako je već rečeno, vjerojatnosti svakog individualnog geološkog faktora rizika su najčešće procijenjene, a procjenjuju ih stručnjaci. Takav pristup podložan je subjektivnosti, a samim time i pogrešnim procjenama te on predlaže alternativni pristup, odnosno upotrebu algoritma.

U 2012. razvijen je algoritam koji služi za procjenu geološkog PoS-a za dio bazena s perspektivnim konvencionalnim ležištima nafte ili plina. Algoritam se sastoji od tablica rizika te se koristi šest procijenjenih geoloških faktora rizika: postojanje strukture, postojanje kolektorske stijene, kvaliteta ležišta, postojanje adekvatnog izolatora, zrelost matičnih stijena i migracija. Svakom faktoru dodjeljuje se određena vrijednost iz Tablica 1.-6. gdje se pritom koriste kvalitativni geološki opisi svakog segmenta. Segment je potpovršinski dio koji predstavlja potencijalnu akumulaciju ugljikovodika te je to također najmanja jedinica procjene. Segment se mora nalaziti unutar jednog „playa". Na kraju, sam PoS za određeni segment ležišta izračunat je na temelju množenja vrijednosti svih šest geoloških faktora. PoS vrijednost se drugačije računa za segment, prospekt koji se sastoji od više segmenata te za istraživačku bušotinu. Ova metoda bavi se samo izračunom PoS-a za segment čiji podatci služe kao parametri za izračun PoS-a.

Tablice rizika temelje se na postojećim podatcima i modelima koji su pouzdani te dokazani. Podatci potječu s izdanaka, bušotina te najčešće geofizičkih mjerenja. Modeli se temelje na strukturnim interpretacijama, litofacijesnim kartama, podatcima o zrelosti matičnih stijena te drugim potpovršinskim podatcima. Vjerojatnost svakog faktora je maksimalna (1,0) kada postoje i izravni podatci te precizni modeli, a vrijednost faktora je minimalna (0,05) kada nema dokaza za postojanje tih elemenata na istraživanom području. Tablice rizika su dizajnirane da uključuju temeljne, relevantne i najvažnije informacije o svakom geološkom faktoru rizika, uz izbjegavanje kompleksnosti koje bi tablice napravile previše kompliciranima i teško uporabljivima.

Slijedi opis tablica rizika za svaki faktor koji se mora uzeti u obzir prilikom izračuna geološkog faktora rizika.

2.2.1 Tablica vjerojatnosti postojanja strukture/zamke

Cilj je procijeniti strukturu, odnosno zamku koja se nalazi na istraživanom području. Procjena se najčešće temelji na rezultatima interpretacije seizmičkih mjerenja. Započinje se s procjenom seizmičkih podataka kako je navedeno u Tablici 1. Gustoća seizmičkih profila bi trebala biti dovoljno gusta kako bi se sa sigurnošću mogao odrediti volumen zamke. Kako bi se procijenio rizik, istraživači opisuju sam oblik strukture na temelju seizmičkih podataka i interpretacije, kompleksnost strukture, ali i pouzdanost podataka, pri čemu se uzimaju u obzir kvaliteta konverzije vrijeme/dubina, pouzdanost odabranih seizmičkih refleksa koji predstavljaju površine koje povezuju mapirane strukture, kvaliteta seizmičkih podataka, korelacija i interpretacija seizmičkih podataka te udaljenost bušotine. Kada se iz modela procijene svi parametri, koristi se Tablica 1. kako bi ih pretvorili u vjerojatnost prisutnosti strukture.

Tablica 1. Tablica vjerojatnosti prisutnosti strukture/zamke (MILKOV,2015)

Struktra (zatvaranje, geometrija, zamka)				PODATCI (postojanje i pouzdanost)			
				3D seizmika	2D seizmika Broj profila u strukturi (uz obaveznu prisutnost međusobno okomitih seizmičkih profila)		
					Gusto (7 profila i više)	Rijetko (3-6 profila)	Vrlo rijetko (2 profila)
Modeli (postojanje i pouzdanost)	Kartiranje i korelacija	Visokoreljefne strukture (≥3puta veće od seizmičke preciznosti) i niska strukturna kompleksnost (zatvaranje sa četiri strane)	Lako interpretirati, pouzdana korelacija na temelju obližnjih bušotina (<50 km)	1	0,90	0,80	0,60
			Nesigurna korelacija (horizonti su lateralno prekinuti) ili na temelju udaljenih bušotina (>50 km)	0,95	0,85	0,75	0,55
			Teška interpretacija, nepouzdana korelacija (horizonti su prekinuti rasjedima, dijapirima) ili na temelju modela koji je dobiven analogno bez bušotinski podataka	0,85	0,75	0,70	0,45
		Struktura srednjeg reljefa (1-3 puta veća od seizmičke preciznosti) ILI visokoreljefna struktura s velikom strukturno kompleksnošću (zatvaranje s tri strane, stratigrafski)	Lako interpretirati, pouzdana korelacija na temelju obližnjih bušotina (<50 km)	0,80	0,70	0,60	0,35
			Nesigurna korelacija (horizonti su lateralno prekinuti) ili na temelju udaljenih bušotina (>50 km)	0,75	0,65	0,50	0,25
			Teška interpretacija, nepouzdana korelacija (horizonti su prekinuti rasjedima, dijapirima) ili na temelju modela koji je dobiven analogno bez bušotinski podataka	0,70	0,55	0,45	0,20
		Niskoreljefna struktura (manja od seizmičke preciznosti) ILI jako nesigurna dubinska konverzija (ispod soli, tokovi lave) ILI područja karakterizirana naglašenim promjenama laterlanih brzina u krovini	Lako interpretirati, pouzdana korelacija na temelju obližnjih bušotina (<50 km)	0,55	0,45	0,35	0,15
			Nesigurna korelacija (horizonti su lateralno prekinuti) ili na temelju udaljenih bušotina (>50 km)	0,50	0,40	0,25	0,10
			Teška interpretacija, nepouzdana korelacija (horizonti su prekinuti rasjedima, dijapirima) ili na temelju modela koji je dobiven analogno bez bušotinskih podataka	0,40	0,30	0,20	0,05
		Niskoreljefna struktura (manja od seizmičke preciznosti) I/ILI jako nesigurna dubinska konverzija (ispod soli ili tokova lave) ILI područja karakterizirana naglašenim promjenama brzina u krovini		0,35	0,25	0,15	0,05

2.2.2 Tablica vjerojatnosti prisutnosti kolektorskih stijena

Cilj je procijeniti koje su kolektorske stijene prisutne unutar istraživanog područja te se zatim pomoću tablice 2. dodjeljuje vrijednost vjerojatnosti prisutnosti kolektorskih stijena. Prvo se trebaju prikupiti direktni podaci (podatci s izdanaka, iz istraživačkih bušotina) te indirektni podatci (geofizička mjerenja) te ih interpretirati kako bi se odredila prisutnost kolektorskih stijena, starost i litofacijesi te također odredila prostorna veza između tih parametara. Zatim slijedi izrada modela ležišta. Taj model je obično paleogeografska karta koja se temelji na rekonstrukciji tektonskog razvoja te integrira, opisuje i ograničava okoliš taloženja i prostornu raspodjelu ležišnih stijena temeljem analiza uzoraka stijena s izdanaka, bušotinskih podataka te seizmičkih podataka (GRANT i sur., 1996; FRASER, 2010). Važni čimbenici koje treba uzeti u obzir su udaljenost do najbližih bušotina s podatcima te potencijalne promjene facijesa u istraživanom području.

Tablica 2. Tablica vjerojatnosti prisutnosti kolektorskih stijena (MILKOV, 2015)

Prisutnost kolektorskih stijena				PODATCI (postojanje i pouzdanost)					
				Bušotine su udaljene <100 km u „playu“. Karte taložnih okoliša (GDE - Gross Depositional Environment)/litofacijesne karte ukazuju na postojanje kolektora na temelju izdanaka, jezgara, bušotinskih podataka, seizmičkih podataka ILI se facijesi kolektorskih stijena pojavljuju na seizmičkim podatcima (amplitude, AVO, koherencije)				Nema bušotina na udaljenosti <100 km u „playu“. Karte taložnih okoliša (GDE) ukazuju na prisutnost kolektorske stijene na temelju analize seizmičkih podataka	
				Sve bušotine <50 km imaju kolektor	Sve bušotine 50-100 km imaju kolektor	Nemaju sve bušotine <100 km kolekotr	Niti jedna bušotina <100 km nema kolektor	Facijes kolektorskih stijena se uočava na seizmičkim podatcima	Seizmički podatci ne ukazuju na postojanje kolektorskih stijena
Modeli (postojanje i pouzdanost)	Interpretirana debljina taložnih okoliša (GDE)	Marinski okoliš	Marinske naslage plitkomorskih okoliša, karbonati	1,00	0,95	0,85	0,60	0,95	0,85
			Obalne, fluvijlnodeltne, deltne, tajdalne naslage	1,00	0,90	0,80	0,55	0,90	0,80
			Dubokomorski turbiditi (kanali, lepeze)	0,75	0,65	0,45	0,20	0,65	0,45
		Kontenentalni okoliš	Eolski	0,95	0,85	0,70	0,45	0,85	0,70
			Lakustrinski	0,90	0,80	0,70	0,45	0,80	0,70
			Aluvijalna lepeza, isprepletene rijeke	0,85	0,75	0,60	0,35	0,75	0,60
			Meandrirajući kanali	0,80	0,70	0,50	0,25	0,70	0,50
		Drugo	Porozni efuzivi ili razlomljene stijene podloge bazena	0,55	0,45	0,25	0,05	0,45	0,25

Legenda: GDE – *gross depositional environment*, AVO – *amplitude versus offset*, DHI – *direct hydrocarbon indicator.*

2.2.3 Tablica vjerojatnosti kvalitete ležišta

Cilj je pronaći ležište koje ima dovoljno veliku poroznost/propusnost i sadrži naftu s niskom viskoznošću kako bi se osigurala pokretljivost fluida. Stoga je bitno procijeniti vjerojatnost kvalitete ležišta prema tablici 3., odnosno vjerojatnost da će proizvodnja iz ležišta biti moguća bez uporabe dodatne stimulacije protoka fluida (primjerice frakturiranje, termičke metode). Trebaju se u obzir uzeti podatci iz bušotina relevantni za procjenu ležišta unutar istraživanog područja; facijesi, dubina, poroznost, propusnost, zasićenje ugljikovodicima, brzina protoka te korelacija između svih njih. Procjena svih ovih parametara daje odgovor je li kvaliteta ležišta dobra ili loša. Potrebno je istražiti prostornu i vertikalnu (dubinsku) raspodjelu svojstava ležišta bitnih za kvalitetu i odrediti granične vrijednosti poroznosti, propusnosti i viskoznosti kako bi se procijenila kvaliteta ležišta. Potrebno je također analizirati i čimbenike koji kontroliraju kvalitetu ležišta (dijageneza / cementacija, zaglinjenost, uvjeti tlaka koji mogu utjecati na očuvanje poroznosti i propusnosti, rana migracija nafte, prisutnost teške i viskozne nafte zbog rane ekspulzije, biorazgradnja nafte, itd.). Kvaliteta ležišta uvelike ovisi o maksimalnoj dubini zalijeganja i temperaturi i tlaku, mineralnom sastavu ležišta i svojstvima ležišnog fluida (AJDUKIWICZ i LANDER, 2010). Potrebno je napraviti modele koji opisuju i/ili predviđaju povijest temperature u ležištu, sedimentološke značajke, mineralni sastav matične stijene, vrstu fluida i njegovu kvalitetu. MILKOV (2015) iznosi mišljenje da je maksimalna temperatura (engl. *maximum burial temperature*) ključni faktor koji kontrolira kvalitetu ležišta te je u tablicama prikazano kako koristiti podatke o temperaturi da bi se dobila vrijednosti koja opisuje kvalitetu ležišta u klastičnim i karbonatnim stijenama.

Tablica 3. Tablica vjerojatnosti kvalitete ležišta (MILKOV,2015)

Kvaliteta ležišta (klastične stijene)					PODATCI (postojanje i pouzdanost)				
					Podaci kvalitete ležišta (RD) (poroznost/propusnost, podaci protoka, viskoznost) podaci za „play“ su vidljivi iz bušotinskih podataka				Nema bušotina u „playu“, samo seizmički podaci
					Sve bušotine <50 km udaljenosti od prospekta imaju dobru kvalitetu ležišta	Sve bušotine 50-100 km udaljenosti od prospekta imaju dobru kvalitetu ležišta	Nemaju sve bušotine <100 km udaljenosti od prospekta dobru kvalitetu ležišta	Sve bušotine <100 km udaljenosti od prospekta imaju slabu kvalitetu ležišta	
Modeli (postojanje i pouzdanost)	Numerički model (npr. Touchstone) sugerira dobru kvalitetu ležišta		35-100˚C za naftu ili <120˚C za plin	Homogeni kolektor u kojem dominira homogeni, čisti kvarc	1.00	0.95	0.80	0.55	0.75
	Nema numeričkog modela	Maksimalna temperatura zalijeganja kolektorskih stijena		Heterogeni kolektor u kojem dominira arkoza, grauvaka	0.95	0.80	0.70	0.45	0.65
			100-130˚C za naftu ili 120-150˚C za plin	Homogeni kolektor u kojem dominira homogeni, čisti kvarc	0.85	0.75	0.55	0.30	0.50
				Heterogeni kolektor u kojem dominira arkoza, grauvaka	0.75	0.60	0.45	0.20	0.40
			>130˚C za naftu ili >150˚C za plin	Rana migracija nafte (prije zalijeganja >130-150°C) ILI znatan nadpritisak	0.65	0.55	0.35	0.15	0.30
			ILI trenutno nafta <35˚C	Homogeni kolektor u kojem dominira homogeni, čisti kvarc	0.55	0.45	0.25	0.10	0.20
	Numerički model (npr. Touchstone) sugerira lošu kvalitetu ležišta			Heterogeni kolektor u kojem dominira arkoza, grauvaka	0.50	0.40	0.20	0.05	0.15

Legenda: RD- *reservoir deliverability* – kvaliteta ležišta.

2.2.4 Tablica vjerojatnosti postojanja adekvatnog izolatora

Cilj je utvrditi vjerojatnost postojanja efektivnh izolatorskih jedinica. Da bi se procijenila vjerojatnost prisutnosti izolatora, potrebno je procijeniti propusnost geoloških površina koje ograničavaju ležište, odnosno litoloških granica, ploha diskontinuiteta te bočne promjene facijesa (MILTON i BERTRAM, 1992). Učinkovitost izoliranja ovisi prvenstveno o propusnosti koja je uvjetovana litološkim sastavom izolatora. Gornji, donji i bočni izolatori imaju jednaku važnost.

Procjena treba započeti analizom bušotinskih i seizmičkih podataka koji dokazuju prisutnost gornjeg izolatora. Učinkovitost izolatora povećava se od tankih i lomljivih škriljavaca do soli i anhidrita kao što je prikazano u Tablici 4.. Nadalje, zamke se mogu podijeliti u dvije glavne grupe na temelju mehanizma zatvaranja (MILTON i BERTRAM, 1992 ; CCOP, 2000). U prvu skupinu spadaju zamke koje imaju izolator samo s jedne strane s jednostavnim izolatorskim mehanizmom, a definirane su gornjim izolatorom te imaju zatvaranje sa sve četiri strane, poput antiklinala, sedimentnih tijela (grebeni) te strukture gdje ravnina rasjeda predstavlja izolator. Druga skupina uključuje kompleksnije stratigrafske i kombinirane zamke s više izolatora, odnosno zamke koje osim gornjeg izolatora zahtijevaju bočne i / ili donje izolatore kako bi omogućile akumuliranje nafte. FÆRSETH i sur. (2007) predstavili su shemu za rizik brtvljenja rasjeda, koja je inkorporirana u tablicu rizika izolatora (Tablica 4).

Tablica 4. Tablica vjerojatnosti prisutnosti izolatora (MILKOV,2015)

Izolator					PODACI (postojanje i pouzdanost)				
					Gornji izolator je dokazan podatcima iz buštotina na udaljenosti <100 km				Gornji izolator je zaključen na temelju seizmičkih podataka
		Mahanizam izolatora			Kvaliteta izolatora				
		Gornji izolator	Donji ili bočni izolator	Strukturni stil	Jako dobar izolator (sol, anhidrit)	Dobar izolator(debelo (>10 m) šejl, bazalt, karbonati)	Prihvatljiv izolator (šejl prosječne debljine (5-10 m) ILI rasjed gornji sloj	Loša kvaliteta (mala debljina (<5 m, ili pjeskoviti) ILI lomljivi šejl	
Modeli (postojanje i pouzdanost)	Zamka s jednim izolatorom	Konkordantno ili diskordantno nalijeganje	nema	Antiklinale,lepeze, grebeni, izdignuća paleoreljefa („burried hill“)	1.00	0.95	0.80	0.55	0.75
		Nekonformni, ravnina rasjeda je dio gornjeg izolatora	nema	Rasjedna struktura (horst)	0.95	0.85	0.70	0.45	0.65
	Zamka s više izolatora	Konformni ili nekonformni	Tektonska površina (rasjed)	Jukstapozicijski izolator	0.95	0.85	0.70	0.45	0.65
				Smicanje glinenog šejla, SSF<4	0.85	0.75	0.55	0.30	0.50
				Nije rađena analiza jukstapozicije/smicanja	0.80	0.70	0.50	0.25	0.45
				Više od jedne ravnine rasjeda ILI curenje uzrokovano jukstapozicijom pijesak-pijesak ILI rezervoar na dubini > 2500 m, SGR> 0,25, SSF <5	0.75	0.65	0.45	0.20	0.40
				Samopostavljeni kolektor na dubini<2500 m, SGR <0,2, SSF> 5	0.50	0.35	0.20	0.05	0.15
		Konformni	Tektonska površina (dijapir)	Zamka formirana solnim ili muljnim dijapirizmom	0.95	0.85	0.70	0.45	0.65
		Konformni	Promjene facijesa, kataklastiti, promjena u fluidu pora (katran, hidrati)	Stratigrafske zamke (isklinjenje, facijesne promjene nastale nakon taloženja)	0.75	0.65	0.45	0.20	0.40
		Konformni	Nekonformni	*Onlap*, Lowstand progradacijski klin	0.65	0.50	0.30	0.10	0.25
		Erozijska diskordancija	Konformni	Strukture neposredno ispod diskordancije	0.50	0.35	0.20	0.05	0.15

Legenda: SSF - *shale smear factor*, SGR – *shale gauge ratio.*

2.2.5 Tablica vjerojatnosti zrelosti matičnih stijena

Cilj je procijeniti vjerojatnost postojanja zrelih, matičnih stijena određene kvalitete na istraživanom području. Prisutnost zrele matične stijene najprije se procjenjuje na temelju analize dostupnih regionalnih podataka kao što su izdanci ili korelacija nafte -matične stijene (Tablica 5.). Postojanje direktnih indikatora ugljikovodika (NANDA, 2016) povećava vjerojatnost prisutnosti zrelih matičnih stijena. DHI odnosno direktni indikatori ugljikovodika (eng. *Direct hydrocarbon indicator*) očituju se kao anomalni seizmički atributi ili uzorci koji ukazuju na postojanje ugljikovodika. Amplitude seizmičke refleksije rezultat su kontrasta akustičnih impedancija kojega seizmički valovi prouzrokuju šireći se granicama slojeva u podzemlju. Sedimentne stijene definirane su kemijskim sastavom, matriksom, šupljikavosti i pornim fluidom, od kojih svaki ima utjecaj na elastična svojstva koja utječu na kompresibilnost stijene. Plin je iznimno stlačiv fluid i kada je prisutan u pornom prostoru značajno smanjuje volumni modul elastičnosti, čineći takvu stijenu kompresibilnijom od stijene zasićene drugim fluidom. Obzirom da visoke amplitude ukazuju na prisustvo ugljikovodika u klastičnim stijenama, nazivaju se direktnim indikatorima ugljikovodika. Direktnim indikatorima ugljikovodika smatraju se tzv. svijetle mrlje (engl. *Bright spot*), tamne mrlje (engl. *Dim spot*) i ravne mrlje (engl. *Flat spot*) (NANDA, 2016). Potrebno je napomenuti kako anomalije iskazane visokom amplitudom ne ukazuju nužno i na prisutnost ugljikovodika. Također, razmatraju se seizmički atributi kako bi se potvrdile direktne indikacije ugljikovodika.

Svijetle mrlje (engl. *Bright spots*) predstavljaju snažne anomalije amplitude s negativnom vrijednošću koeficijenta refleksije, a povezuju se s prisustvom plina u pješčenjačkim ležištima ograničenih šejlom (NANDA, 2016).

Tamne mrlje (engl. *Dim spots*) predstavljaju anomaliju male amplitude s pozitivnim koeficijentom refleksije, a povezuju se najčešće s prisustvom plina u karbonatnim ležištima (NANDA, 2016).

Ravne mrlje (eng. *Flat spot*) definirane su visokim amplitudama i horizontalnim refleksima te se povezuju s kontaktom plin-voda i pokazuju pozitivan koeficijent refleksije. U ovom slučaju, refleks nije povezan s litologijom već kontaktom fluida stoga je kontrast akustičnih impedancija rezultat razlike gustoća fluida, plina i vode. No postoje primjeri gdje

vodom zasićeni pješčenjaci, koji su gotovo horizontalni te prostorno ograničeni, mogu biti prikazani kao ravna mrlja (NANDA, 2016).

U nedostatku izravnih podataka, potrebna je karta taloženja sedimenata koja opisuje okoliš taloženja matičnih stijena kako bi se procijenili lateralno prostiranje, debljina, moguće promjene organskog facijesa i kvaliteta (tip kerogena, ukupni sadržaj organskog ugljika (TOC), vodikov indeks (HI)). Naravno, sveobuhvatno numeričko modeliranje zrelosti pomoću standardnih softvera koji se koriste u industriji (Zetaware, Petromod, Temis itd.) pomoći će u pouzdanoj procjeni zrelosti (Tablica 5.).

Tablica 5. Tablica vjerojatnosti zrelosti matičnih stijena (MILKOV,2015)

Prisutnost zrele matične stijene			PODACI (postojanje i pouzdanost)				
			Direktni dokazi za/protiv postojanje zrelih matičnih stijena u bazenu				Indicirane matične stijene: karte taložnih okoliša (GDE) temelje se isključivo na seizmičkim podacima
	Numerički model postoji	Numerički model ne postoji	Tragovi ugljikovodika, nabušena matična stijena u bazenu	Tragovi ugljikovodika u nabušenom dijelu bazena, pouzdani direktni indikatori ugljikovodika za prospekt	Izostanak tragova ugljikovodika u nabušenim dijelovima bazena	Izdanci matičnih stijena nalaze se na rubovima bazena	
Modeli (postojanje i pouzdanost)	1D-3D numerički model ukazuje na to da je istraživano područje unutar kasnog razdoblja zrelosti ili prezrelo	Drenažno područje matičnih stijena s kerogenom tipa I-II je izloženo maksimalnoj temperaturi zalijeganja >140°C	1,00	0,90	0,50	0,80	0,70
		Drenažno područje matičnih stijena s kerogenom tipa III-IV je izloženo maksimalnoj temperaturi zalijeganja >200°C					
	1D-3D numerički model ukazuje na to da je istraživano područje unutar rane faze zrelosti	Drenažno područje matičnih stijena s kerogenom tipa I-II je izloženo maksimalnoj temperaturi zalijeganja 115-140°C	0,80	0,70	0,25	0,55	0,45
		Drenažno područje matičnih stijena s kerogenom tipa III-IV je izloženo maksimalnoj temperaturi zalijeganja 160-200°C					
	1D-3D numerički model ukazuje na to da je istraživano područje nezrelo	Drenažno područje matičnih stijena s kerogenom tipa I-II je izloženo maksimalnoj temperaturi zalijeganja <115°C	0,55	0,45	0,05	0,30	0,20
		Drenažno područje matičnih stijena s kerogenom tipa III-IV je izloženo maksimalnoj temperaturi zalijeganja <160°C					

Legenda: GDE – *gross depositional environment*.

2.2.6 Tablica vjerojatnosti migracije

Cilj je procijeniti vjerojatnost efektivne migracije nafte iz matične stijene do kolektorske stijene u količini dovoljnoj za stvaranje akumulacije koja se smatra geološkim uspjehom. MILKOV (2015) polazi od pretpostavke kako je vertikalna i lateralna migracija nafte kroz kolektorske stijene efikasniji mehanizam sekundarne migracije nego putem rasjeda, za koje navodi da imaju ograničenu ulogu u sekundarnoj migraciji uslijed male površine rasjedne plohe u odnosu na volumen matičnih i kolektorskih stijena. Stoga se u Tablici 6. migracija putem rasjeda ne uzima u obzir.

Unutar zamke će najvjerojatnije nastati akumulacija ukoliko su kolektorske stijene smještene direktno iznad ili ispod matične stijene, odnosno kada je migracija lokalna. Kada su matična i kolektorska stijena udaljene i migracija se odvija kroz litološki različite stijene, vertikalna i lateralna migracija iz matične stijene do akumulacije rezultira migracijskim gubitcima. Gubitci tijekom migracije nastaju zbog geometrije pora u kolektorskim stijenama kroz koje se migracija odvija, ali i zbog nekomercijalnih akumulacija malih do mikrodimenzija. Općenito vrijedi, što je duža migracija, veći su gubitci, jer je veći broj malih do mikro-akumulacija uslijed većeg broja pora s rezidualnim zasićenjem. Stoga, vjerojatnost efektivne migracije opada s porastom duljine puta migracije.

Tablica 6. Tablica vjerojatnosti migracije (MILKOV,2015)

Migracija iz zrelih matičnih stijena			PODACI (postojanje i pouzdanost)				
			Bušotinski podatci unutar istraživanog područja		Nema bušotinskih podataka iz drenažnog područja, postoje samo seizmički podaci		
			Akumulacije i tragovi ugljikovodikaunutar migracijskih puteva	Izostanak akumulacija i tragova ugljikovodika unutar migracijskih puteva	DHI okoliš je „vidljiv“		DHI okoliš nije „vidljiv“
					Prisutni direktni indikatori ugljiko-vodika	Odsutni direktni indikatori ugljiko-vodika	
Modeli (postojanje i pouzdanost)	3D numerički model (Trinity, Temis, Petromod) ukazuje na migracije	Lokalna migracija prema gore ili dolje (matična i ležišna stijena se nalaze jedna kraj druge)	1,00	0,55	1,00	0,55	0,80
	Nema numeričkog modela	Kratka <2 km vertikalna i kratka <50 km lateralna migracija	0,90	0,45	0,90	0,45	0,70
		Kratka <2 km vertikalna i duga >50 km lateralna migracija	0,80	0,30	0,80	0,30	0,55
		Duga >2 km vertikalna i kratka <50 km lateralna migracija	0,70	0,20	0,70	0,20	0,45
		Duga >2 km vertikalna i duga >50 km lateralna migracija	0,55	0,10	0,55	0,10	0,30
	3D numerički model (Trinity, Temis, Petromod) ukazuje na izostanak migracije	Migrcijska sijena/barijera ILI zamka formirana nakon što je matična stijena postala prezrela	0,45	0,05	0,45	0,05	0,20

Legenda: DHI – *direct hydrocarbon indicator.*

Tablice rizika izračuna PoS-a predstavlaju objektivniji pristup izračunu PoS-a, jer omogućuju jasnije povezivanje procijenjenih podataka o naftnogeološkom sustavu s geološkim faktorima rizika. Vjerojatnosti dobivene ovim načinom za svaki geološki faktor rizika su precizne, a tablice rizika zapravo služe tome da niti jedan faktor ne bude preskočen ili zaboravljen. Ova metoda minimizira subjektivnost, a samim time nema i pogrešaka prouzrokovanih istom.

3. GEOLOŠKE ZNAČAJKE ISTRAŽIVANOG PODRUČJA

Panonski bazenski sustav (PBS) rasprostire se između planinskih lanaca Alpa na zapadu, Karpata na sjeveru i istoku te Dinarida i južnih Karpata ja jugu. Hrvatskoj pripada jugozapadni dio Panonskog bazenskog sustava koji spada u skupinu zalučnih (engl. *back – arc*) bazena te se rasprostire na 25 000 km^2. U hrvatskom dijelu Panonskog bazenskog sustava izdvojene su četiri depresije: Murska, Dravska, Slavonsko-srijemska i Savska depresija (Slika 3). Razlučene su s obzirom na sastav sedimentne ispune, građu i geotektonski položaj, a granice između depresija predstavljaju brdsko-gorski masivi izgrađeni od paleozojsko-mezozojskih magmatita, matamorfita te podpovršinska uzdignuća prekrivena mlađim naslagama (VELIĆ, 2007).

U građi Panonskog bazena prisutna su dva različita kompleksa stijena. Jedan kompleks čine magmatsko-metamorfne stijene i manjim dijelom stijene paleozojske i mezozojske starosti te sedimentna bazenska ispuna koju čine stijene paleogen i neogena (pretežno neogena) i kvartara. Predtercijarnu podlogu karakterizira velika strukturna i tektonska kompleksnost te litološka raznolikost (VELIĆ, 2007). Naslage paleogena i neogena nalaze se većim dijelom ispod kvartarnih naslaga. Debljina neogenskih sedimenata uz rubna područja bazena iznosi 50 do 1500 metara, a najveće debljine ima u središnjem dijelu; 3500 metara u Slavonsko-srijemskoj, 5500 metara u Savskoj i Murskoj depresiji te oko 7000 metara u Dravskoj depresiji (VELIĆ, 2007). Naslage paleogena i neogena taložene su tijekom tri sedimentacijska megaciklusa koji odgovaraju trima glavnim fazama razvoja bazena te je svaki megaciklus odijeljen izraženom diskordancijom (SAFTIĆ et al., 2003).

3.1 Strukturno-stratigrafski odnosi hrvatskoga dijela Panonskog bazenskog sustava

Postanak hrvatskog dijela PBS-a vezan je uz Alpsku orogenezu. Pojedini taložni bazeni unutar PBS-a u različim razdobljima imali su zaseban razvoj, a u nekima zajednički. Općenito, mogu se razlikovati tri strukturne jedinice: zapadni rubni dio (od zone medvedničkog rasjeda pa sve dalje prema sjeverozapadu), južni rubni dio (od Karlovca do Slavonskog Broda – južno od Savskog rasjeda) i središnji dio (Savska et alavska depresija) (Slika 2.). Prema navedenim regionalnim strukturnim odnosima postoje tri faze razvoja struktura koje se podudaraju s megaciklusima taloženja tercijarnih nalaga (VELIĆ, 2007).

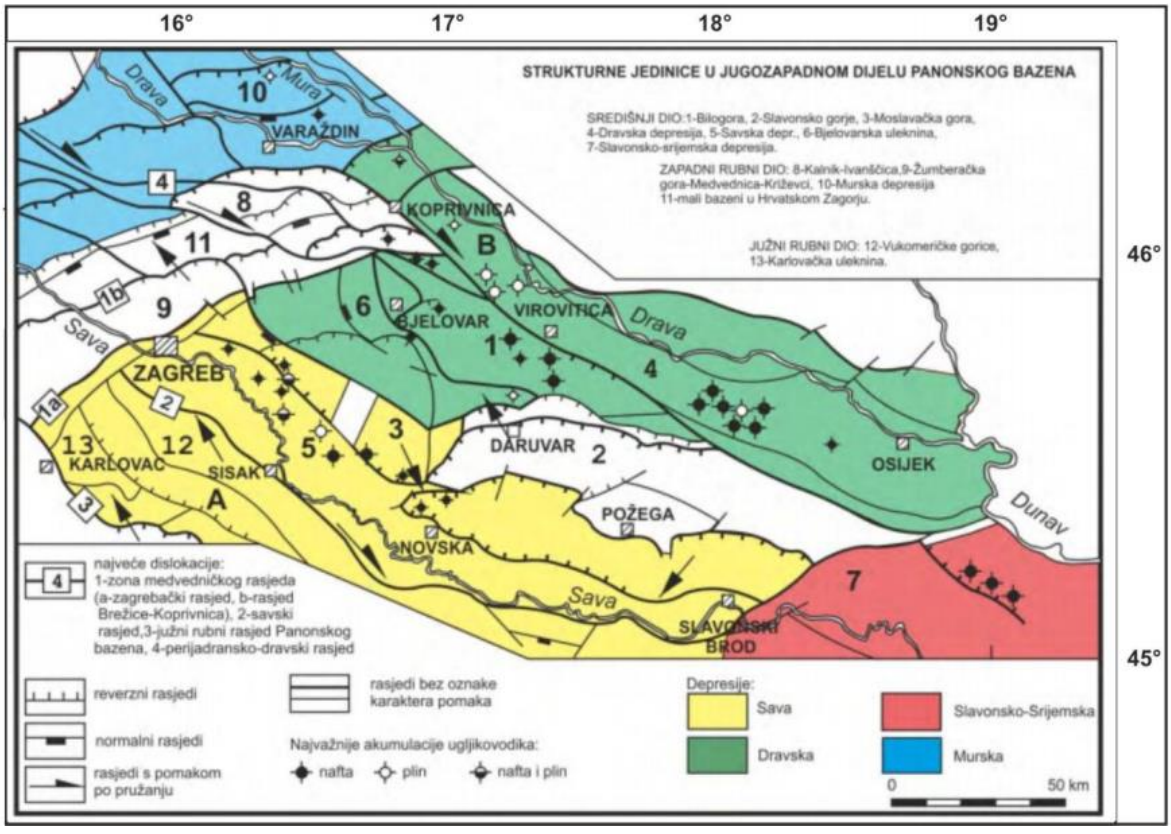

Slika 2. Strukturne jedinice u jugozapadnom dijelu Panonskog bazena (PRELOGOVIĆ et al., 1998.; LUČIĆ et al., 2001.; VELIĆ et al., 2011)

Prvi sedimentacijski megaciklus obuhvaća naslage taložene tijekom prve faze strukturnih promjena u rasponu oligocen – rani miocen koja je uzrokovala stvaranje nekoliko manjih pull-apart bazena nastalih duž aktivnih velikih desnih transkurentnih rasjeda koji se u jugozapadnom dijelu PBS-a pružaju pravcem SZ – JI (SAFTIĆ et al., 2003). Ovaj najstariji izdvojeni megaciklus je starijemiocenske i srednjomiocenske starosti te je trajao 6,8 M.a.. Tijekom ranog i srednjeg miocena (egenburg – baden) dolazi do promjene orijentacije regionalnog stresa na SSI-JJZ koja aktivira lijeve transkurentne rasjede. Tada se počela otvarati Savska depresija. Sedimentacija tijekom egera i egenburga je prisutna samo na pojednim, prostorno ograničenim dijelovima, poput Murske depresije, odnosno u malim bazenima Hrvatskog zagorja i u najzapadnijim zonama Dravske depresije (VELIĆ, 2007). Kao početak ovog ciklusa smatra se otnang jer su tada stvoreni uvjeti koji su omogućili sedimentaciju na gotovo cijelom prostoru. U području Savske depresije u otnangu započinje taloženje slatkovodnih jezerskih naslaga (PAVELIĆ, 2001). Samo lokalno dolazi do marinske transgresije (MALVIĆ i SAFTIĆ, 2008). Sedimentacija tijekom otnanga i karpata odvijala se u kontinentalnim sedimentacijskim okolišima te je karakterizira dominacija krupnih klastita nad sitnozrnastim. Početkom badena ovi sedimenti prelaze u slatkovodne jezerske naslage sa šejlovima i siltitima te mjestimično sadrže konglomerate i turbidite, a nakon toga i u marinske u srednjem badenu, kada je uspostavljena veza s morem (PAVELIĆ i KOVAČIĆ, 2018). Regionalni, prvi transtenzijski događaj započeo je u badenu (ĆORIĆ et al., 2009; MALVIĆ & VELIĆ, 2011). U badenu nastankom velikih dubomorskih područja talože se lapori i paralelno s njima u plitkovodnim sredinama talože se pješčenjaci i biogeni vapnenci (MALVIĆ i VELIĆ, 2011), što se uočava na generaliziranom taložnom stupu Savske et alavske depresije (iz KOLENKOVIĆ (2012), modificirano prema SAFTIĆ, (1998). Kasni baden predstavlja početak post-riftne faze te dolazi do podizanja morske razine. Upravo zbog utjecaja transgresije, prevladavaju bazalni konglomerati, krupnozrnati pješčenjaci te litotamnijski vapnenci. Tektonska aktivnost u kasnom badenu uzrokovala je pojavu heterogenosti u taložnom slijedu. Rubni dijelovi su u pravilu prekriveni litotamnijskim vapnencima te biokalkarenitima, a u središnjim dijelovima taložnih bazena nalaze se turbiditi sa sivoplavkastim laporima (LUČIĆ et al., 2001). Direktno na badenske sedimente talože se sarmatski sedimenti. Prva transpresijska faza odvijala se u sarmatu (MALVIĆ i VELIĆ, 2011). U sarmatu dolazi i do pada salineta, kao uvod u stvaranje brakičnih uvjeta tijekom panona i posebice slatkovodnih za vrijeme kasnog panona

(MALVIĆ, 2006). Druga transtenzijska faza odvijala se već u starijem panonu, a u cijelome prostoru depresije tijekom panona (MALVIĆ i VELIĆ, 2011). Krajem sarmata završava i prvi megaciklus taloženja. Tijekom prvog megaciklusa u Savskoj depresiji formirana je formacija Prečec koja se pretežito sastoji od izrazito heterogenih klastičnih taložina. Debljina ovih sedimenata može varirati na udaljenosti od 3-4 km više od 2000 m, ovisno o iznosu brzine sedimentacije i prisutnosti aluvijalnih lepeza (MALVIĆ i VELIĆ, 2005).

Drugi sedimentacijski megaciklus obuhvaća slijed naslaga taloženih tijekom faze termalne subsidencije, mlađe miocenske je starosti te je trajao 5,9 M.a. tijekom razdoblja panona. Tijekom panona dolazi do izolacije Panonskog bazenskog sustava te ovo razdoblje predstavlja post-riftnu fazu u razvoju bazena. U panonu je prestala subdukcija u Vanjskim Karpatima i tako započinje termalno spuštanje kore u Panonskom bazenu koje rezultira taloženjem velikih količina sedimenata, uglavnom lapora i pješčenjaka, na širokom području, prekrivajući tako i dotadašnje rubove Savske depresije (MALVIĆ i VELIĆ, 2011). Panonske naslage prekrivaju veći dio područja svih depresija hrvatskog dijela Panonskog bazena. Zbog kontinuirane redukcije saliniteta, sedimentacija se odvija u brakičnim lakustrinskim uvjetima. Sve izraženije oslađivanje uzrokuje sve veći i brojniji razvoj slatkovodnih organizama (LUČIĆ et al., 2001). U ovom megaciklusu prevladava jednoličan slijed pješčenjačkih, siltnih i laporovitih tijela, što je vidljivo i na generaliziranom taložnom stupu Savske et alavske depresije na slici 3., koja su međusobno vezana prijelaznim varijetetima – od siltnih pješčenjaka do siltnih lapora (Slika 3.; VELIĆ, 2007). Debljina naslaga drugog megaciklusa u Savskoj depresiji iznosi oko 2000 m (SAFTIĆ et al., 2003). Drugi megaciklus se može raščlaniti na formacije Prkos, Ivanić-Grad, Kloštar Ivanić i Široko Polje (SAFTIĆ et al., 2003). Ono što ovaj megaciklus razlikuje od prethodnog je litološka građa te debljina krupnozrnastih klastita koja je puno veća u odnosu na stariji ciklus (VELIĆ, 2007). Druga transpresijska faza započela tijekom panona a traje sve do danas (MALVIĆ i VELIĆ, 2011). Ono što je karakteristično za ovu fazu je stvaranje strukturnih odnosa obilježenih orijentacijom regionalnog stresa S-J, desni transkurentni pomaci i kompresija (VELIĆ, 2007). Od rasjeda najvažniji su južni rubni rasjed PBS-a i Savski rasjed (slika 4).

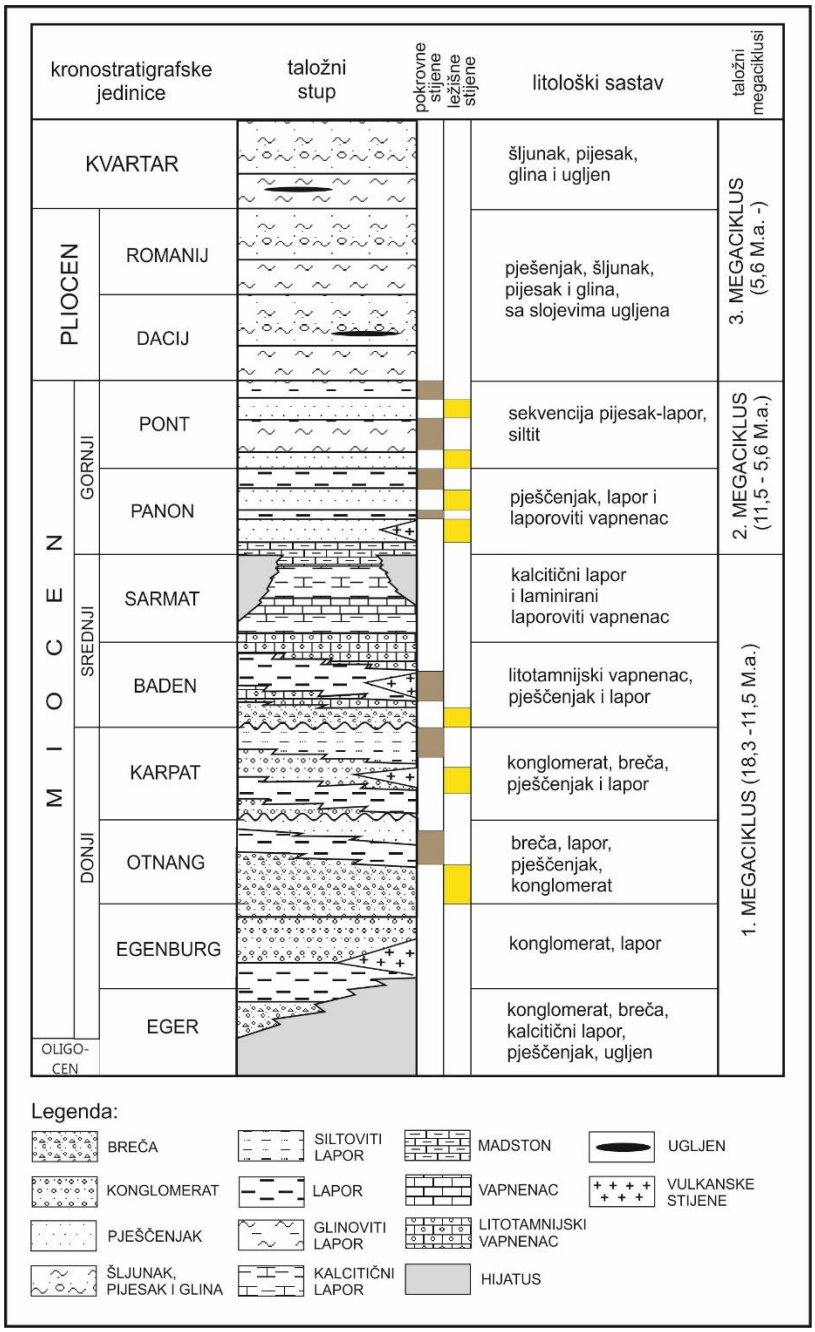

Slika 3. Generalizirani taložni stup Savske et alavske depresije (iz KOLENKOVIĆ, 2012, modificirano prema SAFTIĆ, 1998)

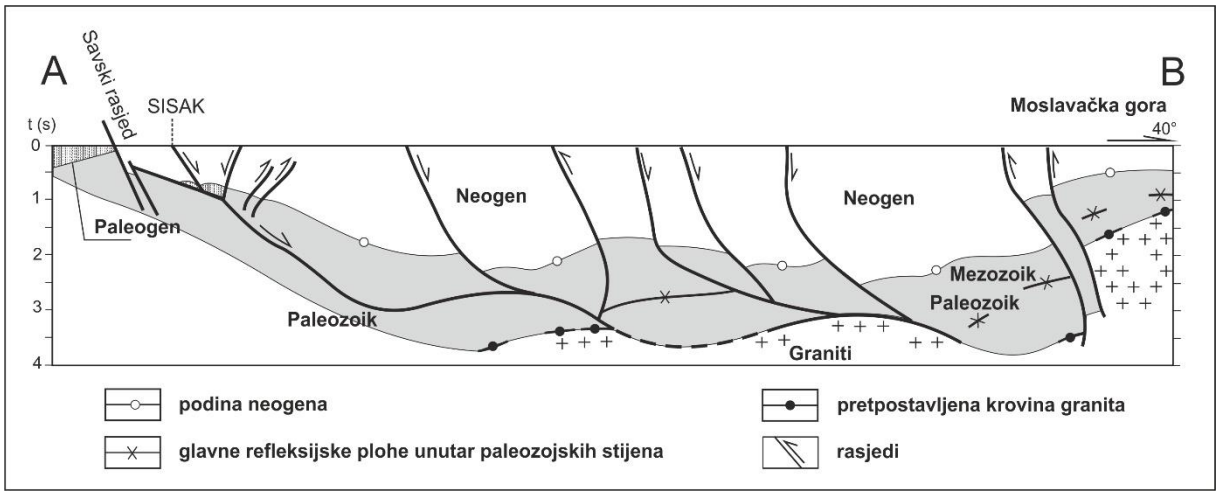

Slika 4. Regionalni geološki profil kroz Savsku depresiju (preuzeto iz KOLENKOVIĆ, 2012 prema PRELOGOVIĆ et al., 1998)

Treći sedimentacijski megaciklus koji je obilježen inverzijom bazena, pliocensko – holocenske je starosti, a trajao je 5,333 M.a. Ovaj megaciklus poprilično se razlikuje od ostalih, ponajprije u geološkoj građi. Izgrađen je od sivih, slabo vezanih pijesaka i glina koje mjestimično sadrže slojeve lignita (Slika 3.). Završava šljuncima, praporima i rastresitim površinskim pokrivačem (VELIĆ, 2007). Taložni okoliši su riječni, močvarni, jezerski i eolski te se taloženje odvijalo u najnižim dijelovima depresije. Debljina bazenske ispune trećeg megaciklusa u Savskoj depresiji iznosi do 1500 m (CVETKOVIĆ, 2013), a obuhvaća sedimente formacije Lonja. Ovo je razdoblje reaktivacije tektonske aktivnosti nakon relativno mirnog razdoblja i promjene režima naprezanja iz ekstenzijskog u kompresijski na području cijelog bazena.

4. REGIONALNE NAFTNOGEOLOŠKE ZNAČAJKE

4.1. Matične stijene Savske depresije

Kako bi uopće nastala akumulacija nafte potrebno je prvenstveno postojanje matičnih stijena, odnosno uvjeta za stvaranje istih. Matične stijene su sedimentne stijene, često laminirane, tamno-sive do crne boje s udjelom organskog ugljika većim od 0,5 %. Također, matične stijene imaju ili su u određenoj fazi termalne zrelosti imale moć generiranja i ekspulzije takvih količina ugljikovodika koja je mogla ispuniti pore u stijenama, stvarajući komercijalne akumulacije nafte i/ili plina (VELIĆ, 2007).

Na području Savske depresije matične stijene su one koje pripadaju vremenskom razdoblju srednjeg i mlađeg miocena, odnosno badensko-sarmatski (gornji dijelovi Prečec formacije) i donjopanonski (Prkos formacija). Ispitivanja sedimenata Savske depresije su potvrdila kako je u laporima, kalcitičnim laporima, glinovitim vapnencima srednjeg miocena (baden i sarmat) te gornjeg miocena (donji panon) prisutan visok sadržaj organske komponente. Organska tvar je ponajviše algalnog podrijetla s prisutnom bakterijskom biomasom te manjim udjelom terigenog materijala. Ukupan sadržaj organskog ugljika (engl. *Total Organic Carbon* - TOC) u uzorcima uzetim iz ovih intervala iznosi između 0,46 i 4,94% TOC, s prosjekom od 1,37%. Dubinski interval u kojem se nalaze matične stijene je 1300-3362 metara, a prosječne debljine su 100 do 200 metara (TROSKOT – ČORBIĆ et al., 2009). ALAJBEG et al. (1990) su naglasili kako sve nafte potječu od sličnih matičnih stijena miocenske starosti koje zajedno tvore jednu širu skupinu. Njihovo podrijetlo je povezano s bakterijski prerađenim marinskim algalnim materijalom koji je bio miješan s tvarima s kopna i taložen u anoksičnom do suboksičnom okolišu.

Prevladavajući tip kerogena je tip II koji ima dobar ugljikovodični potencijal. U Savskoj depresiji organska tvar taložila se u dubljim dijelovima depresije, u anoksičnom, mirnom okolišu s postupnim prijelazom iz marinskog okoliša u brakični. Kerogen tipa II-III pretežito je zastupljen u jugoistočnom dijelu depresije te potječe iz terestričke organske tvari kojima nedostaju masne/voštane komponente, a glavni sastojci su celuloza i lignin. Totalni generativni ugljikovodični potencijal određen Rock-Eval pirolizom iznosi između 2,4 i 37,40 mgHC/g stijene. Vodikovi indeksi se kreću u vrijednostima između 195 i 743 s prosjekom od 398 mg HC/g Corg. (TROSKOT – ČORBIĆ et al., 2009)

Termalna zrelost matičnih stijena utvrđena je pomoću pirolize te vitrinitne refleksije. Maksimalna temperatura pirolize (Tmax) iznosi 420–453 °C u badenskim matičnim stijenama te 420–444 °C u matičnim stijenama donjeg panona, a postoji i trend povećavanja maksimalne temperature s dubinom. Vrijednosti vitrinitne refleksije variraju od Ro 0,29% (na 1265 m) do 0,91% (na 3515 m) i uglavnom se nalaze unutar vrijednosti naftnog prozora od 0,6–0,8% Ro. Također je dokazano kako zrelost stijena linearno raste s porastom dubine, a organska tvar je ušla u zrelu katagenetsku fazu koja omogućuje stvaranje ugljikovodika. Procijenjena dubina ulaska u naftni prozor je između 2100 i 2200 metara (približno 0,5% Ro), a kraj na dubini od približno 3600 metara. Analizom matičnih stijena Savske depresije badensko-sarmatske i donjopanonske starosti došlo se do zaključka kako se radi o zrelim matičnim stijenama te su ostvareni uvjeti za ekspulziju ugljikovodika (TROSKOT – ČORBIĆ et al., 2009).

4.2. Kolektorske stijene

Dubina ležišta nafte u hrvatskom dijelu Panonskog bazena kreće se od tristotinjak do tri tisuće metara apsolutne dubine (VELIĆ, 2007). Kolektorske stijene su, osim paleozojsko-mezozojskih stijena, i pješčenjački članovi Iva i Okoli. Pješčenjaci Iva jedni su od najznačajnijih nosioca ugljikovodika u hrvatskom dijelu Panonskog bazenskog sustava. Pješčenjaci Iva krupnijeklastični je član heterogene građe, sastoji se od pješčenjaka, silta, lapora. Debljina se kreće oko 300 metara te varira u pojedinim dijelovima, a prostorni smještaj je izrazito nejednolik, u središnjem dijelu nalazi se na dubini od 2600 m, a na rubnim dijelovima na samo 200 m. Na području polja Žutice debljina ovog pješčenjaka iznosi 149 m, a na području polja Okoli 50 m. Na polju Ivanić debljina Iva pješčenjaka je 160 m na istoku te 260 m na sjeverizapadu i jugozapadu (VELIĆ, 2007). Petrološkim analizama, pješčenjaci tog član određeni su kao litične subgrauvake i grauvake, izgrađeni od detritičnog kvarca s nešto feldspata i tinjaca. Velika je zastupljenost karbonata, uglavnom dolomita, uz prisustvo rožnjaka i škriljavaca. Pješčenjaci sadrže i manju količinu glina, a po veličini zrna su to sitnozrnasti pješčenjaci. Taloženje se odvijalo u jezerskoj, brakičnoj do slatkovodnoj sredini na dubini od 100-150 m prema nalazima fitoplanktona (VELIĆ, 2007). Na području polja Stružec, na temelju kojeg je definirano tipsko potencijalno ležište, akumulacije se

nalaze unutar formacija Ivanić-Grad (tzv. "Banatica" naslage), Kloštar Ivanić (tzv. "Abichi" naslage) te Široko Polje (tzv. "Rhomboidea" naslage), koje odgovaraju naslagama gornjeg miocena odnosno gornjeg panona. Osim u pijescima i pješčenjacima, ugljikovodici se u manjoj mjeri nalaze i u raspucanim laporima. Pojedini slojevi pijeska i pješčenjaka isklinjavaju ili prelaze u pjeskovite gline i lapore, što se tumači kao posljedica sinsedimentacijske tektonike. Poroznost pješčenjaka varira u širokim granicama, pa tako poroznost pješčenjaka polja Stružec iznosi od 15 do 35%, prosječno 25%, poroznost naftonosnih pješčenjaka polja Žutica iznosi od 16% do 22%, a poroznost pješčenjaka polja Ivanić od 3 do 33% (VELIĆ, 2007). Vrijednosti propusnosti također se kreću u širokom rasponu; od 1,8 do $175x10^{-3}$ μm^2 u pješčenjacima polja Stružec, od 5,1 do $91,5\times10^{-3}$ μm^2 u pješčenjacima polja Žutica te od 0,1 do 380×10^{-3} μm^2 u pješčenjacima polja Ivanić (VELIĆ, 2007). Nafta je kvalitetna, prosječne gustoće od 820 do 870 kg/m^3 (VELIĆ, 2007), odnosno između 16,9 do 39,6°API.

4.3. Migracija

Migracija ugljikovodika unutar depresija hrvatskog dijela Panonskog bazen na temelju dosadašnjih istraživanja je relativno kratka te se uglavnom odvija vertikalno. Kao najvjerojatnije trase vertikalne migracije mogu se izdvojiti zone rasjeda. Neogenske stijene sastoje se od izmjene propusnih i nepropusnih taložina velike rasprostranjenosti koje onemogućuju vertikalnu migraciju, ali te su stijene ispresijecane sustavima rasjeda od kojih je dio omogućio puteve migracije stvarajući zone povećane propusnosti i povezujući matične i kolektorske stijene. Također, ležišta se uglavnom nalaze u skupinama pravca orijentacije sjeverozapad-jugoistok (ponajviše u Savskoj depresiji) koje su omeđene rasjedima jednakog pravca pružanja. Pritom, ne samo da su rasjedi poslužili kao trase migracije već su i sami poslužili kao odlučujući faktor za nastanak ležišta. PLETIKAPIĆ (1969) se bavio razmatranjem pitanja migracije ugljikovodika u zapadnom dijelu Savske depresije. Proučavajući ležišta unutar formacije Ivanić-Grad (pješčenjaci Iva i Okoli) došao je do zaključka kako se unutra pješčenjaka Iva odvijala slojna migracija, u smjeru suprotnom od regionalnog nagiba slojeva unutar kojih su nastala ležišta –prema sjeverozapadu. Autor također navodi da je migracija započela vrlo rano, no da je dolazilo i do naknadnih migracija.

Osim slojne, PLETIKAPIĆ (1969) spominje i međuslojnu migraciju, kojom je nafta dospjela u plića ležišta. Slojna migracija rekonstruirana je za dionicu od Stružeca do Štakorovca, gdje dužina migracije iznosi oko 60 kilometara. Brojna hrvatska polja sastoje se od više ležišta, jedno povrh drugoga uzduž rasjeda među kojima je i polje Stružec (VELIĆ, 2007).

4.4. Značajke nafti u Savskoj depresiji

U tablici 7. prikazan je sastav i gustoća nafti iz ležišta u Savskoj depresiji. Gustoća nafte u hrvatskome dijelu Panonskog bazena kreće se između 16,9 do 39,6°API te se te nafte klasificiraju kao „normalne“ nafte. Dominantno su zastupljeni zasićeni ugljikovodici te aromati, a pojavljuju se i heteroaromati. Uglavnom se radi o niskosumpornoj nafti zbog udjela sumpora manjeg od 0,5%, no prisutne su i nafte s većim udjelom sumpora pa tako Križ i Žutica imaju postotak sumpora od 0,7%, Dugo Selo s 0,8% te Bunjani s 0,9%. Povišeni sadržaj sumpora ukazuje na marinsko podrijetlo organske tvari, ali i na biodegradacijsko djelovanje (VELIĆ, 2007).

Tablica 7. Svojstva nafte iz ležišta u Savskoj depresiji (VELIĆ, 2007)

smjestište	dubina [m]	gustoća [°API]	sumpor [%]	alkani [%]	aromati [%]	NSO+asf. t. [%]
Jamarice	1411	38,1	0,3	70,3	20,3	9,4
Lipovljani	923	39,3	0,2	75,4	14,5	10,1
Kozarice	807	54,9	0,5	56,9	28,3	14,8
Stružec	695	39,6	0,4	74,2	16,5	9,3
Križ	375	16,9	0,7	66,1	14,6	19,3
Bunjani	471	29,7	0,9	61,6	24,4	14,0
Žutica	1177	34,8	0,7	69,9	19,4	10,7
Dugo Selo	1011	27,3	0,8	60,6	19,5	19,9

5. TIPSKO POTENCIJALNO NAFTNO-PLINSKO LEŽIŠTE

Tipsko potencijalno ležište definirano je kao izdužena antiklinala (Slika 5.), odnosno brahiantiklinala čija duža os ima pružanje istok-zapad. Antiklinala je rasjednuta s jednim većim rasjedom pružanja sjever-jug koji dijeli ležište na dva bloka, istočni i zapadni. Pretpostavka je kako je antiklinalu oblikovalo djelovanje kompresije za vrijeme pliocena i kvartara. Nadalje, pretpostavlja se da je akumulacija ugljikovodika vrlo vjerojatno nastala prije samog rasjedanja antiklinale, kao što je slučaj s ležištima polja Stružec gdje je ta teza potvrđena korelacijom EK-dijagrama u plićim dijelovima bušotina (DEVIĆ et al., 1978 u VELIĆ, 2007). Ležišne stijene su pretpostavljeno pješčenjaci mlađe miocenske starosti. Pretpostavljena debljina kolektora je konstanta te iznosi 50 metara, a prosječna poroznost je 17%. Nafta je pretpostavljeno lagana, parafinska te ima vrijednost 39°API.

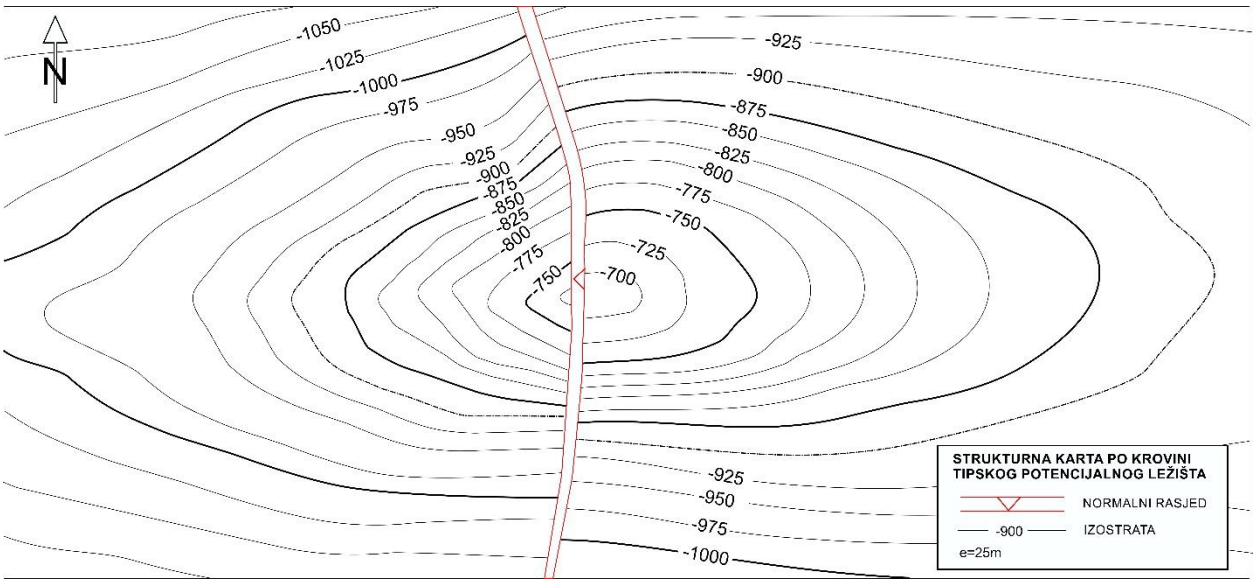

Slika 5. Strukturna karta tipskog potencijalnog ležišta po krovini

6. IZRAČUN VJEROJATNOSTI GEOLOŠKOG USPJEHA

6.1. Volumen zamke

Ukupni volumen zamke procijenjen je prema strukturnoj karti krovinske plohe tipskog potencijalnog ležišta, uz pretpostavku jednolične debljine kolektorskog sloja od 50 m. Iz strukturne karte krovinske plohe definirana je ploha prelijevanja na -900 m (na njoj leže točke prelijevanja, engl. „*spill points*“) koja predstavlja donju granicu zamke. Volumen je računat kao da se računa volumen ležišta, no umjesto kontakta nafta-voda, izopahe su definirane s obzirom na udaljenost od plohe prelijevanja. Volumen pora zamke je izračunat korištenjem Simpsonove i trapezoidalne formule i uz pretpostavljenu poroznost od 17% iznosi 8 025 736,93 m^3. Naravno, to ne znači da je vjerojatnost geološkog uspjeha izračunavana s pretpostavkom tolikog volumena rezervi nafte u ležištu (engl. *oil in place*), već je izračun volumena pora proveden kako bi se utvrdilo je li veličina minimalnog ležišta potrebna za izračun PoS-a prema WHITE-u (1993) pravilno odabrana, odnosno je li zamka veća od minimalnog ležišta.

6.2. Izračun vjerojatnosti geološkog uspjeha prema WHITE (1993)

Minimalna veličina ležišta je uzeta kao $1{,}5\times10^6$ m^3, odnosno kao nešto manja vrijednost od pridobivih rezervi naftnog polja Mramor Brdo koje iznose približno 2×10^6 m^3. S obzirom na to da je „play“ uspješan, odnosno postoje dokazane akumulacije ugljikovodika, šansa „playa” iznosi 1,0 (Slika 6., linija e). Zatim se pristupa izračunu šanse adekvatnosti prospekta. Kako je već napisano, procjenjuju se uvjetni faktor uspjeha prospekta. Na slici 6. podcrtani su oni faktori koji se smatraju rizičnima te su individualni, odnose se na istraživani prospekt bez prevelikog utjecaja na druge prospekte. Znači, procjenjuje se individualna šansa adekvatnosti za 4 kategorije: h, i, j, k na slici 6..

U prvoj kategoriji nalaze se zamka, izolator te vremenska komponenta koja se odnosi na vrijeme nastanka zamke u odnosu na migraciju nafte iz matičnih stijena. Pretpostavka je da je u ovoj kategoriji rizičan faktor rasjed koji može uzrokovati dismigraciju, odnosno gubitak ugljikovodika iz ležišta, no postoje komercijalna ležišta nafte unutar „playa” koja su

slične građe, stoga se ovog kategoriji dodjeljuje vrijednost od 0,85 koja se unosi na liniju h, slika 6.

Kolektorske stijene, poroznost i propusnost nalaze se u drugoj kategoriji. Uz pretpostavku da se temeljem regionalnih korelacija na području potencijalnog ležišta nalaze deblje naslage pješčenjaka te temeljem ekstrapolacije kolektorskih svojstava sa susjednih postojećih ležišta, u ovoj kategoriji nema lokalnih rizičnih faktora, izuzev činjenice da su gornjomiocenski pješčenjaci Savske depresije mjestimice intenzivno cementirani što utječe na izraženu heterogenost njihovih petrofizikalnih svojstava (TADEJ et al., 1996) te procijenjena šansa ove kategorije iznosi 0,85 i ta vrijednost se unosi na liniju i, na slici 6.

U kategoriji matičnih stijena, zrelosti te migracije može se pretpostaviti da se za šansu prospekta uzima šansa čitavog „playa", jer su postojanje i zrelost matičnih stijena utvrđeni u samoj depresiji i nema indikatora koji bi upućivali na uvjete koji bi negativno utjecali na vrijednost prospekta, stoga procijenjena šansa adekvatnosti iznosi 1,0 te se ta vrijednost unosi na liniju j, slika 6.

Napokon, kod zadnje kategorije, kvalitete ugljikovodika, može se uzeti raspon gustoća nafte iz poznatih ležišta u depresiji koji iznosi od 16,9 do 54,9 °API (VELIĆ, 2007). S obzirom da je ležište smješteno na većoj dubini, razumna je pretpostavka da nema utjecaja biodegradacije na gustoću nafte, kao u slučaju ležišta polja Križ, odnosno da se gustoća kreće u rasponu od približno 30-40°API, uz veliki udio alkana, pa se za vrijednost ovog faktora uzima 1,0 te je ta vrijednost unijeta na liniju k, slika 6.

Uvjetni faktor uspjeha prospekta, koji se dobije množenjem vrijednosti na linijama h, i, j, k iznosi 0,72 i ta se vrijednost nalazi na liniji m na slici 6. Kako bi se dobila šansa adekvatnosti prospekta (linija t) potrebno je pomnožiti šansu „playa" (linija e) koja iznosi 1,0 te uvjetni faktor uspjeha prospekta (linija m) koja je 0,72, odnosno vrijednosti p, q, r, s koje se nalaze na slici 6. Nakon što se pomnože navedene vrijednosti, šansa adekvatnosti prospekta iznosi 0,72 .

„PLAY“ – Panonski bazenski sustav PROSPEKT – Tipsko potencijalno ležište

a. 1,0 ZAMKA – IZOLATOR – VRIJEME h. 0,85 x a = 0,85 p.

VOLUMEN ZAMKE (površina i visina zatvaranja, strukturna ili stratografska)

IZOLATOR (gornji, bočni; nema značajnijeg istjecanja duž rasjeda, pukotina)

VRIJEME ZATVARANJA (u odnosu na migraciju)

b. 1,0 KOLEKTOR – POROZNOST – PROPUSNOST i. 0,85 x a = 0,85 q.

DEBLJINA KOLEKTORA (nema prekida taloženja, promjene facijesa, isklinjavanja ili rasjedanja; odgovarajuća efektivna debljina)

POROZNOST (primarna ili sekundarna, pore nisu zatvorene ili cementirane)

PROPUSNOST I KONTINUIRANOST

c. 1,0 MATIČNA STIJENA – ZRELOST – MIGRACIJA j. 1,0 x a = 1,0 r.

ORGANSKA TVAR (područje prostiranja matičnih stijena, debljina, TOC (eng. *total organic carbon*)) I KVALITETA (tip organske tvari)

ZRELOST (adekvatno vrijeme, temperatura; nije prezrelo)

MIGRACIJA (primarna ili ekspulzija; sekundarna, migracija od matične stijene do zamke)

d. 1,0 OČUVANOST – KVALITETA UGLJIKOVOIDKA – ISCRPAK k. 1,0 x a = 1,0 s.

OČUVANOST (nema ispiranja, biodegradacije, difuzije)

KVALITETA UGLJIKOVODIKA I KONCENTRACIJA (nafta nije previskozna, zasićenje je zadovoljavajuće; ugljikovodične komponente prirodnoga plina nisu previše raspršene ili razrijeđene; zadovoljavajuća visina stupca nafte ili plina u ležištu)

ISCRPAK (energija ležišta, tlak, dubina)

e. 1,0 ŠANSA „PLAYA“ = a x b x c d (minimalna veličina polja = 1,5 x 10^6 m^3)

f._____OMJER USPJEHA PLAYA

g. PROSJEČNA ŠANSA PROSPEKTA = e x f = _____

UVJETNI FAKTOR USPJEHA PROSPEKTA = h x i x j x k = 0,72 m.

ŠANSA ADEKVATNOSTI PROSPEKTA = e x m = p x q x r x s = 0,72 t.

Slika 6. Procjena vrijednosti geološkog faktora rizika prema WHITE (1993)

6.3. Izračun vjerojatnosti geološkog uspjeha prema MILKOV (2015)

Kako bi izračunali vjerojatnost geološkog uspjeha prema MILKOV-u (2015) potrebno je odrediti 6 rizičnih faktora: strukturu, prisutnost kolektorskih stijena, kvalitetu ležišta, izolator, zrelost matičnih stijena te na kraju migraciju. Svaki od ovih faktora potrebno je odrediti na temelju dostupnih podataka te im pomoću tablica rizika dodijeliti odgovarajuće vrijednosti. U Tablici 8. nalazi se pregled rezultata određivanja vjerojatnosti geološkog uspjeha prema MILKOV-u (2015).

6.3.1. Vjerojatnost postojanja strukture

Tipsko potencijalno ležište ima oblik izdužene antiklinale koja je rasjednuta normalnim rasjedom. To je visokoreljefna struktura, niske strukturne kompleksnosti te se lako može interpretirati pomoću podataka s obližnjih bušotina i pretpostavka je da je definirana temeljem interpretacije 3D seizmičkog volumena, stoga prema tablici rizika vrijednost vjerojatnosti strukture iznosi 1,0.

6.3.2. Vjerojatnost prisutnosti kolektorskih stijena

Glavne kolektorske stijene su pješčenjaci taloženi u slatkovodnoj do brakičnoj sredini, odnosno kontinentalnom, lakustrinskom okolišu, na samom rubu bazena. Područje je jako dobro istraženo te se bušotine nalaze na udaljenosti <50 km. Prema tablici rizika vjerojatnosti prisutnosti kolektorskih stijena određena je vrijednost 0,90.

6.3.3. Vjerojatnost kvalitete ležišta

Pretpostavljeno podatci o kvaliteti ležišta dolaze iz bušotina koje se nalaze na udaljenosti<50 km i ukazuju na dobru kvalitetu ležišta. Podatci o kvaliteti ležišta uključuju

podatke poroznosti, propusnosti, viskoznosti te protoka fluida. Maksimalna temperatura zalijeganja pješčenjaka se prema tablici 3. nalazi u rasponu između 35-100 °C, odnosno najveća relativna dubina ležišnih stijena pri dnu zamke je procijenjeno 1050 metara te kada se uzme prosječni geotermalni gradijent Savske depresije od približno 3,8°C/100 m (CVETKOVIĆ et al., 2019) i prosječnu godišnju temperaturu od 10,7°C dobije se temperatura od 50,6 °C. Radi se pretpostavljeno o heterogenom ležištu gdje prevladavaju litične grauvake (TADEJ, 1996), stoga im se prema tablici rizika kvalitete ležišta dodjeljuje vrijednost 0,95.

6.3.4. Vjerojatnost postojanja adekvatnog izolatora

Struktura unutar koje je pretpostavljena akumulacija nafte je izdužena antiklinala koja je također i rasjednuta stoga je moguće prisutno više izolatora. Rasjed moguće predstavlja jukstapozicijski izolator, a pretpostavljena debljina lapora je između 10-20 metara stoga vrijednost postojanja adekvatnog izolatora iznosi 0,85.

6.3.5. Vjerojatnost zrelosti matičnih stijena

Prisutnost te zrelost matičnih stijena u Savskoj depresiji, a unutar koje se nalazi tipsko potencijalno ležište, jako je dobro istražena. Na temelju podataka s izdanaka te iz bušotina, došlo se do zaključka kako prevladavaju matične stijene u kojima se nalazi kerogen tipa II, samo lokalno i kerogen tipa II-III, a pretpostavljeno se radi o ranoj fazi zrelosti matičnih stijena, podatci o matičnim stijenama dolaze iz bušotina koje su nabušile matične stijene, stoga se prema tablici rizika zrelosti matičnih stijena dodjeljuje vrijednost 0,80.

6.3.6. Vjerojatnost migracije

Na temelju dosadašnjih istraživanja (PLETIKAPIĆ, 1969), pretpostavlja da se migracija odvija vertiklano, a su trase migracije kratke. Kao najvjerojatnije trase migracije uzimaju se rasjedi i rasjedne zone, ali u tablici rizika vjerojatnosti migracije rasjedi nisu uzeti u obzir kao moguća trasa migracije. Vertikalna migracija je pretpostavljeno kraća od 2

kilometra, a lateralna je pretpostavljeno kraća od 50 kilometara stoga prema tablici rizika, vrijednost vjerojatnosti migracije iznosi 0,90.

Tablica 8. Pregled rezultata određivanja vjerojatnosti geološkog uspjeha prema MILKOV (2015).

Faktor rizika	**Vrijednost faktora rizika**
Struktura	1,0
Kolektorske stijene	0,90
Kvaliteta ležišta	0,95
Izolator	0,85
Zrelost matičnih stijena	0,80
Migracija	0,90
Ukupni geološki faktor rizika	**0,52**

7. DISKUSIJA I ZAKLJUČAK

Svaki prospekt treba imati jasno definiranu i razrađenu vjerojatnost geološkog uspjeha prije nego li se krene s bušenjem. Izračun PoS-a radi se za ležište koje ili postoji ili ne. Kako bi dokazali akumulacije ugljikovodika te isplativost eksploatacije ugljikovodika potrebno je dokazati kolika je šansa značajnih te isplativih akumulacija ugljikovodika na tom području. Kako bi to dokazali potrebno je procijeniti, na temelju podataka, parametre poput: faktora volumena (volumen zamke gdje je uključena struktura te geometrijski elementi zamke, prosječnu poroznost, efektivnu debljinu, zasićenje ugljikovodicima), matične stijene, kolektorske stijene, migracija kako bi izračunali PoS. Pitanje je kako zapravo objektivno procijeniti PoS. Prilikom izračuna PoS-a postoje razilaženja u razmišljanju između pojedinih autora koja su najviše usmjerena na dva pitanja: kako znati koji su faktori međusobno neovisni, a takve treba uzeti u obzir prilikom izračuna te kako znati procijeniti vrijednost svakog faktora rizika (MILKOV, 2015).

Vjerojatnost geološkog uspjeha temelji se na procjeni vjerojatnosti postojanja ležišta, pri čemu se uzima u obzir i pouzdanost geološkog modela. Način na koji se izračunava PoS korištenjem metoda prema WHITE-u (1993) i MILKOV-u (2015) je vrlo različit. Prema WHITE-u (1993), faktorima koji se uzimaju obzir, a prikazani su na slici 1., dodjeljuje se vrijednosti na temelju stručnog, ali subjektivnog mišljenja te ovom metodom dvije različite osobe istom prospektu mogu dodijeliti različite vrijednosti. Metoda koju je predložio MILKOV (2015) temelji se na algoritmu, odnosno tablicama rizika koje predstavljaju objektivniji pristup izračunu PoS-a. Tablice rizika napravljene su tako da u obzir uzmu najvažnije elemente koje je potrebno analizirati kako bi se procijenila vjerojatnost šest rizičnih faktora: strukturu, kolektorske stijene, kvalitetu ležišta, izolatore, zrelost matičnih stijena te migraciju.

Vrijednosti PoS-a >0,5 smatraju se zadovoljavajućima te možemo pretpostaviti kako će prospekt biti uspješan, no ukoliko imamo vrijednosti PoS-a <0,5, ROSE (2001) smatra kako se ta vrijednost može povećati pribavljanjem podataka, najčešće seizmičkih ili geokemijskih podataka. No, PEEL i BROOKS (2015) navode kako povećanje količine podataka utječe na vrijednost PoS-a, ali ne na pozitivan način, već umanjuju vrijednosti PoS-a. Naime, ukoliko je prosječna vrijednost PoS-a <0,5 može se očekivati kako će novi podatci utjecati na smanjenje PoS-a prije nego li će ga povećati. Naravno, u nekim slučajevima vrijednost PoS-a se može i povećati. Isto tako, ukoliko vrijednost PoS-a naraste, ona naraste u većoj vrijednosti nego li ju novi podatci snize kod manjih vrijednosti PoS-a i time zapravo prosjek PoS-a ostaje nepromijenjen.

U ovom radu, izračun vjerojatnosti geološkog uspjeha rađen je za tipsko potencijalno ležište koje je razvijeno po uzoru na naftno-plinsko polje Stružec. Područje istraživanja dobro je istraženo te su podatci bili dostupni za gotovo svaki potreban segment procjene. To je pojednostavljeno ležište koje ima oblik antiklinale, rasjednuto je jednim rasjedom, pretpostavljena debljina pješčenjaka iznosi 50 m, a prosječna poroznost 17%. Volumen pora zamke iznosi 8 025 736,93 m^3. Prema WHITE (1993), vjerojatnost geološkog uspjeha za tipsko potencijalno ležište iznosi 0,72, a prema MILKOV (2015) iznosi 0,52. Kako se vrijednosti PoS-a >0,5 smatraju zadovoljavajućima, a prema izračunu obje metode dobivene su vrijednosti PoS-a tipskog potencijalnog ležišta >0,5 možemo zaključiti kako unutar njega zasigurno postoje akumulacije ugljikovodika. Potrebno je napomenuti kako je tipsko potencijalno ležište rađeno po uzoru na polje Stružec koje se nalazi u dobro istraženom dijelu bazena gdje je iznimno mala vjerojatnost da postoje još neprobušene strukturne zamke

izgleda i veličine kakva je pretpostavljena za tipsko potencijalno ležište. U bazenima visokog stupnja istraženosti uglavnom su za istraživanje bušenjem, pa i izračun PoS-a preostale stratigrafske zamke koje je teže definirati interpretacijom refleksijske seizmike te ih je lakše definirati koristeći volumene nego seizmičke profile.

Razlika između ove dvije metode je u pristupu podatcima, odnosno način na koji podatcima dodjeljujemo vrijednost. Kada određujemo vrijednost PoS-a prema WHITE-u (1993), u obzir se uzimaju faktori općenito te se na temelju dostupnih podataka i stručnog mišljenja pojedinoj kategoriji dodjeljuje vrijednost. Kod metode prema MILKOV-u (2015) pokušava se eliminirati subjektivnost na način da su opisno unaprijed definirani potrebni podaci te su svojstva ležišta prikazana vrijednostima u tablicama iz kojih se jednostavno očitavaju vrijednosti faktora rizika. Uzmimo za primjer kategoriju u kojoj se kod WHITE-a (1993) nalaze zamka, izolator te vremenska komponenta koja se odnosi na vrijeme nastanka zamke u odnosu na migraciju nafte iz matičnih stijena kojoj je dodijeljena vrijednost 0,85. Kada bi se toj kategoriji dala manja procijenjena vrijednost, recimo 0,75 rezultat bi bio drugačiji. Također, ukoliko bi i kategoriji u kojoj su kolektorske stijene, poroznost i propusnost pridali manju vrijednost od trenutno procijenjene, primjerice 0,75, tada bi vrijednost PoS-a prema WHITE-u (1993) bila znatno drugačija, ali i bliža vrijednosti PoS-a dobivenoj prema MILKOV-u (2015).

8. LITERATURA

8.1. Objavljeni radovi

ALAJBEG, A., BRITVIĆ, V., ŠVEL-CEROVEČKI, S., CORNFORD, C., TODORIĆ, A., RAJKOVIĆ, J., BARIĆ, G., PUTNIKOVIĆ, A., 1990. Geochemical study of the oils and source rocks in the Pannonian Basin.– Org. Geoch., 16, 339–352.

AJDUKIWICZ, J. M, LANDER, R.H., 2010. Sandstone reservoir quality prediction: The state of the art. AAPG Bull., 94, pp. 1083-1091.

CCOP (Coordinating Committee for Offshore Prospecting in Asia), 2000. The CCOP Guidelines for Risk Assessment of Petroleum Prospects.

CVETKOVIĆ, M., 2013. Naftno geološki potencijal i litostratigrafska razradba trećega neogensko – kvartarnog megaciklusa u Savskoj depresiji, Disertacija, Rudarskogeološko-naftni fakultet, Zagreb.

CVETKOVIĆ, M., MATOŠ, B., RUKAVINA, D., KOLENKOVIĆ MOČILAC, I., SAFTIĆ, B., BAKETARIĆ, T., BAKETARIĆ, M., VUIĆ, I., STOPAR, A., JARIĆ, A., PAŠKOV, T., 2019. Geoenergy potential of the Croatian part of Pannonian Basin: insights from the reconstruction of the pre-Neogene basement unconformity, Journal of Maps, 15 (2) p. 651-661.

ĆORIĆ, S., PAVELIĆ, D., RÖGL, F., MANDIC, O., VRBANAC, S., AVANIĆ, R., JERKOVIĆ, L., VRANJKOVIĆ, A., 2009. Revised Middle Miocene datum for initial marine flooding of North Croatian Basins (Pannonian Basin System, Central Paratethys), Geologica Croatica 62/1, Zagreb

FÆRSETH, R.B., E. JOHNSEN, AND S. SPERREVIK, 2007. Methodology for risking fault seal capacity: Implications of fault zone architecture: AAPG Bulletin, v. 91, p. 1231-1246.

FRASER, A.J., 2010. A regional overview of the exploration potential of the Middle East: a case study in the application of play fairway risk mapping techniques, in B.A. Vining and S.C. Pickering, eds., Petroleum geology: from mature basins to new frontiers, Proceedings of the 7th Petroleum Geology Conference, London, Geological Society, p. 791-800.

GRANT, S., MILTON, N., THOMPSON, M., 1996. Play fairway analysis and risk mapping: an example using the Middle Jurassic Brent Group in the northern North Sea, in A.G. Dore and R. Sinding-Larsen, Quantification and prediction of petroleum resources, NPF Special Publication 6, Elsevier, Amsterdam, p. 167-181.

KOLENKOVIĆ, I., 2012. Mogućnosti za geološko skladištenje ugljičnoga dioksida u gornjomiocenskim pješčenjacima zapadnoga dijela Savske depresije. Disertacija, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, Zagreb, 130 str.

LUČIĆ, D., SAFTIĆ, B., KRIZMANIĆ, K., PRELOGOVIĆ, E., BRITVIĆ, V., MESIĆ, I., TADEJ, J. 2001. The Neogene evolution and hydrocarbon potential of Pannonian basin, Marine and Petroleum Geology 18, str. 133-147.

MALVIĆ, T., 2009. Stochastical approach in deterministic calculation of geological risk - theory and example, Nafta 60 (12), p. 651-657.

MALVIĆ, T., SAFTIĆ, B., 2008. Dubinsko kartiranje, fakultetska skripta, Rudarsko – geološko – naftni fakultet, Sveučilište u Zagrebu, str. 5-8.

MALVIĆ, T., VELIĆ, J., 2005. Neogene tectonics in Croatian part of the Pannonian Basin and reflectanse in hydrocarbon accumulation, INA i Sveučilište u Zagrebu, RGN-F, Zagreb.

MALVIĆ, T., VELIĆ, J., 2011. Neogene Tectonics in Croatian Part of the Pannonian Basin and Reflectance in Hydrocarbon Accumulations. –SCHATTNER, U. (ed.): New Frontiers in Tectonic Research: At the Midst of Plate Convergence, InTech, Rijeka, str. 352.

MILKOV, A.V., 2015. Risk tables for less biased and more consistent estimation of probability of geological success (PoS) for segments with conventional oil and gas prospective resources, Earth Science Reviews.

MILTON, N.J., AND G.T. BERTRAM, 1992. Trap styles – A new classification based on sealing surfaces: AAPG Bulletin, v. 76, p. 983-999.

NANDA, F.C., 2016. Seismic Data Interpretation and Evaluation for Hydrocarbon Exploration and Production: Springer.

NEWENDORP, P.D., AND J.R. SCHUYLER, 2000. Decision analysis for petroleum exploration: 2nd Edition, Aurora, Colorado, Planning Press, 606 p.

PAVELIĆ, D., 2001. Tectonostratigraphic model for the North Croatian and North Bosnian sector of the Miocene Pannonian Basin System. Basin Research, 12, 359-376.

PAVELIĆ, D., KOVAČIĆ M., 2018. Sedimentology and stratigraphy of the Neogene rifttype North Croatian Basin (Pannonian Basin System, Croatia): A review; Marine and Petroleum Geology 91, str. 455-469, Elsevier, str. 1-15.

PEEL, F.J., BROOKS, J.R.V., 2015. What to expect when you are prospecting: How new information changes our estimate of the chance of success of a prospect: AAPG Bulletin, v. 99, pp. 2159–2171.

PLETIKAPIĆ, Ž., 1969. Stratigrafija, paleogeografija i naftoplinonosnost Ivanić Grad formacije na obodu Moslavačkog masiva. Disertacija, Zagreb, 1965. Poseb. izd. Rud.-geol.-naft. fakult. Sveuč. u Zagrebu, 71 str.

PRELOGOVIĆ, E., SAFTIĆ, B., KUK, V., VELIĆ, J., DRAGAŠ, M. & LUČIĆ, D., 1998. Tectonic activity in the Croatian part of the Pannonian basin. Tectonophysics, 297, 283-293.

ROSE, P.R., 2001. Risk analysis and management of petroleum exploration ventures: AAPG Methods in Exploration Series, no. 12, 164 p.

SAFTIĆ, B. (1998): Genetska stratigrafska sekvencijska snalizapontskih naslaga u zapadnom dijelu Savske depresije. Disertacija, Rudarsko-geološko-naftni fakultet, Sveučilišta u Zagrebu, Zagreb, 112 str.

SAFTIĆ, B., VELIĆ, J., SZTANO, O., JUHASZ, G., IVKOVIĆ, Ž., 2003. Tertiary subsurface facies, source rocks and hydrocarbon reservoirs in the SW part of the Pannonian Basin (Northern Croatia and South-Western Hungary, Geologia Croatica, 56/1, str. 101-122, Zagreb.

TADEJ, J., MARIĆ-ĐUREKOVIĆ, Ž. & SLAVKOVIĆ, R., 1996. Porosity, Cementation, Diagenesis and Their Influence on the Productive Capability of Sandstone Reservoirs in the Sava Depression (Croatia). U: Velić, J., Hernitz, Z. & Saftić, B. (ur.): Proceedings of the 1st International Symposium of Petroleum Geology, Zagreb, April 18-19, 1996., Geologia Croatica, 49/2, 311-316.

TROSKOT-ĆORBIĆ, T., VELIĆ, J., MALVIĆ, T., 2009. Comparison of the Middle Miocene and the Upper Miocene source rock formations in the Sava Depression (Pannonian Basin, Croatia), Geologica Croatica, 62/2, str. 123-133, Zagreb.

VELIĆ, J. 2007. Geologija ležišta nafte i plina, Sveučilište u Zagrebu, RGN-f, Zagreb, 342 str.

VELIĆ, J., MALVIĆ, T., CVETKOVIĆ, M., 2011. Palinspastic reconstruction of synsedimentary tectonics of Neogene and Quaternary sediments in the Kloštar Field 42 (Sava Depression, Pannonian Basin, Croatia). Zeitschrift der Deutschen Gesellschaft für Geowissenschaften, 162, 2, 193-203.

WATSON, P., 1998. A process for estimating geological risk of petroleum exploration prospects: The APPEA Journal, v. 34, p. 577-583.

WHITE, D.A., 1993. Geological risking guide for prospects and plays: AAPG Bulletin, v. 77, p. 2048-2061.

8.2. Neobjavljeni radovi

DEVIĆ, P., PERIĆ, M., BAUK, A., THALLER, J. 1978. Polje Stružec (ležišta serije „a“ i „b“). Elaborat o rezervama nafte i plina. Fond struč. dok. INA-Naftaplina, Zagreb.

KLASA: 602-04/20-01/267
URBROJ: 251-70-03-21-2
U Zagrebu, 11.02.2021.

Karla Radoević, studentica

RJEŠENJE O ODOBRENJU TEME

Na temelju Vašeg zahtjeva primljenog pod KLASOM 602-04/20-01/267, UR. BROJ: 251-70-14-20-1 od 22.12.2020. godine priopćujemo temu diplomskog rada koja glasi:

USPOREDBA METODA PROCJENE VJEROJATNOSTI GEOLOŠKOG USPJEHA NA PRIMJERU TIPSKOG POTENCIJALNOG LEŽIŠTA U KLASTITIMA

Za voditeljicu ovog diplomskog rada imenuje se u smislu Pravilnika o diplomskom ispitu dr. sc. Iva Kolenković Močilac, docentica Rudarsko-geološko-naftnog fakulteta Sveučilišta u Zagrebu.

Voditeljica

(potpis)

Doc. dr. sc. Iva Kolenković Močilac

(titula, ime i prezime)

Predsjednik povjerenstva za završne i diplomske ispite

(potpis)

Izv. prof. dr. sc. Stanko Ružičić

(titula, ime i prezime)

Prodekan za nastavu i studente

(potpis)

Izv. prof. dr. sc. Dalibor Kuhinek

(titula, ime i prezime)