Potpovršinski odnosi Požeške kotline i procjena litološkog sastava korištenjem geomatematičkih metoda

Brcković, Ana

Master's thesis / Diplomski rad

2018

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:169:635333

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

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







SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET
Diplomski studij geologije

POTPOVRŠINSKI ODNOSI POŽEŠKE KOTLINE I PROCJENA LITOLOŠKOG SASTAVA KORIŠTENJEM GEOMATEMATIČKIH METODA

Diplomski rad

Ana Brcković
G257

Zagreb, 2018.

KLASA: 602-04/18-01/9
URBROJ: 251-70-03-18-3
U Zagrebu, 11.01.2018.

Ana Brcković, studentica

RJEŠENJE O ODOBRENJU TEME

Na temelju Vašeg zahtjeva primljenog pod KLASOM 602-04/18-01/9, UR. BROJ: 251-70-03-19-1 od 10.01.2018. godine priopćujemo temu diplomskog rada koja glasi:

POTPOVRŠINSKI ODNOSI POŽEŠKE KOTLINE I PROCJENA LITOLOŠKOG SASTAVA KORIŠTENJEM GEOMATEMATIČKIH METODA

Za voditelja ovog diplomskog rada imenuje se u smislu Pravilnika o diplomskom ispitu dr. sc. Marko Cvetković, docent Rudarsko-geološko-naftnog fakulteta Sveučilišta u Zagrebu.

Voditelj

Doc.dr.sc. Marko Cvetković
(potpis)

(titula, ime i prezime)

REPUBLIKA HRVATSKA 1 ZAGREB SVEUČILIŠTE U ZAGREBU

Predsjednica povjerenstva za završne i diplomske ispite

Dunja Aljinović
(potpis)

Prof. dr. sc. Dunja Aljinović
(titula, ime i prezime)

o. d. prodekanice za nastavu i studente

(potpis)

Izv. prof. dr. sc. Lidia Hrnčević
(titula, ime i prezime)

Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet

Diplomski rad

POTPOVRŠINSKI ODNOSI POŽEŠKE KOTLINE I PROCJENA LITOLOŠKOG SASTAVA KORIŠTENJEM GEOMATEMATIČKIH METODA

ANA BRCKOVIĆ

Diplomski rad izrađen: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za geologiju i geološko inženjerstvo
Pierottijeva 6, 10002 Zagreb

Sažetak

Požeška kotlina predstavlja relativno slabo istražen dio hrvatskog dijela Panonskog bazena. Zbog debelog slijeda kvartarnih naslaga na površini, prve informacije o dubinskoj građi dobivene su na temelju geofizičkih istraživanja u sedamdesetim i osamdesetim godinama 20. stoljeća. U ovom radu, jedini postojeći seizmički podaci su, zajedno s bušotinskim, interpretirani u računalnom programu Schlumberger Petrelu. Dostupni seizmički profili reinterpretirani su te prebačeni u dubinsko mjerilo kako bi se mogle konstruirati karte reprernih horizonata. Na temelju konstruiranih ploha horizonata napravljen je strukturni model istraživanog područja. U konačnici je pomoću metode umjetnih neuronskih mreža u programu Statistica predviđen litološki sastav na trasama seizmičkih profila. Svrha izrade modela je priprema podataka za procjenu ugljikovodičnog potencijala ovog izoliranog dijela podzemlja.

Ključne riječi: interpretacija seizmičkih podataka, strukturno modeliranje, umjetne neuronske mreže, predviđanje litološkog sastava, Požeška kotlina, Hrvatska

Diplomski rad sadrži: 45 stranica, 1 tablicu, 25 slika i 52 reference.

Jezik izvornika: hrvatski

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

Voditelj: dr. sc. Marko Cvetković, docent RGNF

Ocjenjivači: dr. sc. Marko Cvetković, docent RGNF
dr. sc. Iva Kolenković Močilac, docentica RGNF
dr. sc. Davor Pavelić, redoviti profesor RGNF

Datum obrane: 19. siječnja 2018.

University of Zagreb
Faculty of Mining, Geology
and Petroleum Engineering

Master's Thesis

SUBSURFACE RELATIONS OF POŽEGA VALLEY AND LITHOLOGY ESTIMATION BASED ON GEOMATHEMATICAL METHODS

ANA BRCKOVIĆ

Thesis completed in: University of Zagreb
Faculty of Mining, Geology and Petroleum engineering
Department of Geology and Geological Engineering,
Pierottijeva 6, 10 002 Zagreb

Abstract

Požega Valley is relatively poorly eplored area of the Croatian part of the Pannonian Basin. Due to the thick Quarternary deposits on the surface, first detailed insights into the subsurface ralations were made in the 70' and 80' of the 20th century. This was after the first geophysical surveys and exploration drilling had been preformed. Re-interpretation of the seismic sections and time to depth conversion have been performed in order for the major horizons surfaces to be constructed. Generated horizon surfaces have been used for the structural modeling of the area. In the end, lithofacies values were predicted by artificial neural network analysis along the section traces using Statistica software. The model has been constructed to enable the evaluation of the hydrocarbon potential of this lateraly-closed area.

Keywords: seismic interpretation, structural modeling, artificial neural networks, lithology predictions, Požega Valley, Croatia

Thesis contains: 45 pages, 1 table, 25 figures and 52 references.

Original in: Croatian

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

Supervisor: PhD Marko Cvetković, Assistant Professor

Reviewers: PhD Marko Cvetković, Assistant Professor
PhD Iva Kolenković Močilac, Assistant Professor
PhD, Davor Pavelić, Full Professor

Date of defense: January 19th, 2018.

Hvala poštovanom mentoru doc. dr. sc. Marku Cvetkoviću na ukazanom povjerenju, ogromnom strpljenju, te konstantnoj dostupnošću za bilo kakve rasprave prilikom izrade ovoga rada.

Doc. dr. sc. Ivi Kolenković Močilac veliko hvala na savjetima i komentarima kojima je doprinjela ovom radu.

Hvala svim kolegama i prijateljima koji su pratili sa zanimanjem napredak ovog rada, a osobito hvala članovima obitelji koji su bili konstatna podrška tijekom školovanja i u konačnici izrade diplomskog rada.

Veliko hvala Ministarstvu zaštite okoliša i energetike, Agenciji za ugljikovodike I Vermilionu Zagreb d.o.o. na ustupljenim podatcima bez kojih ovaj diplomski rad ne bi bio moguć.

In the end, special appretiation to Schlumberger Company for providing academic licence for Petrel Software without which this work would be impossible.

Sadržaj

1. Uvod ... 1
2. Geografske značajke istraživanog područja ... 2
3. Geološke značajke istraživanog područja ... 4
   3.1. Strukturno-tektonski sklop ... 6
   3.2. Sedimentacijski uvjeti ... 9
4. Pregled prijašnjih istraživanja na području Požeške kotline ... 12
5. Metodologija ... 14
   5.1. Interpretacija seizmičkih profila te modeliranje jednostavne mreže i rasjeda ... 15
   5.2. Umjetne neuronske mreže ... 19
6. Rezultati ... 22
   6.1. Rezultati interpretacije seizmičkih profila ... 22
   6.2. Konstrukcija karata po reperima ... 25
      Karta po repernom horizontu Tg ... 26
      Karta po repernom horizontu H (Rs7) ... 27
      Karta po repernom horizontu G (Rs5) ... 27
      Karta po repernom horizontu B (Rfi) ... 28
      Karta po repernom horizontu A (α') ... 29
   6.3. Jednostavni model istraživanog područja (Simple Grid) ... 30
   6.4. Strukturni model s rasjedima ... 31
   6.5. Predviđanje litološkog sastava umjetnim neuronskim mrežama ... 35
7. Zaključak ... 39
8. Literatura ... 41

Popis slika

Slika 2.1. Geografski položaj istraživanog područja (Google Maps, https://www.google.hr/maps/@45.370776,17.7251113,37486m/data=!3m1!1e3)..... 2
Slika 3.1. OGK istraživanog područja sastavljena od listova Daruvar (Jamičić, 1989), Orahovica (Jamičić i Brkić, 1987), Slavonski Brod (Šparica, 1986), Nova Gradiška (Šparica et al., 1983), Nova Kapela (Šparica e. al., 1979) i Našice (Boško i Jamičić, 1989); istraživano područje nalazi se unutar ucrtanog pravokutnika 5
Slika 3.2. Pojednostavljena strukturna karta slavonskih planina s naglaskom na neogenskoj tektonici (prema Jamičić, 1995) 6
Slika 3.3. Shematski prikaz evolucije Požeške kotline (modificirano prema Pavelić, 2001) 8 13
Slika 4.1. Prikaz nabušenih formacija i litologije iz bušotine Tek-1 (modificirano prema Brcković et.al., 2017, prema Najdenovski, 1988.) 13
Slika 5.1. Načelni prikaz metodologije obrade podataka 14
Slika 5.2. Primjeri nekoliko mogućih seizmičkih atributa prikazanih na seizmičkom profilu B iz Požeške kotline (modificirano prema Brcković et.al., 2017)..... 17
Slika 5.3. Usporedba principa prijenosa i obrade podataka biološkog i umjetnog neurona 19
Slika 5.4. Strukture mreže a) s povratnim postupkom (MLP) s više skrivenih slojeva te najčešće sigmoidalnom aktivacijskom funkcijom i b) mreže s radijalnom funkcijom (RBF) s jednim skrivenim slojem i radijalnom aktivacijskom funkcijom (Bouzgou, 2012) 20
Slika 5.5. Usporedba grafova litoloških jedinica a) interpretiranih prema bušotinskim podatcima (karotažni dijagrami i ostaci sa sita) i b) svedenih na četiri osnovne kategorije u svrhu poboljšanja rezultata predviđanja neuronskih mreža..... 21
Slika 6.1. Interpretirani seizmički profili na području Požeške kotline 23
Slika 6.2. Dio interpretiranog seizmičkog profila A s vidljivo rasjedanom predneogenskom podlogom koju od mlađih naslaga odvaja horizont Tg; Zone omeđene plohama repernih horizonata predstavljaju izdvojene formacije iz jednostavnog modela – nema dislociranja horizonata po plohama rasjeda 24
Slika 6.3. Prikaz funkcije modela brzina po kojoj je transformirana seizmička interpretacija (TWT – Z) 25
Slika 6.4. Strukturna karta plohe repernog sloja Tg 26
Slika 6.5. Strukturna karta plohe repernog sloja H..... 27

Slika 6.6. Strukturna karta plohe repernog sloja G 28
Slika 6.7. Strukturna karta plohe repernog sloja B 28
Slika 6.8. Strukturna karta plohe repernog sloja A 29
Slika 6.9. Prikaz jednostavnog modela Požeške kotline i ploha repernih horizonata 30
Slika 6.10. Modeliranje i ekstrapolacija rasjeda u Petrelu postupkom Corner Point Gridding (lijevo) te prikaz ploha svih interpretiranih rasjeda na temelju seizmičkih profila (desno) 31
Slika 6.11. 3D prikaz ploha repernih horizonata prema modelu s rasjedima (zelena strelica označava smjer sjevera) 32
Slika 6.12. Prikaz zona strukturnog modela Požeške kotline 34
Slika 6.13. Predviđanja litologije dobivena neuronskim mrežama preklopljena preko seizmičkog profila A 35
Slika 6.14. Prikaz uspješnosti predviđanja litološkog sastava pojedinih neuronskih mreža unutar korištene kombinacije mreža (Ensamble); prvi broj u nazivlju mreže predstavlja ulazni sloj, drugi skrivene slojeve, a treći izlazne slojeve 36
Slika 6.15. Prikaz procjene litološkog sastava kombinacijom dvaju različitih postupaka koja je prebačena u litološka svojstva jednostavnog modela Požeške kotline radi bolje vizualizacije 38

Popis tablica

Tablica 1. Elektrokarotažni (EK) markeri ustanovljeni na području Požeške kotline i pojava koja ih predstavlja (prema Lučić et. al., 2001; Saftić, 2003; Velić, 2007; Malvić i Saftić, 2008) 15

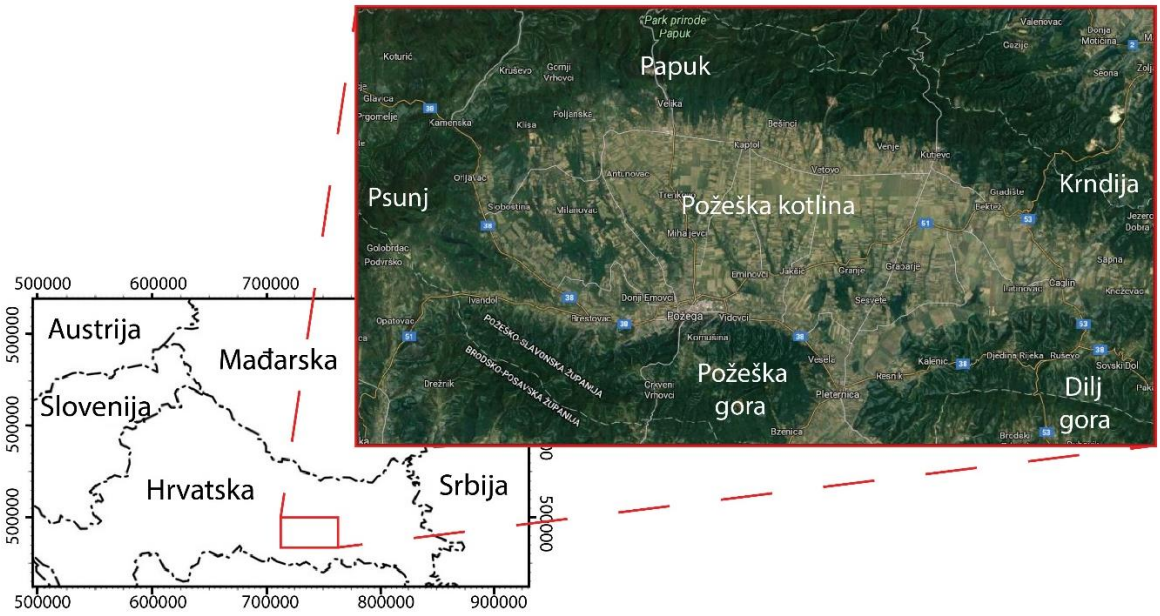
1. Uvod

Požeška kotlina nalazi se u središnjem dijelu hrvatskog dijela Panonskog bazena. Okružuju je takozvane slavonske planine - Papuk, Psunj, Krndija te Požeška i Dilj gora. Sam postanak Požeške kotline vezan je upravo za neotektonske pokrete prilikom kojih je u miocenu došlo do tonjenja dijela kotline te izdizanja spomenutih gorja na njenom obodu. Hrvatski dio Panonskog bazena kao geološka cjelina je vrlo dobro istraženo područje s vrlo visokim naftnogeološkim potencijalom, čemu ide u prilog da se sva naftna i većina plinskih ležišta Republike Hrvatske eksploatiraju upravo unutar hrvatskog dijela Panonskog bazena (Velić et. al, 2012a; 2012b). Ipak, Požeška kotlina ostala je prilično neistražena po jedinici površine te bez otkrića ugljikovodika.

Najviše pažnje prilikom prethodnih geoloških istraživanja posvećeno je planinskim nizovima koji okružuju kotlinu. Rezultati tih istraživanja omogućili su tek načelna razmatranja dubinskim geološkim odnosima u kotlini. S prvim geofizičkim istraživanjima krenulo se 60-ih godina 20. stoljeća. Na području prostiranja same kotline, koje je otprilike 870 km^2, napravljeno je šest refleksijskih seizmičkih profila te jedna istražna bušotina.

Cilj ovog diplomskog rada je prikazati tektonsko-strukturne odnose koji su pridonijeli formiranju kotline te na temelju analiza i statističke obrade (umjetne neuronske mreže) prikupljenih podataka prikazati litološki sastav neogenske ispune. Interpretirani su postojeći seizmički podatci te je, uz pomoć bušotinskih podataka i dodatne objavljene literature, načinjen jednostavni model područja, a potom i model koji uključuje rasjede. Litološki sastav bazenske ispune determiniran je samo za pojedine tragove na seizmičkim profilima pomoću geomatematičke analize seizmičkih i bušotinskih podataka umjetnim neuronskim mrežama. Dobiveni rezultati služe kao temelj za daljnje propitivanje o naftnogeološkoj perspektivnosti Požeške kotline.

2. Geografske značajke istraživanog područja



Slika 2.1. Geografski položaj istraživanog područja (Google Maps, https://www.google.hr/maps/@45.370776,17.7251113,37486m/data=!3m1!1e3)

Požeška subdepresija nalazi se u Požeško-slavonskoj županiji. Okružena je takozvanim slavonskim gorjem - Papukom, Krndijom i Psunjem na sjeveru subdepresije te Požeškom i Dilj gorom na njenom jugu. Najviša točka nalazi se na planini Psunj na 989 m nadmorske visine, a najniže područje nalazi se u dolini rijeke Orljave između 150 i 200 m. Ovo istraživano podučje predstavlja geografski zatvorenu cjelinu. Na relativno malom području izmjenjuju se planinski šumoviti predjeli na čijim obroncima su zasađeni vinogradi i voćnjaci te prostrana dolina s obradivim poljoprivrednim tlom. Požešku kotlinu, kao dio kontinentalne Hrvatske, karakterizira umjerena kontinentalna klima odnosno topla, vlažna klima s toplim ljetima (Institut IGH, 2017). Minimalna mjesečna srednja temperaura izmjerena na postaji Požega iznosi oko 1 °C, maksimalna oko 21 °C, a srednja iznosi oko 11 °C. Područje Požeške kotline tijekom godine ima do 1975 sunčanih sati (Institut IGH, 2017). Prosječna vrijednost oborina na području kotline iznosi oko 800 mm godišnje (planinski predjeli bilježe nešto veću vrijednost od prosječne, a nizinski dio nešto manju). Strujanje vjetra većinom se odvija sa zapada što je karakteristika umjerenih klima, ali u ovom slučaju je uvjetovano i longitudinalnom izduženošću kotline u smjeru zapad–istok (Institut IGH, 2017). Obodi okolnih planina prekriveni su bujičnjacima. Hidrografsku

mrežu, koja je prilično asimetrična i centripetalna, čine rijeka Orljava i rijeka Londža sa svojim pritocima. Dolina rijeke Orljave, koja se proteže između Požeške gore i Dilj gore, povezuje Požešku kotlinu s Posavinom. Morfološke karakteristike terena i hidrološka mreža povezani su s geološkim i tektonskim značajkama ovog područja čemu u prilog ide i povezanost riječnih tokova s trasama rasjeda (Najdenovski, 1988). Najstariji tragovi ljudskog bivanja na području Požeške kotline datiraju iz vremena oko 10 000 godina prije Krista, a nalaze se uz tokove rijeka (Potrebica, 2012). Dugački period praćenja ljudskih aktivnosti govori o pogodnosti naseljavanja ovog područja te o bogatstvu prirodnih sirovina kojima se moglo raspolagati. U rimsko doba, kotlina je dobila pridjev Zlatne doline. Razlozi ovog nazivlja vidljivi su i danas u činjenici da je polovina kotline prekrivena oranicama te se većina gospodarstva temelji na poljoprivredi. U skladu s bogatstvom obradive površine, najveća naseljenost zabilježena je u središnjem dijelu kotline s gradom Požegom kao upravnim i gospodarskim središtem Požeško-slavonske županije. Područje kotline obilježeno je također vrlo karakterističnim i atraktivnim pojavama. Izdizanjem gorja tektonskim pokretima na površinu su dospjeli i propusni slojevi s termalnom vodom. Jedan takav izvor termalne vode na površini nalazi se na području Velike podno Papuka. Ona je također i polazišna točka za Park prirode i geopark Papuk. Interesantno je i Sovsko jezero na području Dilj gore koje predstavlja jedini ostatak Paratethysa u našoj zemlji (Petrić-Stepanović, 2002).

3. Geološke značajke istraživanog područja

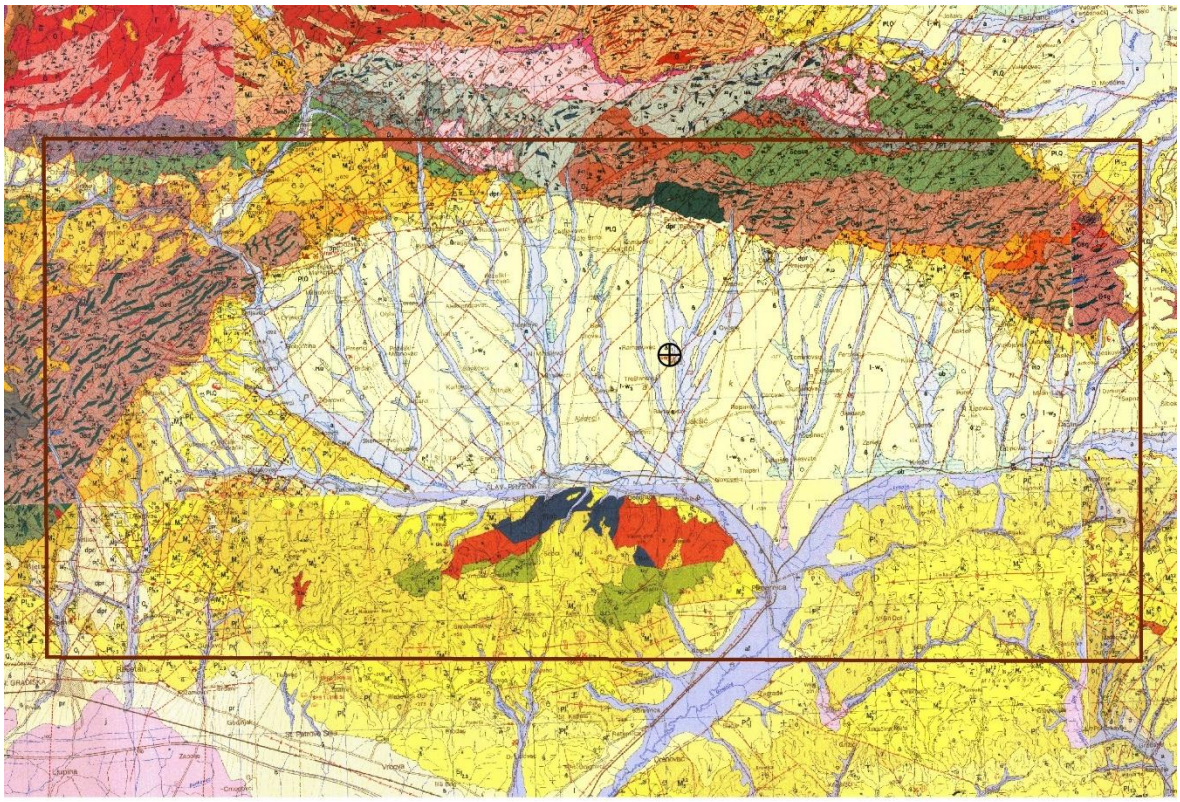
Požeška kotlina jedna je od subdepresija u jugozapadnom dijelu Panonskog bazena. Nalazi se u istočnom dijelu Savske depresije. Na sjeveru graniči s Dravskom, a na istoku sa Slavonsko-srijemskom depresijom.

Na temelju osnovne geološke karte (OGK) SFRJ, listova Daruvar (Jamičić, 1989), Orahovica (Jamičić i Brkić, 1987), Slavonski Brod (Šparica, 1986), Nova Gradiška (Šparica et al., 1983), Nova Kapela (Šparica et al., 1979) i Našice (Boško i Jamičić, 1989), odmah su jasno prepoznatljive tri cjeline stijena na istraživanom području (Slika 3.1.). Na sjeveru i sjeverozapadu područja na površinu su izdignute stijene predneogenske podloge u sklopu izdizanja Psunja, Papuka i Krndije. Većinom su to nisko do visoko-metamorfozirane magmatske stijene, uglavnom kloritski škriljavci i gnajsevi. Najstarije kartirane stijene na ovom području potječu iz prekambrija.

Cijelim južnim rubom dominiraju neogenske naslage koje su na površinu dospjele u sklopu izdizanja Požeške i Dilj gore. Neogenske naslage se mjestimice mogu pronaći i na sjeveru područja odnosno na južnim obroncima Papuka i Krndije. Neogenski slijed naslaga po obodima Požeške kotline obuhvaća stijene od donjeg miocena pa sve do pliocena. Stijene otnanga i karpata mogu se naći u obliku konglomerata taloženih u riječnim okolišima, pješčenjaka, prahova, vapnenaca i dolomita u jezerima tipa saline (Kovačić et al., 2017) te čak i eolskih sedimenata (Pavelić et al., 2015). Konglomerati i pješčenjaci badena određeni su na obroncima planina u djelomično transgresivnom, a većinski rasjednom kontaktu sa starijim stijenama. Stijene badenske starosti mogu se naći i na Požeškoj gori koje prema njenim obodima prelaze u sarmatske vapnence i lapore. Na Dilj gori se uz naslage badena i sarmata mogu pronaći i izdanci naslaga gornjeg miocena (panona i ponta).

Središte istraživanog područja koje zahvaća samu kotlinu većinski je prekriveno kvartarnim naslagama koje prema rubovima transgresivno naliježu na neogenske i predneogenske naslage.

Značajan tektonski utjecaj na razvoj depresije naznačen je nizom rasjeda s pomakom po pružanju, pružanja SI–JZ. Da je riječ o rasjedima s lijevim pomakom vidljivo je na pomaknutim predneogenskim jedinicama na sjeveru karte (Slika 3.1.).



LEGENDA:

KVARTAR
- dpr — deluvijalno-proluvijalni sedimenti
- al — aluvij recentnih tokova
- l — prapor
- p — Pijesci i šljunci akvatične sredine

PLIOCEN
- Pl,Q — šljunci, pijesci, siltno-pjeskovite gline
- Pl 2,3 — Gline, pijesci, šljunci, pojave ugljena
- Pl $^{2}_{1}$ — pijesci, pješčenjaci, glinoviti lapori

MIOCEN
- Pl $^{1,2}_{1}$ — Pijesci, pješčenjaci i ugljevite gline
- Pl $^{1}_{1}$ — Glinoviti i siltno-glinoviti lapori, pijesci
- $_{2}M^{2}_{3}$ — Vapneni i siltozni lapori
- $_{1}M^{2}_{3}$ — Laporoviti vapnenci, lapori
- M^{1}_{3} — Lapori, pješčenjaci, gline, pijesci, šljunci
- B — bazalti
- a — andeziti
- M^{2}_{2} — konglomerati
- M^{1}_{2} — konglomeratični pješčenjaci, pješčenjaci, pjeskoviti i siltozni lapori, tufiti, ugljen

KREDA
- K^{2}_{2} — rudistni vapnenci

JURA
- J — Pločasti vapnenci

TRIJAS
- T_3 — Vapnenci i dolomitični vapnenci
- T^{2}_{2} — Dolomiti i vapneni dolomiti
- T^{1}_{2} — Dolomiti, dolomitični vapnenci, vapnenci, dolomitno-vapnenačke breče, laporoviti vapnenci

PERM
- T_1 — Pješčenjaci, šejlovi, siltiti
- $^{2}P_2T$ — Kvarcni pješčenjaci
- $^{1}P_2T$ — Filitni konglomerati, pješčenjaci, konglomeratični pješčenjaci

KARBON
- BBab — Spilitizirani dijabazi
- v — Graniti Omanovca
- ^{2}C — Metagrauvake, metapješčenjaci, šejlovi
- ^{1}C — Metagrauvake, kloritoidni škriljavci, grafitične metagrauvake

STARI PALEOZOIK
- Sco — Kloritski škriljavci
- Gbm — Biotit-muskovitski gnajsevi
- p′ — Pegmatitske i aplitske žile
- A′ — Amfiboliti i amfibolski škriljavci
- Mi — Migmatiti: homogeni i heterogeni
- G — Granitoidi

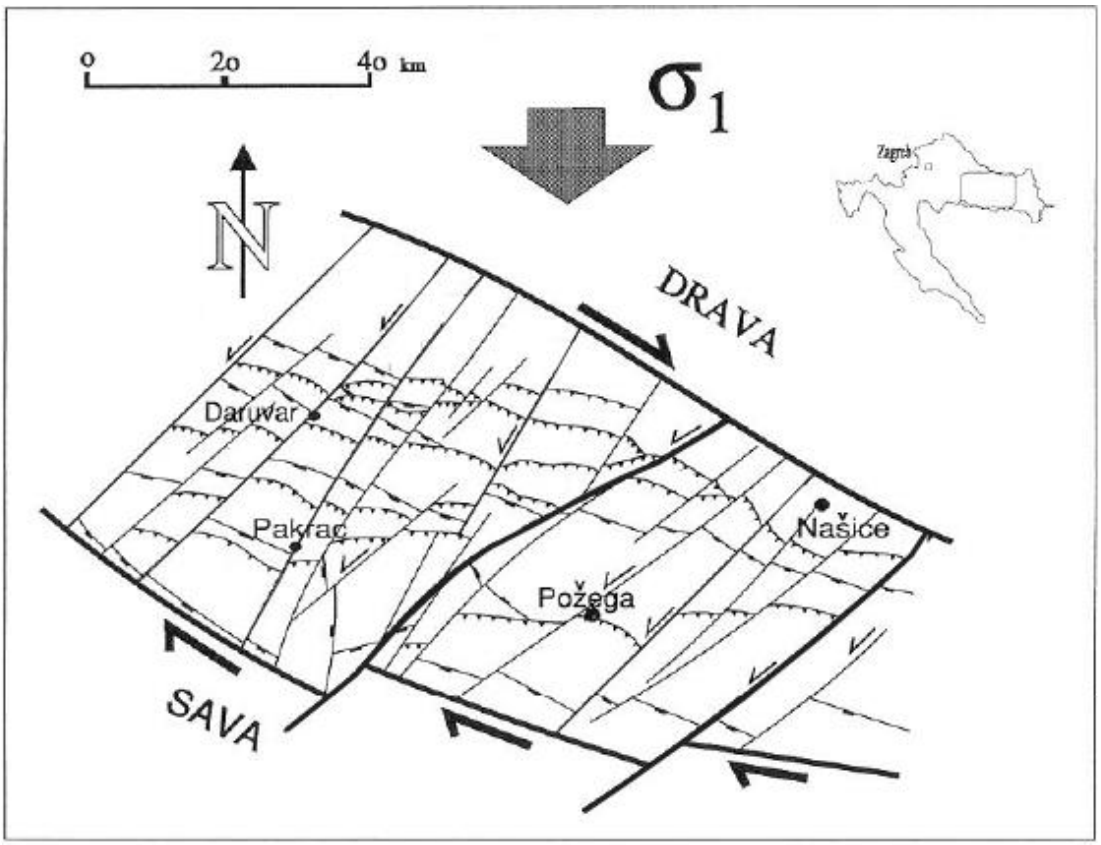
PREKAMBRIJ
- Scose — Klorit-sericitski škriljavci
- Sgr — Grafitični škriljavci
- Gsd — Granat-staurolitski gnajsevi
- A — Amfiboliti i amfibolski škriljavci
- M — Mramori
- v — Metagabri
- r — Flazerirani granitoidi
- P — Pegmatiti
- Se — Serpentiniti
- Gk — Gnajsevi s kordijeritom

⊕ Bušotina Tek-1

Slika 3.1. OGK istraživanog područja sastavljena od listova Daruvar (Jamičić, 1989), Orahovica (Jamičić i Brkić, 1987), Slavonski Brod (Šparica, 1986), Nova Gradiška (Šparica et al., 1983), Nova Kapela (Šparica e. al., 1979) i Našice (Boško i Jamičić, 1989); istraživano područje nalazi se unutar ucrtanog pravokutnika

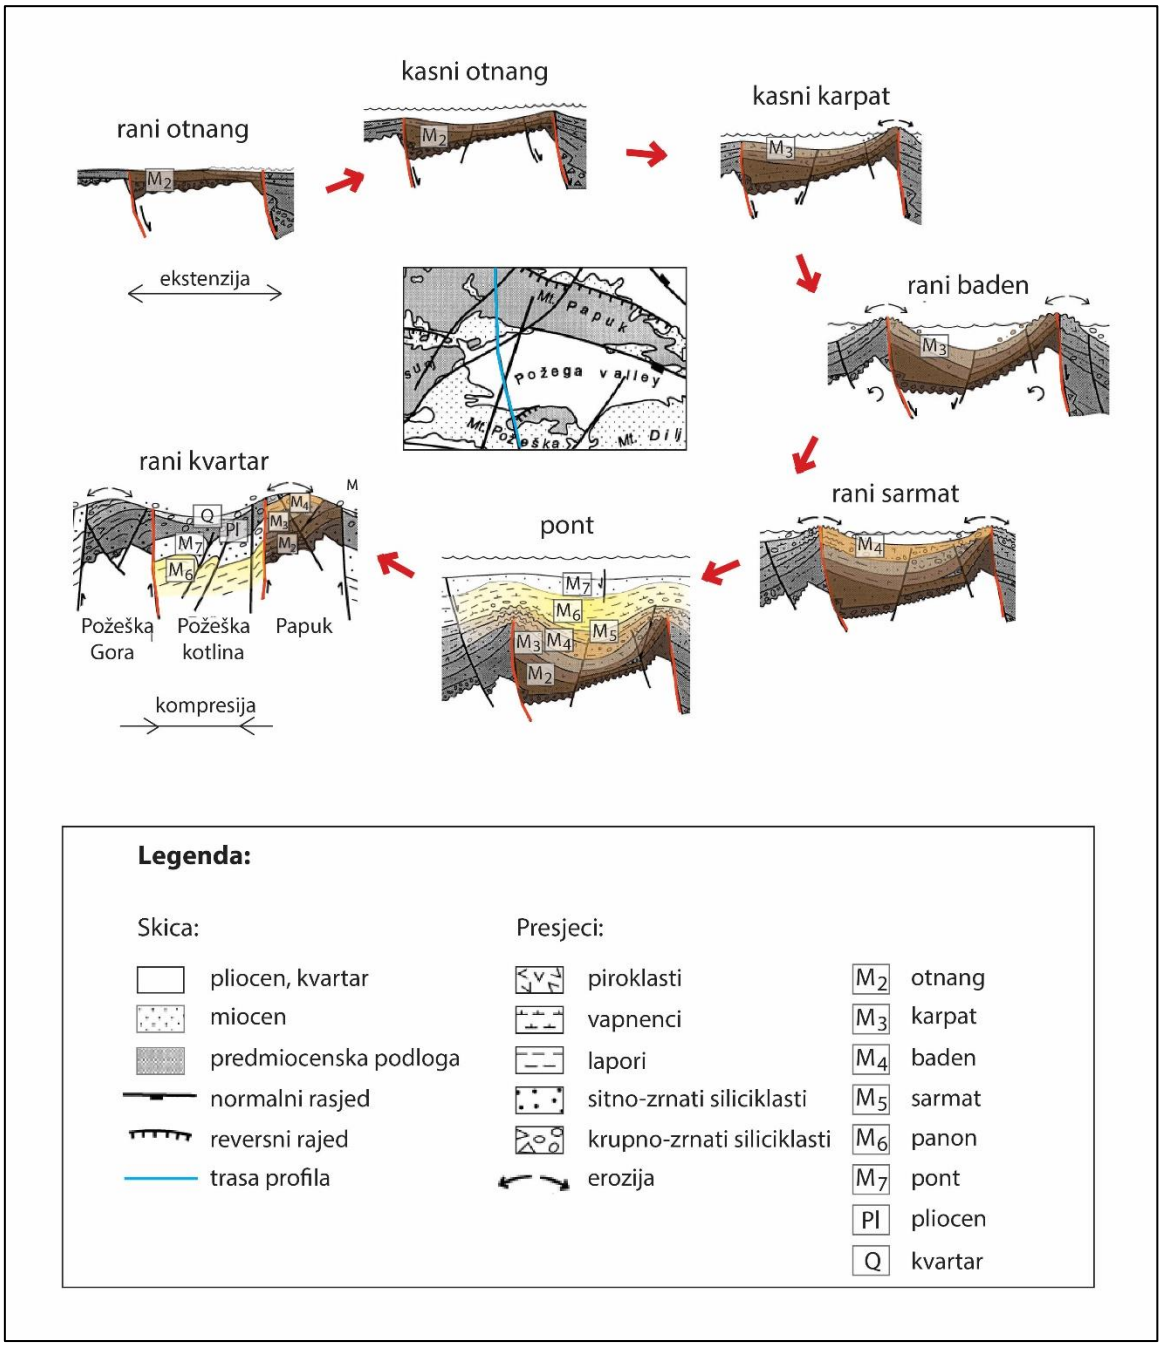
3.1. Strukturno-tektonski sklop

Kao dio Panonskog bazenskog sustava ovo područje utjecano je intenzivnim tektonskim događajima. Već pred kraj krede, snažna kompresija u smjeru I–Z uzrokovala je povijanje boranih struktura i izdizanje struktura s orijentacijom S–J te stvaranje glavnih transkurentnih rasjeda s desnim pomakom na rubovima kotline (Slika 3.2.). Te izdignute strukture erodiranjem će dati materijal za ispunjavanje bazena u neogenu (Jamičić, 1995).
Tektonski sklop slavonskih planina formira se kroz neogen i kvartar. Promjena orijentacije glavnih osi stresa iz smjera I–Z u SSI–JJZ uzrokovana je subdukcijom europske ploče pod zapadne Karpate od oligocena do miocena (Royden et al., 1983.; Prelogović et al., 1998; Schmid et al., 2008; Handy et al., 2014), uslijed čega je došlo do ekstenzije u panonskom bazenskom sustavu u smjeru I–Z. Pri novonastalom stanju stresa, između rubnih desnih transkurentnih rasjeda pojavili su se manji rasjedi s lijevim pomakom po pružanju, pružanja SI–JZ (Slika 3.2.).



Slika 3.2. Pojednostavljena strukturna karta slavonskih planina s naglaskom na neogenskoj tektonici (prema Jamičić, 1995)

Svoj sadašnji izgled kotlina zahvaljuje (neo)tektonskim aktivnostima koje su se odvijale od miocena na dalje. U ranom miocenu dolazi do kontinentalnong riftovanja (Pavelić i Kovačić, 1999; Pavelić, 2001) pri čemu se otvara Sjevernohrvatski sedimentacijski bazen na jugozapadnom rubu Panonskog bazenskog sustava. Normalnim rasjedanjem u ranom otnangu na južnim rubnim dijelovima nastale su izdužene strukture polugraba, karakteristične za Požešku kotlinu. Listričkim rasjedanjem počelo je odvajanje Požeške kotline od Požeške gore (Pavelić, 2001). Za vrijeme onoga što se prethodno smatralo karpatom (danas baden prema Ćorić et al., 2009) dolazi do marinske transgresije kao posljedica tektonskih aktivnosti u Dinaridima, prilikom čega pretpostavljeno dolazi do spajanja Paratethysa i Mediterana. Padom razine mora, slavonske planine se izdižu na površinu uslijed rotacije rasjednih blokova (Pavelić, 2001; Slika 3.3.). Kontinuiranom erozijom emergiranih blokova nastavio se trend izdizanja uslijed izostazije te su tako na površinu dospjele stijene predneogenske podloge (Slika 3.3.). Intenzivno izdizanje popraćeno je formiranjem rasjeda s pomakom po pružanju, pružanja SI–JZ u ranom badenu, a prisutne su i pojave vulkanske aktivnosti. U kasnom badenu opet dolazi do marinske transgresije uzrokovane globalnim porastom morske razine uslijed kratkotrajnog povezivanja Paratethysa s Indopacifikom. Dolazi do naglog produbljivanja kotline i prekrivanja izdignutih struktura morem, a vulkanska aktivnost prestaje. Prelaskom u postriftnu fazu, otvaranjem sedimentacijskog prostora rasjedanjem, ulazi se u fazu subsidencije prilikom hlađenja litosfere (Pavelić, 2001). Sarmat je obilježen smanjivanjem tektonske aktivnosti, uz povremene kompresijske događaje koji su doveli do ponovnog izdizanja struktura prilikom promjena u Alpsko-karpatskom sustavu čime je došlo do potpune izolacije Panonskog jezera. Krajem miocena (panon) i početkom pliocena, Požeška subdepresija kao i Panonski bazenski sustav prolazi kroz period postriftnog termalnog slijeganja nakon čega dolazi do inverzije i izdizanja pojedinih dijelova Panonskog bazena koja traje kroz pliocen i kvartar (Najdenovski, 1988; Prelogović et al., 1998; Velić, 2007; Matenco i Radivojević, 2012; Cvetković, 2013). Generalni uvjeti stresa mijenjaju se iz ekstenzijskih u kompresijske u JZ dijelu Panonskog bazena, gdje se orijentacija ekstenzijskih vektora pomiče kao posljedica rotiranja Južnih Karpata u smjeru kazaljke na satu (Matenco i Radivojević, 2012). Uslijed kompresijskih sila dolazi do reaktivacije normalnih rasjeda kao reversnih, osobito glavnih na sjevernom i južnom rubu kotline. Vertikalno uzdizanje najveće je razmjere imalo uz rasjede u kontaktu s planinama na sjeverozapadu kotline.



Slika 3.3. Shematski prikaz evolucije Požeške kotline (modificirano prema Pavelić, 2001)

3.2. Sedimentacijski uvjeti

Sedimentacija je tijekom miocena bila izrazito povezana s oscilacijama razine mora, koje su bile uvjetovane povezanošću Paratethysa s Mediteranom i Indopacifičkim oceanom (Pavelić, 2005). Uslijed izdizanja pojedinih dijelova te u konačnici potpune izolacije Paratethysa, na istraživanom području izmjenjuju se različiti taložni okoliši, od slatkovodnog, marinskog, preko brakičnog, pa opet do slatkovodnog (Pavelić et al., 2003). Stratigrafski gledano, u kotlini se razaznaju dva kompleksa stijena, poznatijih pod nazivom predneogenska podloga i neogenska ispuna bazena. Predneogensku podlogu čine uglavnom magmatske i metamorfne stijene paleozojske i mezozojske starosti te sedimentne stijene permske do kredne starosti. Najveća dubina na kojoj se na ovom području mogu naći je -2700 m (Najdenovski, 1988., Kovačić i Pavelić, 2017).

Neogenske sedimentne naslage taložene su kroz tri transgresivno-regresivna megaciklusa pod većinskim utjecajem tektonike (Lučić et al., 2001; Velić et al., 2002; Saftić, 2003). Megaciklusi su međusobno odijeljeni većim diskordancijama koje su jasno prepoznatljive po karakterističnom odazivu na elektrokarotažnim krivuljama (EK). Sinriftna diskordancija po podini neogena predstavlja početak prvog megaciklusa i odvaja sedimentne naslage neogena od predneogenske podloge heterogenog sastava. Karakterističan odaziv na EK krivuljama pod utjecajem ove diskordancije predstavlja uvjetni reper Pt i/ili Tg, ovisno o tome jesu li u podlozi neogenskih naslaga starije sedimentne ili pak magmatske i metamorfne stijene (Vrbanac, 2002). Drugi megaciklus započinje diskordancijom po podini panona koja je prouzročena izdizanjem uslijed inverzije stresa iz ekstenzijskog u kompresijski kojeg slijedi termalna subsidencija bazena, a predstavlja je EK marker/reper H (Rs7). Početak trećeg megaciklusa označava taloženje pliocenskih naslaga diskordantno na nanovo izdignute starije naslage uslijed jačanja kompresijskih sila, a označava je EK marker A (α'). Jačanjem kompresijskih sila dolazi do reaktivacije rasjednih ploha uz reversni pomak te posljedičnog izdizanja naslaga na rubovima kotline (Saftić i Malvić, 2008).

Jedinom istražnom bušotinom na istraživanome području (Tekić-1) nabušeni su paleozojski gnajsevi i škriljavci, dok stijene mezozojske starosti nisu nabušene. Izostanak mezozojskih stijena upućuje na erodiranost naslaga, s obzirom da se mjestimice o nalaze na izdancima na obodima kotline (Najdenovski, 1988.).

Naslage otnanga i karpata su prve široko rasprostranjene naslage na području Panonskog bazena te su pronađene unutar svih depresija na jugu bazena. To su obično krupno-zrnati

klastiti taloženi u riječnim do jezerskim okolišima (Saftić, 2003). Postupno podizanje razine mora tijekom doba koje se prije smatralo karpatom, a danas badenom, pridonijelo je marinskoj sedimentaciji pjeskovitih i glinovitih lapora. Produbljivanjem sedimentacijskog prostora naknadnom transgresijom u ranom badenu, prvo se talože erodirani krupnoklastični sedimenti izdignutih otočnih planina na koje se nastavlja sedimentacija vapnenaca i kalcitičnih lapora (Lučić et al., 2001). Intenziviranjem tektonike u kasnom badenu, rubni dijelovi sedimentacijskom bazena dodatno se izdižu te postaju podložni eroziji. U sedimentacijskom prostoru talože se konglomerati, breče i pješčenjaci, a djelovanjem turbiditnih tokova u dubljim dijelovima bivaju istaloženi plavo-sivi i smećkasti lapori. Istovremeno, za rubne dijelove je specifična precipitacija litotamnijskog vapnenca popraćeno stvaranjem kalkarenita. Specifična pojava trakastih lapora vezana je za vršne dijelove badena. Ove naslage izrazito su bogate mikro i makrofosilnom zajednicom (Lučić et al., 2001; Zečević et al., 2010; Kovačević, 2017). Uslijed tektonike i izdizanja, odnosno oplićavanja sedimentacijskog bazena, na badenske naslage konkordantno su istaložene relativno tanke naslage sarmata koje uključuju tanko uslojene laporovite vapnence i pješčenjake. U jugoistočnom dijelu Požeške kotline, na sjevernim obroncima Dilj gore, unutar sarmatskih naslaga pronađeni su tamni lapori interpretirani kao sekundarni klasti matične stijene (Kovačević, 2017). Izoliranje centralnog Paratethysa od Tethysa za posljedicu je imalo prelazak iz marinskih u brakične pa potom slatkovodne okoliše, što se očitovalo i u promjeni fosilne zajednice u panonu. Na temelju specifičnih fosilnih vrsta mekušaca pronađenih u velikoj količini u panonskim naslagama, one se dijele u dvije skupine: donjopanonske Croatica naslage koje se sastoje od vapnenaca, lapora i pješčenjaka koji su taloženi u jezerskim plitkovodnim uvjetima te gornjopanonske Banatica naslage, koje čine pretežno pjeskoviti i glinoviti lapori (Lučić et al., 2001; Pavelić et al., 2001). Produbljavanje dna u pontu omogućuje konkordantno taloženje debelog sloja naslaga na panonsku podlogu. Pontske naslage su također na temelju fosilne zajednice podijeljenje na donjopontske Abichi naslage koje čine sitnozrnati pješčenjaci s proslojcima lapora te Rhomboidea naslage sačinjene od kvarcnih pješčenjaka i lapora s proslojcima ugljena (Lučić et al., 2001). I u panonskim i u pontskim naslagama pronađeni su lapori s blago povećanim sadržajem organske tvari (Kovačević, 2017). Tektonskom inverzijom taložnog bazena dolazi do stvaranja jezerskih i riječnih uvjeta te se aluvijalnim lepezama odlažu krupnoklastični sedimenti pomiješani s glinom, uz proslojke lignita (Saftić, 2003).

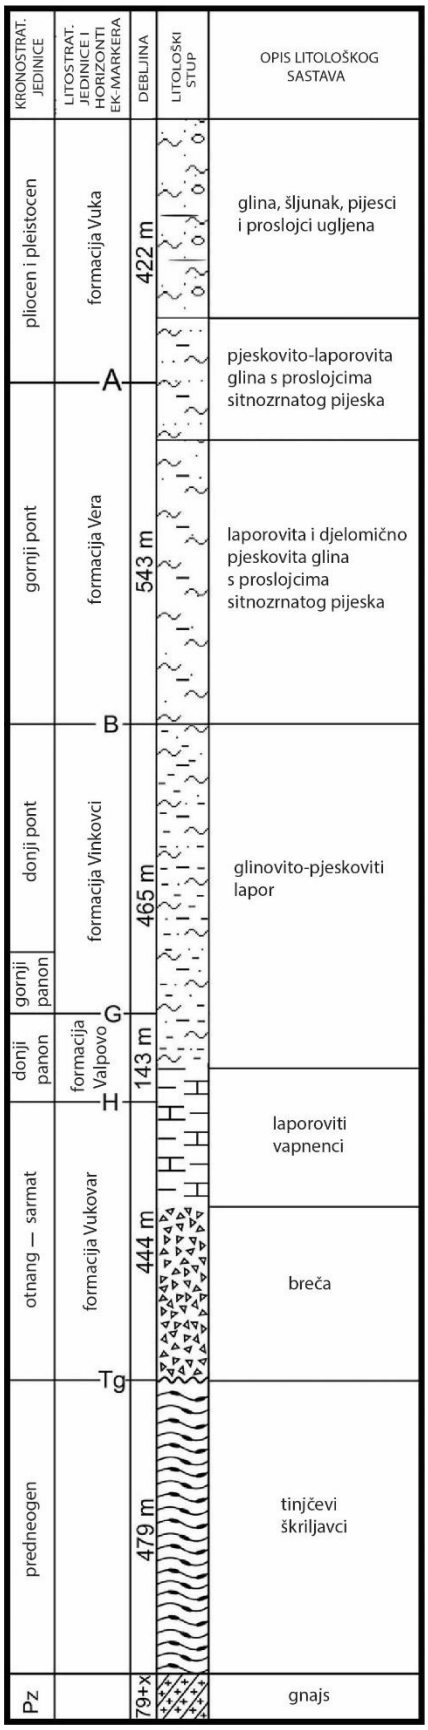
Jezersko-riječni uvjeti vladaju i tijekom pliocena unutar manjih dezintegriranih jezera. U kvartaru facijesi riječnih kanala postaju dominantni, uz značajniji doprinos eolskih sedimenata (Lučić et al., 2001; Saftić et al., 2003).

Neogenske naslage Požeške kotline podijeljene su u pet formacija, krenuvši od najstarije Vukovarske formacije koju većinom čine breče i laporoviti vapnenci, zatim pretežno laporovite Valpovačke i Vinkovačke formacije te glinovite formacije Vera koja prelaskom iz sitno u srednjo do krupnozrnate sedimente (pijesak, šljunak) prelazi u najmlađu formaciju Vuka (Slika 4.1.). Granice između tih formacija mogu se popratiti pomoću EK markera/repera očitanih s krivulja otpornosti (Slika 6.2.) (Vrbanac, 2002; Velić, 2007).

4. Pregled prijašnjih istraživanja na području Požeške kotline

U literaturi se okolica Požeške kotline počinje spominjati već 50-ih godina 19. stoljeća, a s obzirom da je sama kotlina ispunjena debelim pokrovom kvartarnih naslaga, geološka istraživanja najprije su započela na obodima planina koje ju okružuju. Prvi geofizički radovi vezani za kotlinu objavljeni su u drugoj polovici 20. stoljeća, a pregled istaknutijih (geoloških, geofizičkih) istraživanja do 1988. godine objedinio je i kronološki objavio Najdenovski u svojoj disertaciji iz navedene godine. U sklopu navedenih geofizičkih istraživanja postavljeno je šest seizmičkih profila unutar kotline. Lokacija za istražnu bušotinu Tek-1 koja je postavljena 150 m sjeverno od sela Tekić, jedinu bušotinu na samom prostoru Požeške kotline, odobrena je 1979. godine. Bušenje je započelo naredne godine kako bi se utvrdilo postojanje kolektorskih stijena i njihove eventualne zasićenosti ugljikovodicima, a konačna dubina iznosila je 2575 m. Probušen je neogenski slijed naslaga, a nabušena je i predneogenska podloga (Slika 4.1.). Prilikom izvođenja radova jezgrovano je oko 30 m stijena unutar interesantnih intervala, uzorci sa sita opisani su s različitim dubinskim razmacima kroz tri kroz tri dubinska intervala bušotine te su izvedena elektrokarotažna mjerenja (karotaža spontanog potencijala, karotaže otpornosti i radioaktivnosti te zvučna karotaža) (INA Naftaplin, 1981).

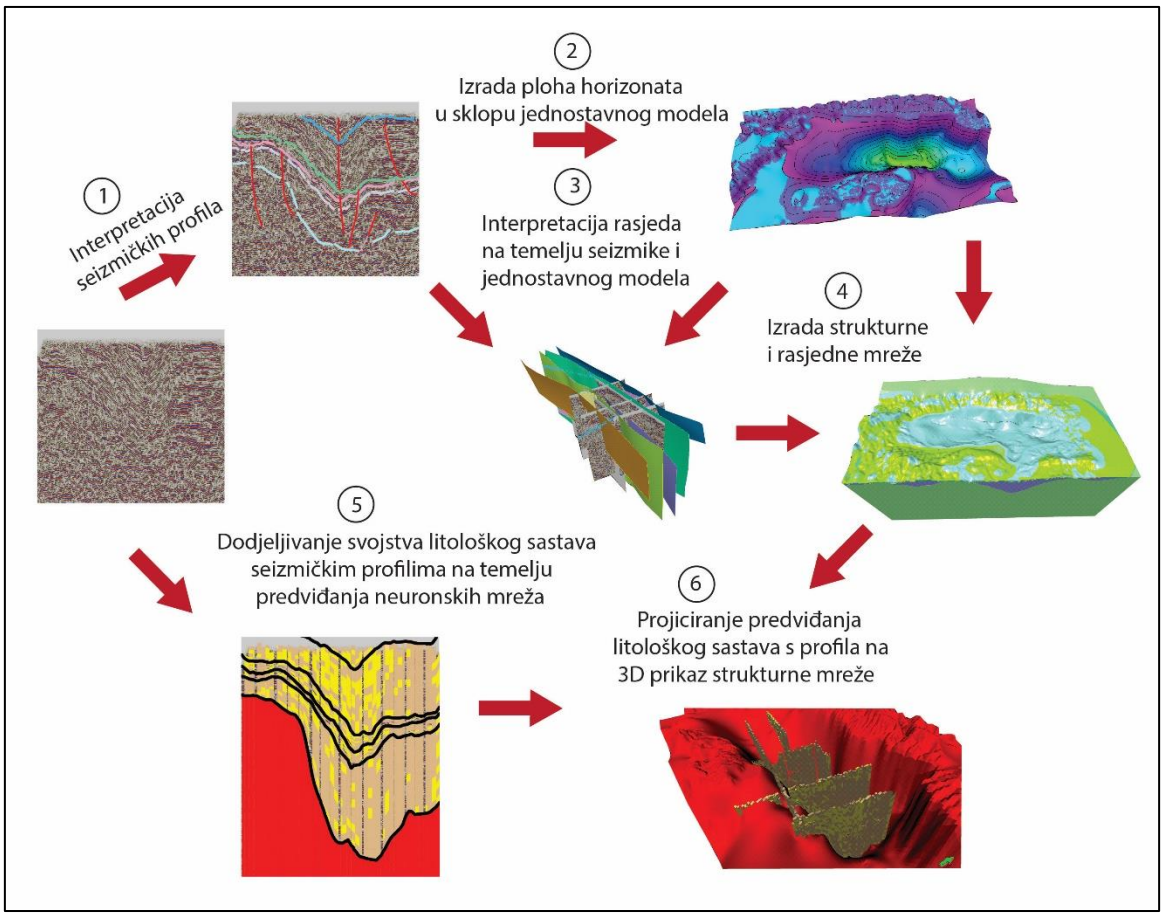
Uvid u tektonske odnose kotline u sklopu tektonostratigrafije Panonskog bazena dali su u novije vrijeme, među ostalima, Pavelić (2001), Saftić et al. (2003), Horvath et al. (2006), Matenco i Radivojević, (2012). Uz neogensku evoluciju i tektoniku, naftnogeološkim potencijalom hrvatskog dijela Panonskog bazena bavili su se Lučić et al. (2001), Saftić et al. (2003), Malvić i Velić (2011), Kovačević (2017), Emanović (2018). Zbog slabe istraženosti područja Požeške kotline u zadnje vrijeme dosta se pažnje posvećuje i alternativnim (nekonvencionalnim) oblicima prikupljanja podataka pomoću umjetnih neuronskih mreža kao što se može vidjeti u radovima Malvić et al. (2011), Cvetković i Velić (2012) i Cvetković et al. (2014), Brcković et al. (2017). U tom smjeru nastavljaju se i istraživanja unutar ovog diplomskog rada.



Slika 4.1. Prikaz nabušenih formacija i litologije iz bušotine Tek-1 (modificirano prema Brcković et.al., 2017, prema Najdenovski, 1988.)

5. Metodologija

Krajnji cilj ovog rada bio je geološko modeliranje Požeške kotline na temelju vrlo malog broja dostupnih podataka. Obrada podataka za ovaj diplomski rad odvijala se u nekoliko koraka. U prvom koraku na šest međusobno okomitih seizmičkih profila interpretirani su horizonti prema podatcima iz bušotine Tek-1. Zatim su na temelju svih do tada obrađenih podataka i njihovih rezultata napravljena dva strukturna modela istraživanog područja - jednostavni model te model s rasjedima. Na kraju su sa seizmičkih profila derivirani seizmički atributi te su njihove numeričke vrijednosti, zajedno s litološkim sastavom iz bušotine, upotrijebljene za predviđanje litološkog sastava na profilima pomoću umjetnih neuronskih mreža (Slika 5.1.).



Slika 5.1. Načelni prikaz metodologije obrade podataka

5.1. Interpretacija seizmičkih profila te modeliranje jednostavne mreže i rasjeda

Na temelju podataka ustupljenih ljubaznošću Ministarstva zaštite okoliša i energetike, Agencije za ugljikovodike i naftne kompanije Vermilion, izvedena je interpretacija šest seizmičkih profila u vremenskom mjerilu na području Požeške kotline. Pomoću Schlumbergerova programa Petrel interpretirani su refleksi koji predstavljaju horizonteznačajne za to područje (Slika 4.1.). Horizonti su utvrđeni kao elektrokarotažni markeri (EK) bušotinom Tek-1 i prikazani su u Tablici 1.

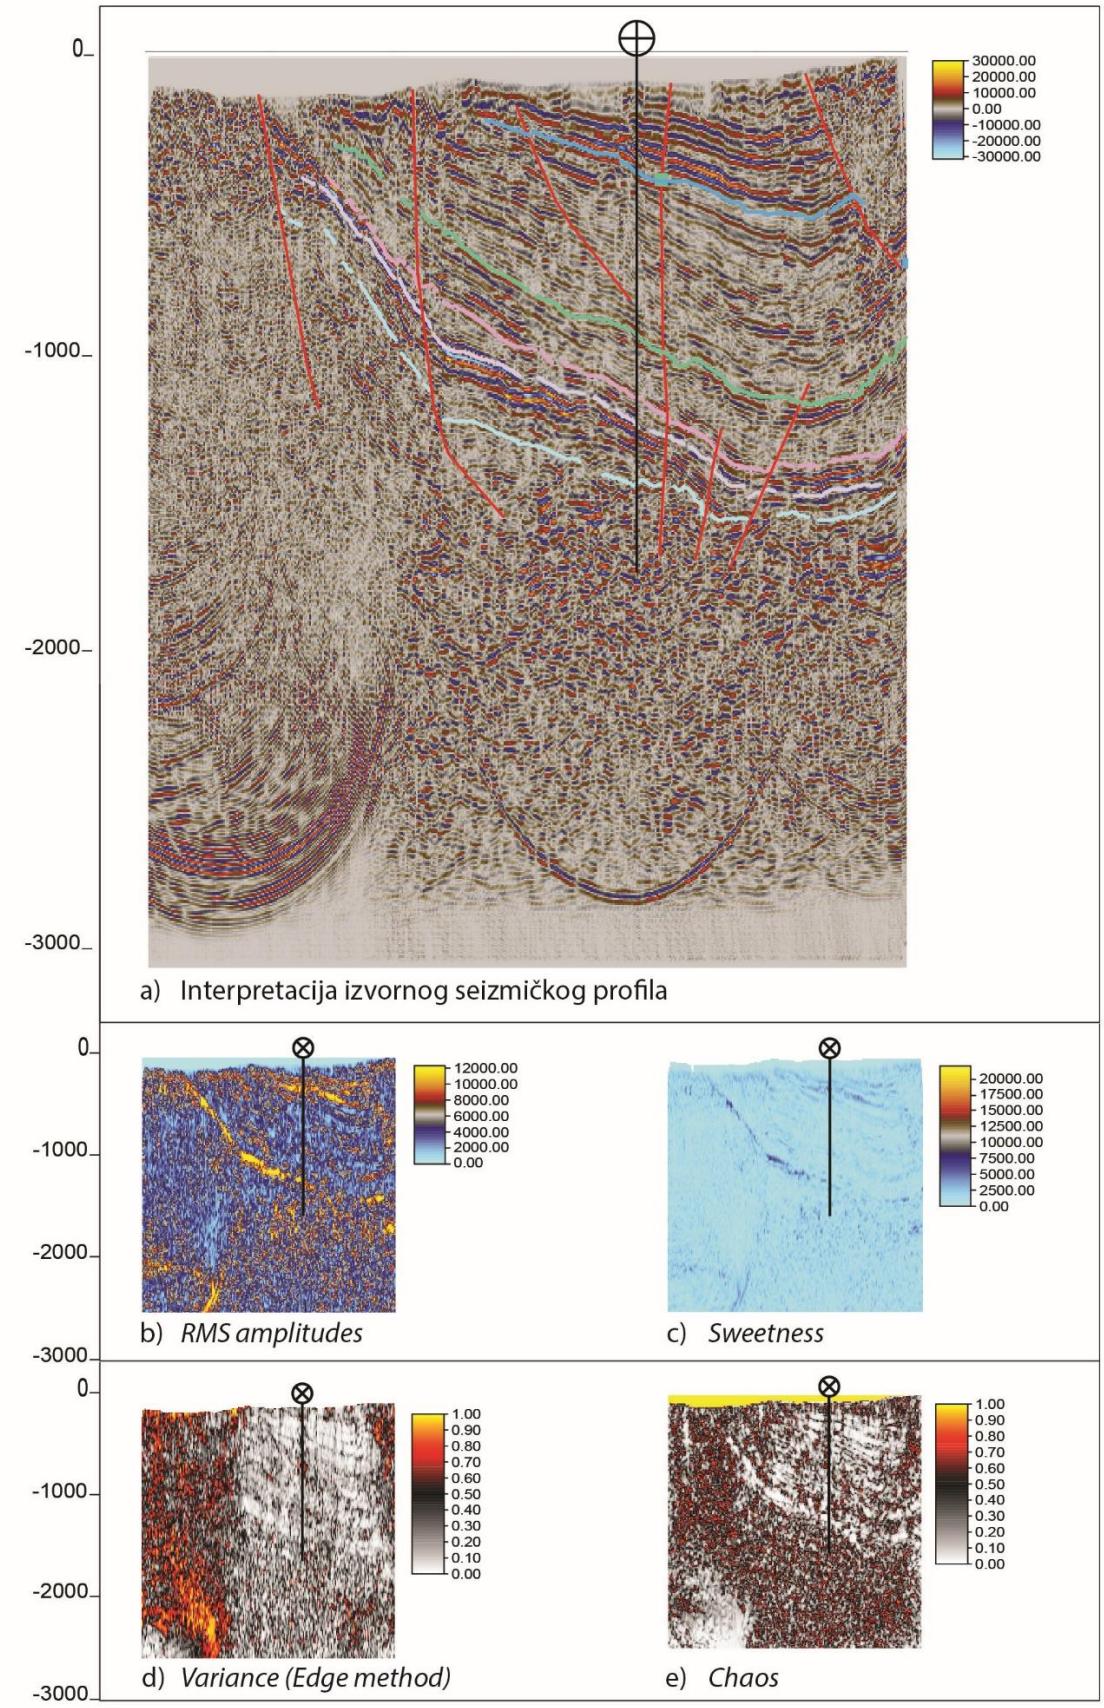
Tablica 1. Elektrokarotažni (EK) markeri ustanovljeni na području Požeške kotline i događajikoje predstavljaju (prema Lučić et al., 2001; Saftić, 2003; Velić, 2007; Malvić i Saftić, 2008)

EK markeri	Litostratigrafski smještaj	Događaj	Manifestacija na seiz. profilu
A (α')	Odvaja kvartarne i pliocenske naslage od miocenskih	Završetak termalne subsidencije i reaktivacija rasjeda uslijed tektonske inverzije (promjena u kompresijski tektonski režim)	Set refleksa visokih amplituda koji odgovaraju pjeskovitoj i laporovitoj glini blizu površine (korelacijom s bušotinskim podatcima, kao referentan je uzet središnji refleks u setu)
B (R_ρ)	Razdvaja naslage donjeg ponta (Abichi naslage) i gornjeg ponta (Rhomboidea naslage)	Usijedanje dna Panonskog bazena uslijed termalnog spuštanja te produbljavanje slatkovodnog jezerskog okoliša; povezivanje Panonskog i Dacijskog bazena (postriftni događaj)	Set refleksa viših amplituda prelazi u set refleksa niskih amplituda s positnjavanjem sedimenata na granici donjeg ponta (lapori i pješčenjaci) i gornjeg ponta (pjeskoviti i glinoviti lapori)
G (Rs5)	Razdvaja naslage donjeg panona (Croatica naslage) i gornjeg panona (Banatica naslage)	Promjena sedimentacijskih uvjeta tijekom regresivnog ciklusa	Isprekidani refleksi viših amplituda koje pripisujemo dubokovodnim

		prilikom kojeg dolazi do smanjenja saliniteta (prelazak iz morskih u brakične i slatkovodne okoliše)	laporovitim vapnencima donjeg panona prema površini prelaze u reflekse nižih amplituda koji predstavljaju glinovite i pjeskovite lapore gornjeg panona
H (Rs7)	Badenska diskordancija (odjeljuje panonske od starijih naslaga)	Tektonsko-erozijska diskordancija po plohi donjeg panona (završetak ekstenzijskog stanja stresa i početak termalnog spuštanja kore, prijelaz iz sinriftnog u postriftni događaj)	Jaki, nekontinuirani refleks u krovini sarmatskih laporovitih vapnenaca visokih amplituda; iznad tendencija smanjivanja amplitude refleksa ulaskom u glinovite i pjeskovite lapore
Tg	Razdjeljuje neogenske naslage i temeljno gorje (predneogenska podloga)	Tektonsko-erozijska diskordancija podloge bazenske ispune (sin-riftna diskordancija)	Rasipanje i prekidanje refleksa (neposredno ispod jakog refleksa klastičnih sedimentnih stijena u krovini te iznad jakog refleksa magmatskih i metamorfnih stijena u podini)

Iako se u zadnje vrijeme raspravlja o geološkom značenju EK markera (Vrbanac, 2002; Velić, 2007), zbog ograničenog fonda podataka vezanih za istraživano područje, oni su imali temeljnu ulogu pri samoj interpretaciji. Pri olakšanju interpretacije poslužili su u određenoj mjeri i seizmički atributi koji na različite načine ističu različite mjerene vrijednosti amplituda, frekvencije i faze seizmičkog vala (Slika 5.2.).

Na temelju prekida i vertikalnih pomaka refleksa, interpretirani su rasjedi, a pomoću atributa *Variance* i *Chaos* lakše su prepoznate rasjedne zone na profilima te je time smanjena višeznačnost interpretacije.



Slika 5.2. Primjeri nekoliko mogućih seizmičkih atributa prikazanih na seizmičkom profilu B iz Požeške kotline (modificirano prema Brcković et.al., 2017)

Bušotinski podatci su na samom početku dali polazišne informacije za interpretaciju seizmičkih profila. Utvrđeni stratigrafski slijed naslaga u bušotini Tek-1 (Slika 4.1.) povezan je sa seizmičkim profilima preko EK markera/repera utvrđenih na karotažnim krivuljama. Dubina EK markera/repera očitana u bušotini prebačena je u vremensko mjerilo (po zakonu brzina) nakon čega se pristupilo interpretaciji seizmičkih profila. S obzirom da se bušotina nalazi na sjecištu dvaju profila, B i D (Slika 6.1.), interpretacija horizonata započeta je od njih, a zatim se prešlo na profile koji ih sijeku te se indirektno dobila poveznica između bušotinskim podaka i ostalih profila. Za obradu profila C i F korišten je i seizmički atribut prve derivacije (pomak faze za 90°) zbog nepodudaranja s ostalim profilima.

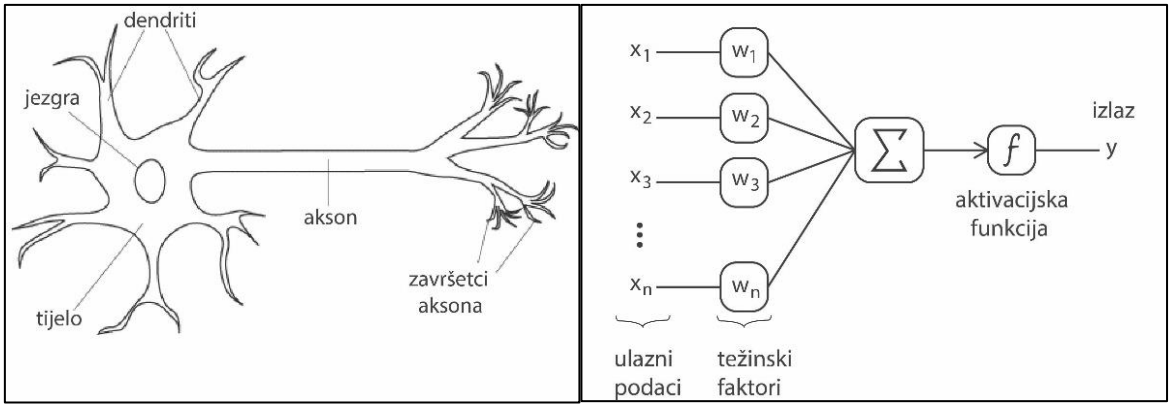
Prilikom interpretacije seizmičkih profila bilo je važno pripaziti na odabir odgovarajućih refleksa koji predstavljaju reperne slojeve te se stoga, gdje god je bilo moguće, držalo određenih pravilnosti pojavljivanja odabranih refleksa (Tablica 1.). Na temelju pojavljivanja zona rasipanja refleksa, pomaka refleksa i linija horizonata, interpretirane su rasjedne plohe.

Podatci iz seizmičkih interpretacija horizonata u vremenskom mjerilu za daljnju obradu trebali su biti prebačeni u dubinsko mjerilo. Za te potrebe, prvo je napravljen model brzina u Petrelu na temelju podataka o odnosu dvostrukoga vremena (TWT) i dubine (Z) rasprostiranja refleksijskih valova iz bušotine (engl. *checkshot*). Prema njemu su zatim načinjene transformacije interpretacija. Interpretacije seizmičkih horizonata u dubinskom mjerilu, zajedno s podatcima očitanima s OGK, dalje su korištene za kreiranje ploha horizonata. One su služile kao ulazni podatci za izradu jednostavnog modela (engl. *Simple Grid*) (Slika 5.1.). Ovim jednostavnim modelom definirani su horizonti između kojih je prostor popunjen velikim brojem prizmi, odnosno ćelija. Lakoća i brzina izrade ovakve vrste modela omogućavaju kontinuirani uvid u poboljšavanje konačnog modela u odnosu na eventualne izmjene u interpretaciji. S obzirom da model jednostavne mreže ne uzima u obzir rasjedne plohe, bilo je potrebno u dobiveni model istraživanog područja dodati i njihov utjecaj na morfologiju ploha horizonata. Najprije su interpretirani ocrti rasjeda na profilima prebačeni u plohe unutar procesa modeliranja rasjeda (engl. *Fault modeling*). Budući je interpretacija striktno ograničena seizmičkim profilima kojima se je raspolagalo, bilo je potrebno pomoću alata "*Corner Point Gridding*" produžiti rasjedne plohe kroz ostatak istraživanog područja (Slika 5.1.). Nakon utvrđivanja međuodnosa pojedinih rasjednih ploha, generiran je strukturni model (Structural Framework). Unutar tog modela, vidljiv je utjecaj pojedinih rasjeda na morfologiju ploha te je prikaz istraživanog terena

vjerodostojniji (Slika 5.1.). Jednostavnom modelu su na kraju dodijeljena litološka svojstva proizašla iz procesa predviđanja litološkog sastava umjetnim neuronskim mrežama (Slika 5.1.)

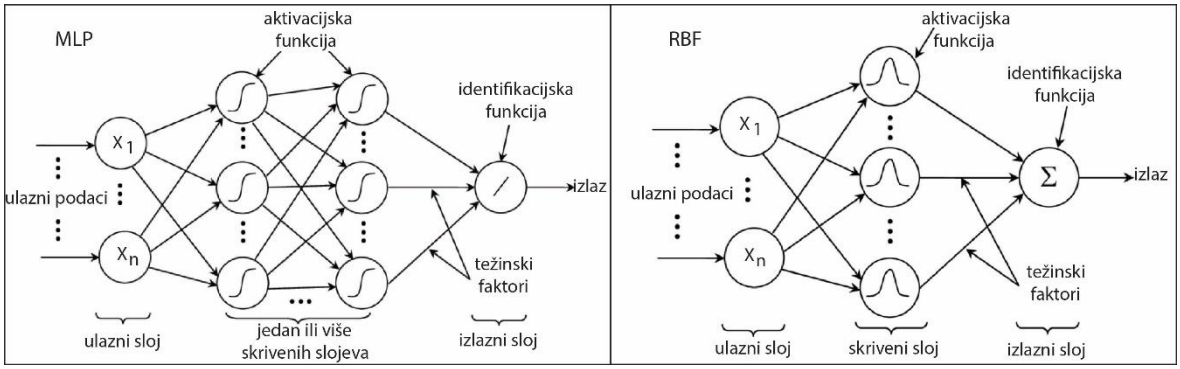
5.2. Umjetne neuronske mreže

Umjetne neuronske mreže relativno su nova metoda obrade podataka. Načelno se temelji na biološkim neuronskim vezama u živčanom sustavu živih bića, što znači da se od računalnog programa očekuje učenje na skupu dostupnih podataka te prilagođavanje novonastalim uvjetima (Slika 5.3.). Sam koncept umjetne inteligencije datira iz 40-ih godina 20. stoljeća, kada su McCulloh i Pitts (1943) predstavili prvi jednostavni model umjetnog neurona s binarnim ulaznim i izlaznim podatcima i linearnom graničnom funkcijom. Kako moć procesiranja računala tog doba nije bila dovoljna da bi ova ideja u potpunosti zaživjela, istraživanje i razvoj umjetnih neuronskih mreža pauzirani su do 90-ih godina. Od tada su neizostavan pojam na području umjetne inteligencije (Dalbelo Bašić, 2008). Njihova popularnost vidi se i u širokom spektru područja u kojima se danas koriste, najčešće za klasifikaciju i predviđanje podataka. Upravo zbog svoje moći upotrebe nejasnih i nepotpunih podataka, dobre nelinearne procjene odnosa uzoraka, korištenja velikog broja različitih parametara te stjecanja novih znanja procesom učenja iz prijašnjih iskustva, idealna su opcija pri obradi podataka u geologiji i geofizici.



Slika 5.3. Usporedba principa prijenosa i obrade podataka biološkog i umjetnog neurona

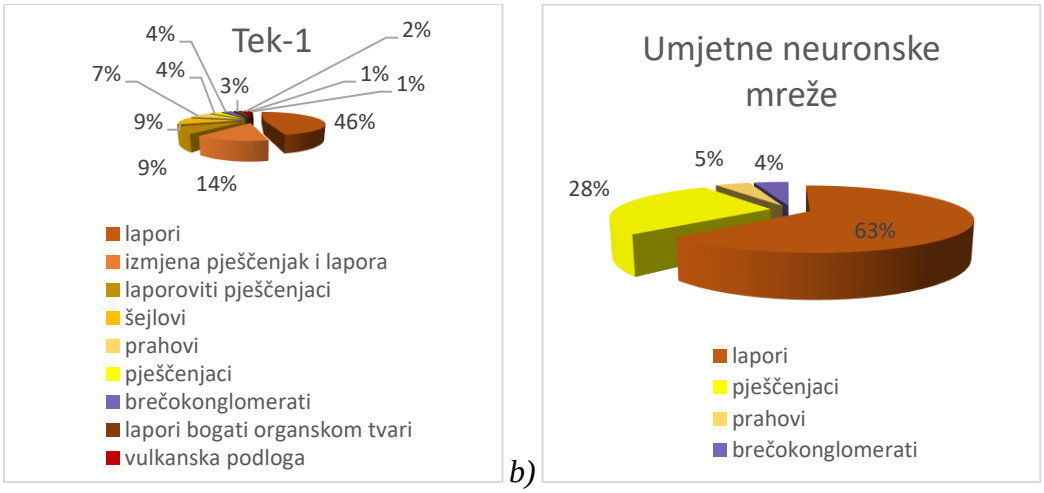
U ovom diplomskom radu umjetne neuronske mreže korištene su na 2D seizmičkim podatcima. Sa seizmičkih profila uzete su numeričke vrijednosti 12 seizmičkih atributa koje su korištene kao ulazni podatci u modelima umjetnih neuronskih mreža. Seizmički atributi koji su korišteni tom prilikom izabrani su prema kriteriju učestalosti korištenja te na temelju općeg raspoznavanja, a oni su: *Original Amplitude, Reflection Intensity, RMS Amplitude, Sweetness, Amplitude contrast, Chaos, Edge Evidence, Iso-frequency Component, RMS Iterative, RMS time gain, t*attenuation, Variance (Edge Method).* Metodom učenja, mreže su uvježbane za predviđanje već poznatog litološkog sastava sa što manjom greškom. Uvježbavanje se izvodilo u StatSoft softveru Statistica pomoću mreže s povratnim postupkom *Multiple Layer Perceptron* (MLP) te kombinacijom više različitih mreža (*Ensamble*) koje su se međusobno natjecale za željeni rezultat u svrhu postizanja što manje greške predviđanja. Razlika između različitih mreža je prvenstveno u njihovoj arhitekturi i aktivacijskim funkcijama (Slika 5.4.). Dvije najčešće korištene vrste mreža u svrhu predviđanja podataka su mreža s povratnim postupkom (*MultiLayer Perceptron* - MLP) te mreža s radijalnom funkcijom (*Radial Basis Function* - RBF). MLP se koristi za predviđanja i klasifikaciju, dok RBF najbolje rezultate daje pri klasifikaciji podataka. Obje su se, prema literaturi, u predviđanjima litološkog sastava pokazale kao pouzdane te su zato korištene i u ovom radu (Malvić, 2006; Cvetković i Velić, 2012; Hami-Eddine et al., 2015; i dugi.)



Slika 5.4. Strukture mreže a) s povratnim postupkom (MLP) s više skrivenih slojeva te najčešće sigmoidalnom aktivacijskom funkcijom i b) mreže s radijalnom funkcijom (RBF) s jednim skrivenim slojem i radijalnom aktivacijskom funkcijom (Bouzgou, 2012)

Uvježbavanje se izvodilo na podatcima izdvojenih s traga seizmičkog profila B na kojemu se nalazi bušotina kako bi seizmički i litološki podaci bili u direktnoj vezi. S obzirom na mali broj ulaznih podataka, određene su samo 4 litološke kategorije koje su potom dodane kao svojstvo ćelija jednostavnom modelu u svrhu što ispravnijeg i korektnijeg predviđanja (pješčenjaci, prahovi, lapori i brečokonglomerati) (Slika 5.5.).

Uvježbane mreže s najvećim uspjehom u predviđanju litološkog sastava, na temelju poznatih i novih podataka, korištene su na podatcima ostalih tragova s profila te kasnije i na ostalim tragovima na drugim profilima.



Slika 5.5. Usporedba grafova litoloških jedinica a) interpretiranih prema bušotinskim podatcima (karotažni dijagrami i ostaci sa sita) i b) svedenih na četiri osnovne kategorije u svrhu poboljšanja rezultata predviđanja neuronskih mreža

6. Rezultati

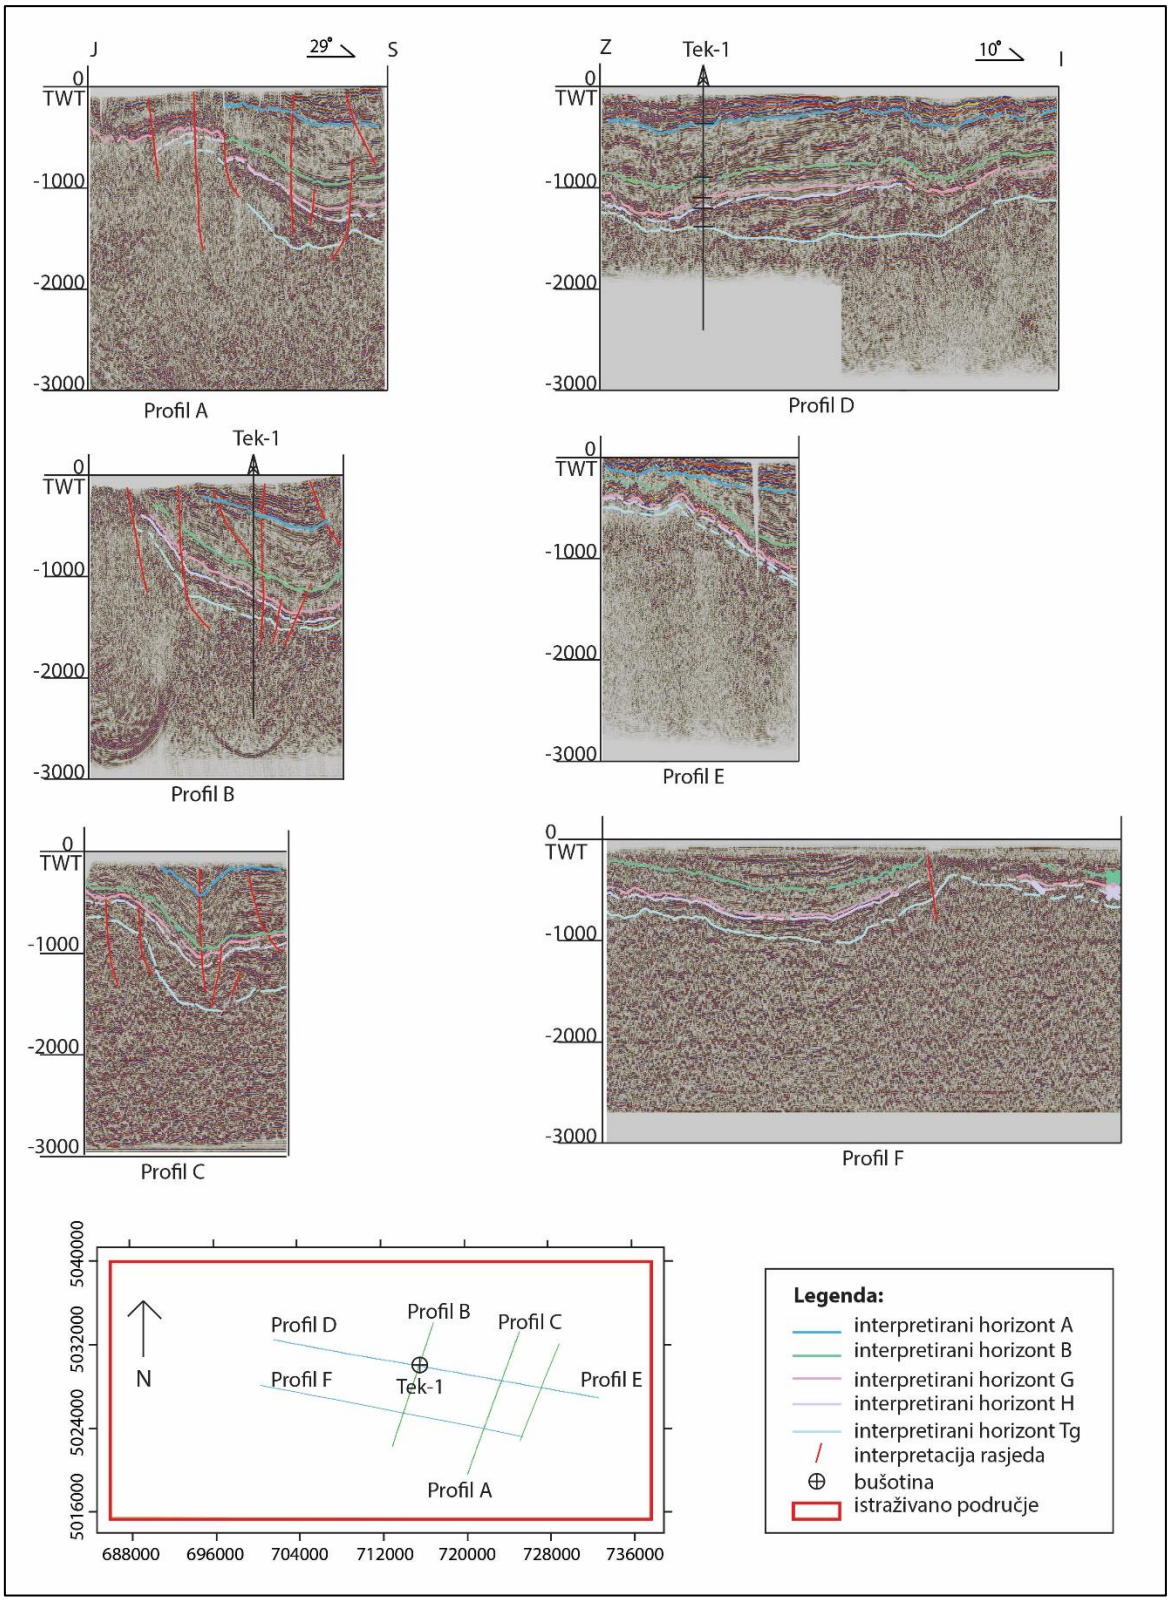
Na temelju šest seizmičkih profila i jedne istražne bušotine na području Požeške kotline, zajedno s informacijama prikupljenima s OGK istraživanog područja te dodatno dostupnom literaturom, cilj je bio interpolirati i povezati podatke te na osnovi dobivenog kreirati plohe horizonata, a potom i konstruirati modele.

6.1. Rezultati interpretacije seizmičkih profila

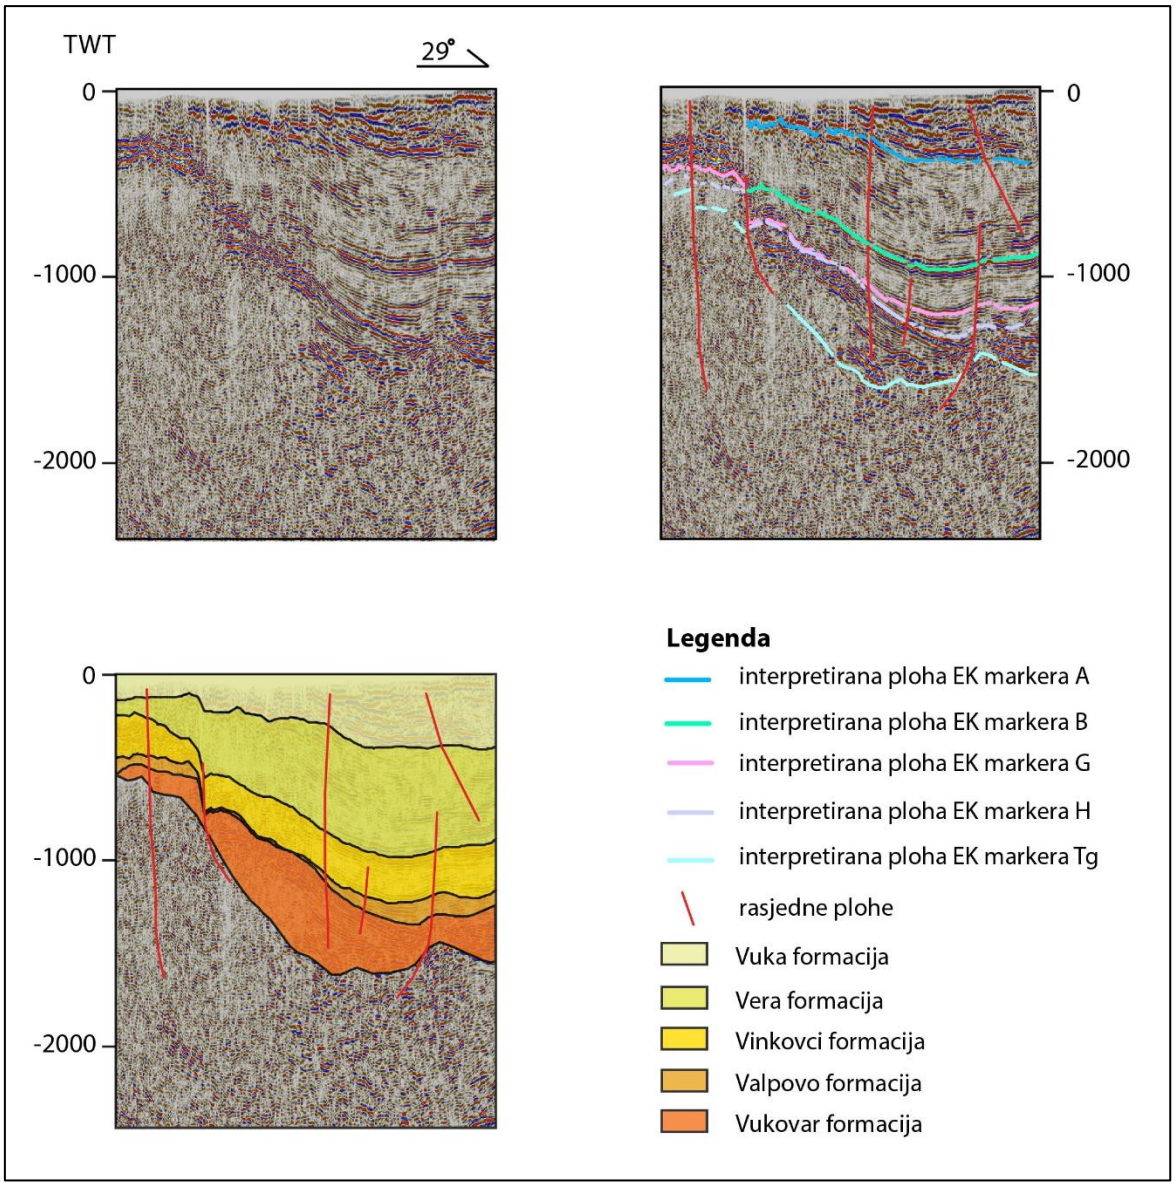
Od ukupno šest seizmičkih profila, tri su snimljena s orijentacijom sjever-jug, a tri istok-zapad (Slika 6.1.). Na interpretiranim profilima vidljivo je da bez obzira na orijentaciju, horizonti većinom prate isti trend, s iznimkom horizonta Tg u podini miocenskih naslaga. Također je i vidljivo isklinjavanje donjopanonskih naslaga omeđenih horizontom H i horizontom G (Slika 6.2.).

Na sjevernom dijelu profila, horizonti zaliježu na najvećim dubinama, neposredno uz sjeverni rub kotline. Horizonti Tg i A, koji omeđuju miocenski slijed naslaga, ustanovljeni su na dubinama do -1500 ms za Tg i do -500 ms za A. Idući prema jugu kotline, horizonti se sve više približavaju površini te se Tg horizont nalazi na oko 500 ms, dok A horizont na polovini svih profila izlazi na površinu, tj. značajne debljine pliocenskih i pleistocenskih naslaga izostaju. Prepoznati su reversni rasjedi na samom sjevernom i južnom rubu. S obzirom da su oni bili reaktivirani tijekom kvartara, njihov karakter uklapa se u kompresijski tektonski sklop toga doba. Ostali normalni rasjedi pružanja su I-Z unutar kotline te su relativno lako bili raspoznati Oni su po svojoj orijentaciji paralelni do subparalelni rasjedima na samom obodu kotline.

Profili orijentirani Z-I prikazuju jednoliko i ujednačeno rasprostiranje horizonata kroz kotlinu. Primjećuje se kako ploha horizonta Tg na profilu koji je postavljen sjevernije zaliježe puno dublje u odnosu na južniji profil, što je u skladu sa zapažanjima na njima okomitim profilima. Postavljen je jedan rasjed pružanja SI-JZ, znatno manjih dimenzija od prehodno definiranih. S obzirom da je interpretiran na temelju jednog seizmičkog profila, na području gdje se predneogenska podloga nalazi već blizu površine, o samom karakteru rasjeda dalo bi se diskutirati. Najvjerojatnije je nastao tijekom miocena te je moguće došlo do vertikalnog pomaka tijekom termalne subsidencije krajem miocena ili je reaktiviran u kvartaru.



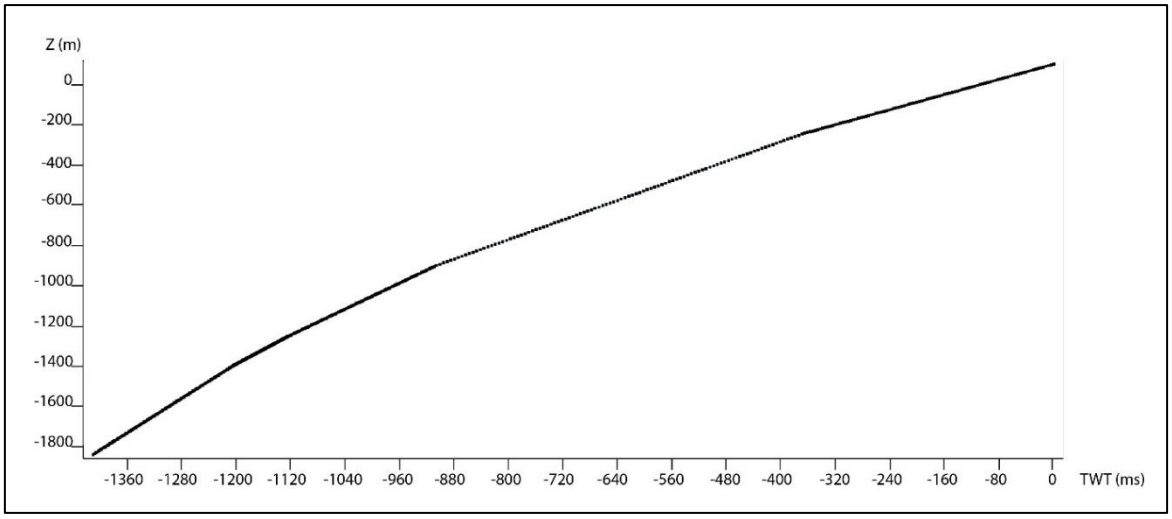
Slika 6.1. Interpretirani seizmički profili na području Požeške kotline



Slika 6.2. Dio interpretiranog seizmičkog profila A s vidljivo rasjedanom predneogenskom podlogom koju od mlađih naslaga odvaja horizont Tg; Zone omeđene plohama repernih horizonata predstavljaju izdvojene formacije iz jednostavnog modela – nema dislociranja horizonata po plohama rasjeda

6.2. Konstrukcija karata po reperima

Nakon interpretacije repernih horizonata sa seizmičkih profila, uspostavljen je model brzina prema podatcima iz bušotine. Prema modelu brzina, seizmičke interpretacije su transformirane iz vremenskog (TWT) u dubinsko (m) mjerilo (Slika 6.3.).



Slika 6.3. Prikaz funkcije modela brzina po kojoj je transformirana seizmička interpretacija (TWT – Z)

Potom su točke koje su izvučene iz tih interpretacija u dubinskom mjerilu poslužile kao ulazni podaci za izradu ploha horizonata. Pomoću generiranih ploha konstruiran je jednostavni model područja. Rasjedi interpretirani na seizmičkim profilima u vremenskom mjerilu također su prema zakonu brzina prebačeni u rasjedne poligone. Iz horizonata jednostavnog modela postupkom „*Horizon modeling*“ te iz poligona rasjeda procesom „*Fault modeling*“ izvučene su strukturne plohe prema kojima je načinjen model rasjeda (*Structural Framework*). Na temelju strukturnog modela su stvorene strukturne karte pojedinih horizonata. Valja također napomenuti kako su plohe horizonata te rasjedne plohe modelirane iz izrazito malog broja pouzdanih podataka, što znači da u interpoliranom području postoji stanovita doza nesigurnosti. S obzirom na rezultate vidljive na kartama neke strukture mogu izgledati nešto drugačije od predstavljenog, što je očekivano kod interpretacije podzemlja bez seizmičkih volumena. Uz pomoć prikupljenih podataka o istraživanom području na temelju objavljene literature, podzemlje Požeške kotline se pokušalo prikazati što vjerodostojnije.

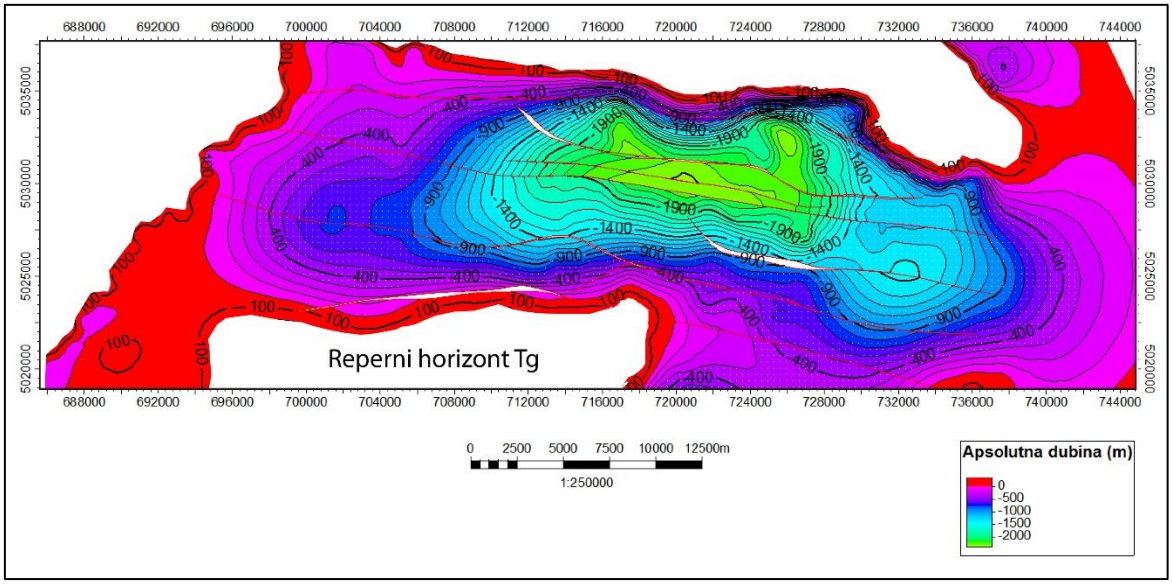
Primarni cilj ovoga rada bio je prikazati litološki sastav neogenske ispune Požeške kotline uz pomoć dubinskog modela koji je ovisan o strukturno-tektonskoj evoluciji same kotline.

Rubni dijelovi istraživanog područja koji djelomice zahvaćaju Slavonske planine (dijelovi ploha iznad površine) stoga nisu detaljno razrađivani.

Karta po repernom horizontu Tg

Ploha repernog horizonta Tg, koja predstavlja diskordanciju između podloge neogena i starijih stijena, izrazito je tektonizirana (Slika 6.4.).

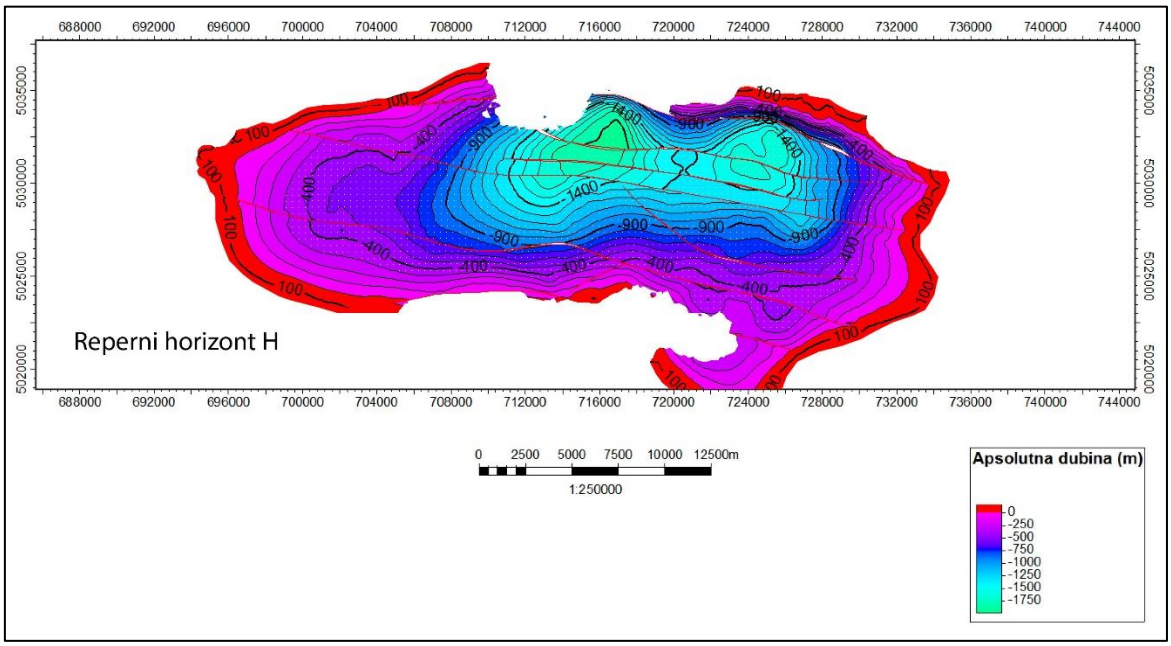
Vrijednosti izolinija apsolutne dubine (m) na strukturnoj karti kreću se do -2500 m, u samom središtu kotline. U središtu se nalazi izdužena prostrana tektonska graba koja se proteže na oko 3,5 km u smjeru istok-zapad i približno 1,5 km u smjeru sjever-jug. Ona je na istoku i zapadu odijeljena manjim prijevojima od dviju tektonski pomaknutih sinformnih strukturi znatno manjih dimenzija. Graba u svim smjerovima prema rubovima prelazi u rasjedane monokline, sve do izlaska plohe na površinu, a gustoće izolinija, ukazuju na strme nagibe na rubovima kotline. (Slika 6.4.). Strmi nagibi osobito su uočljivi na sjevernom i južnom rasjednom kontaktu kotline s gorjem.



Slika 6.4. Strukturna karta plohe repernog sloja Tg

Karta po repernom horizontu H (Rs7)

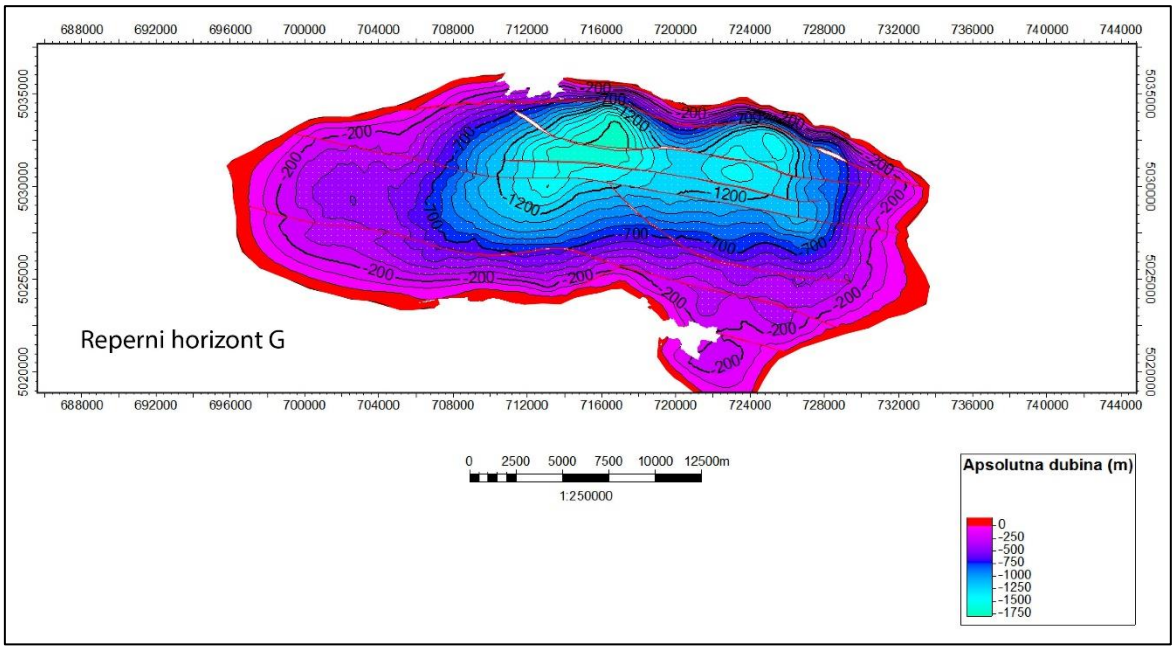
Izolinije na strukturnoj karti plohe H gušće su u odnosu na ostale karte, a najdublje vrijednosti su do -1750 m. Vidljivo je da je struktura grabe nasljeđena na repernom horizontu podine panona (H) s tendencijom razdvajanja na dvije manje sinklinale (Slika 6.5.).



Slika 6.5. Strukturna karta plohe repernog sloja H

Karta po repernom horizontu G (Rs5)

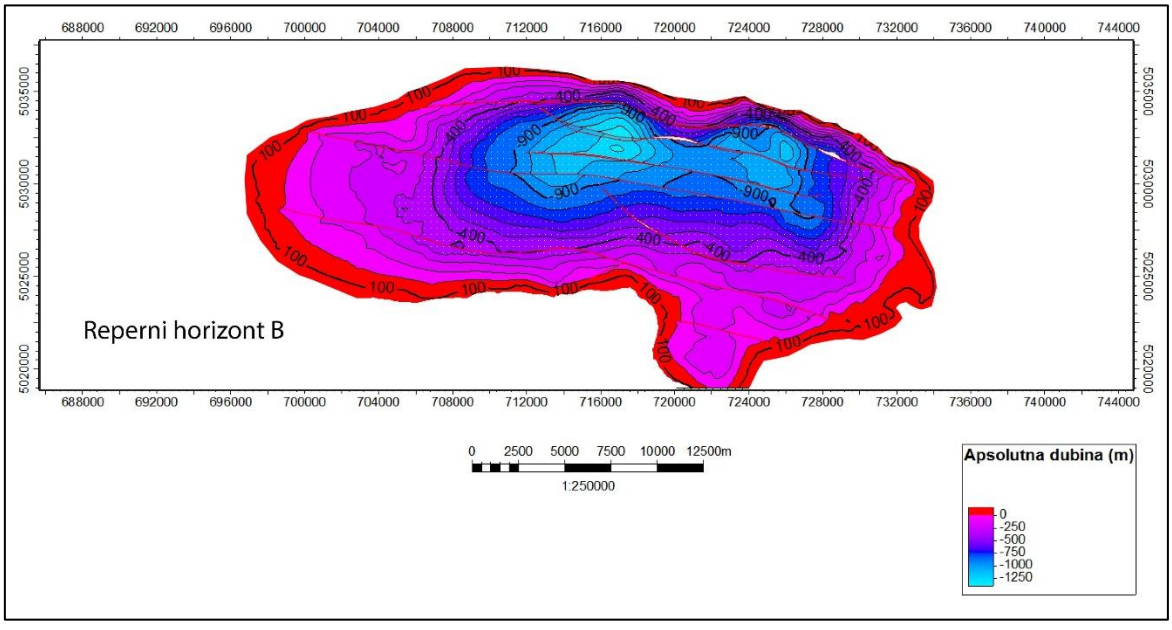
Opaža se nasljeđivanje dominantne strukture tektonske grabe, te se i dalje, iako neznatno u odnosu na prvi dublji horizont H, nastavlja trend njenog oplićavanja (Slika 6.6.). Najveća dubina horizonta od nekih -1750 m uočava se u središnjem dijelu, dok je uz rubove kotline horizont na dubini od 0 m, odnosno smješten je plitko pod površinom.



Slika 6.6. Strukturna karta plohe repernog sloja G

Karta po repernom horizontu B (Rfi)

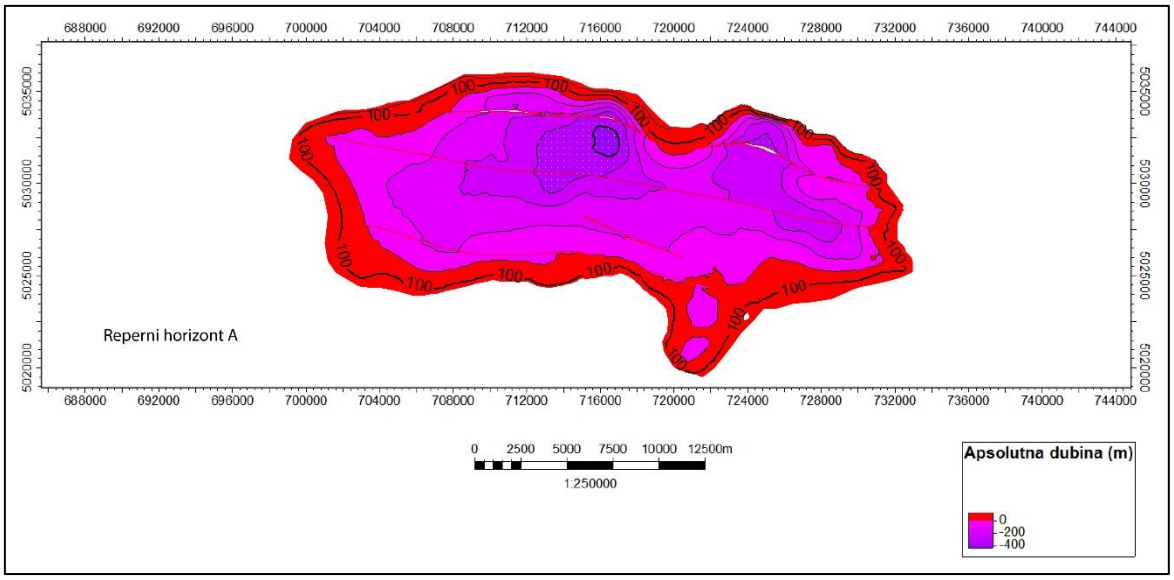
Dominantna struktura tektonske grabe i dalje se može vidjeti na strukturnoj karti repernog horizonta B (Slika 6.7.). Dimenzijom je znatno manja nego na plohama dubljih horizonata. Zapaža se i nasljeđivanje plitke sinklinalne strukture koja se nastavlja prema jugoistočnom rubu grabe.



Slika 6.7. Strukturna karta plohe repernog sloja B

Karta po repernom horizontu A (α')

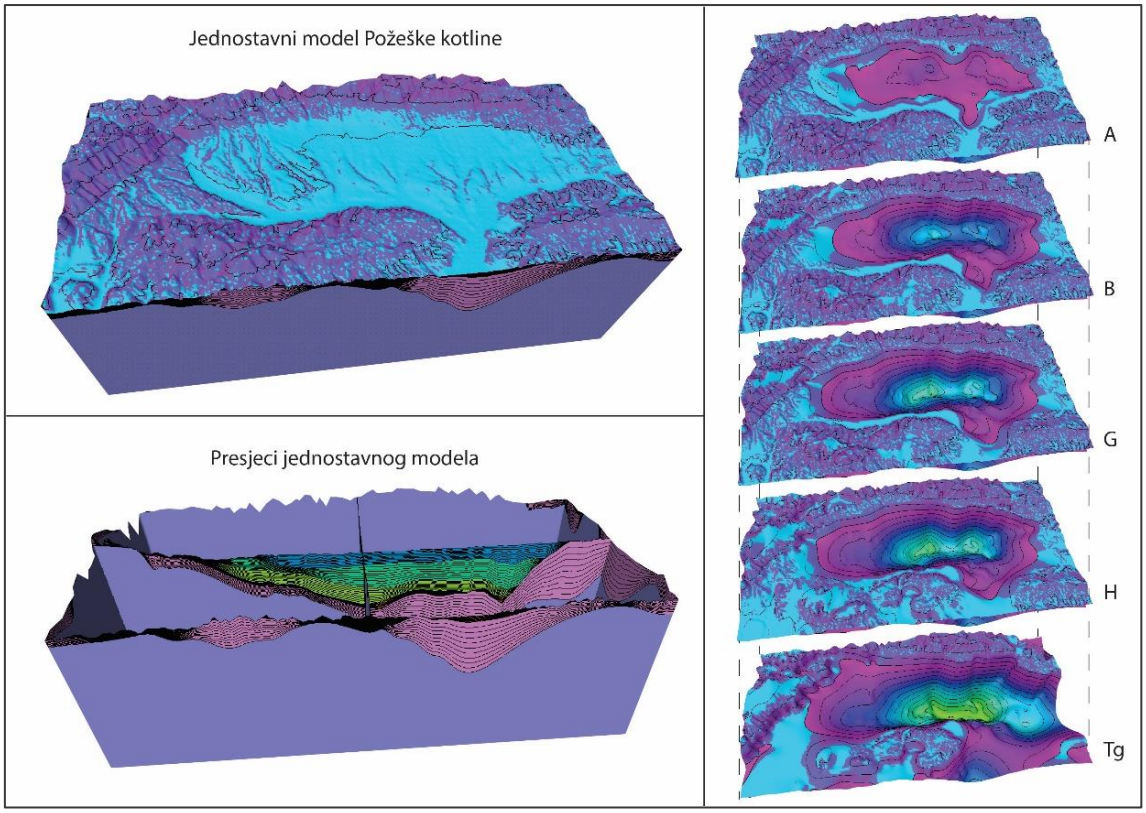
Oplićavanje taložnog bazena može se pratiti kroz rasprostiranje naslaga na strukturnim kartama. S obzirom da se horizont A nalazi plitko pod površinom, vrijednosti izolinija znatno su manje nego na kartama prijašnjih horizonata i kreću se do -400 m (Slika 6.8.). Također je vidljiv i utjecaj manjeg broja rasjeda na ovaj reperni horizont. Na jugoistočnom dijelu se vidi rasjedanje koje nije uočeno na plohama starijih horizonanta.



Slika 6.8. Strukturna karta plohe repernog sloja A

6.3. Jednostavni model istraživanog područja (Simple Grid)

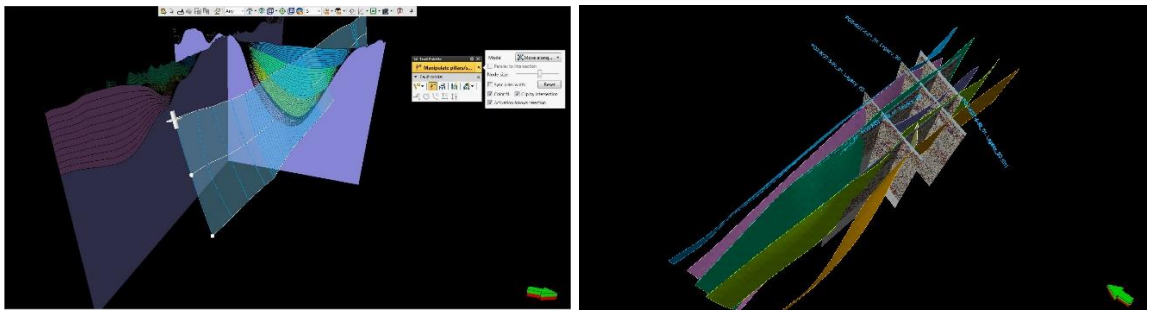
Na temelju ranije generiranih ploha horizonata napravljen je jednostavni model istraživanog područja u dubinskom mjerilu (m). Sastavljen je od ukupno sedam ploha, od kojih je pet ploha horizonata, jedna ploha na -3000 m kao bazna ploha, te morfologija terena kao vršna ploha modela. Za smještaj bazne plohe uzeta je vrijednost -3000 m koja je proizvoljno odabrana na dubini otprilike 500 m dublje od najdublje modeliranog horizonta Tg. Iako u jednostavnom modelu nedostaju rasjedi, on pruža vizualni dojam podzemlja Požeške kotline i oboda planina koje je okružuju (Slika 6.9.). Korištenjem presjeka modela uočene su i ispravljene anomalije na plohama horizonata koje su većinski bile pozicionirane na mjestima između interpretiranih seizmičkih profila (interpolirano područje) te osobito prema rubnim dijelovima istraživanog terena. Odnosi naslaga dobiveni modeliranjem iz seizmičkih horizonta uspoređeni su s bušotinskim podatcima i literaturom. Korektnost geoloških odnosa među njima, posebice s obzirom na superpoziciju. Vidljive su strukture središnje sinklinale te dvije manje na njenom zapadnom i južnom rubu. Naposlijetku su iz modela preuzete strukturirane plohe na temelju kojih se, zajedno s rasjednim plohama, generirao model s rasjedima.



Slika 6.9. Prikaz jednostavnog modela Požeške kotline i ploha repernih horizonata

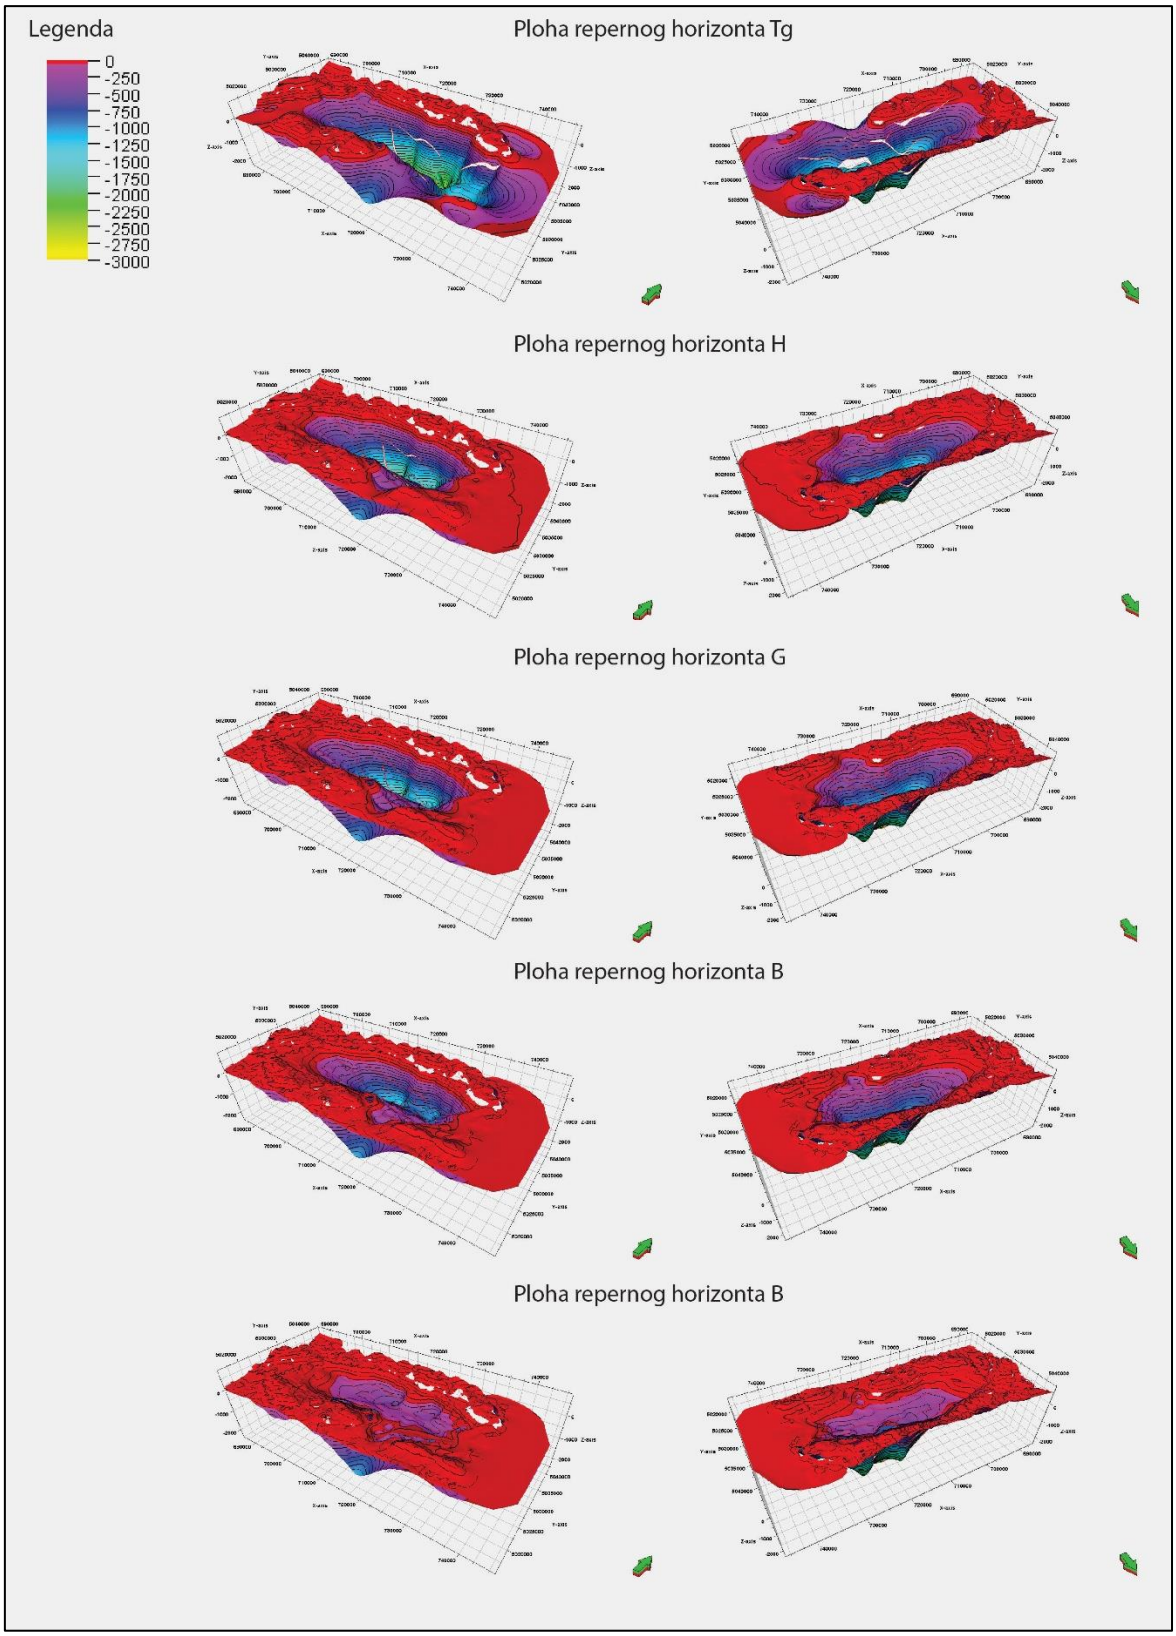
6.4. Strukturni model s rasjedima

Za modeliranje horizonata unutar strukturnog modela s rasjedima kao osnovica su korištene plohe horizonata iz jednostavnog modela. Unutar strukturnog modela dodane su plohe rasjeda koje su prvo procesom *Corner Point Gridding* ekstrapolirane kroz ostatak istraživanog područja koji nije obuhvaćen seizmičkim profilima. Kako bi se rasjedne plohe korektno ekstrapolirale na tim područjima, korišteni su presjecima jednostavnog modela. U *Grid playeru* su presjeci pomicani po x i y osi, kako bi se našao presjek na kojem je najuočljivije moguće pružanje paraklaze kroz naslage (Slika 6.10.). Rasjedne plohe su potom dodane u strukturni model gdje su definirani njihovi međuodnosi (glavni i sporedni rasjedi).



Slika 6.10. Modeliranje i ekstrapolacija rasjeda u Petrelu postupkom Corner Point Gridding (lijevo) te prikaz ploha svih interpretiranih rasjeda na temelju seizmičkih profila (desno)

Na plohama reprenih horizonata unutar modela s rasjedima, prema velikom broju rasjeda s većim pomacima po paraklazama, vidljivo je da je sve do gornjeg miocena tektonska aktivnost bila intenzivna. U gornjem miocenu se na svakom mlađem horizontu vidi sve manji utjecaj rasjeda odnosno pomaci nisu toliko izraženi, iako se oni protežu cijelim miocenskim slijedom naslaga, a potom i kroz pliocenske i pleistocenske naslage (Slika 6.11.). Treba uzeti u obzir da se na rasjednom modelu vide većinski rasjedi pružanja Z–I čiji postanak je karakterističan za uvjete koji su vladali prije i za vrijeme ranog miocena. Već početkom srednjeg miocena, promjena stanja stresa pogoduje rajedanju pružanja SSI–JJZ. Rasjedi toga pružanja nisu zastupljeni u modelu iz ranije navedenih razloga, vezanih za količinu postojećih podataka na kojima se temelji interpretacija, stoga treba pažljivo pristupiti donošenju zaključaka.

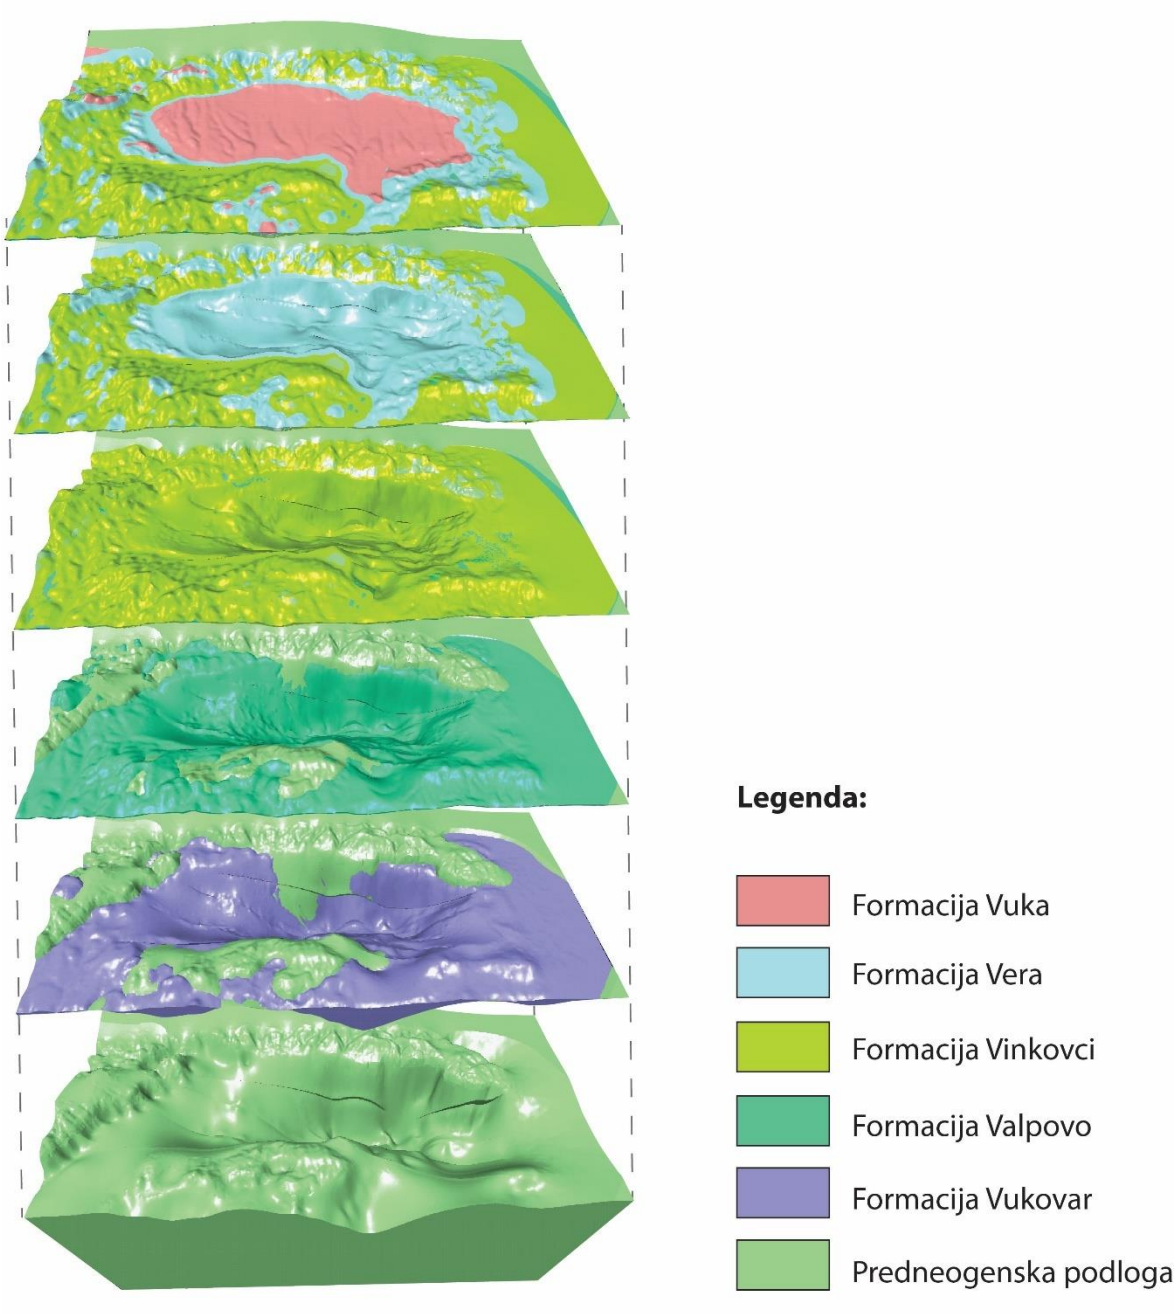


Slika 6.11. 3D prikaz ploha repernih horizonata prema modelu s rasjedima (zelena strelica označava smjer sjevera)

Zone strukturnog modela su 3D tijela koja zapravo predstavljaju debljinu neogenskih formacija Požeške kotline (Slika 6.12.). Predneogenska podloga Požeške kotline je i prije neogena bila pod velikim tektonskim utjecajem. Otvaranjem tektonske grabe stvoren je akomodacijski prostor u kojem su taloženi mlađi sedimenti. Velika rasprostranjenost formacije Vukovar unutar cijele kotline te na obodima slavonskih planina podudara se s opisanom tektonostratigrafskom slikom područja između otnanga i sarmata (Slika 6.12.). Iz modela je vidljivo da je donos sedimenata bio s dvije strane kotline, sjeverozapadne i sjeveroistočne. U otnangu, kada je započela sedimentacija u kotlini, vladali su jezerski uvjeti uz riječne okoliše prepletenih rijeka. Produbljivanjem bazena te marinskom transgresijom koja je uslijedila u srednjem badenu taloženje se počinje odvijati i po obroncima planina, a tijekom potonje transgresije su čak i planinski nizovi potopljeni što je omogućilo sedimentaciju i na nekad izdignutim vrhovima na južnom i jugozapadnom dijelu bazena. Formacija Valpovo ima gotovo identično rasprostiranje kao i formacija Vukovar, a naslage su taložene izravno na starije (Slika 6.12.). Prelaskom u regresivne uvjete u panonu te istovremenim prijelazom iz marinskih u jezerske okoliše, taloženje se konkordantno nastavlja pa je vidljivo i sve veće prekrivanje predneogenske podloge novodonešenim sedimentima. Formacija Vinkovci obuhvaća sedimente taložene tijekom mlađeg panona i starijeg ponta (Slika 6.12.). Izoliranjem Panonskog bazena te produbljavanjem jezerskih okoliša uslijed termalne subsidencije, panonske i pontske naslage se nastavljaju konkordantno taložiti pokrivajući sve veću površinu predneogenske podloge na prikazanom području Požeške kotline. Vidljivi su erodirani dijelovi bez naslaga po uzvišenjima i obroncima gdje je erozijski utjecaj bio jači od sedimentacijskog. Daljnje produbljivanje bazena i izdizanje okolnih dijelova omogućilo je nastavak konkordantnog taloženja gornjopontskih naslaga kao dio formacije Vera (Slika 6.12.). Nastavkom izdizanja pojedinih dijelova taložnog prostora počinju se mijenjati sedimentacijski uvjeti iz jezerskih u riječne. Sve većom izolacijom Panonskog jezera smanjuje se količina donosa sedimenata, a sav taloženi materijal dolazi iz okolnog područja odnosno iz erodiranih najviše izdignutih te rubnih dijelova bazena. Iz priloženog je vidljivo da se glavnina sedimentacije odvija u produbljenoj bazenskoj udolini. Formacija Vuka obuhvaća pliocenske i pleistocenske naslage (Slika 6.12.). Pod utjecajem novonastalog kompresijskog stresa pretpostavljena je reaktivacija već postojećih rasjeda. Pojačavaju se vertikalni pokreti stijenskih masa te se dodatno povećava utjecaj erozije. Transport

sedimenata riječnim putem počinje prevladavati uz pretpostavljenu sedimentaciju u plitkom jezerskom i kasnije močvarnom okolišu.

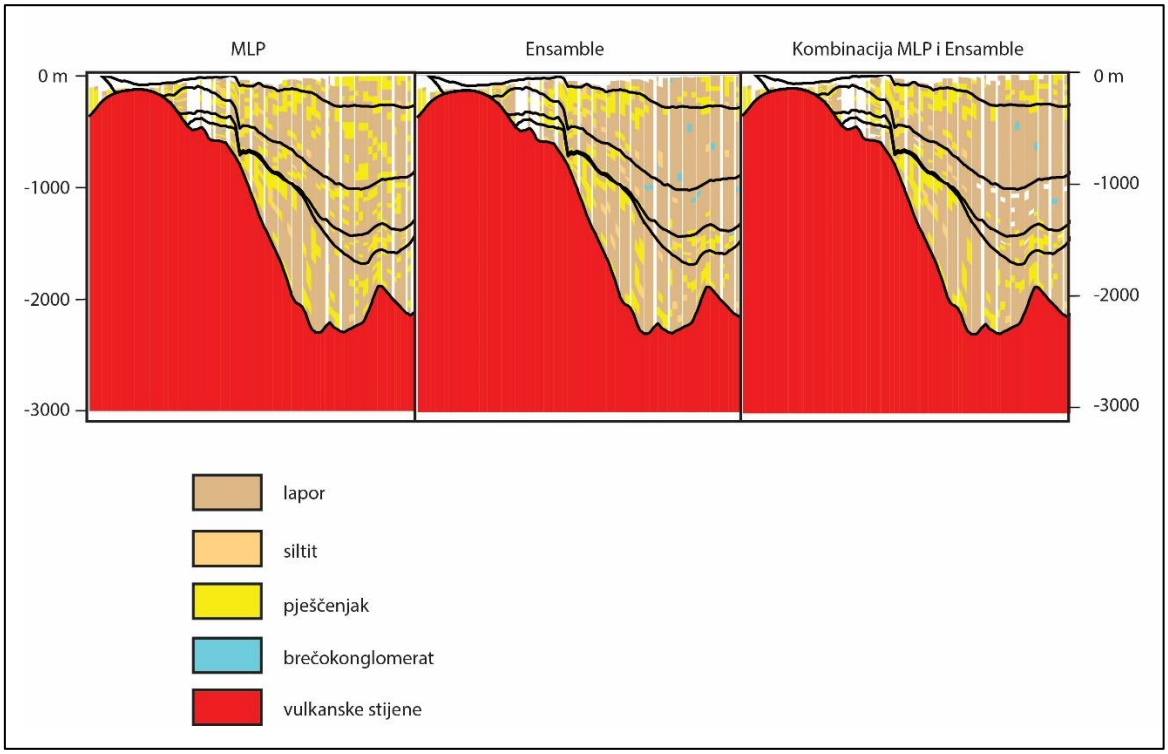
S obzirom na glavninu podataka koncentriranih u samom središtu Požeške kotline, modeliranje rubnih dijelova modela rezultira nesigurnošću zbog čega nisu detaljno razrađeni u ovom radu.



Slika 6.12. Prikaz zona strukturnog modela Požeške kotline

6.5. Predviđanje litološkog sastava umjetnim neuronskim mrežama

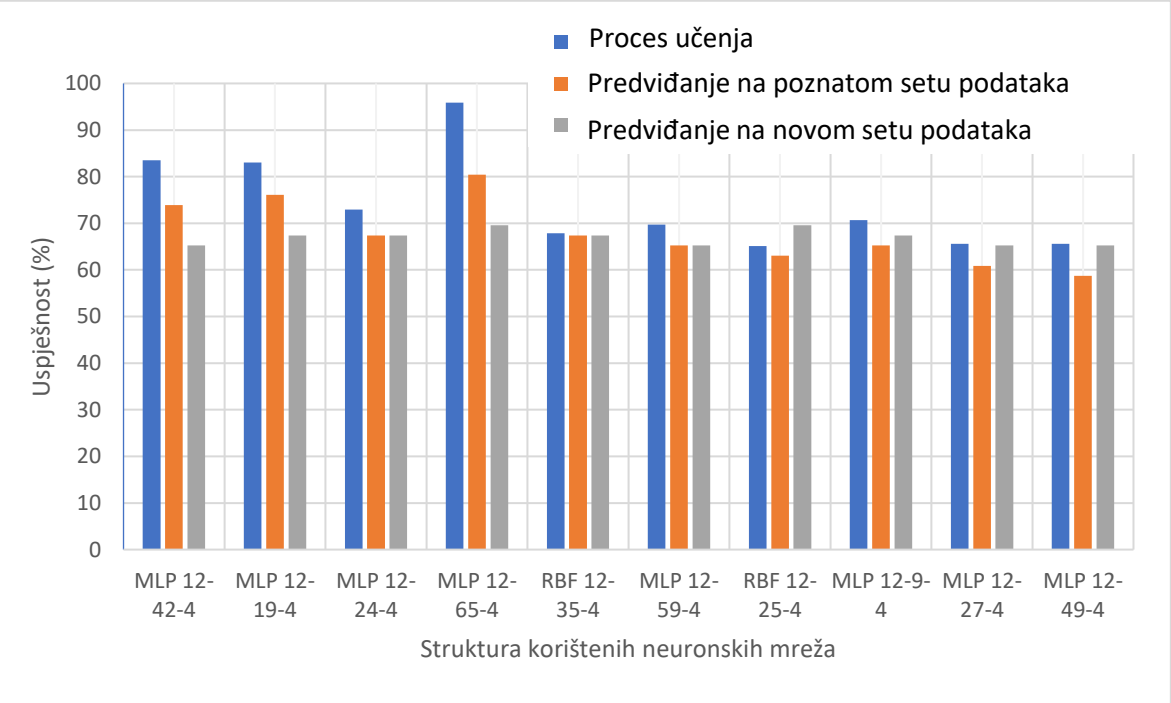
Umjetna neuronska mreža uvježbana je na setu podataka dobivenih sa seizmičkih profila i iz jedne bušotine u svrhu predviđanja litološkog sastava duž profila. Predviđanja su provedena na svakom desetom tragu profila u horizontalnom mjerilu te svakih četiri ms u vertikalnom. Dobiveni rezultati predviđanja se sastoje od tri procjene litološkog sastava za svaki profil i to zato što je za prvo predviđanje upotrijebljena mreža s povratnim postupkom (MLP), za drugo kombinacija deset različitih mreža (Ensamble) čije se karakteristike mogu vidjeti na slici 6.14., a treće predviđanje je zapravo kombinacija prva dva (Slika 6.13.).



Slika 6.13. Predviđanja litologije dobivena neuronskim mrežama preklopljena preko seizmičkog profila A

Iz priloženog je vidljivo da su sve tri mreže većinski predvidjele lapor u neogenskim naslagama. Ako se osvrnemo na podatke dobivene iz bušotine, vidimo da je ta pretpostavka sasvim ispravna s obzirom da sve formacije u sebi sadrže većinom lapore (Slika 4.1.; Slika 5.5.). Razlika u predviđanjima postaje uočljivija kada govorimo o ostalim litološkim jedinicama koje se nalaze unutar formacija.

Mreža s povratnim postupkom (MLP) predvidjela je nešto veću zastupljenost pješčenjaka, što je u skladu s litologijom iz bušotine, no geološki je upitna prikazana jednolika rasprostranjenost unutar svih formacija. Vrlo lako je uočljivo da je MLP imala problema s predviđanjem facijesa brečokonglomerata te ih većinom ili nije uopće predviđala ili su pak predviđeni u vrlo maloj mjeri. Zanimljiv rezultat je činjenica da unatoč slabom predviđanju ovog facijesa, u nekoliko navrata (četiri od šest profila) predviđen je unutar formacije unutar koje bi se na temelju bušotinskih podataka očekivao nalaziti, iako se u isto vrijeme pojavio i u drugim naslagama. Također, predviđena pojava brečokonglomerata je vrlo izolirana pojava koju se ne može lateralno popratiti na profilima. Na temelju MLP predviđanja vidljivo je kako je pojavljivanje facijesa siltita predviđeno više-manje u svim formacijama u vrlo maloj, ali podjednakoj mjeri.

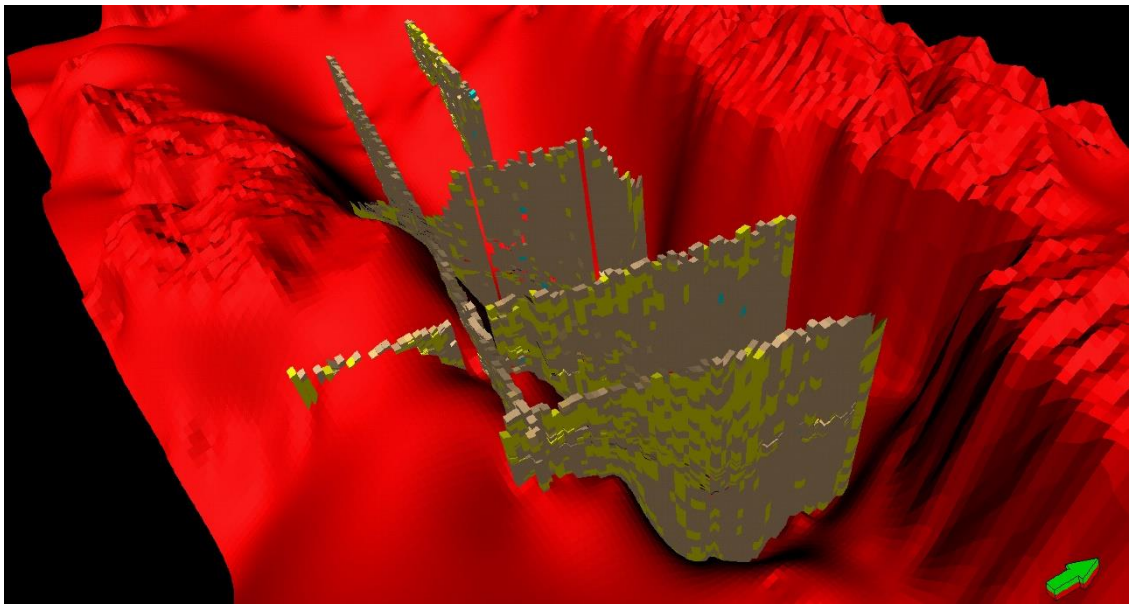


Slika 6.14. Prikaz uspješnosti predviđanja litološkog sastava pojedinih neuronskih mreža unutar korištene kombinacije mreža (Ensamble); prvi broj u nazivlju mreže predstavlja ulazni sloj, drugi skrivene slojeve, a treći izlazne slojeve

Kombinacija više različitih mreža (Ensamble) predvidjela je pješčenjake u manjem opsegu. Koncentracija predviđenih pješčenjaka povećava se prema mlađim naslagama te ih je najviše unutar Vera i Vuka formacija. Ta činjenica ide u prilog Ensamble slučaju

predviđanja. Ipak, pješčenjaci predviđeni u najstarijoj Vukovar formaciji ipak pokazuju određenu geološku nekorektnost u predviđanju s obzirom da se prema stupu bušotine Tek-1 ispod laporovito-pješčenjačkog kompleksa gornjeg miocena nalaze breče na koje naliježu laporoviti vapnenci (Slika 4.1.). Na račun slabijeg predviđanja pješčenjaka, u većoj su mjeri predviđeni facijesi siltita i brečokonglomerata. Siltit je u većoj mjeri predviđan unutar mlađih naslaga, dok u najstarijoj Vukovar formaciji gotovo da uopće nije predviđan. Ova raspodjela odgovara nabušenim naslagama. Što se tiče facijesa brečokonglomerata, kombinacija neuronskih mreža ga je predvidjela u više navrata, ali na ne posve logičan način. Iako se na polovici profila doista nalazi u krovini predneogenskih naslaga unutar formacije Vukovar, što bi bilo za očekivati za ovaj facijes s obzirom na taložni okoliš i tektoniku, također je na većini profila predviđen i u ostalim formacijama. Rezultat slabog predviđanja ovog facijesa je vrlo mali broj slučajeva na temelju kojeg bi ga mreža mogla raspoznati.

Na temelju prikazanog, vidljivo je da svaki tip mreže ima svoje prednosti i mane u rezultatima predviđanja te je stoga načinjen i treći tip predviđanja litologije koji zapravo obuhvaća oba tipa mreža u sebi. Za predviđanje litološkog sastava u tom slučaju uzet je podatak za one točke na profilu koje su bile istovjetno predviđene u prethodna dva slučaja. Iz takvog prikaza litološkog sastava vidljivo je kako se rezultatikoje je dala mreža s povratnim postupkom u velikoj mjeri poklapaju s rezultatima dobivenima kombinacijom više različitih mreža (Slika 6.13. i 6.15.).



Slika 6.15. Prikaz procjene litološkog sastava kombinacijom dvaju različitih postupaka koja je prebačena u litološka svojstva jednostavnog modela Požeške kotline radi bolje vizualizacije

7. Zaključak

Strukturno modeliranje istraživanog područja na temelju seizmičkih i bušotinskih podataka, uz pomoć ranije objavljenih istraživanja, dalo je zadovoljavajuće konačne rezultate. Na temelju malog fonda podataka korištenih za obradu i analizu, dobiven je model Požeške kotline koji se u većoj mjeri podudara u sa saznanjima iz do sada objavljenih radova. Prikazana tektonska i sedimentacijska evolucija ispune bazena (strukturne zone) prati tektonostratigrafske događaje opisane u literaturi vezanoj za postanak slavonskih planina te općenito hrvatskog dijela Panonskog bazena. Rasjedi s pružanjem paralelnim izduženoj osi kotline su bili jasnije izraženi na seizmičkim profilima pa je moguće da su u tom smjeru ili rasjedne zone većih dimenzija ili su lakše prepoznatljivi zbog svog karaktera i vertikalnih pomaka po paraklazama. Na temelju ranijih istraživanja JZ dijela Panonskog bazena i objavljenih radova (Poglavlje 3) utvrđeni su rasjedi s pomakom po pružanju okomito na os izduženja kotline. Prilikom interpretacije rasjeda, njihovo pružanje nije moglo biti određeno s velikom sigurnošću djelomice zbog rijetke mreže profila, a djelomice i zbog lošije rezolucije pojedinih profila. Zbog toga rasjedi S(SI)–J(JZ) u ovom radu nisu zastupljeni.

Predviđanje litološkog sastava duž seizmičkih profila pomoću statističke analize podataka umjetnim neuronskim mrežama pokazalo se također uspješnim. Prvenstveno treba napomenuti da podatci iz jedne bušotine nisu dovoljni za korelaciju naslaga na širem području. Tu se primjena umjetnih neuronskih mreža pokazala kao izvrsna i vrlo pristupačna alternativa. Pojam „predviđanje“ zvuči vrlo nesigurno, no predviđanja dobivena ovom statističkom analizom temeljena su na stvarnim podatcima i matematički dokazanom postupku. Iako, kako je već napomenuto, taj set podataka nije izdašan, bio je dovoljan za adekvatnu predodžbu litoloških jedinica u podzemlju. Relativno jednostavan osnovni princip koji se krije iza ove metode omogućuje brzo uočavanje grešaka što ostavlja dovoljno vremena za njihovo ispravljanje. Prikupljanjem dodatnih podataka visoke rezolucije, rezultati se vrlo brzo i efikasno mogu prilagoditi i poboljšati. Sukladno tome, može se reći kako ispravnost rezultata neuronskih mreža uvelike ovisi vrsti, raznolikosti, količini i kvaliteti korištenih podataka.

Uzimajući u obzir činjenice da je razvoj istraživanog prostora (Požeške kotline) bio dinamičan, relativno neistražen u odnosu na ostale dijelove hrvatskog dijela Panonskog bazena (manji fond podataka), da seizmički podaci variraju u kvaliteti rezolucije, te da je

proces interpretacije izrazito podložan subjektivnom dojmu interpretatora i iskustvu, dobiveni rezultati predstavljaju korektan prikaz dubinskih i litoloških odnosa unutar Požeške kotline. Postoje i dalje neka pitanja vezana za ovo područje kojih se nije dotaklo u ovom radu, što ostavlja prostora za daljnja istraživanja.

U sklopu ovog diplomskog rada objedinjene su različite vrste podataka i metoda u svrhu cjelovitog prikaza dubinskog i litološkog odnosa Požeške kotline. Prikaz podataka prikupljenih krajem prošlog stoljeća dobio je novu dimenziju obradom istih u analitičkim softwareima, razvijenim za širu namjenu u zadnjih petnaestak godina. 3D prikazom strukturnog modela, vizualno su predočeni dubinski odnosi istraživanog područja na više razina, s aspekta tektonske i stratigrafske evolucije. Polazišni podatci za konstrukciju strukturnog modela bili su interpretirani seizmički i bušotinski podatci. Temeljem njih, prikazana je struktura tektonske grabe koja je tijekom miocena predstavljala sedimentacijski bazen. Za predviđanje litoloških svojstava korištena je metoda umjetnih neuronskih mreža koja uz brzu obradu podataka daje zadovoljavajuće rezultate. Uz najmanju moguću grešku predviđanja na temelju dotupnih podataka, litološki prikaz profila pokazuje dominantnu raspodjelu lapora i sitno-klastičnih sedimenata unutar ispune, uz učestalu izmjenu s pješčenjacima i krupno-klastičnim sedimenatima.

8. Literatura

ABRAHAM, A., 2005. Artificial Neural Networks – chapter 129 in Handbook of Measuring System Design. John Wiley & Sons, Ltd., 901-908

BOŠKO, K., JAMIČIĆ, D., 1989. Osnovna geološka karta SFRJ 1:100000, list Našice L34 -85. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

BOUZGOU, H., 2012. Advanced Methods for the Processing and Analysis of Multidimensional Signals: Application to Wind Speed. University of Hadj Lakhdar, Batna, 98

BRCKOVIĆ, A., KOVAČEVIĆ, M., CVETKOVIĆ, M., KOLENKOVIĆ MOČILAC, I., RUKAVINA, D., SAFTIĆ, B., 2017. Application of artificial neural networks for lithofacies determination based on limited well data. Central European Geology, 60, 3, 299-315.

CVETKOVIĆ, M., VELIĆ, J., 2012. Successfulness of inter well lithology prediction on Upper Miocene sediments with artificial neural networks. 4th HR-HU and 15th HU geomathematical congress "Geomathematics as Geoscience", 13-20

CVETKOVIĆ, M., 2013. Naftnogeološki potencijal i litostratigrafska razradba trećega neogensko-kvartarnoga megaciklusa u Savskoj depresiji – doktorski rad. Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 175

CVETKOVIĆ, M; VELIĆ, J., VUKIČEVIĆ, F, 2014, Selection of the most successful neural network algorithm for the purpose of subsurface velocity modeling, example from Sava depression, Croatia. 6th HR-HU and 17th HU geomathematical congress "Geomathematics – from theory to practice", 21-28

ĆORIĆ, S., PAVELIĆ, D., RÖGL, F., MANDIĆ, O., VRABAC, 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). Geologia Croatica, 62(1), 31-43.

DALBELO BAŠIĆ, B., ČUPIĆ, M, ŠNAJDER, J., 2008. Umjetne neuronske mreže. Fakultet elektrotehnike i računarstva, Zagreb, 49

DUMANČIĆ, S., 2014. Neuronske mreže – diplomski rad. Sveučilište Josipa Jurja Strossmayera, Osijek, 36

EMANOVIĆ, I., 2018. Procjena ugljikovodičnog potencijala područja Požeške kotline bazenskim modeliranjem – diplomski rad. Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 47

HAMI-EDDINE, K., KLEIN, P., RICHARD, L., DE RIBET, B., GROUT, M, 2015. A new technique for lithology and fluid content prediction from prestack data: An application to a carbonate reservoir. Interpretation, 3(1), 19–32.

HANDY, M. R., USTASZEWSKI, K., KISSLING, E., 2014. Reconstructing the Alps-Carpathians-Dinarides as a key to understanding switches in subduction polarity, slab gaps and surface motion. Int J Earth Sci (Geol Rundsch), 26

HORVÁTH, F., BADA, G., SZAFIÁN, P., TARI, G., ÁDÁM, A., CLOETINGH, S., 2006. Formation and deformation of the Pannonian Basin: constraints from observational data. Geological Society London Memoirs, 32, 191-206

INSTITUT IGH d.d., 2017. Elaborat zaštite okoliša pri zahvatu izgradnje pristupnog puta na desno obalnom nasipu potoka Veličanka. 99

JAMIČIĆ, D., BRKIĆ, M., 1989. Osnovna geološka karta SFRJ 1:100000, list Orahovica L33 -96. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

JAMIČIĆ, D., 1989. Osnovna geološka karta SFRJ 1:100000, list Daruvar L33 -95. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

JAMIČIĆ, D., 1995. The Role of Sinistral Strike-Slip Faults in the Formation of the Structural Fabric of the Slavonian Mts. (Eastern Croatia). Geologica Croatica, 48(2), 155-160

KOVAČEVIĆ, M., 2017. Petrološke, petrofizikalne i geokemijske značajke miocenskih naslaga Požeške kotline. Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 51

KOVAČIĆ, M., PAVELIĆ, D., 2017. Neogene Stratigraphy of the Slavonian Mountains. 7th International Workshop – Neogene of North and Central and South-Eastern Europe, 5-9

KOVAČIĆ, M., TIBLJAŠ, D., PAVELIĆ, D., HAJEK-TADESSE, V., BAKRAČ, K., MANDIC, O., GALOVIĆ, I., WACHA, L., FILJAK, R., MARKOVIĆ, F., 2017. Early-Middle Miocene Salina-type and Open Lake Deposits - Field Trip Guidebook: Neogene of Central and South-Eastern Europe. Hrvatsko geološko društvo, Zagreb, 11-15

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

MALVIĆ, T., 2006. Clastic facies prediction using neural network (case study from Okoli field). Nafta, 57(1), 10

MALVIĆ, T.; SAFTIĆ, B., 2008. Dubinsko kartiranje (vježbe). Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, 46

MALVIĆ, T., VELIĆ, J., 2011. Neogene Tectonics in Croatian Part of the Pannonian Basin and Reflectance in Hydrocarbon Accumulations. – U: New Frontiers in Tectonic Research - At the Midst of Plate Convergence, SCHATTNER, U. (ur), 215-238.

MALVIĆ, T., VELIĆ, J., HORVATH, J., CVETKOVIĆ, M., 2011. Neural networks in petroleum geology as interpretation tools. Central European Geology, 53, 1, 97-115.

MATENCO, L., RADIVOJEVIĆ, D., 2012. On the formation and evolution of the Pannonian Basin: constraints derived from the structure of the junction area between the Carpathians and Dinarides. Tectonics, 31, 31

MCCULOH, W., PITTS, W., 1943. A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, 5, 115-133

MOHSENI, H., ESFANDYARI, M I ASL, E. H., 2015. Application of artificial neural networks for prediction of Sarvak Formation lithofacies based on well log data, Marun oil field, SW Iran. Geopersia, 5(1), 111-123

NAJDENOVSKI, J., 1988. Dubinski geološki odnos i razvitak struktura u tercijarnim sedimentima Požeške kotline – disertacija. Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 146

PAVELIĆ, D., KOVAČIĆ, M., 1999. Lower Miocene Alluvial Deposits of the Požeška Mt. (Pannonian Basin, Northern Croatia): Cycles, Megacycles and Tectonic Implications. Geologia Croatica, 55, 1, 83-92

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., MIKNIĆ, M., AVANIĆ, R., VRSALJKO, D., BAKRAČ, K., TIŠLJAR, J., GALOVIĆ, I., BORTEK, Ž., 2003. The Evolution of the Miocene

Environments in the Slavonian Mts. Area (Northern Croatia). 22nd IAS Meeting of Sedimentology, Opatija, 173-181.

PAVELIĆ, D., 2005. Cyclicity in the evolution of the Neogene North Croatian Basin (Pannonian Basin System). Elsevier B.V., 273-283.

PAVELIĆ, D., KOVAČIĆ, M., BANAK, A., JIMÉNEZ-MORENO, G., MARKOVIĆ, F., PIKELJ, K., VRANJKOVIĆ, A., PREMUŽAK, L., TIBLJAŠ, D. , BELAK, M., 2015. Early Miocene European loess: A new record of aridity in southern Europe. Geological Society of America Bulletin, 12

PETRIĆ-STEPANOVIĆ, V., 2002. Sovsko jezero na Dilj Gori kao ostatak Panonskog mora. Građevina, 54(7), 445-448

PIGOTT, J. D. I RADIVOJEVIĆ, D., 2010. Seismic Stratigraphy Based Chronostratigraphy (SSBC) of the Serbian Banat Region of the Pannonian Basin. Central European Journal of Geosciences, 481-500

POTREBICA, H., 2012. Požeška kotlina – europsko kulturno središte (arheološka perspektiva). Radovi zavoda za znanstveni i umjetnički rad u Požegi, 1, 185-208

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

ROYDEN, L., HORVÀTH, F., RUMPLER, J., 1983. Evolution of the Pannonian Basin System: 1. tectonics. John Wiley & Sons, Ltd, 2(1)., 63-90.

SAFTIĆ, B., VELIĆ, J., SZTANÓ, O., JUHÀSZ, 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), 101-122.

SCHMID, S. M., BERNOULLI, D., FÜGENSCHUH, B., MATENCO, L., SCHEFER, S., SCHUSTER, R., TISCHLER, M., USTASZEWSKI, K., 2008. The Alpine-Carpathian-Dinaric orogenic system: correlation and evolution of tectonic units. Swiss J. Geosci., 101, 139-183.

ŠPARICA, M., JURIŠA, M., CRNKO, J., ŠIMUNIĆ, A., 1979. Osnovna geološka karta SFRJ 1:100000, list Nova Kapela L33 -108. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

ŠPARICA, M., BUZALJKO, R., JOVANOVIĆ, C., 1983. Osnovna geološka karta SFRJ 1:100000, list Nova Gradiška L33 -107. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

ŠPARICA, M., 1986. Osnovna geološka karta SFRJ 1:100000, list Slavonski Brod L34 - 97. Geološki zavod, Zagreb, Savezni geološki zavod, Beograd

VELIĆ, J., WEISSER, M., SAFTIĆ, B., VRBANAC, B., IVKOVIĆ, Ž., 2002. Naftnogeološke značajke i istraženost triju neogenskih megaciklusa u hrvatskom dijelu Panonskog bazena. Nafta, 53(6-7), 239-249

VELIĆ, J., 2007. Geologija ležišta nafte i plina; Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 342

VELIĆ, J., KRASIĆ, D. I KOVAČEVIĆ, I., 2012a. Exploitation, reserves and transport of natural gas in the Republic of Croatia. Technical Gazette, 19(3), 633-641

VELIĆ, J., MALVIĆ, T., CVETKOVIĆ, M. I VRBANAC, B., 2012b. Reservoir geology, hydrocarbon reserves and production in the Croatian part of the Pannonian Basin System. Geologia Croatica, 65(1), 91-101

VRBANAC, B., 2002. Contribution to the debate on the stratigraphic classification system and the importance of EK-markers in the Sava Depression. Nafta, 53(1), 39-44

ZEČEVIĆ, M., VELIĆ, J., SREMAC, J., TROSKOT-ČORBIĆ, T., GARAŠIĆ, V., 2010. Significance of the Badenian petroleum source rocks from Krndija Mt. (Pannonian Basin, Croatia). Geologia Croatica, 63(2), 225-239

Neobjavljeni izvori:

INA Naftaplin, 1981. Geološki izvještaj duboke istražne bušotine Tekić-1 (Tek-1). 70