

Deterministički i stohastički geološki modeli gornjomiocenskih pješčenjačkih ležišta u naftno-plinskom polju Kloštar

Novak Zelenika, Kristina

Doctoral thesis / Disertacija

2012

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:169:593501>

Rights / Prava: [Attribution-NoDerivatives 4.0 International](#)/[Imenovanje-Bez prerada 4.0 međunarodna](#)

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



Repository / Repozitorij:

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





SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Kristina Novak Zelenika

**DETERMINISTIČKI I STOHAISTIČKI
GEOLOŠKI MODELI
GORNJOMIOCENSKIH PJEŠČENJAČKIH
LEŽIŠTA U NAFTNO-
-PLINSKOM POLJU KLOŠTAR**

DOKTORSKI RAD

Zagreb, 2012.



UNIVERSITY OF ZAGREB
FACULTY OF MINING, GEOLOGY AND PETROLEUM
ENGINEERING

Kristina Novak Zelenika

**DETERMINISTIC AND STOCHASTIC
GEOLOGICAL MODELS OF UPPER
MIOCENE SANDSTONE RESERVOIRS AT
THE KLOŠTAR OIL AND GAS FIELD**

DOCTORAL THESIS

Zagreb, 2012



SVEUČILIŠTE U ZAGREBU
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Kristina Novak Zelenika

**DETERMINISTIČKI I STOHAISTIČKI
GEOLOŠKI MODELI GORNJOMIOCENSKIH
PJEŠČENJAČKIH LEŽIŠTA U NAFTNO-
-PLINSKOM POLJU KLOŠTAR**

DOKTORSKI RAD

Mentori:

1. Doc. dr. sc. Tomislav Malvić
2. Prof. dr. sc. Bruno Saftić

Zagreb, 2012.

Veliku zahvalnost dugujem mentoru doc. dr. sc. Tomislavu Malviću na pomoći, podršci, ukazanom povjerenju i brojnim korisnim savjetima tijekom izrade rada.

Također hvala mentoru prof. dr. sc. Bruni Saftiću na mnogim savjetima i uputama prilikom izrade rada.

Željela bih zahvaliti i članovima povjerenstva za ocjenu rada, prof. dr. sc. Josipi Velić, prof. dr. sc. Janosu Geigeru i prof. dr. sc. Jasenki Sremac na uloženom trudu i korisnim primjedbama koji su doprinijeli boljem sadržaju disertacije.

Hvala i svim kolegama, a posebno neposrednoj rukovoditeljici Renati Vidaček na podršci tijekom mog poslijediplomskog studija.

Na kraju veliko hvala mojoj obitelji na potpori i razumijevanju.

SAŽETAK

DETERMINISTIČKI I STOHAISTIČKI GEOLOŠKI MODELI GORNJOMIOCENSKIH PJEŠČENJAČKIH LEŽIŠTA U NAFTNO-PLINSKOM POLJU KLOŠTAR

Ključne riječi: determinističke interpolacijske metode, stohastičke simulacije, obični kriging, indikatorski kriging, sekvencijske Gaussove simulacije, sekvencijske indikatorske simulacije, geološki model, gornji miocen, polje Kloštar, Savska depresija, Hrvatska

Geostatističke metode su uspješno uporabljene prilikom izrade detaljnog modela dvaju najvećih i bitno različitih ležišta starosti gornjeg panona i donjeg pontu u polju Kloštar. Cilj disertacije bila je izrada detaljnog geološkog modela ležišta polja Kloštar, koji bi ujedno predstavljao i tipski model (u smislu litološkog sastava, granulometrije i taložnih uvjeta) za analizu gornjomiocenskih pješčenjačkih ležišta u Savskoj depresiji.

Kombinacijom triju varijabli (poroznosti, debljine i dubine ležišta) dobio se uvid u položaj taložnog kanala, postojanje različitih litofacijesa, smjer donosa detritusa, utjecaj bliskog paleoreljefa, prostornu distribuciju varijabli unutar pojedinog ležišta te određivanje područja najvećih nesigurnosti. Ležišta su analizirana determinističkim interpolacijskim metodama (tehnikama običnog i indikatorskog kriginga) i stohastičkim metodama (sekvencijskim Gaussovim i sekvencijskim indikatorskim simulacijama).

Antiklinala Kloštar prikazana je kartama dobivenim tehnikom običnog kriginga. Sekvencijske Gaussove simulacije dale su odlične rezultate pri određivanju distribucije varijable i područja najvećih nesigurnosti.

Dokazano je da je u gornjem panonu glavni smjer donosa materijala turbiditima iz Istočnih Alpi bio sjeverozapad-jugoistok, dok se on u donjem pontu mijenja u sjever-jug. Upravo su ti smjerovi lokalno, na području polja Kloštar potvrđeni kartama vjerojatnosti dobivenim tehnikom indikatorskog kriginga i sekvencijskim indikatorskim simulacijama za varijable poroznosti i debljine. Uz potvrdu smjera donosa materijala, karte jasno pokazuju vjerojatnosti pojave različitih litofacijesa u rasponu od čistih pješčenjaka do bazenskih lapora, no pitanje utjecaja Moslavačke gore kao lokalnog izvora materijala još je uvijek ostalo otvoreno.

ABSTRACT

DETERMINISTIC AND STOCHASTIC GEOLOGICAL MODELS OF UPPER MIOCENE SANDSTONE RESERVOIRS AT THE KLOŠTAR OIL AND GAS FIELD

Key words: deterministical interpolation methods, stochastical simulations, Ordinary Kriging, Indicator Kriging, Sequential Gaussian Simulations, Sequential Indicator Simulations, geological model, Upper Miocene, Kloštar Field, Sava Depression, Croatia

Geostatistical methods were successfully used in detailed modeling of the two most important and significantly different Upper Pannonian and Lower Pontian reservoirs in the Kloštar Field. The research was aimed at construction of a detailed geological model of these two sandstones, which should represent typical model (in terms of lithology, granulometry and depositional conditions) for the analysis of the Upper Miocene sandstone reservoirs in the Sava Depression.

The combination of the three variables (porosity, thickness and depth of the reservoirs) has helped to map the position of a depositional channel, different lithofacies, detritus transport direction, local palaeorelief influence, variables distribution within the reservoirs and mapping areas of greatest uncertainty. The reservoirs have been analyzed with deterministical interpolation methods (Ordinary and Indicator Kriging techniques) and stochastical methods (Sequential Gaussian and Sequential Indicator Simulations).

Kloštar anticline was mapped using Ordinary Kriging. The Sequential Gaussian Simulations have given excellent results in defining variables distribution as well as in locating the areas of the greatest uncertainties.

It was proven that during the Late Pannonian the main material transport direction from the Eastern Alps by turbidites was northwest-southeast, whereas during the Early Pontian it has changed to north-south direction. Those directions have been confirmed locally in the Kloštar area by the probability maps obtained by the Indicator Kriging technique and the Sequential Indicator Simulations for the porosity and thickness variables. The maps clearly show distribution of various lithofacies ranging from pure sandstones to basin marls, and also indicate the material transport direction. However the question of the influence of Moslavačka Gora Mt. as a local material source still remained unsolved.

EXTENDED ABSTRACT

DETERMINISTIC AND STOCHASTIC GEOLOGICAL MODELS OF UPPER MIOCENE SANDSTONE RESERVOIRS AT THE KLOŠTAR OIL AND GAS FIELD

The application of the geostatistical methods in geology is a relatively new approach to the geological underground interpretation. This dissertation has successfully used such methods in detail modeling of the two most important and significantly different reservoirs of the Kloštar Field. The age of the reservoirs is Upper Pannonian and Lower Pontian. The combination of the three variables (porosity, thickness and depth of the reservoirs) has helped to map the position of a depositional channel, different lithofacies, detritus transport direction, local palaeorelief influence, variables distribution within the reservoirs and mapping areas of greatest uncertainty. The Upper Pannonian and the Lower Pontian reservoirs have been analyzed by deterministic interpolation methods (Ordinary and Indicator Kriging techniques) and stochastic methods (Sequential Gaussian and Sequential Indicator Simulations). Although the deterministical interpolation methods are still a tool very often used in geological mapping, it is very important to emphasize that our underground knowledge can never be completely certain, thus non of the geological models can be completely deterministic.

The methodology applied in the Kloštar Field can be used in all Upper Pannonian and Lower Pontian sandstone reservoirs in the Sava Depression, primarily because all depositional conditions, migrations and traps forming were almost the same. The Kloštar anticline was mapped using Ordinary Kriging. Furthermore, it has been proven that Sequential Gaussian Simulations provide very good results in variable mapping within the reservoirs and in defining areas of the highest uncertainties. The Sequential Indicator Simulations and the Indicator Kriging have been used in the probability mapping of the certain variable value.

During the Late Pannonian and the Early Pontian in the Croatian part of the Pannonian Basin the second transtension prevailed. Minor fault depressions represented suitable places for sediments accumulations. Detritus had been brought by turbidites from the Eastern Alps, several times redeposited, until it finally reached the Sava Depression. Due to the long distance transport (several hundred kilometers), turbidites have incomplete Bouma sequence (Tb-Td).

It has been proven that in the Upper Pannonian the main turbiditic transport direction was northwest-southeast. This direction has been proven locally in the Kloštar Field area with the probability maps obtained by the Indicator Kriging technique and the Sequential Indicator Simulations for the variables porosity and thickness. Different lithofacies ranging from pure sandstones to basin marls were clearly shown on the probability maps. Interpretation of the maps shows higher thickness and porosity in the channel center. Lateral decrease of the thickness points to changes in pelitic sediments (marl and sandy marl). The coarsest material was deposited in local synclines, therefore today it has the highest thickness. Marls and argillitic marls were depositing continuously, especially during Late Pannonian, in shallow lacustric environment toward north and north-east, i.e. toward Moslavačka Gora Mt. The depositional channel direction (northwest-southeast) can be observed in the probability maps of the Upper Pannonian and Lower Pontian reservoirs for the variables porosity and thickness. However, during the transition from Late Pannonian to Early Pontian the regional normal fault occurred, causing the lowering of the northeastern and the uprising of the southwestern part, which created a new sedimentation area. Dominant transport direction during the Early Pontian was north-south and it passed by the Moslavačka Gora Mt.

Location of the highest averaged porosities does not match with the location of the averaged thicknesses of the Lower Pontian reservoir. Reason for that is the coarsest material transport from northwest and north. One part of material deposited directly with the fault and another part continued its flow towards southeast, parallel with the Kloštar fault, partly eroding its basement. The most fine grained turbiditic fraction could be deposited in the marginal part of the Kloštar structure, covering normal basin sediment without any erosion. The Indicator Kriging maps and the Sequential Indicator Simulations proved heterogeneity of the reservoirs by existence of different lithofacies starting with sandstones in the central part of the channel to marly sandstones, sandy marls and marls. Indicator maps also show probabilities of the lithofacies at the certain location. In this way it is easier to create precise boundary around the reservoirs and to get accurate estimation of the original hydrocarbon in place.

POPIS TABLICA PO POGLAVLJIMA:

POGLAVLJE 3:

Tablica 3.1: *Vrijeme trajanja pojedinih kronostratigrafskih jedinica, razdoblja oblikovanja hrvatskog dijela Panonskog bazena te dominantni mehanizmi transporta i taloženja materijala (MALVIĆ & VELIĆ, 2011)*

Tablica 3.2: *Kolektorska svojstva na temelju analiza jezgara gornjopanonskih ležišta*

Tablica 3.3: *Kolektorska svojstva na temelju analiza jezgara donjopontskih ležišta*

POGLAVLJE 4:

Tablica 4.1: *Tektonska aktivnost tijekom neogena, sedimenti i paleookoliši*

POGLAVLJE 8:

Tablica 8.1: *Vrijednosti analiziranih varijabli ležišta Beta u bušotinama polja Kloštar*

Tablica 8.2: *Vrijednosti analiziranih varijabli ležišta T u bušotinama polja Kloštar*

Tablica 8.3: *Vrijednosti standardiziranih variograma varijabli gornjopanonskog ležišta Beta*

Tablica 8.4: *Vrijednosti standardiziranih variograma varijabli donjopontskog ležišta T*

Tablica 8.5: *Indikatorska transformacija poroznosti ležišta Beta na temelju različitih graničnih vrijednosti*

Tablica 8.6: *Vrijednosti variograma varijable poroznosti ležišta Beta za određenu graničnu vrijednost*

Tablica 8.7: *Indikatorska transformacija ukupne debljine ležišta Beta na temelju različitih graničnih vrijednosti*

Tablica 8.8: *Vrijednosti variograma varijable debljine ležišta Beta za određenu graničnu vrijednost*

Tablica 8.9: *Indikatorska transformacija poroznosti ležišta T na temelju različitih graničnih vrijednosti*

Tablica 8.10: *Vrijednosti teorijskih standardiziranih variograma varijable poroznosti ležišta T za određenu graničnu vrijednost*

Tablica 8.11: *Indikatorska transformacija ukupne debljine ležišta T na temelju različitih graničnih vrijednosti*

Tablica 8.12: *Vrijednosti teorijskih standardiziranih variograma varijable debljine ležišta T za određenu graničnu vrijednost*

POPIS SLIKA PO POGLAVLJIMA:

POGLAVLJE 1:

Slika 1.1: *Dijagrami toka obradbe podataka kod determinističkih i stohastičkih metoda*

Slika 1.2: *Dijagram toka obradbe podataka kod kriginga općenito te kod tehnike indikatorskog kriginga (skr. IK)*

Slika 1.3: *Dijagram toka obradbe podataka kod indikatorskih postupaka, tj. tehnike indikatorskoga kriginga (skr. IK) te sekvencijskih indikatorskih simulacija (skr. SIS)*

POGLAVLJE 2:

Slika 2.1: *Zemljopisni položaj polja Kloštar (VELIĆ et al., 2008*)*

Slika 2.2: *Karta lokacija bušotina na polju Kloštar (VELIĆ et al., 2008*)*

POGLAVLJE 3:

Slika 3.1: *Formacije u Savskoj depresiji (prilagođeno iz SAFTIĆ et al., 2003; *početak ekstenzije prema ĆORIĆU et al., 2009; megaciklusi prema VELIĆ et al., 2002)*

Slika 3.2: *Složeni geološki stup kroz bušotinu Klo-62*

Slika 3.3: *Složeni geološki stup kroz bušotinu Klo-145*

Slika 3.4: *Fotografije jezgara iz različitih ležišta polja Kloštar s odgovarajućim kronostratigrafskim jedinicama*

Slika 3.5: *Današnji položaj gornjopanonskog ležišta Alfa*

Slika 3.6: *Današnji položaj gornjopanonskog ležišta Beta*

Slika 3.7: *Današnji položaj gornjopanonskog ležišta Gama*

Slika 3.8: *Granice taložnog okoliša (područje slojeva pješčenjaka) gornjopanonskih ležišta Alfa, Beta i Gama*

Slika 3.9: *Uzorak arkoznog arenita iz ležišta Gama u bušotini Klo-88 (1378,0 – 1381,4 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)*

Slika 3.10: Mikroskopski izbrusak arkoznog arenita (Klo – 88, 1378,0 – 1381,4 m, I m) (lijevo) i sekundarna poroznost u istom arkoznom arenitu (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.11: Uzorak litoarenita iz ležišta Beta u bušotini Klo-82 (1404,6 – 1411,7 m, II m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.12: Mikroskopski izbrusak litoarenita (Klo – 82, 1404,6 – 1411,7 m, II m) (lijevo) i intergranularna poroznost (plavo) u istom uzorku (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.13: Današnji položaj donjopontskog ležišta Z

Slika 3.14: Današnji položaj donjopontskog ležišta Y

Slika 3.15: Današnji položaj donjopontskog ležišta V

Slika 3.16: Današnji položaj donjopontskog ležišta U

Slika 3.17: Današnji položaj donjopontskog ležišta T

Slika 3.18: Današnji položaj donjopontskog ležišta S

Slika 3.19: Današnji položaj donjopontskog ležišta R

Slika 3.20: Današnji položaj donjopontskog ležišta Q

Slika 3.21: Današnji položaj donjopontskog ležišta P

Slika 3.22: Današnji položaj donjopontskog ležišta O

Slika 3.23: Uzorak proslojka pjeskovitog fosilifernog lapora u ležištu R iz bušotine Klo-1 (911,9 – 917,9 m, I m) s makrofosilima (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.24: Pjeskoviti fosiliferni lapor sa slabo razvijenom otvorenom mikrofrakturnom poroznošću, (Klo – 1, 911,9 – 917,9 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.25: Uzorak litoarenita u vršnom dijelu ležišta TUV u bušotini Klo-57 (788,9 – 793,3 m, III. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.26: Litoarenit s laminama organske tvari, (Klo – 57, 788,9 – 793,3 m, III. m) (lijevo) te isti uzorak litoarenita sa slabo razvijenom intergranularnom poroznošću (plavo, desno), (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.27: Uzorak sitnozrnatog litoarenita u vršnom dijelu ležišta TUV u bušotini Klo-57 (788,9 – 793,3 m, II. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Slika 3.28: *Sitnozrnati litoarenit (Klo – 57 (788,9 – 793,3 m, II. m)) (lijevo) te isti litoarenit s dobro razvijenom intergranularnom poroznošću (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)*

Slika 3.29: *Uzorak proslojka lapora u ležištu Z u bušotini Klo-12 (1071,0 – 1073,0 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)*

Slika 3.30: *Lapor s otvorenom mikrofrakturnom poroznošću, (Klo – 12, 1071,0 – 1073,0 m, I. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)*

POGLAVLJE 4:

Slika 4.1 *Seizmički profil kroz Savsku depresiju s interpretiranim regionalnim reperskim horizontima i rasjednim plohama (SAFTIĆ et al., 2003)*

Slika 4.2: *Kompilacijski geološki stup Savske depresije (SAFTIĆ et al., 2003)*

Slika 4.3: *Strukturne karte antiklinale Kloštar (VELIĆ et al., 2011)*

Slika 4.4: *Položaj profila A-B u polju Kloštar (VELIĆ et al., 2011)*

Slika 4.5: *Paleotektonski profil A-B (VELIĆ et al., 2011): a) nakon taloženja formacije Prečec, b) nakon taloženja formacije Prkos, c) nakon taloženja formacije Ivanić-Grad, d) nakon taloženja formacije Kloštar Ivanić, e) nakon taloženja formacije Široko Polje i f) nakon taloženja formacije Lonja*

POGLAVLJE 5:

Slika 5.1: *Karta lokacija 38 podataka gdje '1' predstavlja lokacije pješčenjaka, a '0' lokacije ostalih litofacijesa (NOVAK ZELENKA et al., 2010)*

Slika 5.2: *Dijagram toka obradbe podataka metodom sekvencijskih Gaussovih simulacija*

Slika 5.3: *Dijagram toka obradbe podataka metodom sekvencijskih indikatorskih simulacija*

POGLAVLJE 6:

Slika 6.1: *Parametri variograma (MALVIĆ, 2008)*

Slika 6.2: *Karta raspodjele poroznosti dobivena metodom najbližeg susjedstva (lijevo) i metodom inverzne udaljenosti (desno) (iz VELIĆ et al., 2008*)*

Slika 6.3: *Karta raspodjele poroznosti dobivene metodom kriginga (iz VELIĆ et al., 2008*)*

Slika 6.4: Različiti načini vizualizacije u računalnom programu Petrel™ (Petrel Introduction Course-Petrel 2009*)

Slika 6.5: Modeliranje rasjeda u računalnom programu Petrel™ (Petrel Introduction Course-Petrel 2009*)

POGLAVLJE 7:

Slika 7.1: Korelacijski profil kroz bušotine koje su probušile gornjopanonska ležišta

Slika 7.2: Korelacijski profil kroz bušotine koje su probušile donjopontska ležišta

Slika 7.3: Konceptualni taložni model gornjopanonskih naslaga u polju Kloštar

Slika 7.4: Konceptualni taložni model donjopontskih naslaga u polju Kloštar

Slika 7.5: Konceptualni taložni model gornjopontskih naslaga u polju Kloštar

Slika 7.6: Konceptualni taložni model tijekom pliocena i kvartara u polju Kloštar

Slika 7.7: Karta po krovini ležišta Alfa

Slika 7.8: Karta po krovini ležišta Z

Slika 7.9: Karta po krovini ležišta T

Slika 7.10: Karta po krovini ležišta O

Slika 7.11: Temeljni strukturalni model gornjopanonskih i donjopontskih ležišta

POGLAVLJE 8:

Slika 8.1: Karte variogramskih površina varijabli poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta

Slika 8.2: Karte variogramskih površina varijabli poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Slika 8.3: Eksperimentalni variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta

Slika 8.4: Eksperimentalni variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Slika 8.5: Teorijski variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta

Slika 8.6: Teorijski variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Slika 8.7: Poroznost ležišta Beta kartirana tehnikom običnog kriginga

Slika 8.8: Dubina krovine ležišta Beta kartirana tehnikom običnog kriginga

Slika 8.9: Debljina ležišta Beta kartirana tehnikom običnog kriginga

Slika 8.10: Poroznost ležišta T kartirana tehnikom običnog kriginga

Slika 8.11: Dubina ležišta T kartirana tehnikom običnog kriginga

Slika 8.12: Debljina ležišta T kartirana tehnikom običnog kriginga

Slika 8.13: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable poroznosti ležišta Beta za granične vrijednosti: a-15%, b-16%, c-18% i d-19%

Slika 8.14: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 15%

Slika 8.15: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 16%

Slika 8.16: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 18%

Slika 8.17: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 19%

Slika 8.18: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable ukupne debljine ležišta Beta za granične vrijednosti: a-7m, b-9m, c-15m i d-21m

Slika 8.19: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 7 m

Slika 8.20: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 9 m

Slika 8.21: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 15 m

Slika 8.22: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 21 m

Slika 8.23: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable poroznosti ležišta T za granične vrijednosti: a-14%, b-18%, c-19%, d-20% i e-22%.

Slika 8.24: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 14%

Slika 8.25: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 18%

Slika 8.26: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 19%

Slika 8.27: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 20%

Slika 8.28: *Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 22%*

Slika 8.29: *Standardizirani variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable ukupne debljine ležišta T za granične vrijednosti: a-5m, b-9m, c-13m, d-17m i e-21m*

Slika 8.30: *Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 5 m*

Slika 8.31: *Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 9 m*

Slika 8.32: *Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 13m*

Slika 8.33: *Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 17m*

POGLAVLJE 9:

Slika 9.1: *Distribucija poroznosti ležišta Beta kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.2: *Distribucija debljine ležišta Beta kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.3: *Distribucija dubine ležišta Beta kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.4: *Distribucija poroznosti ležišta T kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.5: *Distribucija debljine ležišta T kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.6: *Distribucija dubine ležišta T kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.7: *Distribucija poroznosti ležišta Beta kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.8: *Distribucija debljine ležišta Beta kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija*

Slika 9.9: *Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 15%*

Slika 9.10: *Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 16%*

Slika 9.11: *Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 18%*

Slika 9.12: Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 19%

Slika 9.13: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 7 m

Slika 9.14: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 9 m

Slika 9.15: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 15 m

Slika 9.16: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 21 m

Slika 9.17: Distribucija poroznosti ležišta T kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija

Slika 9.18: Distribucija debljine ležišta T kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija

Slika 9.19: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 14%

Slika 9.20: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 18%

Slika 9.21: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 19%

Slika 9.22: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 20%

Slika 9.23: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 22%

Slika 9.24: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 5 m

Slika 9.25: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 9 m

Slika 9.26: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 13 m

Slika 9.27: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 17 m

Slika 9.28: Usporedba realizacija distribucije poroznosti ležišta Beta dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija

Slika 9.29: Usporedba realizacija distribucije debljine ležišta Beta dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija

Slika 9.30: Usporedba realizacija distribucije poroznosti ležišta T dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija

Slika 9.31: Usporedba realizacija distribucije debljine ležišta T dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija

POGLAVLJE 10:

Slika 10.1: *Smjer donosa materijala u gornjem panonu interpretiran na karti vjerojatnosti poroznosti veće od 18% (lijevo) i debljine veće od 15m (desno)*

Slika 10.2: *Smjer donosa materijala u donjem pontu interpretiran na karti vjerojatnosti poroznosti veće od 19% (lijevo) i debljine veće od 13 m (desno)*

Slika 10.3: *Smjer donosa materijala u donjem pontu interpretiran na karti vjerojatnosti poroznosti manje (lijevo) i veće (desno) od 18% dobivenoj indikatorskim krigingom (lijevo) i sekvencijskim indikatorskim simulacijama (desno)*

SADRŽAJ:

1. UVOD.....	1
2. POVIJEST NAFTNOGEOLOŠKIH ISTRAŽIVANJA ŠIRE OKOLICE POLJA KLOŠTAR.....	8
3. STRATIGRAFSKI MODEL POLJA KLOŠTAR S OSVRTOM NA POLOŽAJ UNUTAR ZAPADNOG DIJELA SAVSKE DEPRESIJE.....	12
3.1. STRATIGRAFSKI PREGLED NEOGENSKO-KVARTARNIH NASLAGA U POLJU KLOŠTAR.....	16
3.1.1. „Temeljno gorje“	19
3.1.2. Baden i sarmat.....	20
3.1.3. Donji panon.....	20
3.1.4. Gornji panon.....	20
3.1.5. Donji pont.....	27
3.1.6. Gornji pont.....	42
3.1.7. Dacij, romanij, pleistocen i holocen.....	42
4. NEOGENSKO-KVARTARNI TEKTONSKI POKRETI U SAVSKOJ DEPRESIJI TE NJIHOV ODRAZ U PODRUČJU STRUKTURE KLOŠTAR.....	43
4.1. STRUKTURNO-TEKTONSKI ODNOSI U POLJU KLOŠTAR.....	45
4.1.1. Strukturne karte i paleotektonski profili antiklinale Kloštar.....	46
5. GEOSTATISTIČKE ISTRAŽIVAČKE METODE.....	50
5.1. METODA KRIGINGA.....	51


5.1.1. Obični kriging.....	52
5.1.2. Indikatorski kriging.....	53
5.2. STOHAŠTIČKE SIMULACIJE.....	56
5.2.1. Sekvencijske Gaussove simulacije.....	57
5.2.2. Sekvencijske indikatorske simulacije.....	58
 6. PROGRAMSKI ISTRAŽIVAČKI ALATI (SOFTVERSKI PAKETI).....	61
6.1. RAČUNALNI PROGRAM VARIOWIN.....	61
6.2. RAČUNALNI PROGRAM SURFER 8.0 TM	63
6.3. RAČUNALNI PROGRAM PETREL TM	65
6.4. RAČUNALNI PROGRAM WINGSLIB TM	67
 7. STRUKTURNO MODELIRANJE POLJA KLOŠTAR.....	69
7.1. POSTOJEĆE STRUKTURNE KARTE LEŽIŠTA.....	74
7.2. OSNOVNI STRUKTURNI MODEL POLJA KLOŠTAR.....	80
 8. DETERMINISTIČKO GEOSTATISTIČKO KARTIRANJE PETRO- FIZIKALNIH VARIJABLI I LITOFACIJESA.....	82
8.1. PRIKUPLJANJE PETROFIZIKALNIH PODATAKA.....	82
8.2. VARIOGRAMSKA ANALIZA KARTIRANIH VARIJABLI.....	84
8.3. KARTIRANJE DUBINE, DEBLJINE I POROZNOSTI OBIČNIM KRIGINGOM...87	
8.3.1. Kartiranje varijabli gornjopanonskog ležišta Beta.....	88
8.3.2. Kartiranje varijabli donjopontskog ležišta T.....	92
8.4. KARTIRANJE INDIKATORSKIM KRIGINGOM.....	96
8.4.1. Kartiranje indikatorskih varijabli gornjopanonskog ležišta Beta.....	96
8.4.2. Kartiranje indikatorskih varijabli donjopontskog ležišta T.....	111
 9. SEKVENCIJSKE GEOSTATISTIČKE SIMULACIJE LEŽIŠNIH VARIJABLI.....	128
9.1. SEKVENCIJSKE GAUSSOVE SIMULACIJE.....	128

9.1.1. Kartiranje varijabli gornjopanonskog ležišta Beta.....	129
9.1.2. Kartiranje varijabli donjopontskog ležišta T.....	130
9.2. SEKVENCIJSKE INDIKATORSKE SIMULACIJE.....	138
9.2.1. Kartiranje varijabli gornjopontskog ležišta Beta.....	138
9.2.2. Kartiranje varijabli donjopontskog ležišta T.....	151
9.2.3. Usporedba rezultata dobivenih sekvencijskim Gausovim i sekvencijskim indikatorskim simulacijama.....	153
 10. RASPRAVA.....	 169
 11. ZAKLJUČAK.....	 178
 12. LITERATURA.....	 180
12.1. OBJAVLJENI RADOVI.....	180
12.2. IZ FONDA STRUČNE DOKUMENTACIJE I NEOBJAVLJENI RADOVI.....	185

1. UVOD

Primjena matematike u geologiji razmjerno je novi metodološki pristup interpretaciji geoloških odnosa podzemlja. Geostatistika, kao grana geomatematike, započinje svoj razvoj tek u drugoj polovici prošlog stoljeća. Dva su velika znanstvenika utemeljila tu disciplinu: prof. dr. sc. Daniel Krige te prof. dr. sc. George Matheron. Učestalija primjena geostatistike, kao i njezin intenzivniji razvoj usko su vezani s razvojem informatike i računarstva, što nikako ne treba biti začuđujuća činjenica, budući da se interpretacije, koje su bazirane na geostatističkim metodama, rade uporabom statistike, pomoću računalnih programa.

Geostatističke metode mogu se podijeliti na determinističke i stohastičke. Kod determinističkih metoda svi uvjeti koji utječu na procjenu moraju biti potpuno poznati te deterministički sustav ne smije sadržavati slučajnost bilo koje vrste u opisu varijabli. Potpuno je jasno da je geološka građa podzemlja samo jedna, no prilikom opisa takve slike, na temelju točkastih bušotinskih podataka nikada nije moguće sa potpunom sigurnošću tvrditi da je rješenje dobiveno geostatističkim metodama apsolutno točno. Stoga, sve geostatističke metode u sebi sarže određenu nesigurnost, procjenjuju sliku podzemlja te mogu dati jedino najvjerojatnije rješenje ili rješenje najbliže istini. Ipak, neke metode daju samo jedno rješenje, odnosno za isti skup podataka i primjenom iste metode, uvijek će se dobiti npr. ista karta. Takve se metode mogu nazivati determinističkim metodama, no točnije ih je nazivati determinističkim interpolacijskim metodama. S druge strane stohastičkim realizacijama se za isti skup podataka dobije različiti broj rješenja, koja će biti vrlo slična, no nikada identična, a sva dobivena rješenja jednako su vjerojatna (**slika 1.1**).



Slika 1.1: Dijagrami toka obradbe podataka kod determinističkih i stohastičkih metoda

Determinističke interpolacijske metode kod nas su još uvijek češće primjenjivane, unatoč činjenici da je naše poznavanje geoloških procesa uglavnom daleko od potpunoga. Ipak, svjesni smo barem da takve determinističke interpretacije nikada ne mogu biti potpuno jednoznačne i sigurne, već najčešće opisane kao najvjerojatnije. Dakle, potpuno deterministički sustavi u prirodi gotovo da i nisu mogući. Zbog toga je možda bolje, kada to podaci ili naše znanje dopuštaju, koristiti stohastiku. Stohastičke su metode standardni dio matematičke geologije (kao dijela matematičkih geoznanosti) i u svijetu široko primijenjen alat za karakterizaciju ležišta ugljikovodika, ali i podzemlja općenito.

Ipak, i kod stohastičkih procesa nužno je započeti determinizmom. Deterministička karta predstavlja osnovni ulaz za stohastičke simulacije, a naziva se “nultim” rješenjem. U statističkom smislu takvo rješenje je blisko medijanskoj realizaciji. Broj realizacija unutar stohastičkog modela može biti bilo koji. Jasno je da će veći broj realizacija pokriti područje veće nesigurnosti, odnosno što je više realizacija, nesigurnost je manja. Smatra se da će broj od 100 realizacija pokriti 95% svih mogućih rješenja, dok će 200 realizacija pokriti njih 99%. U praksi se najčešće koristi 100 realizacija jer već taj broj daje dovoljnu sigurnost prilikom opisa ležišta. Nadalje, unutar stohastike razlikuju se uvjetne i bezuvjetne simulacije.

Kod uvjetnih simulacija postojeća mjerenja, a to su najčešće bušotinski podaci, uvijek imaju mjerene vrijednosti koje se smatraju čvrstim točkama, za razliku od bezuvjetnih, gdje te vrijednosti ne ostaju konstantne. Objašnjenje za takav pristup je to da je bušotinska vrijednost točkasti podatak, koji se ekstrapolira na cijelu ćeliju. Veličina ćelije najčešće iznosi 50x50 ili 100x100 m, a ekstrapolacija točkastog podatka u tom slučaju opet daje određenu nesigurnost. Da je bušotina bila samo malo pomaknuta u prostoru, ulazna vrijednost bi bila vjerojatno malo drugačija. Zato se točkasti podatak kod bezuvjetnih simulacija „okružuje“ varijancom postojećih mjerenja, pa se unutar toga intervala bira vrijednost ćelije. Od tuda i naziv bezuvjetne simulacije. Općenito se češće koriste uvjetne simulacije.


Brojna su ležišta u hrvatskom dijelu Panonskog bazena interpretirana posebno determinističkim interpolacijskim, ali i stohastičkim metodama (poput ležišta polja Ivanić, Molve, Kalinovac, Stari Gradac-Barcs Nyugat, Beničanci, Ladislavci, Galovac-Pavljani, Velika Ciglena i neka druga manja npr. u radovima MALVIĆ, 1998, 2003, 2006; MALVIĆ & ĐUREKOVIĆ, 2003; MALVIĆ et al., 2005). Posebno je detaljno analizirano polje Kloštar (npr. BALIĆ et al., 2008; CVETKOVIĆ et al., 2009; MALVIĆ & BALIĆ, 2009), koje je među najvećim naftnim i plinskim poljima prema kumulativnoj proizvodnji ugljikovodika u Savskoj depresiji. Tu je u okviru zajedničke studije Ine i Rudarsko-geološko-naftnog fakulteta, a pod vodstvom prof. dr. sc. Josipe Velić i doc. dr. sc. Tomislava Malvića, napravljena deterministička analiza podataka za donjopontska ležišta (VELIĆ et al., 2008*). Rezultati su istakli primjerenost variogramске analize na podacima iz pješčenjačkih ležišta te obični kriging kao najprimjereniju interpolacijsku metodu. No, uočeno je kako ti rezultati pružaju posebnu priliku za razvoj teorije i primjenu drugih geostatističkih metoda u hrvatskom dijelu Panonskoga bazena, kako determinističkih interpolacijskih, tako i stohastičkih. Na temelju toga zamišljeno je opsežno istraživanje vezano uz ovu doktorsku disertaciju u području Savske depresije, pa je više nego razumljivo da je kao istraživački lokalitet ponovno odabrano polje Kloštar, tj. pješčenjačka ležišta u istome, kao objekti s dovoljno velikom i točnom bazom postojećih mjerenja, ali i nizom već postojećih geostatističkih rezultata i interpretacija.

Dakle, cilj ovoga rada je nastavak primjene različitih geostatističkih metoda u istome polju. Hipoteze istraživanja su: (1) pješčenjačka tijela se analiziraju kao kompleksni sedimentacijski objekti s prijelaznim litofacijesima čija se svojstva kvantificiraju indikatorskim metodama; (2) razdioba ležišnih varijabli može se prikazati kroz niz mogućih realizacija, što se postiže stohastičkim simulacijskim metodama; (3) razlike u ležišnim litofacijesima mogu se opisati kao rezultat promjene taložnih okoliša, no zbog toga što je skup podataka ograničen i kad se

smatra reprezentativnim, stohastički pristup može unaprijediti uobičajeno determinističko kartiranje.

Uz primjenu determinističke interpolacijske tehnike indikatorskog kriginga, u radu su upotrijebljene različite vrste stohastičkih simulacija i to sekvencijske indikatorske simulacije te sekvencijske Gaussove simulacije. Cilj je razviti metode za dobivanje najdetaljnijih mogućih litofacijsnih karata na temelju pretpostavke da određeno svojstvo (poroznost) odgovara litofacijsu, uz što bolje određivanje granice različitih litofacijsa u sustavu pješčenjak-lapor kroz niz realizacija. Na takvim kartama su litofacijsi interpretirani indirektno na temelju vrijednosti određenih ležišnih varijabli, poput poroznosti. To je i razlog zbog kojeg su odabrane metode indikatorskog kriginga i indikatorskih simulacija kao istraživački alati u ovome radu.

Deterministička interpolacijska tehnika indikatorskog kriginga temelji se na određivanju vjerojatnosti pojave određenog litofacijsa na nekoj lokaciji. Na **slici 1.2** prikazan je dijagram toka obradbe podataka kod tehnike indikatorskog kriginga te osnovna razlika u odnosu na ostale tehnike. Metodologija uključuje niz graničnih vrijednosti pomoću kojih se radi indikatorska transformacija analizirane varijable u vrijednosti 0 i 1. Nakon variogramске analize rade se indikatorske karte vjerojatnosti pojavnosti odabrane varijable.



Slika 1.2: Dijagram toka obradbe podataka kod kriginga općenito te kod tehnike indikatorskog kriginga (skr. IK)

Ključan je odabir broja graničnih vrijednosti, a on uglavnom ovisi o iskustvu osobe koja će raditi analizu. Ipak, za ulazni skup podataka veći od 15, preporuča se broj graničnih vrijednosti od 5 do 11, kako bi se zadovoljili statistički kriteriji izračuna varijance, histograma te uvjeti stacionarnosti.

Varijable analizirane ovom tehnikom su poroznost i ukupna debljina odabranog gornjopanonskog i donjopontskog ležišta. Pri analizi i interpretaciji rezultata poštovala se činjenica definiranja različitih litofacijesa s dvostrukom provjerom: (a) da broj litofacijesa ne bude preveliki, jer se tada oni ne bi mogli egzaktno razlikovati niti kroz petrofizikalne varijable, niti kroz opise jezgara, niti kroz karotažne krivulje, (b) da se litofacijesi ne opisuju isključivo numerički te granice među njima ne shvaćaju kao „čvrste“ linije, upravo zbog postojanja prijelaznih litofacijesa. Prikazani su kartama vjerojatnosti njihove pojave na određenoj lokaciji.

Unutar naslaga starosti donjeg ponta izdvojena su četiri litofacijesa: čisti pješčenjaci, laporoviti pješčenjaci, pjeskoviti lapori i naposljetku lapori. Numeričke vrijednosti koje se pripisuju svakom prijelaznom facijesu od pješčenjaka do lapora uglavnom su odabir interpretatora načinjen na temelju jedne ili nekoliko egzaktnih varijabli, te potpomognut opisom (determinacijom) jezgara. Valjana pretpostavka je da će vrijednosti poroznosti biti veće ukoliko ima više pješčenjačke komponente. Odabirom dovoljnog broja graničnih vrijednosti te prikazom karata vjerojatnosti za svaku pojedinu graničnu vrijednost moguće je utvrditi lokacije s vrlo velikom vjerojatnošću pojave određenog litofacijesa, tj. promjenu u pružanju dijelova pješčenjačkog tijela boljih ležišnih svojstava i onih lošijih. Na taj se način može i pretpostaviti pružanje taložnog kanala, kao i utvrditi bočna promjena litofacijesa.

Na isti je način analizirana varijabla debljine, čija vjerojatnost rasprostiranja unutar ležišta pruža važne informacije o granicama cijeloga taložnoga prostora ležišnih stijena na području današnje strukture Kloštar. Tako je npr. poznato da velike debljine pješčenjaka, čiji je detritus prenašan turbiditima unutar Savske depresije, ukazuju na sredinu taložnog kanala, no približan položaj granica toga kanala postat će vidljiv tek iz rezultata stohastičkih simulacija.


Druga vrsta uporabljenih metoda obuhvaćaju stohastičke metode. Njima su analizirane geološke varijable poroznosti, debljine i dubine i to metodom sekvencijskih Gaussovih simulacija (SGS) te varijable poroznosti i debljine sekvencijskim indikatorskim simulacijama (SIS). Obje vrste primijenjenih simulacija bile su uvjetne.

Osnovni uvjet sekvencijskih Gaussovih simulacija je normalna razdioba ulaznih podataka. U slučaju da razdioba nije normalna podaci se moraju transformirati. Prva točka, odnosno ćelija u kojoj se radi procjena izabire se slučajno, a to znači prvo uvođenje stohastike. Procijenjenoj

vrijednosti ćelije dodaje se interval $\pm 3 \sigma$ (σ = standardna devijacija). Slučajnim odabirom (drugo uvođenje stohastike) bilo koje vrijednosti iz tog intervala, dobije se simulirana vrijednost za tu ćeliju (**slika 1.1**). Postupak se ponavlja za sve ćelije u kojima nije bilo mjerenih podataka te se na taj način dobije jedna realizacija. Budući da se i u praksi najčešće koristi broj od 100 realizacija, taj je broj i zadržan prilikom prikaza distribucije geoloških varijabli poroznosti, debljine i dubine. Zbog praktičnih razloga i interpretacije, najčešće se prikazuju realizacije P5, P25, P50, P75 i P95 ili samo P5, P50 i P95. To su realizacije odabrane prema kriteriju ukupne vrijednosti pojedinačne realizacije. Realizacija P5 prikazuje rješenje od kojeg 5% svih rješenja ima manje vrijednosti, dok realizacija P95 prikazuje rješenje od kojeg 95% svih rješenja ima manje vrijednosti na točkama ili lokacijama u kojima se radi procjena. Takva interpretacija vrijedi i za sve ostale „P“ realizacije. Također je moguće prikazati 1., 50. i 100. realizaciju. U tom slučaju kriterij odabira je statistički i one se izdvajaju prema poretku njihova pojavljivanja kao rješenja.

Sekvencijske Gaussove simulacije (skr. SGS) se najčešće upotrebljavaju prilikom procjene distribucije petrofizikalnih parametara u ležištu. U ovom radu koristile su se u svrhu određivanja distribucije nešto širega skupa ležišnih podataka, tj. vrijednosti geoloških varijabli poroznosti, debljine i dubine.

Sekvencijske indikatorske simulacije (skr. SIS), za razliku od indikatorskog kriginga koji daje vjerojatnosti putem jedinstvenoga rješenja za svaku odabranu graničnu vrijednost (engl. *cutoff*), daju niz realizacija takvih vjerojatnosti za svaku ćeliju (**slika 1.3**). Kao ulazne vrijednosti sekvencijske indikatorske simulacije koriste izvorne podatke, ali i indikatorski transformirane za svaku graničnu vrijednost, uzevši u obzir i njihovu krivulju kumulativne vjerojatnosti. Kriteriji odabira prikladnih realizacija jednaki su kao kod SGS-a.




Slika 1.3: Dijagram toka obradbe podataka kod indikatorskih postupaka, tj. tehnike indikatorskoga kriginga (skr. IK) te sekvencijskih indikatorskih simulacija (skr. SIS)

Ipak, procjena sekvencijskim indikatorskim simulacijama (SIS) dat će ujednačenije i niže vrijednosti ćelija, a razlika između realizacija neće biti toliko velika kao prilikom kartiranja sekvencijskim Gaussovim simulacijama (SGS). Razlog tomu je da se procjene dobivene metodom SIS uglavnom kreću oko srednje vrijednosti. Zbog toga je metoda SGS primjerenija za procjenu distribucije parametara unutar nekog litofacijesa, dok se metoda SIS može bolje iskoristiti kako bi se kartiralo područje toga litofacijesa.

Računalni programi u kojima su se radile interpretacije su Variowin za variogramsku analizu, Surfer8, za izradu karte tehnikom običnoga kriginga, te WinGSlab za izradu karti vjerojatnosti metodom indikatorskog kriginga te izrade realizacija metodama SIS i SGS. Naglasak je stavljen na metodu SIS i tehniku IK, budući da se one po prvi put upotrebljavaju u geologiji ležišta ugljikovodika u Republici Hrvatskoj, ali i na metodu SGS, koja nije prvi put upotrijebljena, no ne koristi se često, iako je pokazala izvrsne rezultate prilikom kartiranja distribucije petrofizikalnih parametara u međubušotinskom prostoru ležišnih stijena neogenske starosti (MALVIĆ, 2008). Zbog uporabe relativno rjeđe korištenih metoda u kartiranju, posebno se opisala njihova teorijska osnova te praktična primjena u ležištima ugljikovodika u polju Kloštar, ali i ležištima slične geneze u Savskoj depresiji. Opisane metode omogućile su konstrukciju detaljnog modela ležišta polja Kloštar, koji bi ujedno bio i tipski model za analizu gornjomiocenskih pješčenjačkih ležišta Savske depresije. U praktičnom smislu to vodi preciznijoj procjeni volumena i svojstava ležišta, a time i točnijoj procjeni geoloških rezervi ugljikovodika.

2. POVIJEST NAFTNOGEOLOŠKIH ISTRAŽIVANJA ŠIRE OKOLICE POLJA KLOŠTAR

Polje Kloštar smješteno je oko 35 km istočno od Zagreba, na zapadnim padinama Moslavačke gore, gdje je površina terena na nadmorskoj visini 110 do 180 m. Promatrano regionalno, struktura polja smještena je uz SI rub Savske depresije (**slika 2.1**).



Slika 2.1: Zemljopisni položaj polja Kloštar (VELIĆ et al., 2008*)

Prostor polja je već na samom početku 20. stoljeća smatran vrlo interesantnim zbog pojava plina u bunarima okolnih naselja, no prva bušenja iz 1904. i 1905.g. nisu rezultirala otkrićem nafte. Od 1940. pa do 1942. započinju regionalna gravimetrijska mjerenja u sjeverozapadnoj Hrvatskoj, kojima je otkrivena struktura Križ, na krajnjem sjeverozapadnom dijelu Moslavačke gore, a unutar prostora Savske depresije. Naziv je dobila prema obližnjem, istoimenom selu Križ. Pravac pružanja te strukture je SZ-JI, tj. dinarski. Unutar strukture Križ kasnije su otkrivena naftna polja Šumečani i Bunjani. Nakon toga otkriveno je polje Kloštar i to prvom istraživačkom bušotinom Kloštar-1 (Klo-1). Lokacija bušotine određena je na temelju interpretacije gravimetrijskih i 2D seizmičkih mjerenja. Treba naglasiti kako je u to vrijeme (godina je 1952.) seizmika bila nova geofizička metoda istraživanja. Bušotina Klo-1 rezultirala je otkrivanjem ekonomski značajnih količina nafte te potvrdom novog naftnog polja Kloštar unutar veće strukture Križ. Tako je potvrđena i važnost uporabe seizmike kod traganja za zamkama ugljikovodika. Nadalje, od 1953. pa do 1961. godine traje intenzivna


razrada polja, a sama eksploatacija nafte započinje 1954. godine. O polju Kloštar postoji niz podataka objavljenih u više radova, regionalnih studija i disertacija, (SAFTIĆ, 1998; BAKRAČ, 2005; BALIĆ, 2007; CVETKOVIĆ, 2007; BALIĆ et al., 2008; CVETKOVIĆ et al., 2009; VRBANAC et al., 2010), ali i u arhivi tvrtke INA d.d.. Ti podatci sadrže opise geološke građe, tj. litološkog sastava, litostratigrafskih jedinica, zatim matičnih stijena, tektonskih odnosa, kao i brojnih podataka o proizvodnji iz polja, ali i regionalno u prostoru zapadnog dijela Savske depresije.

Geofizička istraživanja u zadnjih deset do dvadeset godina obuhvatila su snimanje novih seizmičkih profila, posebno na rubovima strukture Kloštar. Time su bolje određene granice ležišta, ali i određeni tektonski odnosi prema okolnim strukturama. Do danas je u polju Kloštar otkriveno 20 ležišta svrstanih u 5 jedinica temeljenih na litološkom sastavu, a koje se mogu korelirati s litostratigrafskim jedinicama Savske depresije. Većina ležišta se nalaze u stijenama miocenske starosti, a jedno je u stijenama podine miocena (VELIĆ et al., 2008*). Mlađa ležišta u pješčenjacima starosti gornjeg panona i donjeg pontona određena su kao slojevitost ležišta (prema klasifikaciji BROD, 1945) ili ležišta strukturnoga tipa (prema klasifikaciji LEVORSEN, 1956). Starija miocenska ležišta (baden do donji panon) pripadaju kombiniranim (strukturno-stratigrafskim) zamkama prema Levorsenu i slojnim ležištima s tektonskim i litološkim ekranom prema Brodu. Najstarije paleozojsko ležište svrstano je u masivna ležišta prema klasifikaciji Broda (1945), odnosno u strukturna prema klasifikaciji Levorsena (1956).

Neformalne, operativne jedinice razvrstane su pod sljedećim nazivima:

1. I. pješčenjačka „serija“; ležišta Z, Y, V, U, T, S, R, Q, P, O, I i K
2. II. pješčenjačka „serija“; ležišta Alfa, Beta i Gama
3. Prevalencienezijske naslage;
4. „Miocen“; ležišta VI, V, IV, III i II
5. „Temeljno gorje“.

Prema stanju u 2009. godini od ukupno 197 bušotina na polju (**slika 2.2**), 57 ih je označeno kao mjerne, 73 su bile tehnički likvidirane, 5 utisnih za odlaganje tehnološke vode u slojeve (ne i za povećanje iscrpka) i 62 su bile proizvodne. Nafta se pridobivala pomoću dubinskih sisaljki iz ležišta s prosječne dubine od 800 do 1000 m. Također se uz naftu proizvodi i plin otopljen u nafti. Sabirna stanica posjeduje tri separatora za odvajanje kapljevine od plina, te zatim odvajanje vode od nafte (VELIĆ et al., 2008*).



Slika 2.2: Karta lokacija bušotina na polju Kloštar (VELIĆ et al., 2008*)

Posljednjih godina napravljene su brojne geostatističke analize podataka prikupljenih u stijenama polja Kloštar. Većina rezultata objavljena je u znanstvenim i stručnim člancima, prvenstveno u časopisima „Nafta“ i „Geologia Croatica“. Tako su BALIĆ et al. (2008) prikazali primjenu različitih interpolacijskih metoda u pješčenjačkim ležištima spomenutog polja, te odabrali tehniku običnoga kriginga kao najprimjereniju za kartiranje poroznosti. Zatim su MALVIĆ & BALIĆ (2009) opisali značenje linearnosti i proračun Lagrangeovog linearnoga multiplikatora u jednadžbama običnog kriginga također na primjeru podataka iz polja Kloštar. CVETKOVIĆ et al. (2009) primijenili su neuronske mreže na rekonstrukciji zasićenja vodom i litološkog sastava u ležištima toga polja. NOVAK ZELENKA et al. (2010) su po prvi puta u hrvatskom dijelu Panonskoga bazena izradili dubinskogeološke karte vjerojatnosti distribucije poroznosti u donjopontskim ležištima polja Kloštar tehnikom indikatorskog kriginga.

Upravo zbog dostupnosti podataka i velikog broja već izrađenih analiza, odlučeno je, u okviru ove doktorske disertacije, napraviti svojevrstan nastavak radova na polju Kloštar. To znači daljnje analize i mogućnosti primjene novih geostatističkih (determinističkih interpolacijskih i stohastičkih) metoda, koje bi omogućile najdetaljnija kartiranja litofacijesa do sada te dale novu sliku podzemlja i taložnih okoliša tijekom gornjeg miocena. Ovaj rad se posebno nastavlja na rezultate geomatematičkih istraživanja koja su zadnjih godina načinili BALIĆ et al. (2008), CVETKOVIĆ et al. (2009) te NOVAK ZELENKA et al (2010). Treba svakako spomenuti jednu vrlo obimnu i možda prvu statističku i palinspastičku analizu velikog broja podataka na bliskoj strukturi Ivanić-Grad, koju su prije gotovo četrdeset godina načinili HERNITZ & JURAK (1973). Statističkom analizom autori su ispitali stohastičku zavisnost debljina formacija i dubina repernih horizonata te utvrdili visoke vrijednosti koeficijenata korelacije. Rezultati statističkih analiza potvrdili su paleotektonsku rekonstrukciju, pa je to bio poticaj da se ista sad pokuša dokazati novim metodama.

3. STRATIGRAFSKI MODEL POLJA KLOŠTAR S OSVRTOM NA POLOŽAJ UNUTAR ZAPADNOG DIJELA SAVSKE DEPRESIJE

Kako bi se mogao napraviti detaljni model ležišta u naftno-plinskom polju Kloštar, vrlo je važno opisati stratigrafske odnose i uvjete koji su vladali u vrijeme kasnog panona i ranog pontaa. Budući da o tome postoje brojni radovi, u ovom poglavlju najprije će se dati kratak prikaz taložnog modela klastičnih naslaga Savske depresije, a zatim će se opisati i neogensko-kvartarne naslage u samom polju.

Početak oblikovanja Savske depresije smješta se u donji miocen, a po najnovijim shvaćanjima (ĆORIĆ et al., 2009) u srednji miocen, tj. baden. Njezin razvoj nastavio se tijekom gornjeg miocena, pliocena i završno kvartara. Početak transgresije u cijeloj depresiji zabilježen je u sedimentima donjeg i srednjeg miocena. Litostratigrafski pripadaju formaciji Prečec (**slika 3.1**) (ŠIMON, 1970, 1973.). Početak ekstenzije u cijelom Panonskom bazenu pretpostavljen je u otnangu i karpatu (ROYDEN, 1988; RÖGL, 1996, 1998; SAFTIĆ et al., 2003; MALVIĆ & VELIĆ, 2011).

Sedimentacijski prostor u Hrvatskoj u vrijeme ekstenzije činili su obalni dijelovi uz "otočne gore" (Medvednica, Papuk i Psunj), zatim dijelovi Savske i Dravske depresije, Slavonsko-srijemska i Murska depresija (npr. VRBANAC, 1996; MALVIĆ, 2003). Prema RÖGLU (1996, 1998) marinski prostori u otnangu i karpatu smješteni su uglavnom na zapadu u području Hrvatskog zagorja i Murske depresije, dok se slatkovodni prostori nalaze istočno od njih.

ĆORIĆ et al. (2009) navode da najstarije miocenske naslage pripadaju badenu. Diskordantno naliježu na paleozojsko-mezozojsku podinu, a slijed sedimenata započinje konglomeratima, pješčenjacima, siltovima, te se nastavlja međusobnom izmjenom pješčenjaka i lapora.

Baden (16,4-13,0 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) je razdoblje u kojem jača ekstenzijska tektonika, uz otvaranje nekoliko glavnih romboidnih taložnih bazena (engl. *pull-apart*) ranga depresija, te niza manjih (HORVATH, 1995; PAVELIĆ, 2001). Tijekom badena marinska se sedimentacija odvija u najvećem dijelu Sjeverne Hrvatske, dok su velike gore (Kalnik, Papuk i Psunj, možda i neke druge) bile otoci (VRBANAC, 1996 i RÖGL, 1996, 1998).

Mehanizmi kojima je taložen siliciklastični materijal u tadašnjem priobalju i plitkom moru bile su aluvijalne lepezne delte (TIŠLJAR 1993; MALVIĆ, 1998, 2006), a izvor materijala lokalni. To podrazumijeva da je većina klastita u delte dospjela trošenjem okolnih dijelova

paleozojskih i mezozojskih stijena. Drugi obilan izvor karbonatnih klastita bili su koralinacejski i brizojski grebeni koji su nastajali u plitkim marinskim sredinama. Kraj badena obilježava taloženje kalcitnih lapora i glinovitih vapnenaca. Sredina postaje mirnija, čemu je glavni razlog slabljenje ekstenzijskih pokreta.

Upravo u takvim mirnim uvjetima oplićavanja započinje sarmat (13,0-11.5 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**), čiji je početak zapravo vrlo teško odijeliti od vršnog dijela badenskih naslaga. Talože se glinoviti lapori i pješčenjaci (VRBANAC, 1996; RÖGL, 1996, 1998).

Donji panon (11,5-9,3 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) obilježava zapunjavanje boćatih plićaka (RÖGL & STEININGER, 1984; VRBANAC, 1996; RÖGL, 1996, 1998; MAGYAR & GEARY, 1999; MAGYAR et al., 1999; MULLER et al., 1999). Naslage litostratigrafski pripadaju formaciji Prkos (ŠIMON, 1970, 1973) (**slika 3.1**), a predstavljene su ritmičnim izmjenama glinovitog vapnenca, siltnog lapora, lapora i pješčenjaka. Na rubovima depresija postojale su manje delte.

Slijedi gornji panon (9,3-7,1 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) koji litostratigrafski odgovara formaciji Ivanić-Grad (**slika 3.1**) (ŠIMON, 1970, 1973). Unutar formacije Ivanić-Grad izdvojena su dva litostratigrafska člana. To su pješčenjaci Okoli i pješčenjaci Iva. Oba su nosioci značajnih količina ugljikovodika u Savskoj depresiji, a detaljno ih je kartirao PLETIKAPIĆ (1969), prikazujući vezu ležišnih stijena formacije Ivanić-Grad u naftnim i plinskim poljima Kloštar, Ivanić, Žutica i Okoli. Također, u svojoj disertaciji pokušava objasniti ulogu Moslavačke gore kao lokalnog izvora detritusa za gornjopanonska ležišta. Iako smatra da je Moslavačka gore u vrijeme kasnog panona bila otok, nikako nije mogla biti glavni izvor materijala. Na temelju količine istaloženog detritusa navodi kako bi s Moslavačke gore trebala biti erodirana prizma visine oko 1200 m. Takvu visinu i tako brzu eroziju teško je pretpostaviti na otoku, gdje su se mogli razviti samo kratki tokovi površinskih voda. Ipak, autor ne isključuje vrlo mali mogući utjecaj Moslavačke gore kao lokalnog izvora detritusa, budući da je kopneno područje bilo oko 200 m visoko. Također je u svojoj disertaciji, na temelju paleogeografske rekonstrukcije dao približne konture otoka, koji je u to vrijeme postojao na području Moslavačkog masiva, te pojas laguna i močvarišta kojima je otok bio odvojen od žala u boćatom okolišu nekadašnjeg jezera.

Litološki su gornjopanonski sedimenti predstavljeni laporima, siltovima i pješčenjacima. Sedimentacija u vrijeme gornjeg panona označava početak znatne promjene taložnog okoliša, kada počinje dominirati mehanizam turbiditnih struja. Takva sedimentacija odvijala se ciklički turbiditnim tokovima u boćatim do (kasnije) slatkovodnim sredinama (RÖGL &

STEININGER, 1984; VRBANAC, 1996; RÖGL, 1996, 1998). Pješčenjaci koji čine gornjopanonska ležišta su najčešće sitnozrnati, s poroznošću od 10 do 33%, a vrijednosti se smanjuju od sjeverozapada prema jugoistoku. Morfologija pješčenih tijela prati smjer taložnih struja (SAFTIĆ et al., 2003), generalno sjever–sjeverozapad/jug-jugoistok. Glavni izvor sedimenata bio je u Istočnim Alpama, od kuda je višestrukim turbiditnim strujama, uz regionalne tektonske rampe, prenošen do mjesta taloženja (ŠIMON, 1980; MALVIĆ et al. 2005).

Sedimenti donjeg pontu (7,1-6,3 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) litostratigrafski odgovaraju formaciji Kloštar Ivanić (ŠIMON, 1970, 1973) (**slika 3.1**). Predstavljani su izmjenom pješčenjaka i lapora. Pješčenjaci su taloženi djelovanjem turbiditnih tokova u najdubljim dijelovima taložnog prostora, a izvor sedimenata također bile su Alpe. U mirnim razdobljima, kada turbiditne struje nisu bile aktivne jer nije bilo gravitacijske nestabilnosti i dovoljne količine akumuliranog materijala, taložili su se lapori, kao sedimenti karakteristični za mirne uvjete dubljevodnih okoliša. Donjopontske naslage vrlo je detaljno razlučio SAFTIĆ (1998) povezujući litostratigrafske članove naslaga turbiditnog podrijetla, u zapadnom dijelu Savske depresije u genetske stratigrafske jedinice. Ova vrsta jedinica omogućila je najdetaljniju korelaciju, jer one na temelju fizičkih svojstava probušenih stijena objedinjuju istovremene taložne okoliše.


U gornjem pontu (6,3-5,6 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) polako dolazi do promjene taložnih mehanizama koji ponovno postaju lokalni (delte), te do zapunjavanja taložnog prostora. Naslage gornjeg pontu litostratigrafski pripadaju formaciji Široko polje (ŠIMON, 1970, 1973) (**slika 3.1**) i predstavljene su glinovitim laporima, laporovitim glinama i glinama te pojavama lignita, karakterističnim za slatkovodni jezerski okoliš (RÖGL & STEININGER, 1984; VRBANAC, 1996; RÖGL, 1996, 1998).

U vrijeme pliocena i dijela pleistocena (5,6-0,0 mil. god.; HAQ & EYSINGA, 1998) (**tablica 3.1**) sedimentacija se nastavila u preostalim plićim ostacima Panonskog jezera, zapunjavajući ga laporovitim glinama, laporima te rjeđe pjeskovitim laporima, a tek lokalno u deltama i pijescima. Ove naslage pripadaju formaciji Lonja (ŠIMON, 1970, 1973) (**slika 3.1**). Nešto kasnije talože se i krupnozrnati klastiti (šljunak, pijesak) te glina uz pojavu lignita. U kvartaru dolazi do klimatskih promjena i konačne inverzije struktura, koje su danas antiklinale (FRISCH et al., 1998), te taloženja sedimenata karakterističnih za periode glacijala i interglacijala, a o njihovim taložnim okolišima može se više naći u radovima VELIĆ & SAFTIĆ (1991), VELIĆ & DURN (1993), VELIĆ et al. (1999), BAČANI et al. (1999). Najmlađe naslage su nekonsolidirani sedimenti prapor, glina, humus, šljunak i pijesak.

Opisane litostratigrafske formacije, kao i taložni okoliši Savske depresije prikazani su na **slici 3.1.**

Tablica 3.1: Vrijeme trajanja pojedinih kronostratigrafskih jedinica, razdoblja oblikovanja hrvatskog dijela Panonskog bazena te dominantni mehanizmi transporta i taloženja materijala (MALVIĆ & VELIĆ, 2011)


starost u milijunima godina																			
19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
otnang	kar-pat	baden				sarmat	panon				pont		dacij, romanij				pleistocen, holocen		
							rani		kasni		rani	kasni							
moguća djelomična ekstenzija		prva transtenzijska faza				prva transpresijska faza		druga transtenzijska faza						druga transpresijska faza					
		lokalno trošenje stijena s kopna i mehanizam donosa aluvijalnim lepezama				oplićavanje i smanjenje saliniteta		udaljeni klastični izvor materijala i mehanizam donosa turbiditnim strujama						završno strukturno oblikovanje, migracija ugljikovodika, kontinentalni okoliši					




Slika 3.1: Formacije u Savskoj depresiji (prilagođeno iz SAFTIĆ et al., 2003; *početak ekstenzije prema ĆORIĆU et al., 2009; megaciklusi prema VELIĆ et al., 2002)

3.1. STRATIGRAFSKI PREGLED NEOGENSKO-KVARTARNIH NASLAGA U POLJU KLOŠTAR

Ležišta ugljikovodika u polju Kloštar nalaze se u stijenama u podini miocena, zatim u naslagama badena, sarmata, donjeg i gornjeg panona te donjeg pontaa. Na **slici 3.2** prikazan je detaljan geološki stup bušotine Klo-62 u kojoj je utvrđeno zasićenje naftom u gornjopanonskim ležištima, a na **slici 3.3** može se vidjeti detaljan geološki stup bušotine Klo-145 s utvrđenim naftnim i pliskim zasićenjem u donjopontskim ležištima. U hrvatskoj naftnogeološkoj praksi se paleozojske stijene u podini miocena često nazivaju „temeljnim gorjem“. Na njima sedimenti badena i sarmata označavaju početak transgresije na cijelom prostoru. Od stijena u podini dijeli ih tektonsko-erozijska diskordancija. Na badenske i sarmatske sedimente uglavnom konkordantno naliježu naslage panona, pontaa te pliocena i kvartara. U sljedećim potpoglavljima bit će opisane stijene prema njihovom stratigrafskom slijedu.



Slika 3.2: Složeni geološki stup kroz bušotinu Klo-62



Slika 3.3: Složeni geološki stup kroz bušotinu KLO-145

Kako bi se utvrdila moguća razlika u mineralom sastavu između stijena gornjopanonske i donjopontske starosti, determinirani su uzorci jezgara iz Ininog skladišta jezgara Mramor Brdo. Pregledano je i opisano 13 jezgara, a mineralni sastav u njima nije se mnogo razlikovao. Gornjopanonski pješčenjaci nešto su kompaktniji u odnosu na donjopontske te ono što je važnije, sadrže više tinjaca. Osim gornjopanonskih i donjopontskih jezgara, pregledane su i fotografirane i ostale jezgre različitih kronostratigrafskih pripadnosti te su prikazane slikom 3.4.

Donji pont		Klo-22 (977,5-983,5) V. metar	tinjčasti pješčanjak
Gornji panon		Klo-74 (1366,4-1372,4) II. metar	tinjčasti pješčanjak
Donji panon		Klo-9 (1378,8-1384,3) I. metar	lapor
Baden		Klo-67 (1520,6-1524,6) I. metar	brečo- konglomerat
Temeljno gorje (paleozoik)?		Klo-1 (1212,5-1217,9) I. metar	trošena metamorfna stijena

Slika 3.4: Fotografije jezgara iz različitih ležišta polja Kloštar s odgovarajućim kronostratigrafskim jedinicama

3.1.1. „Temeljno gorje“

Stijene „temelnog gorja“ su magmatiti i metamorfiti paleozojske starosti. Tektonika, kao i dugo površinsko izlaganje uzrokovali su njihovu raspucanost i trošenje. Kontakt s miocenskim stijenama predstavljen je tektonsko-erozijskom diskordancijom, vidljivom na EK dijagramu kao granica „Tg“ (**slika 3.1**). Unutar ovih stijena postoji ekonomsko zasićenje ugljikovodicima (ležište I) u izdignutim dijelovima paleoreljefa, (engl. *burried hill*).

3.1.2. Baden i sarmat

Diskordantno na stijene temeljnog gorja naliježu naslage badena i sarmata. Iako je riječ o tektonsko-erozijskoj diskordanciji, početak slijeda miocenskih naslaga nije lako uočljiv zbog vrlo sličnog litološkog sastava. Na EK dijagramima nalaze se između repera Tg i Rs7 (**slika 3.1**). Slijed naslaga započinje konglomeratima, konglomeratičnim pijescima te pijescima s glinovitim proslojcima. Na njima slijede lapori i pješčenjaci te pjeskoviti, bituminozni lapori s proslojcima sitnozrnatih pješčenjaka. Ležišta ugljikovodika nalaze se u stijenama na južnom i istočnom dijelu polja (ležišta VI, V, IV, III i II). Ležišne stijene uglavnom su krupnozrnati klastiti.


3.1.3. Donji panon

Konkordantno, na sarmatske naslage naliježu sedimenti donjeg panona. Na EK dijagramima nalaze se između repera Rs7 i Rs5 (**slika 3.1**). Predstavljaju ih bijeli, tvrdi kalcitni lapori, koji se mogu razlikovati od sarmatskih lapora, prvenstveno po pojavi provodnih fosila (*Radx croatica*, *Radx cobelti*, *Limnaea extensa*). Lapori su proslojeni sitnozrnatim pješčenjacima, koji su u južnom dijelu polja zasićeni naftom. Unutar ovih naslaga utvrđene su značajne količine ugljikovodika u ležištu nazvanom Prevalencijenezijske naslage.


3.1.4. Gornji panon

Sedimenti gornjeg panona omeđeni su u podini reperom Rs5, dok ih od krovine dijeli reporni sloj Z' (**slika 3.1**) i rasprostiru se unutar cijelog polja Kloštar. Litološki se radi o pješčenjacima i laporima, koji se međusobno izmjenjuju kako vertikalno, tako i lateralno. Zasićenje ugljikovodicima je u jugozapadnom dijelu polja, unutar tri pješčenjačka ležišta nazvana (od najstarijega) Alfa, Beta i Gama. Ti nazivi mogu se smatrati neformalnim litostratigrafskim jedinicama ranga sloja. **Slike 3.5, 3.6 i 3.7** prikazuju rasprostiranje gornjopanonskih ležišta, dok se na **slici 3.8**, preklapanjem kontura ležišta sa **slikom 3.5, 3.6 i 3.7** može pratiti pomicanje granice taložnog okoliša pješčenjaka prema sjeveroistoku. Granice taložnih okoliša rekonstruirane su na temelju bušotinskih podataka, odnosno na temelju bušotina u kojima je dokazan lapor. U vrijeme taloženja ležišta Gama nastaje normalni rasjed po kojem dolazi do spuštanja sjeveroistočnog i izdizanja jugozapadnog dijela


21



Slika 3.6: Današnji položaj gornjopanonskog ležišta Beta



Slika 3.7: Današnji položaj gornjopanonskog ležišta Gama



Slika 3.8: Granice taložnog okoliša (područje slojeva pješčenjaka) gornjopanonskih ležišta Alfa, Beta i Gama

U okviru izrade studije o polju Kloštar na projektu „Unapređivanje geoloških interpretacijskih metoda u cilju povećanja iscrpka unutar pješčenjačkih ležišta“ (VELIĆ et al. 2008*) napravljene su petrografske-sedimentološke i biostratigrafske analize uzoraka ležišnih stijena iz polja Kloštar, a opisi jezgara korišteni u ovom potpoglavlju preuzeti su iz te studije. Analizirane jezgre gornjopanonskih ležišta prikazane su na **slikama 3.9, 3.10, 3.11 i 3.12**. **Tablica 3.2** prikazuje ležišne parametre dobivene laboratorijskim analizama na jezgrama iz gornjopanonskih ležišta. Izvor podataka prikazanih u tablici bila je arhiva bušotina tvrtke INA (*Dossieri* bušotina eksploatacijskog polja Kloštar*).

Tablica 3.2: Kolektorska svojstva na temelju analiza jezgara gornjopanonskih ležišta


Bušotina	Dubina jezgre (m)	Ležište	Srednja poroznost (%)	Dubine ležišta (m)
Klo-5	1339,2-1345,2	Gama	29,5	1330,0-1350,0
Klo-60	1487,0-1493,0	Alfa	20,2	1486,5-1500,0
Klo-64	1374,9-1380,7	Gama	29,8	1350,0-1388,5
Klo-74	1366,4-1372,4	Beta	23,4	1358,0-1378,5
Klo-76	1369,0-1374,0	Beta	23,8	1362,5-1377,0
Klo-78	1385,2-1390,3	Beta	23,7	1376,5-1390,0
Klo-82	1404,6-1411,7	Beta	22,5	1396,5-1415,0
Klo-83	1375,7-1382,0	Beta	22,4	1368,5-1377,0
Klo-88	1378,0-1381,4	Gama	27,6	1291,0-1396,0

a) Bušotina Klo-88:



Slika 3.9: Uzorak arkoznog arenita iz ležišta Gama u bušotini Klo-88 (1378,0 – 1381,4 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Arenit na **slici 3.9** je svijetlosive boje, drobiv pod prstima i slabo reagira s 10%-tnom otopinom HCl kiseline. Na **slici 3.10** prikazan je mikroskopski izbrusak istog arenita, u kojem se mogu jasno vidjeti zrna kvarca, plagioklasa, K-feldspata, muskovita, kloritiziranog biotita, čerta, mikrita i odlomaka granitoidnih stijena. Vezivo je kalcitni i dolomitni cement. Uz primarnu intergranularnu poroznost razvijena je i sekundarna, koja je nastala otapanjem cementa (**slika 3.10** desno).




Slika 3.10: Mikroskopski izbrusak arkoznog arenita (Klo – 88, 1378,0 – 1381,4 m, I m) (lijevo) i sekundarna poroznost u istom arkoznom arenitu (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

b) Bušotina Klo-82:



Slika 3.11: Uzorak litoarenita iz ležišta Beta u bušotini Klo-82 (1404,6 – 1411,7 m, II m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)


Litoarenit iz ležišta Beta, prikazan na **slici 3.11** je žućkastosmeđe do sivkasto-narančaste boje, drobiv je pod prstima te slabo reagira s 10%-tnom HCl kiselinom. Mikroskopski izbrusak (**slika 3.12**) prikazuje uglata do poluzaobljena zrna kvarca, plagioklasa, listiće muskovita, kloritiziranog biotita, klorita, čestice kvarcita, karbonata te sporadično kalcitizirane mikrofosile. Vezivo je kalcitni i dolomitni cement. Stijena ima razvijenu primarnu međuzrnsku poroznost (**slika 3.12** desno).




Slika 3.12: Mikroskopski izbrusak litoarenita (Klo – 82, 1404,6 – 1411,7 m, II m) (lijevo) i intergranularna poroznost (plavo) u istom uzorku (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

3.1.5. Donji pont


Naslage su ograničene repnim slojevima Z' (u podini) i Δ (u krovini). Litološki odgovaraju sitnozrnatim pješčenjacima i laporima. Pješčenjaci su uglavnom taloženi u sjevernom i zapadnom dijelu polja, dok se lapori nalaze u južnom i istočnom. Ukupno je 17 pješčenjačkih slojeva nazvanih Z, Y, V, U, T, S, R, Q, P, O, N, M, L, K, I, H i, G. Najznačajnija ležišta u zasićenju naftom su V, U i T. U intervalima I i K zabilježene su tek pojave nafte, u intervalima G i H pojave plina, dok su intervali L, M i N uglavnom zasićeni vodom. Na **slikama 3.13** do **3.22** prikazano je rasprostiranje donjopontskih pješčenjačkih ležišta. Može se pratiti pomicanje linije zalaporenja od početka taloženja najstarijeg ležišta Z pa sve do završetka taloženja ležišta O. Također se može pratiti progradacija (**slike 3.13** do **3.17**), zatim retrogradacija (**slike 3.17** do **3.18**) te ponovna progradacija (**slike 3.18** do **3.22**), što ukupno čini dva ciklusa. Današnje granice ležišta zemljopisno su bliske njihovom položaju prije šest do sedam milijuna godina, no promijenila se struktura samog taložnog prostora. Točnije, došlo je do izdizanja tijekom druge transtenzijske faze (**tablica 3.1**).




Slika 3.13: *Današnji položaj donjopontskog ležišta Z*




Slika 3.14: Današnji položaj donjopontskog ležišta Y




Slika 3.15: *Današnji položaj donjopontskog ležišta V*




Slika 3.16: *Današnji položaj donjopontskog ležišta U*




Slika 3.17: *Današnji položaj donjopontskog ležišta T*




Slika 3.19: *Današnji položaj donjopontskog ležišta R*



Slika 3.20: Današnji položaj donjopontskog ležišta Q



Slika 3.21: Današnji položaj donjopontskog ležišta P



Slika 3.22: Današnji položaj donjopontskog ležišta O

Opisi jezgara donjopontskih ležišta preuzeti su iz studije VELIĆ et al. (2008)*, a analizirane jezgre prikazane su na **slikama 3.23, 3.24, 3.25, 3.26, 3.27, 3.28, 3.29 i 3.30**. **Tablica 3.3** prikazuje prosječne ležišne parametre dobivene laboratorijskim analizama na jezgrama iz donjopontskih ležišta, odnosno na bušotini Klo-104 rezultate triju mjerenja na bočnim jezgrama. Izvor podataka prikazanih u tablici također je bila je arhiva bušotina tvrtke INA (*Dossieri* bušotina eksploatacijskog polja Kloštar*).

Tablica 3.3: Kolektorska svojstva na temelju analiza jezgara donjopontskih ležišta

Bušotina	Dubina jezgre (m)	Dubina bočne jezgre (m)	Ležište	Poroznost (%)	Dubine ležišta (m)
Klo-16	947,7-953,7		V	28,0	946,0-950,0
Klo-22	977,5-983,5		U	15,8	980,0-989,0
Klo-26	993,6-998,5		R	6,3	994,0-996,0
Klo-95	914,0-919,0		Q	9,4	912,0-918,0
	978,3-983,3		U	21,2	971,0-984,0
Klo-104		915,0	T	37,6	912,5-918,5
		921,0	U+V	27,7	920,0-925,5
		923,0	U+V	33,9	920,0-925,5

Postoje detaljne sedimentološke analize stijena iz tri bušotine:


a) Bušotina Klo-1:



Slika 3.23: Uzorak proslojka pjeskovitog fosilifernog lapora u ležištu R iz bušotine Klo-1 (911,9 – 917,9 m, 1 m) s makrofosilima (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Pjeskovit fosiliferni lapor (**slika 3.23**) burno i kratko reagira s 10%-tnom otopinom HCl. U mikroskopskom preparatu vidljiv je detritus veličine silta i sitnog pijeska (kvarc, feldspati, kalcit, dolomit, sporadično muskovit i čestice kvarcita i čerta) i fosilni ostaci, uglavnom školjkaša. Sediment ima slabo razvijenu otvorenu mikrofrakturnu poroznost (**slika 3.24**).

Prema VRBANCU (1996) u to doba stvara se veza između Panonskog i Dacijskog bazena pa sredina postaje "kaspibrakična", dok je prema RÖGLU (1996, 1998) taložna sredina slatkovodna. Taloženje lapora odvijalo se u razdobljima između aktivnosti dviju turbiditnih struja.




Slika 3.24: Pjeskoviti fosiliferni lapor sa slabo razvijenom otvorenom mikrofrakturnom poroznošću, (Klo – 1, 911,9 – 917,9 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

b) Bušotina Klo-57:



Slika 3.25: Uzorak litoarenita u vršnom dijelu ležišta TUV u bušotini Klo-57 (788,9 – 793,3 m, III. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Litoarenit u vršnom dijelu amalgamiranog ležišta TUV (**slika 3.25**) drobi se pod prstima i slabo reagira s 10%-tnom otopinom klorovodične kiseline (HCl). Detritus je slabo sortirani, srednjozrnati, a sastoji se od kvarca, feldspata, muskovita, kloritiziranog biotita, klorita, čestica kvarcita, čerta, niskometamorfni škrljavaca, pelita i karbonata. Vezivo je karbonatni cement. U mikroskopskom preparatu vidljivo je da pješčenjak sadrži organsku tvar u obliku lamina (**slika 3.26** - lijevo), a stijena ima slabo razvijenu primarnu poroznost (**slika 3.26** - desno). Taložen je turbiditnim strujama velike gustoće u dubokim dijelovima taložnog prostora.




Slika 3.26: Litoarenit s laminama organske tvari, (Klo – 57, 788,9 – 793,3 m, III. m) (lijevo) te isti uzorak litoarenita sa slabo razvijenom intergranularnom poroznošću (plavo, desno), (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)



Slika 3.27: Uzorak sitnozrnatog litoarenita u vršnom dijelu ležišta TUV u bušotini Klo-57 (788,9 – 793,3 m, II. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Drugi metar iste jezgre (**slika 3.27**) siltoznog litoarenita, koji se već i po boji razlikuje od trećeg metra iste jezgre, drobitiv je pod prstima i nema reakcije s 10%-tnom klorovodičnom kiselinom (HCl). Ima gusto pakirani detritus, koji se sastoji od zrna kvarca, feldspata, muskovita, biotita, kloritiziranog biotita, klorita, granata i cirkona, malo opakih minerala te

čestica stijena kvarcita, čerta, dolomita i vapnenca (**slika 3.28**, lijevo). Detritus je povezan kalcitnim i dolomitnim cementom. Intergranularna poroznost vidljiva je na **slici 3.28** (desno).




Slika 3.28: Sitnozrnati litoarenit (Klo – 57 (788,9 – 793,3 m, II. m)) (lijevo) te isti litoarenit s dobro razvijenom intergranularnom poroznošću (desno) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

c) Bušotina Klo-12:



Slika 3.29: Uzorak proslojka lapora u ležištu Z u bušotini Klo-12 (1071,0 – 1073,0 m, I m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

Proslojak lapora iz ležišta Z (**slika 3.29**) u bušotini Klo-12 reagira s 10%-tnom klorovodičnom kiselinom (HCl). Osnova mu je glinovito – karbonatna, a sadrži i nešto zrna kvarca, feldspata i sericita. Poroznost je izražena u obliku niza subparalelnih i isprekidanih mikropukotina (**slika 3.30**).



Slika 3.30: Lapor s otvorenom mikrofrakturnom poroznošću, (Klo – 12, 1071,0 – 1073,0 m, I. m) (autor TADEJ, J., iz studije: VELIĆ et al., 2008*)

3.1.6. Gornji pont

Sedimenti gornjeg pontu nalaze se između repnih slojeva Δ i α' . Konkordantno naliježu na naslage donjeg pontu, a čine ih pjeskovito-glinovite naslage. Udio pjeskovite komponente povećava se u smjeru mlađih naslaga. Sedimenti starosti gornjeg pontu rasprostranjeni su unutar cijelog polja Kloštar.


3.1.7. Dacij, romanij, pleistocen i holocen

Podina je određena reperom α' . Stijene pliocenske starosti litološki su predstavljene izmjenama glina i krupno do srednjozrnatih pijesaka. Pleistocenske i holocenske naslage sastoje se uglavnom od pjeskovite gline, a česte su i pojave vapnenačkih konkreција.

4. NEOGENSKO-KVARTARNI TEKTONSKI POKRETI U SAVSKOJ DEPRESIJI TE NJHOV ODRAZ U PODRUČJU STRUKTURE KLOŠTAR


Cikličnost slijeda neogenskih sedimenata u hrvatskom dijelu Panonskog bazena bila je prepoznata i opisana u brojnim radovima npr. u FILJAK et al. (1969), PLETIKAPIĆ (1969), ŠIMON (1980), a prema VELIĆ et al. (2002) neogenski slijed sedimenata može se podijeliti u tri taložna megaciklusa. Megaciklusi su međusobno odijeljeni regionalnim diskordancijama.

Diskordancija u podini neogena je tektonsko erozijska, a predstavljena je repnim horizontom Pt ili Tg. Sljedeća regionalna diskordancija je u podini panonskih sedimenata, a na EK dijagramima prepoznata je kao repni horizont Rs7. Također je tektonsko-erozijskog karaktera, a nastala je kao rezultat izdizanja i erozije uzrokovanih prvom neogenskom transpresijom (npr. TARI, 1994; CSONTOS et al. 2002). Treća velika diskordancija je u podini pliocena (reperi horizont α'), a nastala je također kao rezultat kompresijske tektonike tijekom pliocena i kvartara (SAFTIĆ et al., 2003; **slika 4.1**)



Slika 4.1 Seizmički profil kroz Savsku depresiju s interpretiranim regionalnim repnim horizontima i rasjednim plohama (SAFTIĆ et al., 2003)

Neogenski sedimenti mogu se podijeliti u tri taložna megaciklusa (VELIĆ et al., 2002). Prvi, najstariji taložni megaciklus sadrži stijene različitog litološkog sastava starosti ranog i srednjeg miocena. Utjecaj tektonike na sedimentaciju u sin-riftnoj fazi je velik, a posljedica je raznolikost u uvjetima taloženja i brojnost litofacijesa (SAFTIĆ et al., 2003; **slika 4.2**).



Slika 4.2: Kompilacijski geološki stup Savske depresije (SAFTIĆ et al., 2003)

Za ekstenzijsku tektoniku sin-riftna faze svojstveno je nastajanje utonulih (engl. *pull-apart*) struktura. Takve strukture posljedica su djelovanja horizontalne komponente stresa i nastaju uz rasjede s pomakom po pružanju. Kako je ekstenzija Istočnih Alpi u području današnjeg Panonskog bazena tijekom srednjeg miocena uzrokovala znatnu prostornu translaciju, za očekivati je da je u JZ rubnom području Panonskog bazena bilo puno takvih rasjeda i to i lijevih i desnih. Često se nazivaju negativnim cvjetnim strukturama (engl. *negative flower structures*).

Sedimenti drugog taložnog megaciklusa (**slika 4.2**) taloženi su u vrijeme post-riftna termalne subsidencije (ponovne ekstenzije) bazena (npr. HORVATH & TARI, 1999). Starosti su kasnog miocena, a prema litološkom sastavu su pješčenjaci i lapori sa svim prijelaznim litofacijesima (VELIĆ et al., 2002). U zapadnom dijelu Savske depresije debljina panonsko-pontskih sedimenata iznosi oko 2000 m. Okoliši taloženja karakteristični za drugi taložni megaciklus bili su jezerski i aluvijalno-terestrički. Prema regionalnoj seizmičkoj interpretaciji

u Savskoj depresiji (IVKOVIĆ et al., 2000) naslage od panona pa do kvartara se mogu podijeliti na one istaložene turbiditima, zatim dubokovodnim deltama, koje postupno oplićavaju pa sve do aluvijalnih sedimenata.

Naslage trećeg taložnog megaciklusa (pijesci, gline i šljunci s pojavama lignita) nastale su inverzijom većine struktura u rubnim dijelovima taložnih bazena tijekom pliocena i kvartara (**slika 4.2**), kada dolazi do pretaložavanja najmlađih sedimenata u pretežno terestičkim okolišima (SAFTIĆ, 2003). Normalni rasjedi, koji su bili aktivni tijekom ekstenzijske faze, reaktiviraju se i mijenjaju karakter pomaka, a u izdignutim područjima formiraju se brojne transpresijske strukture.

Tablica 4.1 prikazuje tektonsku aktivnost tijekom neogena, kronostratigrafsku i pripadajuću joj litostratigrafsku jedinicu te paleookoliš u kojem su neogenski sedimenti taloženi.

Tablica 4.1: Tektonska aktivnost tijekom neogena, sedimenti i paleookoliši


Apsolutna starost	Kronostratigrafska jedinica	Litostratigrafska jedinica u Savskoj depresiji	Debljina sedimenata u Savskoj depresiji (m) (ŠIMON, 1980)	Paleookoliš	Tektonika (MALVIĆ & VELIĆ, 2011)	Taložni megaciklus (VELIĆ et al. 2002)
6,3-0,0	Pl, Q	Formacija Lonja	100-800	Aluvijalno-terestički	Druga transpresija	Treći taložni megaciklus
	M ₇ ²	Formacija Široko Polje	400-750			
11,5-6,3	M ₇ ¹	Formacija Kloštar Ivanić	200-700	Bočato-slatkovodni	Druga transtenzija	Drugi taložni megaciklus
	M ₆ ²	Formacija Ivanić Grad	200-300			
	M ₆ ¹	Formacija Prkos	25-200	Jezerski		
13,0-11,5	M ₅	Formacija Prečec	100-700	Marinski	Prva transpresija	Prvi taložni megaciklus
16,4-13,0	M ₄				Prva transtenzija	

4.1. STRUKTURNO-TEKTONSKI ODNOSI U POLJU KLOŠTAR

Paleoreljef temeljnog gorja i ekstenzijska tektonika za vrijeme miocena imali su bitan utjecaj na oblikovanje strukture polja Kloštar. Struktura Kloštar je antiklinala pružanja SZ-JI, prvobitno naslijeđena od paleozojskoga paleoreljefa. Presječena je uzdužnim, normalnim rasjedom, kojem je SI krilo spuštено i čija je aktivnost trajala na prijelazu iz panona u pont. Ostali rasjedi manjeg su skoka, također su normalnog karaktera, a pružanje im je meridijalno. Antiklinala je konačno oblikovana kompresijskom tektonikom u pliocenu i kvartaru.

4.1.1. Strukturne karte i paleotektonski profili antiklinale Kloštar

U radu VELIĆ et al. (2011) prikazano je i opisano šest strukturnih karata područja polja Kloštar. Strukturne karte načinjene su u programu SurferTM metodom kriginga, odnosno tehnikom običnog kriginga i to po repnim horizontima Tg, Rs7, Rs5, Z', R ϕ i α' , koji predstavljaju granice između formacija (**slika 4.3**).




Slika 4.3: Strukturne karte antiklinale Kloštar (VELIĆ et al., 2011)

Na **slici 4.3** prikazan je slijed strukturnih karata konstruiranih isključivo na temelju bušotinskih podataka (VELIĆ et al., 2011). Ovim je kartama prikazana apsolutna dubina korelacijskih horizonata koji omeđuju osnovne litostratigrafske jedinice u koje su svrstani sedimenti raspona starosti od srednjeg miocena (ĆORIĆ et al., 2009) do kvartara, a to su u ovom slučaju karte po podinskoj granici, odnosi taloženja za formacije Prečec (**a**), Prkos (**b**), Ivanić-Grad (**c**), Kloštar Ivanić (**d**), Široko Polje (**e**) i Lonja (**f**).


Osim karata prikazanih na **slici 4.3 a-f**, u izvornom su radu konstruirane i karte probušenih debljina svih spomenutih formacija te se usporedbom jednih i drugih pokušalo napraviti paleotektonsku rekonstrukciju, odnosno rekonstrukciju tektonizma i dinamike razvoja strukture Kloštar. Uz pretpostavku da su paleostrukturni odnosi na kartiranom području bili ključni za raspored debljina novih naslaga koje su prekrile topografski razvedeno dno taložnog bazena, ovo je uglavnom i uspjelo, tako da se moglo kroz odabrane bušotine konstruirati paleotektonski profil (**slike 4.4 i 4.5**) i tako procijeniti promjene pomaka po glavnim rasjedima u različitim fazama razvoja ovog dijela PBS-a. Autori ispravno zaključuju da su u rubnim dijelovima strukturnih depresija (a polje Kloštar je na rubu Savske depresije) strukturne promjene bile pod najvećim utjecajem dinamike pomaka po rubnim depresijskim rasjedima tijekom različitih faza lokalne ekstenzije ili kompresije, a glavni rasjed na području polja (Kloštarski rasjed) pruža se smjerom SZ-JI i zasigurno pripada zoni Sjevernog rubnog rasjeda Savske depresije.

U interpretaciji karata na **slici 4.3** treba ipak biti oprezan, osobito u JZ i SI dijelu kartiranog područja, gdje ima premalo podataka da bi se moglo kartirati samo na temelju bušotina, a to osobito vrijedi za sliku **4.3 a**, tj. na kartu paleoreljeva na kojem se istaložila formacija Prečec. Ipak se na temelju ovih karata i usporedbom s paleotektonskim profilima (**slika 4.5**) može zaključiti da je na području polja Kloštar postojao razvoj nasljednih struktura tijekom taloženja formacija Prečec, Prkos, Ivanić-Grad i Kloštar Ivanić (**slike 4.3 a-d**), odnosno u vremenu od badena do ranog pontaa, jer su glavna izdignuća i uleknine kartiranih horizonata uglavnom na istim mjestima i sličnog pružanja, a Kloštarski se rasjed na paleotektonskom profilu ističe normalnim pomakom uz spuštanje SI krila. Do velike promjene strukturnih odnosa došlo je tijekom kasnog pontaa, u vrijeme taloženja formacije Široko Polje, kad Kloštarski rasjed biva reaktiviran kao reverzni, a JZ od strukture Kloštar nalazi se područje s najvećim debljinama gornjopontskih naslaga (**slika 4.5**). Situacija se zatim opet izmijenila tijekom pliocena, jer se i na paleotektonskom profilu i na karti **4.3 e** može vidjeti da se trasa Kloštarskog rasjeda ocrtava znatnim promjenama debljina, ali sada na suprotan način,

Za ovaj je rad značajno da su VELIĆ et al. (2011) usporedbom strukturnih karata s kartama debljina zaključili da se prva inverzija struktura na području polja Kloštar vjerojatno dogodila već u vrijeme taloženja formacije Kloštar Ivanić, tj. tijekom ranog pontaa. Ovo na drugi način potvrđuje važnost Kloštarskog rasjeda kao paleobatimetrijske granice za taloženje gornjopanonskih pješčenjačkih slojeva na JZ području strukture Kloštar, a onih donjopontskih na SI, kako je to opisano u poglavlju 3, gdje su pomoću karata prostornog rasporeda pješčenjačkih slojeva na temelju litofacijesa prvotno dane naznake taložnog modela gornjopanonskih i donjopontskih naslaga (**slike 3.5-3.7 i 3.13-3.22**).



Slika 4.4: Položaj profila A-B u polju Kloštar (VELIĆ et al., 2011)



Slika 4.5: Paleotektonski profil A-B (VELIĆ et al., 2011): a) nakon taloženja formacije Prečec, b) nakon taloženja formacije Prkos, c) nakon taloženja formacije Ivanić-Grad, d) nakon taloženja formacije Kloštar Ivanić, e) nakon taloženja formacije Široko Polje i f) nakon taloženja formacije Lonja

5. GEOSTATISTIČKE ISTRAŽIVAČKE METODE

U ne tako davnoj prošlosti ležišta nafte i plina, smatrala su se homogenima, najvećim dijelom radi pojednostavljivanja složene slike podzemlja i što lakšeg opisa samog ležišta na temelju ograničenih količina podataka. No, oduvijek se znalo kako ti sustavi nikako nisu homogeni, nego upravo suprotno, heterogeni. Danas nam najsuvremenije metode istraživanja u geologiji, posebice geologiji ugljikovodika, omogućuju da sustave počnemo opisivati kao heterogene. Geostatističke metode, kao napredni geološki alati, koriste se najčešće u razdoblju razrade ležišta, budući da se tada raspolaze s velikim brojem podataka potrebnih za statističku obradbu, a time i postizanje vrlo detaljnih i pouzdanih opisa ležišnih varijabli (poroznosti, propusnosti, mineralnog sastava, zasićenja ili udjela nepropusnih naslaga). Drugim riječima, geostatističke se analize mogu primijeniti jedino u slučaju dovoljnog broja ulaznih vrijednosti. Koliki je minimalni broj ulaznih vrijednosti ponekad je teško odrediti, no smatra se da on ne bi trebao biti ispod 10, odnosno 15 za jako anizotropne skupove podataka (MALVIĆ, 2008). Kod skupova s malim brojem podataka poželjno je izbor između interpolacijskih metoda za svaku odabranu geološku varijablu načiniti pomoću krosvalidacije (MALVIĆ & ĐUREKOVIĆ, 2003). Uz kartiranje niza ležišnih varijabli, poput poroznosti, propusnosti, debljina i dubina ležišta, jedan od važnijih postupaka pri modeliranju ležišta ugljikovodika je i kartiranje litofacijesa. Ovo obilježje važno je točno opisati jer upravo litofacijes ima najveći izravan utjecaj na distribuciju ležišnih varijabli. Stoga je također od iznimne važnosti poznavanje njegova rasprostiranja te što točniji opis granica između litofacijesa. Geostatističke metode primijenjene u disertaciji mogu se podijeliti na determinističke interpolacijske i stohastičke. Determinističke interpolacijske metode su dvije uporabljene metode kriginga, poimence obični i indikatorski kriging. Kako bi se heterogenost podzemlja izrazila kroz vjerojatnosti da je njihov prikaz upravo takav na dobivenoj karti, korištene su također i stohastičke simulacije, i to ponovno kroz dvije metode – sekvencijske Gaussove simulacije i sekvencijske indikatorske simulacije. Tehnikom običnog kriginga u disertaciji su uspješno kartirane granice litofacijesa i to čistih pješčenjaka, laporovitih pješčenjaka, pjeskovitih lapora te čistih bazenskih lapora. Razdiobe spomenutih ležišnih varijabli zatim su načinjene stohastičkim Gaussovim simulacijama od kojih je odabrano njih nekoliko. Nadalje, tehnikom indikatorskog kriginga dobivene su karte vjerojatnosti da je na određenoj lokaciji vrijednost kartirane varijable manja od određene granične vrijednosti. Sličan postupak, no kroz niz realizacija, ponovljen je uporabom sekvencijskih indikatorskih

simulacija. Korištene determinističke interpolacijske i stohastičke metode detaljnije će biti opisane u **podpoglavljima 5.1 i 5.2.**

5.1. METODA KRIGINGA

Prema MALVIĆ et al. (2008) determinizam je *”svojstvo modela koji u sebi sadržava varijable koje je moguće u potpunosti opisati matematičkim jednadžbama”*. Prema tome, deterministički sustav ne smije sadržavati slučajnost bilo koje vrste u opisivanju varijabli, a deterministički modeli za jednaki ulaz daju uvijek isti i ponovljivi rezultat pa tako karta raspodjele poroznosti za isti skup vrijednosti, uz primjenu iste metode, uvijek daje jednaki izlaz. Postoji cijeli niz determinističkih interpolacijskih metoda. Najčešće upotrebljavane u kartiranju naftnogeoloških podataka su metoda inverzne udaljenosti, najbližeg susjedstva, pokretne sredine, te metoda kriginga.

Kartiranju metodom kriginga prethodi variogramska analiza podataka. Određene geološke varijable mogu imati vrlo naglašenu međusobnu zavisnost, a variogramsko modeliranje omogućuje da se takva zakonitost uključi u modeliranje i interpolaciju. Variogramskom analizom može se utvrditi npr. smjer taložnog kanala te moguća veza primarne poroznosti i pružanja kanala ili veza između razdiobe sekundarne poroznosti i smjera stresa, no naravno, variogramskom se analizom ne mora utvrditi niti jedna od takvih pretpostavki, nego se samo može odrediti prostorna zavisnost podataka na analiziranom području. Najkraće, variogramom se u kartiranju određuje važnost i utjecaj susjednih točaka na procjenu u odabranoj lokaciji (MALVIĆ, 2008).

Metoda kriginga je matematički napredna interpolacijska metoda. Njom se procjenjuju vrijednosti određene varijable u točkama mreže. Ime je dobila po rudarskom inženjeru i profesoru na Sveučilištu u Johannesburgu D. G. Krigeu koji je pedesetih godina prošlog stoljeća razvio temelje prostornog predviđanja prilikom procjene koncentracije rudače u ležištu zlata (KRIGE, 1951). Daljnjem razvoju metode pridonose brojni znanstvenici, poglavito MATHERON (1965), ali i niz drugih (npr. de WIJS, 1951; ISAACS & SRIVASTAVA, 1989; HOHN, 1988; DUBRUBLE, 1998).

Cilj metode je određivanje prostorne veze između stvarnih, mjerenih podataka i točke u kojoj se računa procijenjena vrijednost. Prilikom procjene metodom kriginga nužno je koristiti variogramsku analizu. Dakle, ne uzima se u obzir samo udaljenost točaka od mjesta procjene, nego i lokalna varijanca, odnosno varijanca kriginga, što znači da je razlika između očekivanih i procijenjenih vrijednosti minimalna. Prilikom procjene ovom metodom svakom

se podatku dodaje težinski koeficijent (λ). Vrijednost koeficijenta govori koliko su točke međusobno zavisne, odnosno, što je λ veća, točka je prostorno bliža točki procjene i jače utječe na nju. Zbroj svih koeficijenata „ λ “ je jednak jedinici, osim kod tehnike jednostavnog kriginga.

Tehnike kriginga su jednostavni kriging, obični kriging, indikatorski kriging, univerzalni kriging, disjunktivni kriging, kriging s vanjskim driftom i druge, a razlikuju se prema obliku matričnih jednažbi.

Sve tehnike kriginga imaju neki faktor ograničenja te potpuno zadovoljavaju uvjet „najboljeg linearnog nepristranog procjenitelja“ (engl. *Best Linear Unbiased Estimator*, abbr. *BLUE*), osim kod jednostavnog kriginga, gdje procjena nije nepristrana. „Najbolji“ znači da su izračunati koeficijenti potrebni za procjenu određeni minimiziranjem varijance kriginga, „linearni“ označava da je procjena napravljena linearnom kombinacijom mjerenih vrijednosti, „nepristrani“ osigurava da je očekivanje procjene jednako stvarnome očekivanju cijele populacije vrijednosti, dok „procjenitelj“ znači metodologiju (MALVIĆ, 2008).

Procjena krigingom opisuje se izrazom (5.1):

$$z_K = \sum_{i=1}^n \lambda_i \cdot z_i \quad (5.1)$$

gdje su:

z_K – procijenjena vrijednost

λ_i – težinski koeficijent na lokaciji „i“

z_i – stvarna vrijednost na lokaciji „i“.

Vrijednost varijable na lokaciji Z_K procjenjuje se pomoću sume svih postojećih okolnih vrijednosti Z_i otežanih za koeficijent λ . Takav težinski koeficijent računa se pomoću sustava linearnih jednažbi (vidjeti npr. JOURNEL & HUIJBREGTS, 1978; HOHN, 1988; LIEBHOLD et al., 1993).

5.1.1. Obični kriging

Najčešće je upotrebljavana tehnika kriginga. Vrijedi pretpostavka da lokalna srednja vrijednost nije jednaka ili približna srednjoj vrijednosti svih podataka (MALVIĆ et al., 2008). Prilikom procjene koristi se lokalna varijanca samo onih podataka unutar elipsoida

pretraživanja, što je korisno u slučaju manjeg broja ulaznih podataka (oko 15 ili 20). Tada globalna varijanca često ne ocrta lokalne promjene pa odstupanja procjene i srednje vrijednosti mogu biti velike. U tehnici običnog kriginga minimiziran je iznos varijance kriginga pomoću linearnog vanjskog parametra, nazvanog Lagrangeov multiplikator ili faktor (μ). Osim linearnih faktora, također je moguće istovremeno dodati i više ograničavajućih nelinearnih faktora (MALVIĆ, 2008). Faktor ograničenja minimizira pogrešku pa procjena postaje nepristrana. Uvjet prilikom procjene tehnikom običnog kriginga je da je zbroj svih težinskih koeficijenata jednak 1 (MALVIĆ et al., 2008). Izraz za procjenu tehnikom običnog kriginga raspisuje se matričnom jednadžbom (5.2):

$$\begin{bmatrix} \gamma(z_1 - z_1) & \gamma(z_1 - z_2) & \dots & \gamma(z_1 - z_n) & 1 \\ \gamma(z_2 - z_1) & \gamma(z_2 - z_2) & \dots & \gamma(z_2 - z_n) & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \gamma(z_n - z_1) & \gamma(z_n - z_2) & \dots & \gamma(z_n - z_n) & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma(x_1 - x) \\ \gamma(x_2 - x) \\ \vdots \\ \gamma(x_n - x) \\ 1 \end{bmatrix} \quad (5.2)$$

gdje su:

- γ - vrijednost variograma;
- $z_1, \dots, z_n$ - stvarna vrijednost na lokaciji 1 do n;
- x - lokacija u kojoj se procjenjuje nova vrijednost;
- μ - Lagrangeov multiplikator.

Prema izrazu (5.1) procijenjena vrijednost je zbroj svih točaka otežanih odgovarajućim koeficijentom (MALVIĆ et al., 2008).

5.1.2. Indikatorski kriging

Tehnika indikatorskog kriginga koristi se pri kartiranju dviju kategoričkih ili indikatorskih varijabli, prikazanih vrijednostima 0 i 1. Uobičajeno se prikazuju dva različita litotipa, odnosno litofacijesa. Način na koji se litofacijesi mogu odrediti je npr. upotreba graničnih vrijednosti poroznosti, gdje je pretpostavljeno da lokaliteti s većim vrijednostima poroznosti sadrže više pjeskovite komponente u usporedbi s lokalitetima na kojima je izmjerena manja poroznost. Transformacija ulaznih vrijednosti u indikatorske radi se na način da se postojanje ili odsutnost pojedinog litofacijesa određuje pomoću granične vrijednosti varijable. Točnije,

ako se pojedinačni facijes odredi vrijednošću varijable " v_{cutoff} " te ako se postojanje ili odsutnost litofacijesa označi vrijednostima 1 i 0, može se prema izrazu 5.3 odrediti indikatorska varijabla (**slika 5.1**) na sljedeći način (NOVAK ZELENKA et al., 2010):


$$I(x) = \begin{cases} 1 & \text{ako } z(x) \leq v_{cutoff} \\ 0 & \text{ako } z(x) > v_{cutoff} \end{cases} \quad (5.3)$$

gdje su:

$I(x)$ - indikatorska varijabla;

$z(x)$ - mjerena vrijednost;

v_{cutoff} - granična vrijednost.



Slika 5.1: Karta lokacija 38 podataka gdje '1' predstavlja lokacije pješčenjaka, a '0' lokacije ostalih litofacijesa (NOVAK ZELENKA et al., 2010)

Umjesto jedne granične vrijednosti na skup podataka može se primijeniti više njih. U tom će slučaju za „ l “ graničnih vrijednosti jednadžba glasiti 5.4:

$$I(x, v_l) = \begin{cases} 1 & \text{ako } z(x) \leq v_{l, cutoff} \\ 0 & \text{ako } z(x) > v_{l, cutoff} \end{cases} \quad (5.4)$$

gdje su:

$z(x)$ - vrijednost regionalizirane varijable (npr. poroznosti) na lokaciji „ x “;

$I(x, v_l)$ - indikatorska varijabla na lokaciji „ x “ za graničnu vrijednost „ l “;

$v_{l, cutoff}$ - granična vrijednost „ l “.

Izvorni podaci transformirani su u „I“ novih vrijednosti, od kojih svaka poprima vrijednosti od 0 ili 1. Izračun indikatorskog kriginga zahtjeva, naravno, izradu variograma za svaku graničnu vrijednost. Pri tomu je adekvatan odabir graničnih vrijednosti ključan. U slučaju prevelikog broja graničnih vrijednosti, vrijeme proračuna drastično raste, a može se upasti i u zamku prevelikog broja razreda za premali broj mjerenja. S druge strane, kod premalo graničnih vrijednosti postoji mogućnost gubitka detalja i broja razreda potrebnih za primjerenu rekonstrukciju distribucije podataka. Preporučeni broj graničnih vrijednosti je između 5 i 11, uz broj podataka dovoljan da podrži odabrani broj razreda (NOVAK ZELENKA et al., 2010). Dakle, potrebno je oko 20 podataka, kako bi svaki razred sadržavao barem 3 mjerenja.

Tehnika indikatorskog kriginga je nelinearna tehnika primijenjena na linearne jednadžbe kriginga. Dakle, kako bi se dobila procijenjena vrijednost varijable na lokacijama bez mjerenja, prema jednadžbi kriginga (5.1) potrebno je izračunati težinske koeficijente λ_i , a koji se opet računaju pomoću sustava jednadžbi jednostavnog ili običnog kriginga. Dobivene vrijednosti se indikatorski transformiraju, te se npr. primjenom procjene jednostavnim krigingom koristi izraz za rezidual $[P^*(A, v_l) - F^*(v_l)]$ da bi se dobilo sljedeće:

$$P^*(A, v_l) - F^*(v_l) = \sum_{i=1}^n \lambda_i(v_l) [i(x_i, v_l) - F^*(v_l)], \quad (5.5)$$

gdje su:

$P^*(A, v_l)$ - vjerojatnost varijable za graničnu vrijednost unutar područja A;

$F^*(v_l)$ - nepristrana procjena učestalosti za graničnu vrijednost v_l ;

$\lambda_i(v_l)$ - težinski koeficijent za graničnu vrijednost v_l .

Sustav jednadžbi jednostavnog kriginga može se prikazati kao:

$$\sum_{k=1}^n \lambda_k(v_l) \gamma_i(x_i - x_m; v_l) = \bar{\gamma}(x_k; x_{k+h}, v_l), \quad k = 1, 2, \dots, n \quad (5.6)$$

gdje su:

$\gamma_i(x_i - x_m; v_l)$ - vrijednosti indikatorskog semivariograma na udaljenosti $x_i - x_m$ za graničnu vrijednost v_l ;

$\bar{\gamma}(x_k, x_{k+h}; v_l)$ - srednja vrijednost indikatorskog semivariograma između lokacija x_k i x_{k+h} za graničnu vrijednost v_l .

Takav postupak indikatorskog kriginga se ponavlja za svaku „l-tu“ graničnu vrijednost (NOVAK ZELENKA et al., 2010). Procjena običnim krigingom različita je od procjene jednostavnim krigingom, jer je nužno da zbroj svih težinskih koeficijenata bude jednak jedinici, a uvodi se i Lagrangeov faktor (μ), kao što je opisano u prethodnom poglavlju.

Rezultat indikatorskog kriginga nisu samo diskretne vrijednosti 0 ili 1, nego odgovaraju i kontinuiranoj procjeni duž intervala $[0,1]$ kada se konstruira kumulativni histogram tih vjerojatnosti. Dakle, indikatorski kriging daje vjerojatnosti događaja $\{z(x) < v_l\}$ (NOVAK ZELENKA et al., 2010).

5.2. STOHAŠTIČKE SIMULACIJE

Stohastičke metode standardni su dio geostatistike, matematički nešto napredniji negoli determinističke interpolacijske metode. Njima je omogućena procjena nesigurnosti vezane uz izračunate vrijednosti odabrane varijable na različitim lokacijama.

Kod stohastičkih procesa uvijek je nužno započeti determinističkim interpolacijskim pristupom. Deterministička karta dobivena metodom kriginga naziva se „nultim rješenjem“, odnosno rješenjem oko kojega se redaju sve kasnije realizacije. Osnovno svojstvo realizacija je njihova jednaka vjerojatnost „događaja“.

Po vrsti se razlikuju uvjetne i bezuvjetne simulacije. Kod uvjetnih simulacija postojeća mjerenja, najčešće bušotinski podaci, uvijek zadržavaju mjerene vrijednosti koje se smatraju čvrstim točkama, za razliku od bezuvjetnih, gdje te vrijednosti ne ostaju konstantne. Bezuvjetnost je opravdano koristiti budući da se točkasti mjereni podatak ekstrapolira na površinu bilo koje ćelije, a tada i to predstavlja uvođenje nesigurnosti u najmanju jedinicu geološkog modela (tj. ćeliju).

Bezuvmjetne simulacije polaze od pretpostavke da mjerena vrijednost ovisi o točnoj lokaciji mjerenja. Da je ta lokacija slučajno bila samo malo pomaknuta, ali unutar istog kvadrata mreže mjerenja ili ćelije, možda bi rezultat bio nešto drugačiji. Veličina ćelija u geološkom modelu obično je dimenzija 50x50 metara ili 100x100 metara, dok je bušotinski podatak točkasti. Ipak, aproksimacija čvrstog (mjerenog) točkastog podatka na veličinu ćelije najčešće je prihvaćena tehnika stvaranja geološkog modela, stoga je većina simulacija uvjetna.

Modeliranje ležišta proces je koji sadrži određene nesigurnosti te je zato stohastički pristup s nizom realizacija često najprimjereniji postupak. Naravno, nije moguće prikazati sva rješenja, nego se treba odlučiti za jedno ili nekoliko njih koja će primjereno prikazivati prostornu distribuciju modeliranog svojstva. Odaberemo li realizaciju P50, 50% rješenja će biti manje, a 50% rješenja veće od odabrane realizacije. Takva realizacija je onda statistički reprezentativno „srednje ili prosječno“ rješenje. Po istome kriteriju P5 je realizacija koja predstavlja minimalno moguće rešenje, a P 95 maksimalno. Realizacije P25 i P75 odgovaraju statističkim veličinama nazvanim kvartilima.


Broj realizacija jednostavno određuje detaljnost kartiranja nesigurnosti. Što je veći broj realizacija, mogu se bolje kartirati promjene u statistički dopuštenom intervalu nesigurnosti, ali veći broj realizacija (100 i više) ima smisla raditi jedino na dovoljno velikom ulaznom skupu mjerenja. Kod manjega broja mjerenja (<15 podataka, bušotina) nesigurnosti u međubušotinskom prostoru toliko su velike da njihovo detaljno kartiranje jednostavno nema smisla. Tada se, ako se načini manje od 10 realizacija, dobiva brzi uvid u glavna područja (ćelije) u kojima su promjene vrijednosti najveće u različitim realizacijama. Takav uvid nam omogućava da lako odredimo područja najveće nesigurnosti u rješenjima. S 50 realizacija pokriveno je oko 66% statistički moguće nesigurnosti kartirane varijable (interval 1 standardne devijacije), sa 100 realizacija kartirano je 95% moguće nesigurnosti (2 standardne devijacije), dok je s 200 realizacija kartirano 99% nesigurnost (3 standardne devijacije).

5.2.1. Sekvencijske Gaussove simulacije

Sekvencijske Gaussove simulacije (SGS) najčešće su primjenjivane uvjetne simulacije, a detaljan opis metode može se naći npr. u radu GEIGER (2006). Priprema podataka za izračun podrazumijeva normalizaciju podataka te uvođenje slučajnosti, što znači da je potrebno izračunati varijance ulaznih vrijednosti. Podatci se zatim različitim transformacijama prilagođavaju na normalnu razdiobu. Izvođenju simulacija prethodi i izrada eksperimentalnih variograma te „nultog rješenja“, odnosno karte dobivene metodom kriginga.

Budući da su sekvencijske Gaussove simulacije uvjetne, procjena se radi u onim ćelijama u kojima ne postoje mjerenja, dok ćelije u kojima postoje „čvrsti“ mjereni podaci zadržavaju svoju vrijednost. Prva ćelija u kojoj se procjenjuje vrijednost odabrana je slučajno, što označava prvo uvođenje stohastike (MALVIĆ, 2008). Procijenjena vrijednost zatim se odabire iz intervala $\pm 3\sigma$ (σ =standardna devijacija), ponovno slučajnim odabirom (drugo uvođenje stohastike) bilo koje vrijednosti iz tog intervala. Tako dobijemo simuliranu

vrijednost točke, odnosno ćelije (MALVIĆ, 2008). Postupak se ponavlja za sve točke u kojima nije bilo mjerenih podataka te se na taj način dobije jedna realizacija, a ponavljanjem cijeloga postupka računaju se i sve ostale realizacije (**slika 5.2**).



Slika 5.2: Dijagram toka obradbe podataka metodom sekvencijskih Gaussovih simulacija

Prednosti sekvencijskih Gaussovih simulacija su procjena vrijednosti nizom realizacija u svim točkama mreže te dobivanje razdiobe simulirane varijable koje je puno točnije nego razdioba (histogram) koja se dobije iz ograničenog broja ulaznih vrijednosti. Nedostatkom bi se moglo nazvati to što se simulirane vrijednosti mogu značajno razlikovati u susjednim ćelijama, a to predstavlja problem prilikom numeričkog modeliranja. Ipak, takvi modeli ponekad točnije opisuje situaciju u podzemlju, posebno ukoliko su ćelije jako velike (MALVIĆ, 2008).

5.2.2. Sekvencijske indikatorske simulacije

Sekvencijske indikatorske simulacije (SIS) druga su metoda unutar skupine stohastičkih simulacija kao alata za procjenu geoloških varijabli. Kao ulazne podatke za izradu variograma i kartiranje koriste prvo originalne vrijednosti, njihovu razdiobu i granične vrijednosti za podjelu u razrede, ali samo kartiranje se odvija na temelju indikatorskih varijabli, kao rezultata indikatorske transformacije, koja je nelinearna metoda primijenjena na

općenito linearne jednadžbe kriginga. Sekvencijske indikatorske simulacije, dakle, uvjetne su simulacije i procjena se radi samo na lokacijama na kojima nije bilo mjerenja.

Sama procedura sekvencijskih indikatorskih simulacija (**slika 5.3**) odvija se na način da je najprije potrebno (1) odrediti granične vrijednosti te napraviti indikatorsku transformaciju ulaznih podataka, zatim (2) odrediti variogram za svaku graničnu vrijednost, (3) slučajnim redoslijedom određuju se lokacije na kojima će se raditi procjena, a svaka lokacija na kojoj se simulira vrijednost može biti određena samo jednom. Nadalje:

- (a) za slučajno odabranu lokaciju koristi se indikatorski variogram, a procjenjuje se vjerojatnost da je vrijednost na toj lokaciji manja od granične vrijednosti,
- (b) radi se CCDF (engl. *Conditional Cumulative Distribution Function*) za odabrani broj graničnih vrijednosti te se
- (c) slučajno odabire simulirana vrijednost sa krivulje CCDF za lokaciju u kojoj se procjenjuje vrijednost, a zatim se
- (d) dodaje indikatorski kod $I(x, v_l)$, odnosno radi se indikatorska transformacija, kako bi se modelirala CCDF iduće lokacije.

Koraci (a) do (d) se ponavljaju i na taj se način procjenjuju vrijednosti na svim lokacijama na kojima nije bilo mjerenja, čime je dobivena prva realizacija (JUANG et al., 2004). Ostale se realizacije također dobivaju na isti način.

Sekvencijskim indikatorskim simulacijama procijenjena vrijednost ćelija kreće se u intervalu bliskom srednjoj vrijednosti te će ćelije biti jednoličnije, a razlike među realizacijama neće biti tako velike kao prilikom kartiranja metodom sekvencijskih Gaussovih simulacija. Razlog tomu je činjenica da je varijanca indikatorske varijable

$$\hat{F}(z_k) \cdot [1.0 - \hat{F}(z_k)] \quad (5.7)$$

gdje je:


$\hat{F}(z_k)$ - funkcija kumulativne distribucije (engl. *Cumulative Distribution Function*, *abbr. CDF*) kontinuirane slučajne varijable „ z_k “, a definirana je kao:

$$F(z_k) = P[z_k \leq z] \quad (5.8)$$

gdje je:

- P - vjerojatnost;
- z - ukupan broj podataka;
- z_k - broj svih podataka do vrijednosti k.

Tako procjena teži manjem ukupnom intervalu rješenja.



Slika 5.3: Dijagram toka obradbe podataka metodom sekvencijskih indikatorskih simulacija

Metodom sekvencijskih indikatorskih simulacija također se mogu izraditi i indikatorske karte temeljene na stohastičkim realizacijama. Takve karte tada prikazuju vjerojatnosti u odnosu na vrijednost veću od određene granične vrijednosti. Mogu se usporediti s kartama vjerojatnosti dobivenim metodom indikatorskog kriginga, samo što će u ovom slučaju vjerojatnosti biti suprotne.

6. PROGRAMSKI ISTRAŽIVAČKI ALATI (SOFTVERSKI PAKETI)

Softverski paketi uporabljeni za geostatističke analize i kartiranje bili su Variowin, Surfer8TM, PetrelTM i WinGslibTM. Dok je prvi od njih slobodni program (engl. *freeware*), ostali su komercijalni paketi za koje je postojala važeća licencija kod njihove uporabe. U sljedećim će potpoglavljima biti opisan svaki od njih.

6.1. RAČUNALNI PROGRAM VARIOWIN

Kako bi se znalo postoji li prostorna veza između podataka mjerenih na različitim lokacijama potrebno je izraditi variogram. Variogram je jedan od osnovnih geostatističkih alata, kojim se određuje zavisnost određene varijable u prostoru. Može se opisati izrazom:

$$2\gamma(h) = \frac{1}{n} \cdot \sum_{i=1}^n [z(x_i) - z(x_i + h)]^2 \quad (\text{jedn. 6.1})$$

gdje su:

- $2\gamma(h)$ - variogram
- n - broj parova podataka uspoređenih na udaljenosti „h“
- $z(x_i)$ - udaljenost varijable na lokaciji „ x_i “
- $z(x_i + h)$ - vrijednost varijable na lokaciji udaljenoj za „h“ od početne lokacije „ x_i “


Izraditi variogram možda je najlakše pomoću programa Variowin. Program je besplatan i kao takav dostupan svima, može se preuzeti s Interneta. Kako bi se mogao izraditi variogram potreban je određeni skup podataka. Podatci koji se unose su ASCII formata. Program se sastoji od tri modula, pri čemu se rezultat jednog modula koristi kao ulaz za drugi. Prvi modul (*Prevar 2D*) služi za unos ulaznih podataka i pretvara ih u *.pcf* zapis. Njime se određuje matrica udaljenosti za sve parove podataka.

Modul dva (*Vario 2D*) služi za izradu variograma iz dobivenog *.pcf* zapisa, no prije izrade samog variograma potrebno je napraviti variogramsku kartu. Ona se dobije upisivanjem sljedećih parametara: broj koraka (engl. *number of lags*) i veličina koraka (engl. *lag spacing*). Iz takve karte određuje se orijentacija glavne i sporedne osi. Glavna os sadrži najveći broj uspoređenih parova podataka s velikim vrijednostima variograma, što ukazuje na značajnu

prostornu zavisnost. Sporedna os odlikuje se suprotnim obilježjima. Slijedi izračun variograma za glavnu i sporednu variogramsku os, tj. za osi anizotropije. Broj podataka koji su uključeni u izračun kod svake anizotropne osi određeni su kutom odklona od glavne osi (engl. *angular tolerance*).

Iz svakoga izračunatog variograma (**slika 6.1**) mogu se očitati:

- odstupanje (engl. *nugget*),
- prag (engl. *sill*),
- doseg (engl. *range*),
- udaljenost (engl. *distance*).



Slika 6.1: Parametri variograma (MALVIĆ, 2008)

Odstupanje je pozitivna vrijednost na osi y, gdje variogramska krivulja sječe tu os. Prag je vrijednost koja odgovara varijanci. Nakon što krivulja dosegne prag prestaje s pravilnim rastom te uglavnom počinje oscilirati oko praga. Doseg je udaljenost po osi x od nule pa do točke na kojoj variogramska krivulja sječe prag. Ova vrijednost je mjera matematički ustanovljene zavisnosti među podacima u određenom smjeru. Na većoj udaljenosti od sjecišta praga i variogramske krivulje više se ne može govoriti o međusobnom utjecaju vrijednosti bliskih točaka. Udaljenost je vrijednost na osi „X“ na kojoj se međusobno uspoređuju podaci. Svaka udaljenost čini jednu klasu. Toj vrijednosti često je dodijeljena određena tolerancija (odmak), kako bi se povećao broj ulaznih podataka, pa na kraju svaki razred „preuzima“ i podatke polovice susjednog razreda. To je tzv. preklapanje razreda i koristi se za povećanje broja podataka kod izračuna svakoga variogramskog koraka, što je neophodno kod razmjerno

malih ulaznih skupova mjerenja od 10 do 15 podataka. Interval preklapanja naziva se „vrijednost odmak“.

Kako je spomenuto, Variowin omogućuje modeliranje anizotropnih geoloških pojava. Treba napomenuti kako najčešće opažena variogramska anizotropija prati anizotropiju strukturnih osi, koja uvjetuje zatim i anizotropiju oblika sedimentnih tijela te prostorne varijabilnosti petrofizikalnih svojstava. Pri opisivanju variogramske anizotropije razlikujemo geometrijsku i zonalnu anizotropiju.

Geometrijska anizotropija je prostorno jednostavnija, jer podrazumijeva da su prag i odstupanje variograma jednaki u bilo kojem smjeru, a samo doseg se mijenja u ovisnosti od smjera osi. To znači da je svaki doseg moguće izraziti umnoškom dosega na glavnoj osi s nekim faktorom.

Zonalna anizotropija je složeniji slučaj i nepovoljnija je kod interpretacije prostorne zavisnosti, jer nema konstantnih vrijednosti variograma za određeni smjer. Znači, promjenom osi mijenja se i doseg, i prag i odstupanje. Većina programa u kojima se kao ulaz za kartiranje koriste rezultati variogramske analize (recimo iz Variowina) ne podržava uporabu zonalne anizotropije, već samo geometrijske.


Završni modul programa Variowin *Model* - služi za aproksimaciju variograma teorijskim modelom. Točkasti podaci iz prethodnog modula aproksimiraju se teorijskim krivuljama, poput krivulja sfernog, eksponencijalnog, Gaussovog ili drugih modela.

6.2. RAČUNALNI PROGRAM SURFER 8.0™

Surfer 8.0™ je softverski paket izrađen za Windows platforme. Transformira podatke u 2D ili 3D koordinatnom sustavu u oblik pogodan za kartiranje, izradu profila te izračun površine i volumena. U prvom koraku određuje se gustoća mreže (engl. *grid*). Dimenzije se određuju definiranjem veličine ćelija. Idealna situacija za determinističku procjenu bila bi da se svaki mjereni podatak nalazi u čvoru mreže, no to opet može rezultirati prevelikim brojem linija u mreži, što troši previše procesorskog vremena. Stoga je potrebno napraviti određene kompromise na način da se podatak koji je unutar ćelije (nije na čvoru) ekstrapolira na čvorište. Veličina ćelije, odnosno razmak između linija mreže izravno utječe i na zaobljenost izolinija. Odnosno, većim brojem linija kojima je određena mreža postiže veća preciznost.

Surfer 8.0™ pruža mogućnost izrade karata različitim determinističkim interpolacijskim metodama, poput uporabe metode najbližeg susjedstva ili inverzne udaljenosti (**slika 6.2**), ali i tehnikom običnog kriginga (**slika 6.3**).

Anizotropija se koristi kada je u ulaznim podacima opažen prostorni trend, odnosno smjer u kojem podatci imaju veću međusobnu zavisnost. Npr, ako su podatci najjače međuovisni pravcem sjeverozapad-jugoistok, tada je pravac anizotropije 135° . Također se unutar programa može mijenjati radijus elipsoida pretraživanja, kojim je određena prosječna veličina skupa mjerenih podataka koji su koriste za izračun u svakoj točki mreže (*grida*). Radijus pretraživanja (kružnica) može se izmijeniti u radijuse pretraživanja (elipsoid) prilagođavajući se time elipsoidu anizotropije. U bilo kojem slučaju za svaku točku unutar granica pretraživanja računa se njezin utjecaj (najčešće ovisno o udaljenosti) na točku čija se vrijednost procjenjuje.




Slika 6.3: Karta raspodjele poroznosti dobivene metodom kriginga (iz VELIĆ et al., 2008*)

Nakon izračuna vrijednosti mreže slijedi konstrukcija karata izolacija (engl. *contour maps*). U programu se može birati ekvidistanciju, sjenčanje te oznake simbola koji prikazuju bušotine ili bilo koji drugi točkasti podatak. Mogućnosti izrade vrlo preglednih prikaza su iznimno velike, a bez većih problema moguće je kod takvih prikaza uvesti i treću dimenziju („Z“) te dobiti blok dijagram kartirane površine s tim da se može mijenjati kut gledanja.

6.3. RAČUNALNI PROGRAM PETREL™


Prva inačica Petrela™ pojavila se 1996. god., a danas Petrel™ predstavlja jedan od najkvalitetnijih programa za geološko modeliranje ležišta ugljikovodika koji omogućava obradu seizmičkih i karotažnih podataka, kartiranje te izračune različitih volumena u ležištu. Za vizualizaciju podataka postoji nekoliko mogućnosti, tj. modula (**slika 6.4**).

Model ležišta moguće je nadopunjavati novim podacima, unaprjeđujući ga smanjivanjem nesigurnosti. To se posebno odnosi na određivanje granica ležišta, njegovo prikazivanje u tri dimenzije s mogućnošću promjene osi promatranja, te određivanje temeljnog strukturnog modela (engl. *skeleton*).



Slika 6.4: Različiti načini vizualizacije u računalnom programu PetrelTM (Petrel Introduction Course-Petrel 2009*)

Temeljni strukturni model je osnovni element s kojim se započinje modeliranje. Uloga mu je podijeliti područje unutar granica polja na ćelije, a zatim se unose vrijednosti dubina korelacijskih horizonata, a eventualno i slojnih ploha, ovisno o detaljnosti modela te se oblikuje trodimenzionalan prikaz građe podzemlja. Vrijednosti različitih parametara poput debljina, poroznosti, volumena i drugih računaju se za svaku pojedinu ćeliju unutar modela. Ovo može biti vremenski zahtjevan postupak, koji je nemoguće provesti bez računala i stabilnog programa. Važan dio modeliranja je kartiranje rasjeda (**slika 6.5**) koji presijecaju analizirano ležište ili ležišta. Ako predstavljaju barijere migraciji fluida, postupak je još zahtjevniji, jer tada oni određuju ne samo tektonske blokove u ležištu, već i hidrodinamske cjeline.



Slika 6.5: Modeliranje rasjeda u računalnom programu PetrelTM (Petrel Introduction Course-Petrel 2009*)

Kako naftna i plinska polja u hrvatskom dijelu Panonskog bazena karakterizira velik broj rasjeda, često je puta prije unosa takvih podataka u PetrelTM potrebno napraviti ekspertizu. Ona obuhvaća procjenu koji su rasjedi bitni za geološki model obzirom na određivanje granica ležišta, nepropusnih barijera, određivanje sedimentoloških i strukturnih osi te procjenu drenažnih radijusa bušotina. Ekspertizom treba izbjeći „zagušenje“ modela prevelikim brojem rasjeda, jer PetrelTM ima ograničenja svojstvena svim takvim programima koja se javljaju kod povezivanja prevelikog broja bliskih rasjednih ili slojnih ploha računalnim algoritmima. U uvjetima vrlo složenih strukturnih odnosa ponekad je model nemoguće suvislo oblikovati.

6.4. RAČUNALNI PROGRAM WINGSLIBTM

GSLIB (engl. *Geostatistical Software Library*) je naziv za skup geostatističkih algoritama i programa razvijenih na Sveučilištu u Stanfordu (DEUTSCH & JOURNEL, 1997). U zadnjih petnaest do dvadeset godina generacije diplomiranih inženjera i studenata na spomenutom Sveučilištu svojim radom, znanjem i novim idejama konstantno su pridonosili razvojem i poboljšanjima geostatističkih programa. Geostatistički programi vjerojatno se najčešće koriste u opisivanju ležišta ugljikovodika. WinGslibTM je jedan od takvih geostatističkih programa izrađen za platformu Windows.

Program prilikom rada stvara tri direktorija:

- direktorij s ulaznim vrijednostima (engl. *data files*),
- direktorij s izlaznim dokumentima (engl. *output files*),

- direktorij sa zapisom koji sadrži sve parametre potrebne za izradu izlaznih dokumenata, kao što su veličina polja, broj ćelija, broj realizacija i sl. (engl. *parameter files*).


Za pregled grafičkih izlaza potrebno je pokrenuti grafičko sučelje programa *Ghostscript*, koje se naziva *Gsview*. *Ghostscript* je zapravo interpretator *PostScript* zapisa izračunatih u WinGslib-u. Dakle, WinGslib daje numeričke rezultate npr. kartiranja ili simulacija, koji se pomoću programa *Ghostscript* mogu prikazati grafički, kao karte. Svi ti moduli korišteni su tijekom rada na disertaciji.

7. STRUKTURNO MODELIRANJE POLJA KLOŠTAR


Polje Kloštar izdužena je antiklinala pružanja sjeverozapad-jugoistok. Uzdužni normalni rasjed, nazvan Kloštarski rasjed, dijeli strukturu u dva dijela, sjeveroistočni i jugozapadni. U gornjomiocenskim slojevima ovaj rasjed predstavlja liniju prestanka razvoja ležišnih facijesa, a samim time i granicu zasićenja ugljikovodicima. Imao je ključnu ulogu u nastanku ležišta starosti gornjeg panona i donjeg ponta. **Slika 7.1** prikazuje korelacijski profil kroz bušotine Klo-78 i Klo-83 (trasa profila na **slici 2.2**), koje su probušile gornjopanonska ležišta, a na **slici 7.2** može se vidjeti korelacijski profil kroz bušotine Klo-22 i Klo-43 (trasa profila na **slici 2.2**), koje su probušile donjopontska ležišta. Na **slici 7.2** može se uočiti spajanje svih donjopontskih ležišta u jedno.

Konceptualni modeli (**slike 7.3-7.6**) konstruirani su na temelju pregleda strukturalnih karata po krovini gornjopanonskih i donjopontskih ležišta u polju Kloštar (DOMITROVIĆ & HINIĆ, 2008*) te na temelju interpretiranih probušenih debljina istih ležišta, u skladu s prikazom strukturalnih karata i paleotektonskih profila u radu VELIĆ et al. (2011). U vrijeme badena do kasnog panona, na polju Kloštar, otvorio se prostor pogodan za taloženje pješčenjačkih ležišta (**slika 7.3**). U vrijeme kasnog panona, kao i ranog ponta prevladavala je transtenzijska tektonika na cijelom području hrvatskog dijela Panonskog bazena (MALVIĆ & VELIĆ, 2011). Na temelju pregledanih strukturalnih karata zaključeno je da je nakon taloženja najplićeg gornjopanonskog ležišta Gama, nastao spomenuti regionalni normalni rasjed. Zbog njegovog djelovanja dolazi do spuštavanja sjeveroistočnog te izdizanja jugozapadnog dijela strukture Kloštar (**slika 7.4**). Sjeveroistočno od rasjeda, u spuštenom dijelu prostora, zapadno od Moslavačke gore stvorio se novi, dublji prostor za sedimentaciju. Moguće je da su postojala dva izvora materijala - prvi su bile Istočne Alpe, dok je drugi predstavljala Moslavačka gora s lokalnim prijenosom erodiranog materijala uglavnom manjim aluvijalnim lepezama. Kako je polje Kloštar smješteno uz sam rub Savske depresije logično je zaključiti da je dio materijala morao biti deriviran i s Moslavačke gore. U vrijeme kasnog ponta započinje transpresija koja traje i danas (**slike 7.5 i 7.6**). Glavni normalni rasjedi (**slika 7.6**) mijenjaju svoj karakter i postaju reverzni. No njihov ukupni reverzni pomak je ostao manji nego normalni, odnosno krovinsko krilo se podiglo u odnosu na podinsko toliko da je kumulativni pomak i dalje normalnog karaktera. Ostali rasjedi u polju, meridijalnog pružanja, također su normalnog karaktera jer je počelo dolaziti do lokalne ekstenzije na vrhu strukture Kloštar (**slika 7.6**), iako su nastali u pliocenu i kasnije, dakle u fazi transpresije, nakon što su


pješčenjačka tijela već bila istaložena. Na lokalnu ekstenziju upućuju i velike debljine pliocenskih i kvartarnih naslaga taloženih u polju Kloštar.




Slika 7.1: Korelacijski profil kroz bušotine koje su probušile gornjopanonska ležišta




Slika 7.2: Korelacijski profil kroz bušotine koje su probušile donjopontska ležišta




Slika 7.3: Konceptualni taložni model gornjopanonskih naslaga u polju Kloštar



Slika 7.4: Konceptualni taložni model donjopontskih naslaga u polju Kloštar



Slika 7.5: Konceptualni taložni model gornjopontskih naslaga u polju Kloštar



Slika 7.6: Konceptualni taložni model tijekom pliocena i kvartara u polju Kloštar

7.1. POSTOJEĆE STRUKTURNE KARTE LEŽIŠTA


Budući da nije bilo moguće napraviti novu detaljnu seizmičku interpretaciju građe podzemlja na području polja Kloštar iskorištene su postojeće strukturne karte po krovini odabranih ležišta. Strukturne karte potrebne za izradu strukturnog modela preuzete su iz *Elaborata o rezervama ugljikovodika eksploatacijskog polja Kloštar* (2008*) i prenesene u računalni program Petrel. Od gornjopanonskih ležišta prikazano je samo najdublje, ležište Alfa. **Ležište Alfa** je sitno do srednjozrnato pješčenjačko tijelo na JZ krilu Kloštarske antiklinale, koje bočno prelazi u lapore u smjeru SI. Očitano je na **slici 7.7** samo na temelju ograničenog broja bušotina tako da se jedino pouzdano može vidjeti bočna promjena litofacijesa i nagib ovog sloja prema JZ. Pretpostavljeno je da se pruža i dale u tom smjeru i ista je građa interpretirana za dva plića pješčenjačka ležišta Beta i Gama. Zbog malog područja koje zashvaća u ležištu nije uočen niti jedan rasjed, a zamka je zatvorena bočnom promjenom litofacijesa prema SI, odnosno prijelazom u lapore (**slika 7.7**).

Od donjopontskih ležišta prikazane su strukturne karte po krovini triju ležišta, najdubljeg ležišta Z (**slika 7.8**), zatim najvećeg, središnjeg ležišta T (**slika 7.9**) te ležišta O (**slika 7.10**). Na temelju tih karata napravljen je u PetreluTM osnovni strukturni model za donjopontske naslage. Ležište O je među najplićim ležištima i kao takvo predstavlja krovinu osnovnog strukturnog modela. Istom analogijom ležište Z, kao najdublje donjopontsko ležište predstavlja podinu osnovnog strukturnog modela. Ležište T nalazi se u središnjem dijelu, a ujedno je i najveće donjopontsko ležište, stoga je ono odabrano kao središnja ploha između krovine i podine osnovnog strukturnog modela. Za kasnije modeliranje odabrani su samo najveći rasjedi, koji presijecaju sva ležišta starosti donjeg pontaa, a određeni su na temelju ponavljanja na sve tri karte (podine, središnje plohe i krovine strukturnog modela).


Ležište Z je najdublje donjopontsko pješčenjačko ležište, unutar kojeg postoje proslojci s povećanim udjelom laporovite komponente. Maksimalna debljina ležišta je na zapadnom dijelu polja i iznosi oko 40 m, dok na istočnom dijelu naglo zalaporuje. Naime, prostorno se prema istoku sloj može i dalje pratiti kroz prijelazne litofacijese (od čistih pješčenjaka do lapora), no lateralna promjena veličine zrna uzrokuje nestanak ležišnih svojstava (**slika 7.8**). Jugozapadnu granicu ležišta čini Kloštarski rasjed koji se po pružanju u smjeru JI dijeli u dva ogranka, a na području ležišta interpretiran je jedan normalni rasjed pružanja JZ-SI, te pet manjih normalnih rasjeda meridijalnog pružanja koji svi imaju spuštenu istočno krilo. Istočnu granicu ležišta u najvećem dijelu čini bočna promjena facijesa.

Ležište T je sitnozrnati slabo vezani pješčenjak, debljine oko 20 m. Isklinjava prema istoku. U istočnom dijelu polja ovo ležište je teško odvojiti od dvaju ležišta u podini (U i V), pa se zajedno kartiraju. Ležište T najveće je donjopontsko ležište, s najviše podataka o prostornom rasporedu poroznosti, stoga će sva kartiranja metodama opisanim u prijašnjim poglavljima biti napravljena za ovo ležište, a zbog taložne i litološke sličnosti s ostalim ležištima rezultati se mogu primijeniti na sva ležišta starosti donjeg pontu (Z, Y, V, U, T, S, R, Q, P, O, I i K). Razlog tomu je taj što je ležište T najvećeg prostiranja i debljine te su se svi tipski litofacijesi najbolje razvili u njemu. Zasićeno je naftom, plinom iz plinske kape ili je u potpunosti zasićeno plinom. Također je podijeljeno u tektonske blokove, koji predstavljaju zasebne hidrodinamske cjeline, odvojene ili normalnim rasjedima ili bočnim promjenama facijesa (**slika 7.9**). Jugozapadnu granicu ležišta čini već spomenuti Kloštarski rasjed, dok je na području ležišta interpretiran jedan normalan rasjed pružanja JZ-SI te sedam manjih normalnih rasjeda meridijalnog pružanja. Svima im je spuštено istočno krilo. Istočna granica ležišta nije definirana bočnom promjenom litofacijesa.


Ležište O (slika 7.10) je sloj slabo vezanog sitnozrnatog pješčenjaka maksimalne debljine oko 20 m na zapadnom dijelu polja, koji isklinjava prema istoku. Sloj nije na cijelom području polja zasićen ugljikovodicima, nego samo u pojedinim tektonskim blokovima, tj. hidrodinamičkim jedinicama. One su omeđene rasjedima koji predstavljaju barijere za migraciju ugljikovodika, a za strukturni model je važno jedino da su na ovoj karti interpretirani isti rasjedi, odnosno neki od rasjeda koji se mogu vidjeti na karti velikog ležišta T u podini.



Slika 7.7: Karta po krovini ležišta Alfa



Slika 7.9: Karta po krovini ležišta T




Slika 7.10: Karta po krovini ležišta O

7.2. OSNOVNI STRUKTURNI MODEL POLJA KLOŠTAR

Kostur (u programu PetrelTM nazvan engl. *skeleton*) polja Kloštar predstavlja definiranje mreže u prostoru u koju će kasnije biti ugrađen osnovni strukturni model. Kostur je definiran s tri plohe, a napravljen je u računalnom programu PetrelTM. Vrlo je jednostavan za gornjopanonska ležišta, budući da glavni rubni rasjed, niti rasjedi meridijalnog sustava nisu zahvatili slojeve tamo gdje su ležišta. Prilikom njihove izrade konstruirana je jednostavna mreža s veličinom ćelija 100x100 m (**slika 7.11**).

Najveći rasjedi presijecaju sva tri modelirana donjopontska ležišta (O, T, Z) i njihove su plohe važni elementi osnovnog strukturnog modela. Rasjedi se u računalnom programu PetrelTM mogu modelirati na nekoliko načina. Budući da su već postojale strukturne karte po krovinama ležišta, a na njima su glavni rasjedi iscrtani, najbolji način za računalno modeliranje rasjeda bilo je njihovo povezivanje preko ocrta na kartama po krovini ležišta koje su prenesene u PetrelTM.

Na temelju rasjeda i krovinskih ploha odabranih ležišta O kao najplićeg, T kao središnjeg i Z kao najdubljeg, napravljen je kostur za donjopontska ležišta. Kostur je određen pomoću tri spomenute plohe, odabrane kao krovinska, središnja i podinska ploha modela. Veličina ćelije mreže modela također iznosi 100x100 m (**slika 7.11**).



Slika 7.11: Temeljni strukturalni model gornjopanonskih i donjopontskih ležišta

Osnovni strukturni model načinjen je također u PetreluTM, a predstavlja izradu strukturnih karata koje odgovaraju krovinama odabranih ležišta unesenih u računalni model zajedno s odabranim rasjedima prijašnjih rješenja (DOMITROVIĆ & HINIĆ, 2008*). Napravljene su strukturne karte za jedno gornjopanonsko ležište, koje odgovara ležištu Alfa i tri donjopontska ležišta, koji odgovaraju ležištima O, T i Z. Sve strukturne karte prikazane su u dubinskom mjerilu, također prikazanom odgovarajućim bojama, te presječene rasjedima.

Budući da na polju Kloštar ne postoji dovoljan broj interpretiranih seizmičkih podataka, osnovni strukturni model se temelji na strukturnim kartama iz prethodnih rješenja dostupnih u arhivi tvrtke (DOMITROVIĆ & HINIĆ, 2008*). Ipak, postoje razlike između prikazanog i ranijih rješenja. Prvenstveno se očituju u broju rasjeda prikazanih kroz ležišta, koji je manji u računalnom modelu. No time je i jasniji, jer su odabrani samo oni rasjedi kod kojih je skok veći od debljine pojedinačnih ležišta. Rasjedi manjega skoka, na temelju dostupnih podataka i debljina pojedinih ležišta, mogu biti tek pretpostavljeni, a za opis nastanka ležišta i migracije su nepotrebni, posebno ako su propusni za fluide.

8. DETERMINISTIČKO GEOSTATISTIČKO KARTIRANJE PETROFIZIKALNIH VARIJABLI I LITOFACIJESA

Za prikaz prostorne distribucije geoloških varijabli danas rabi većina geologa determinističke interpolacijske metode. Osnovno svojstvo tih metoda je da za jednaki ulaz, uz primjenu iste metode, uvijek daju isti i ponovljivi rezultat. Postoji cijeli niz determinističkih interpolacijskih metoda, a najčešće upotrebljavane u geološkim kartiranjima su metoda inverzne udaljenosti, najbližeg susjedstva, pokretne sredine, kriginga i kokriginga. Pri dovoljnom broju podataka gotovo redovito se koriste geostatističke metode zbog svoje veće preciznosti.

U sljedećim potpoglavljima bit će prikazani rezultati dobiveni kartiranjem tehnikama običnog i indikatorskog kriginga. Tehnikom običnog kriginga kartirane su varijable poroznosti, dubine i debljine za donjopontsko ležište T i gornjopanonsko ležište Beta u polju Kloštar. Tehnikom indikatorskog kriginga u istim su ležištima kartirane samo varijable poroznosti i debljine, zato što se ta tehnika koristi za kartiranje litofacijesa.

Kod indikatorske transformacije korištene su dvije pretpostavke. Prva podrazumijeva da povećani udio laporovite komponente u pješčenjacima smanjuje njihovu poroznost, tada se litofacijesi od čistih pješčenjaka pa do bazenskih lapora mogu opisati upravo pomoću vrijednosti poroznosti. Druga pretpostavka je da će facijesi čistih kanalnih pješčenjaka imati povećane debljine u odnosu na prijelazne pješčenjačke facijese prema bazenskim laporima, pa će ponovno biti moguće razlikovati taj litofacijes od drugih.

8.1. PRIKUPLJANJE PETROFIZIKALNIH PODATAKA

Na polju Kloštar do sada su napravljene brojne analize i geostatističke procjene. Osnovni izvor podataka bile su Inina studija polja Kloštar (VELIĆ et al., 2008*), zatim elaborati o rezervama nafte i plina polja Kloštar (GOIĆ & ĐORĐEVIĆ, 1981*; GOIĆ & CAZIN, 1985*; GOIĆ & CELINŠČAK, 1998*; DOMITROVIĆ & VUČKOVIĆ, 2003*; DOMITROVIĆ & HINIĆ, 2008*), a svi bušotinski podatci prikupljeni su iz arhive bušotina tvrtke INA (*Dossieri* bušotina naftno-plinskog polja Kloštar*). Kartirane varijable bile su srednja poroznost, dubina krovine i probušena debljina ležišta Beta, a kako je to najveće gornjopanonsko ležište, zaključci doneseni za njega mogu se primijeniti i na svim ostalim ležištima iste starosti, jer su taložni uvjeti bili jednaki. Iste varijable kartirane su i za ležište T,

donjopontske starosti, također s istom pretpostavkom o primjeni rezultata na ostala ležišta iste starosti. **Tablice 8.1. i 8.2.** prikazuju prikupljene vrijednosti analiziranih varijabli poroznosti, dubine i debljine za ležišta Beta i T, u bušotinama polja Kloštar. Poroznost predstavlja srednju poroznost dobivenu iz karotažnih mjerenja. Budući da je riječ o starijim bušotinama za izračun poroznosti koristila se jedina dostupna krivulja spontanog potencijala (SP). Osnovni podatak bile su vrijednosti poroznosti dobivene iz analiza na jezgrama za svaku bušotinu. Taj se podatak korelirao s krivuljom SP-a na način da su se povezale vrijednosti SP-a s izmjerenom poroznosti na određenoj dubini. Takva vrijednost predstavljala je maksimalnu poroznost. Minimalna poroznost (0%) odabrana je u nepropusnim stijenama, kao minimalna vrijednost SP-a. Na taj se način pomoću programa "eXpress" jednostavno mogla izračunati poroznost za određeni interval.

Tablica 8.1: *Vrijednosti analiziranih varijabli ležišta Beta u bušotinama polja Kloštar*

Bušotina	Poroznost (%)	Dubina krovine (m)	Debljina (m)
Klo-5	18,0	1365,0	3,0
Klo-19		1502,5	15,5
Klo-60	17,9	1447,0	23,0
Klo-62	15,3	1400,0	22,5
Klo-63	16,6	1437,0	9,0
Klo-64	15,0	1397,0	10,0
Klo-70	12,2	1387,5	3,5
Klo-73	13,3	1373,0	4,0
Klo-74		1358,0	20,5
Klo-75	17,5	1375,0	20,0
Klo-76	18,5	1362,5	14,5
Klo-77		1386,0	22,0
Klo-78	16,2	1376,5	13,5
Klo-79	18,5	1393,0	14,0
Klo-81	19,1	1362,0	11,5
Klo-82	18,3	1396,5	18,5
Klo-83	16,0	1368,5	8,5
Klo-84		1406,0	9,0
Klo-86		1338,0	8,5
Klo-87	17,3	1409,0	10,0
Klo-88	15,5	1405,0	8,0
Klo-89	17,9	1395,0	7,0
Klo-163		1394,0	18,0


Tablica 8.2: Vrijednosti analiziranih varijabli ležišta T u bušotinama polja Kloštar

Bušotina	Poroznost (%)	Dubina krovine (m)	Debljina (m)
Klo-1	19,9	940,0	13,0
Klo-12	19,5	991,0	12,0
Klo-16	19,6	916,0	12,0
Klo-20	21,1	1026,0	13,0
Klo-22	23,3	966,0	11,5
Klo-23	20,5	1014,0	12,0
Klo-24	20,1	1020,5	11,0
Klo-26	21,2	1016,0	9,5
Klo-27	17,9	880,0	20,0
Klo-28	19,2	994,0	17,0
Klo-35	13,8	790,0	3,0
Klo-43	5,5	765,5	4,5
Klo-48	19,7	1019,0	13,5
Klo-57	18,2	795,0	25,0
Klo-58	21,8	803,0	6,0
Klo-59	18,1	890,0	9,0
Klo-71	18,5	838,0	10,0
Klo-72	19,6	785,0	11,0
Klo-95	22,0	957,0	8,0
Klo-104	18,4	912,5	6,0


8.2. VARIOGRAMSKA ANALIZA KARTIRANIH VARIJABLI

Prije izrade karata determinističkim interpolacijskim metodama kriginga i stohastičkim simulacijama nužno je napraviti variogramsku analizu. Vrlo je važno da variogram odražava pravu heterogenost sustava, budući da 3D modeli, koji se kasnije dobiju determinističkim interpolacijskim i stohastičkim metodama, poštuju upravo variogram. Stoga je bitno razumijevanje variograma i metodologije rada, koja je jasno opisana u npr. GRINGARTEN & DEUTSCH (1999). Prilikom numeričke procjene točnosti variograma i geostatističkih metoda poželjno je koristiti kros-validaciju, čiju svrhu prikazuje DAVIS (1987). Postupak kros-validacije zapravo je numerička procjena pogreške, koji se koristi kada se žele ocijeniti rezultati kartiranja dobivani dvjema interpolacijskim metodama. Na **slici 8.1 i 8.2** prikazane su karte variogramskih površina varijabli poroznosti, dubine i debljine ležišta Beta i T, na kojima je moguće uočiti anizotropiju ležišnih varijabli po osima. Glavna os prikazuje smjer najvećeg, a sporedna najmanjeg kontinuiteta promatranog svojstva.

Na **slikama 8.1 i 8.2** prikazane su karte variogramskih površina ležišta Beta i T. Oblik kartiranog područja ovisi o lokacijama bušotina, dok je bojom označena ovisnost između ulaznih podataka. Ista ili slična boja na karti definira smjer glavne osi.




Slika 8.1: Karte variogramskih površina varijabli poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta




Slika 8.2: Karte variogramskih površina varijabli poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Također su za njih napravljeni eksperimentalni variogrami, a prikazani su **slikama 8.3 i 8.4**. Na osi X nalazi se udaljenost, a na osi Y vrijednost variograma. Variogramima se određuje prostorna ovisnost između podataka, dakle kada krivulja variograma presječe prag, očitana vrijednost na osi X predstavlja udaljenost do koje su podatci međusobno ovisni. Na udaljenostima većim od te ne može se više govoriti o prostornoj ovisnosti između podataka. Ležište Beta je izduženo u smjeru sjeverozapad-jugoistok (**slika 8.1**), te je glavna os variograma zadržala taj smjer (135°). Za razliku od ležišta Beta, eksperimentalni variogrami varijabli ležišta T napravljeni su kao neusmjereni, budući da se nije mogao prepoznati smjer glavne i sporedne osi (**slika 8.2**).




Slika 8.3: Eksperimentalni variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta




Slika 8.4: Eksperimentalni variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Eksperimentalni variogrami su u sljedećem koraku aproksimirani teorijskim krivuljama, a teorijski su variogrami prikazani **slikama 8.5 i 8.6**. Variogrami su standardizirani, a standardizacija je napravljena kako bi se različite varijable (s različitim skalama) međusobno mogle uspoređivati, budući da je standardizacijom vrijednost praga postavljena na 1.



Slika 8.5: Teorijski variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) gornjopanonskog ležišta Beta



Slika 8.6: Teorijski variogrami poroznosti (lijevo), dubine (sredina) i debljine (desno) donjopontskog ležišta T

Vrijednosti teorijskih standardiziranih variograma ležišta Beta za varijable poroznosti, dubine i debljine prikazani su u **tablici 8.3**, a iste vrijednosti ležišta T prikazani su **tablicom 8.4**:

Tablica 8.3: *Vrijednosti standardiziranih variograma varijabli gornjopanonskog ležišta Beta*

Varijabla	Model	Doseg	Prag	Odstupanje
Poroznost	Sferni	2095,0	0,4	0,6
Dubina	Sferni	1613,5	1,0	0,0
Debljina	Sferni	1707,6	1,0	0,0

Tablica 8.4: *Vrijednosti standardiziranih variograma varijabli donjopontskog ležišta T*

Varijabla	Model	Doseg	Prag	Odstupanje
Poroznost	Ekspencijalni	1078,8	0,6	0,4
Dubina	Sferni	1506,1	1,0	0,0
Debljina	Sferni	488,1	0,4	0,6

Velika odstupanja uočena su kod varijable poroznosti ležišta Beta te debljine i poroznosti ležišta T, što znači da je procjena metodama kriginga slabija, tj. manja je prostorna zavisnost između podataka. Da je to ipak najbolja metoda koja se mogla rabiti za te varijable objavio je MALVIĆ (2008) u radu u kojem je pokazao da čak i u slučaju kada je odstupanje vrijednosti pola varijance, u gornjopanonskim i donjopontskim pješčenjacima, kriging i dalje daje najbolje karte.

Opisani variogrami korišteni su prilikom kartiranja tehnikom običnog kriginga i sekvencijskih Gaussovih simulacija. Druga dva postupka, indikatorski kriging i sekvencijske indikatorske simulacije zahtijevaju indikatorsku transformaciju ulaznih podataka na temelju određenog broja graničnih vrijednosti te izradu variograma za svaku pojedinu graničnu vrijednost. Stoga će variogramska analiza takvih podataka biti opisana u potpoglavljima koja se odnose na kartiranje indikatorskih (tj. kategoričkih) varijabli.


8.3. KARTIRANJE DUBINE, DEBLJINE I POROZNOSTI OBIČNIM KRIGINGOM

Varijable poroznosti, dubine i debljine ležišta Beta i T kartirane su tehnikom običnog kriginga. Kartiranje je napravljeno u programu Surfer8, a rezultati su prikazani **slikama 8.7, 8.8, 8.9, 8.10, 8.11 i 8.12**.


8.3.1. Kartiranje varijabli gornjopanonskog ležišta Beta

Žuta crtkana linija na kartama (**slike 8.7, 8.8 i 8.9**) predstavlja liniju bočne promjene facijesa od pješčenjaka prema laporima, dok je jugozapadna granica ležišta označena kao ravna linija na procijenjenoj srednjoj udaljenosti od zadnjih bušotina. Ona, dakle, ne predstavlja stvarnu ili fizičku granicu, nego jednostavno odabranu granicu do koje se može raditi interpolacija, budući da sve udaljenije lokacije, zbog nedostatka podataka, imaju i povećanu nesigurnost procjene. U tom prostoru nisu bile smještene bušotine, jer je utvrđeno da je tu sloj dublji od početnog kontakta nafte i vode.


Povećane poroznosti na **slici 8.7** mogu se vidjeti na sjeverozapadnom i središnjem do jugoistočnom dijelu karte te u području oko bušotine Klo-81. Usporedbom **slika 8.7, 8.8 i 8.9** može se uočiti djelomično preklapanje područja povećanih poroznosti i debljina u središnjem dijelu karte između bušotina Klo-60 i Klo-75, što ujedno predstavlja i najdublji dio ležišta.



Slika 8.7: Poroznost ležišta Beta kartirana tehnikom običnog kriginga




Slika 8.8: Dubina krovine ležišta Beta kartirana tehnikom običnog kriginga




Slika 8.9: Debljina ležišta Beta kartirana tehnikom običnog kriginga

8.3.2. Kartiranje varijabli donjopontskog ležišta T


Ležište T je s jugozapadne strane omeđeno normalnim rasjedom, nazvanim Kloštarski rasjed. Ono je najveće donjopontsko ležište, nalazi se u sloju pješčenjaka koji prekriva cijelo područje polja, stoga u njemu nije utvrđena linija bočne promjene facijesa. U ostalim donjopontskim ležištima u polju Kloštar ta linija je u smjeru istoka, odnosno prema Moslavačkoj gori. Pružanje regionalnog Kloštarskog rasjeda, koji je nastao krajem gornjeg panona te uvjetovao prostor taloženja donjopontskih pješčenjaka, podudara se s pretpostavljenim putovima transporta klastičnog materijala iz smjera sjeverozapada prema jugoistoku. Usporedbom karte poroznosti ležišta T (**slika 8.10**) s kartom stratoizohipsa po krovni ležišta (**slika 8.11**) može se uočiti kako je poroznost povećana u dubljim dijelovima strukture s iznimkom povećane poroznosti u području oko bušotine Klo-58. Međutim, treba naglasiti kako su današnje dubine posljedica tektonike aktivne i nakon donjeg pontu stoga se varijable poroznosti i dubine ne mogu dovesti u izravnu vezu bez usporedbe s kartom debljina (**slika 8.12**). Na toj se karti vide dva područja povećane debljine, veće u sjevernom, a manje u južnom dijelu ležišta. Dakle, poroznost i dubina dobro se koreliraju na zapadnom dijelu ležišta, a poroznost i debljina na južnom.



Slika 8.10: Poroznost ležišta T kartirana tehnikom običnog kriginga



Slika 8.11: Dubina ležišta T kartirana tehnikom običnog kriginga



Slika 8.12: Debljina ležišta *T* kartirana tehnikom običnog kriginga

8.4. KARTIRANJE INDIKATORSKIM KRIGINGOM

Indikatorski kriging podrazumijeva indikatorsku transformaciju varijabli na temelju određenog broja graničnih vrijednosti te izradu variograma za svaku pojedinu graničnu vrijednost. Varijable kartirane ovom tehnikom su poroznost i debljina ležišta Beta i T.

8.4.1. Kartiranje indikatorskih varijabli gornjopanonskog ležišta Beta


Kartirane varijable ležišta Beta bile su poroznost i debljina. Vrijednosti poroznosti dobivene su aritmetičkom sredinom iz 17 bušotinskih podataka (**tablica 8.1**), dok su vrijednosti debljine predstavljene ukupnim debljinama ležišta na temelju dubina krovine i podine određenih iz EK dijagrama na 23 bušotine (**tablica 8.1**).

Za kartiranje tehnikom indikatorskog kriginga nužno je načiniti indikatorsku transformaciju ulaznih podataka. Indikatorska transformacija za varijablu poroznosti ležišta Beta prikazana je **tablicom 8.5**. Na temelju graničnih vrijednosti od 13, 15, 16, 18, 19 i 20% ulazni skup podataka podijeljen je u 6 razreda. Prilikom kartiranja metodom indikatorskog kriginga najteže je odabrati granične vrijednosti koje definiraju razrede, budući da taj postupak najviše ovisi o iskustvu interpretatora. U ovom slučaju razredi su odabrani na način da njihovi histogrami slijede normalnu distribuciju. Takav postupak nije standardan, budući da indikatorske metode ne zahtijevaju normalizaciju, no pokazao se korisnim prilikom kartiranja.

Tablica 8.5: Indikatorska transformacija poroznosti ležišta Beta na temelju različitih graničnih vrijednosti

Bušotina	Por (%)	13 (%)	15(%)	16 (%)	18 (%)	19 (%)	20 (%)
Klo-60	17,92	0	0	0	1	1	1
Klo-62	15,32	0	1	1	1	1	1
Klo-70	12,23	1	1	1	1	1	1
Klo-75	17,48	0	0	0	1	1	1
Klo-5	18,00	0	0	0	1	1	1
Klo-63	16,56	0	0	0	1	1	1
Klo-64	15,04	0	0	1	1	1	1
Klo-73	13,26	0	1	1	1	1	1
Klo-76	18,46	0	0	0	0	1	1
Klo-78	16,18	0	0	0	1	1	1
Klo-79	18,45	0	0	0	0	1	1
Klo-81	19,06	0	0	0	0	0	1
Klo-82	18,30	0	0	0	0	1	1
Klo-83	16,02	0	0	0	1	1	1
Klo-87	17,29	0	0	0	1	1	1
Klo-88	15,52	0	0	1	1	1	1
Klo-89	17,93	0	0	0	1	1	1

Za kartiranje tehnikom indikatorskog kriginga nužna je variogramaska analiza podataka. Stoga su za svaku graničnu vrijednost napravljeni eksperimentalni variogrami, koji su zatim standardizirani i aproksimirani teorijskom krivuljom. Standardizaciju eksperimentalnog variograma nije bilo moguće napraviti za graničnu vrijednost 13% jer prilikom izrade iste nije dobivena niti jedna variogramaska točka. Razlog tomu je što su sve točke znatno iznad praga. Standardizirani i eksperimentalni variogrami prikazani su **slikom 8.13** i **tablicom 8.6** za glavnu os smjera 135°. Glavna os određena je na temelju karata variogramskih površina opisanim u potpoglavlju 8.1.



Slika 8.13: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable poroznosti ležišta Beta za granične vrijednosti: a-15%, b-16%, c-18% i d-19%

Tablica 8.6: Vrijednosti variograma varijable poroznosti ležišta Beta za određenu graničnu vrijednost


Granična vrijednost (m)	Model	Doseg glavne osi	Prag	Odstupanje
15	Sferni	740	1	0
16	Sferni	750	1	0
18	Sferni	1704	1	0
19	Sferni	525	1	0
20	Sferni	525	1	0

Za izradu karata vjerojatnosti poroznosti ležišta Beta korištene su sljedeće vrijednosti:


- Vrsta indikatorskog kriginga: potpuni (engl. *Full IK*)
- Vrsta kriginga: jednostavni
- Hmaks=2450; Hmin=630; Hvert=1; X=135; Y=0; Z=0
- Definicija mreže: X=233; Y=377; Z=1; min X=6374419; min Y=5064790; min Z=0;
- Veličina: X=10; Y=10; Z=1; Ukupan broj ćelija=87841

Karte su napravljene u programu WinGslib, a prikazane su **slikama 8.14, 8.15, 8.16 i 8.17**. Povećane poroznosti ležišta Beta nalaze se u središnjem i južnom dijelu karte, a najbolje se mogu uočiti na kartama koje prikazuju vjerojatnost da je kartirana varijabla (poroznost) manja od 16 (**slika 8.15**) i 18% (**slika 8.16**). Povećane poroznosti također pokazuju smjer sjeverozapad-jugoistok posebno na **slikama 8.14, 8.15 i 8.16**, odnosno smjer donosa materijala u vrijeme gornjeg panona, kao i smjer taložnog kanala.

Na **slikama 8.14 i 8.15** može se vidjeti da ležište dijagonalno presjeca jedno područje u kojem je povećana vjerojatnost da je poroznost manja od 15% ili 16%. Usporedbom **slika 8.14 i 8.16** može se zaključiti da je u sjeverozapadnom dijelu ležišta poroznost sigurno u rasponu od 15 do 18%, dok je u jugoistočnom dijelu ležišta poroznost veća od 18% s vjerojatnosti od 0,7. Uz jugozapadni rub ležišta proteže se zona u kojoj je poroznost sigurno veća od 15%, ali uz vjerojatnost od 0,8 da je manja od 18% (usporedba **slika 8.14 i 8.16**). Na **slici 8.17** uočava se samo jedno područje oko bušotine Klo-61 na kojem je velika vjerojatnost da je poroznost veća od 19%. Područje je izduženog oblika zbog zadanog smjera glavne osi.



Slika 8.14: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 15%




Slika 8.16: Karta vjerojatnosti varijable poroznosti ležišta Beta manje od granične vrijednosti 18%

Ukupna debljina ležišta Beta dobivena je iz 23 bušotinska podatka za koje je napravljena indikatorska transformacija. Ulazni skup podataka podijeljen je u šest razreda sa sljedećim graničnim vrijednostima: 3, 7, 9, 15, 21 i 23 m, odabranim na temelju normalne distribucije histograma razreda. Indikatorska transformacija ulaznih podataka prikazana je **tablicom 8.7**.

Tablica 8.7: Indikatorska transformacija ukupne debljine ležišta Beta na temelju različitih graničnih vrijednosti

Bušotina	Ukupna debljina (m)	3 (m)	7 (m)	9 (m)	15 (m)	21 (m)	23 (m)
Klo-5	3.0	1	1	1	1	1	1
Klo-19	15.5	0	0	0	0	1	1
Klo-60	23.0	0	0	0	0	0	1
Klo-62	22.5	0	0	0	0	0	1
Klo-63	9.0	0	0	1	1	1	1
Klo-64	10.0	0	0	0	1	1	1
Klo-70	3.5	0	1	1	1	1	1
Klo-73	4.0	0	1	1	1	1	1
Klo-74	20.5	0	0	0	0	1	1
Klo-75	20.0	0	0	0	0	1	1
Klo-76	14.5	0	0	0	1	1	1
Klo-77	22.0	0	0	0	0	0	1
Klo-78	13.5	0	0	0	1	1	1
Klo-79	14.0	0	0	0	1	1	1
Klo-81	11.5	0	0	0	1	1	1
Klo-82	18.5	0	0	0	0	1	1
Klo-83	8.5	0	0	1	1	1	1
Klo-84	9.0	0	0	1	1	1	1
Klo-86	8.5	0	0	1	1	1	1
Klo-87	10.0	0	0	0	1	1	1
Klo-88	8.0	0	0	0	1	1	1
Klo-89	7.0	0	1	1	1	1	1
Klo-163	18.0	0	0	0	0	1	1

Variogramске karte napravljene za svaku graničnu vrijednost ukazale su na postojanje glavne osi smjera 135° i sporedne osi smjera 45°. Eksperimentalni variogrami napravljene su kao standardizirani za glavnu os, a zatim su aproksimirani teorijskim krivuljama. To nije napravljeno samo za graničnu vrijednost 3 m, jer je za nju prilikom standardizacije dobivena samo jedna variogramска točka (dok su ostale bile znatno iznad praga i mogućnosti prikaza programa), pa je na kraju bilo nemoguće načiniti aproksimaciju. Ostali eksperimentalni i teorijski variogrami prikazani su **slikom 8.18** te **tablicom 8.8**.




Slika 8.18: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable ukupne debljine ležišta Beta za granične vrijednosti: a-7m, b-9m, c-15m i d-21m

Tablica 8.8: Vrijednosti variograma varijable debljine ležišta Beta za određenu graničnu vrijednost


Granična vrijednost (m)	Model	Doseg glavne osi	Prag	Odstupanje
7	Sferni	975	1	0
9	Sferni	623	1	0
15	Sferni	1116	1	0
21	Sferni	1329	1	0
23	Sferni	1329	1	0

Za izradu karata vjerojatnosti debljine ležišta Beta korištene su iste vrijednosti kao i prilikom kartiranja poroznosti istog ležišta (opisano u potpoglavlju 8.4.1).


Karte su prikazane slikama **8.19**, **8.20**, **8.21** i **8.22**. Najveće vjerojatnosti za povećane debljine ležišta Beta najbolje se mogu uočiti na **slikama 8.21 i 8.22** m. Južni i središnji dio ležišta ima najmanju vjerojatnost da su na tom području debljine manje od 15 i 21 m. Nasuprot tome, **slika 8.19** prikazuje najveću vjerojatnost da se debljine ležišta smanjuju prema sjeveroistoku, što je ujedno i smjer bočne promjene facijesa. Na slici **8.21 i 8.22** može se uočiti smjer taložnog kanala pružanja sjeverozapad-jugoistok. Zanimljivo je uočiti kako se područja najvećih poroznosti na gotovo svim kartama podudaraju s područjima najvećih debljina, što se najbolje može vidjeti usporedbom karata na **slikama 8.15 i 8.20**, gdje je područje dijagonalno presječeno jednim područjem manje poroznosti i manje debljine pružanja sjeverozapad-jugoistok od bušotine Klo-64 do Klo-73. Isto se vidi i na **slikama 8.21 i 8.16**, ali s tim da se područja smanjenih poroznosti i debljina pružaju i dalje u smjeru sjever-sjeverozapad, odnosno u krajnji sjeverozapadni dio ležišta. Na **slici 8.22** se vidi područje povećane debljine u središnjem dijelu ležišta, od bušotine Klo-60 do Klo-77, koje se uglavnom podudara s distribucijom poroznosti na **slikama 8.14 i 8.15**.



Slika 8.19: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 7 m



Slika 8.20: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 9 m



Slika 8.21: Karta vjerojatnosti varijable debljine ležišta Beta manje od granične vrijednosti 15 m

8.4.2. Kartiranje indikatorskih varijabli donjopontskog ležišta T

Kartirane indikatorske varijable su poroznost i debljina sedimenata ležišta T. Indikatorska transformacija poroznosti prikazana je u **tablici 8.9**. Vrijednosti poroznosti predstavljaju srednje poroznosti dobivene iz karotažnih mjerenja u 20 bušotina. Karotažne krivulje korištene za izračun poroznosti bile su krivulje spontanog potencijala (SP), jer se radilo o starijim bušotinama u kojima su načinjena mjerenja samo konvencionalnom karotažom.

Vrijednost poroznosti u bušotini Klo-43 je iznimno mala u odnosu na ostale bušotine i zato je ona isključena iz daljnjeg proračuna, tj. kartiranja kao statistički ekstrem (engl. *outlier*), kao što su u svom radu opisali NOVAK ZELENKA et al. (2010). Preostalih 19 bušotina predstavlja relativno mali statistički uzorak (rezultati srednje vrijednosti i varijance nisu reprezentativni, tj. izvan su dopuštene granice za interval pouzdanosti od 95%). Također, i udaljenost između nekih bušotina je znatno veća od prosječne unutar skupa od 19 spomenutih vrijednosti. Dodatne ulazne vrijednosti procijenjene su na pogodnim lokacijama na temelju karata dobivenih tehnikom običnog kriginga te su na taj način bušotine "pretpostavljene bušotine". Na taj način je procijenjena vrijednost u šest dodatnih, "pretpostavljenih bušotina" te se indikatorska transformacija načinila na temelju ukupno 25 vrijednosti. Naravno, postavljeno je pitanje pouzdanosti tih novih vrijednosti u odnosu na mjerenje ili „čvrste“ podatke odnosno javlja li se veća pogreška njihovim uvođenjem, negoli je korist od uporabe većeg ulaznog skupa za transformaciju i kartiranje.

No korist od takvog postupka bila je znatno veća i to upravo zbog same indikatorske transformacije te konstrukcije indikatorskih variograma. Kod indikatorskih tehnika jedina prostorna zavisnost dolazi tek iz pretpostavke stacionarnosti 3. reda. To znači da je jedini statistički čvrsti podatak statistika samih variograma. Nadalje, indikatorske varijable definirane graničnim vrijednostima ovise isključivo o broju odabranih razreda i ne preporuča se da ih je manje od pet, jer u tom slučaju frekvencija razreda ne može održavati pretpostavljeni oblik histograma. Znači skup od 25 podataka donosi znatno veću sigurnost u određivanje dosega indikatorskih variograma te razreda graničnih vrijednosti negoli li skup od 19 mjerenja, čak i u slučaju kada je 6 dodatnih mjerenja pretpostavljeno. Spomenute vrijednosti dobivene su kartiranjem običnim krigingom na izvornim podacima (prije indikatorske transformacije).

Dodatne točke (ili imaginarne bušotine) su nazvane A, B, C, D, E i F. Granične vrijednosti na temelju kojih je napravljena indikatorska transformacija sada svih 25 podataka su 14, 18, 19,


20, 22 i 24% (**tablica 8.9**). Odabir graničnih vrijednosti temeljio se na normalnoj distribuciji histograma razreda.

Tablica 8.9: *Indikatorska transformacija poroznosti ležišta T na temelju različitih graničnih vrijednosti*

Bušotina	Por (%)	14%	18%	19%	20%	22%	24%
Klo-1	19.86	0	0	0	1	1	1
Klo-12	19.50	0	0	0	1	1	1
Klo-16	19.62	0	0	0	1	1	1
Klo-20	21.09	0	0	0	0	1	1
Klo-22	23.28	0	0	0	0	0	1
Klo-23	20.53	0	0	0	0	1	1
Klo-24	20.05	0	0	0	0	1	1
Klo-26	21.16	0	0	0	0	1	1
Klo-27	17.94	0	1	1	1	1	1
Klo-28	19.16	0	0	0	1	1	1
Klo-35	13.80	1	1	1	1	1	1
Klo-48	19.67	0	0	0	1	1	1
Klo-57	18.17	0	0	1	1	1	1
Klo-58	21.81	0	0	0	0	1	1
Klo-59	18.06	0	0	1	1	1	1
Klo-71	18.50	0	0	1	1	1	1
Klo-72	19.63	0	0	0	1	1	1
Klo-95	22.04	0	0	0	0	0	1
Klo-104	18.36	0	0	1	1	1	1
A	20.58	0	0	0	0	1	1
B	20.38	0	0	0	0	1	1
C	19.59	0	0	0	1	1	1
D	19.28	0	0	0	1	1	1
E	17.43	0	1	1	1	1	1
F	18.51	0	0	1	1	1	1

Za svaku pojedinu graničnu vrijednost napravljeni su eksperimentalni variogrami, koji su zatim standardizirani i aproksimirani teorijskim krivuljama, osim za graničnu vrijednost 24%, za koju nije bilo potrebno napraviti variogram jer su joj sve vrijednosti iste (iznose 1). Variogrami su standardizirani iz razloga što oni, a da bi se mogli međusobno uspoređivati, kao i rezultati prikazati indikatorskim kartama vjerojatnosti, moraju imati uvijek jednaku srednju vrijednost i varijancu, bez obzira koja se granična vrijednost promatra.

Budući da se nije mogao utvrditi smjer glavne i sporedne osi, variogrami su izračunati kao neusmjereni. Svi eksperimentalni i teorijski indikatorski variogrami poroznosti u ležištu T prikazani su **slikom 8.23**.



Slika 8.23: Eksperimentalni variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable poroznosti ležišta T za granične vrijednosti: a-14%, b-18%, c-19%, d-20% i e-22%.

Vrijednosti standardiziranih variograma varijable poroznosti ležišta T prikazani su **tablicom 8.10**.


Tablica 8.10: Vrijednosti teorijskih standardiziranih variograma varijable poroznosti ležišta *T* za određenu graničnu vrijednost

Granična vrijednost (%)	Model	Doseg	Prag	Odstupanje
14	Sferni	200	1	0
18	Sferni	600	1	0
19	Sferni	800	1	0
20	Sferni	900	1	0
22	Sferni	100	1	0


Karte dobivene tehnikom indikatorskog kriginga su karte vjerojatnosti, a prikazuju vjerojatnost da je vrijednost varijable manja od određene granične vrijednosti. Prikazane su slikama 8.24, 8.25, 8.26, 8.27 i 8.28.

Karte su napravljene u programu WinGslib, a korištene su sljedeće vrijednosti:


- Vrsta indikatorskog kriginga: potpuni (engl. *Full IK*)
- Vrsta kriginga: jednostavni
- Hmaks=1750; Hmin=750; Hvert=1; X=0; Y=0; Z=0
- Definicija mreže: X=251; Y=251; Z=1; min X=6376000; min Y=5066500; min Z=1
- Veličina: X=10; Y=10; Z=1; Ukupan broj ćelija=630010.




Slika 8.24: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 14%



Slika 8.26: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 19%



Slika 8.27: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 20%



Slika 8.28: Karta vjerojatnosti varijable poroznosti manje od granične vrijednosti 22%


Varijabla ukupne debljine ležišta T također je kartirana tehnikom indikatorskog kriginga, a indikatorska transformacija temeljila se na graničnim vrijednostima 5, 9, 13, 17, 21 i 25 m (**tablica 8.11**), odabranim na način opisan u prijašnjim potpoglavljima. Ovoga puta korišteni su samo bušotinski podatci, bez dodanih točaka, a razlog tomu je što varijabla debljine ima manju relativnu varijancu nego varijabla poroznosti te stoga toliko ne ovisi o većem skupu podataka te nije bilo nužno ponavljati postupak s dodatnim „imaginarnim“ točkama. Debljina je izračunata kao ukupna debljina od krovine do podine ležišta. Također su izračunati eksperimentalni i teorijski variogrami za svaku pojedinu graničnu vrijednost. Variogrami su standardizirani i neusmjereni, a prikazani su **slikom 8.29** te **tablicom 8.12**.

Tablica 8.11: Indikatorska transformacija ukupne debljine ležišta T na temelju različitih graničnih vrijednosti

Bušotina	Ukupna debljina (m)	5 m	9 m	13 m	17 m	21 m	25 m
Klo-1	13,0	0	0	1	1	1	1
Klo-12	12,0	0	0	1	1	1	1
Klo-16	12,0	0	0	1	1	1	1
Klo-20	13,0	0	0	1	1	1	1
Klo-22	11,5	0	0	1	1	1	1
Klo-23	12,0	0	0	1	1	1	1
Klo-24	11,0	0	0	1	1	1	1
Klo-26	9,5	0	0	1	1	1	1
Klo-27	20,0	0	0	0	0	1	1
Klo-28	17,0	0	0	0	1	1	1
Klo-35	3,0	1	1	1	1	1	1
Klo-48	13,5	0	0	0	1	1	1
Klo-57	25,0	0	0	0	0	0	1
Klo-58	6,0	0	1	1	1	1	1
Klo-59	9,0	0	1	1	1	1	1
Klo-71	10,0	0	0	1	1	1	1
Klo-72	11,0	0	0	1	1	1	1
Klo-95	8,0	0	1	1	1	1	1
Klo-104	6,0	0	1	1	1	1	1

Tablica 8.12: *Vrijednosti teorijskih standardiziranih variograma varijable debljine ležišta T za određenu graničnu vrijednost*


Granična vrijednost (m)	Model	Doseg	Prag	Odstupanje
5	Sferni	460	1	0,4
9	Sferni	420	1	0,4
13	Sferni	460	1	0,4
17	Sferni	400	1	0,4
21	Sferni	400	1	0,4
25	Sferni	400	1	0,4




Slika 8.29: Standardizirani variogrami (lijevo) te njihova aproksimacija teorijskim krivuljama (desno) varijable ukupne debljine ležišta T za granične vrijednosti: a-5m, b-9m, c-13m, d-17m i e-21m

Karte vjerojatnosti da će debljina biti manja od određene granične vrijednosti prikazane su **slikama 8.30, 8.31, 8.32 i 8.33**.


Tehnika indikatorskog kriginga najčešće se koristi za kartiranje različitih litofacijesa, uz pretpostavku da se upravo odabranim graničnim vrijednostima mogu odvojiti područja svih prijelaznih oblika u ovom slučaju od čistog kanalnog pješčenjaka pa do čistog bazenskog lapora. Karte indikatorskog kriginga prikazuju vjerojatnosti da je kartirana varijabla manja od određene granične vrijednosti, što znači da karta koja prikazuje vjerojatnost debljine manju od 9 m u sebi sadrži i vjerojatnost da je debljina manja i od 5 m. Za točno definiranje litofacijesa bilo bi potrebno napraviti karte vjerojatnosti intervala npr. od 5 do 9 m, no isti se rezultati mogu dobiti promatranjem i preklapanjem dviju karti (jedne koja prikazuje vjerojatnosti da je kartirana varijabla manja od 5 a druga od 9 m). Područja najmanjih vjerojatnosti na karti debljine manjoj od 5 m i najvećih vjerojatnosti debljine manjih od 9 m upravo daju područje intervala 5 do 9 m. Vrijedi mišljenje da su najveće debljine ležišta u najdubljim dijelovima kanala (ŠIMON, 1980). Usporede li se karte vjerojatnosti varijable debljine za granične vrijednost 9 i 13 m može se zaključiti da debljina ležišta varira upravo između te dvije vrijednosti. Najveće vjerojatnosti za najdeblje dijelove ležišta prikazana su zelenom bojom na **slici 8.32**, a zanimljivo je da se one ne poklapaju s lokacijama vjerojatnosti najvećih poroznosti (**slike 8.24, 8.25 i 8.26**), nego tek djelomično s povećanim. Smjer sjeverozapad-jugoistok, može se dobro uočiti na karti vjerojatnosti debljine za graničnu vrijednost 13 m (**slika 8.32**), dok se na ostalima (**slike 8.30, 8.31 i 8.33**) ne razabire. Smjer sjeverozapad-jugoistok može se također dobro uočiti na karti vjerojatnosti varijable poroznosti za graničnu vrijednost 19% (**slika 8.26**). Plava boja na karti prikazuje područje u kojem su najveće vjerojatnosti da su vrijednosti poroznosti veće od 19%, dakle područje u kojem se nalaze čisti pješčenjaci. Naime, prema iskustvu i povijesti proizvodnje u Savskoj depresiji, slobodno se može tvrditi da takva poroznost odgovara čistim pješčenjacima. Smjer sjeverozapad-jugoistok ujedno je i pružanje velikog regionalnog Kloštarskog rasjeda, koji jugozapadno zatvara ležište. Na **slici 8.27** može se uočiti kako su najveće poroznosti u zapadnom, najdubljem dijelu ležišta. No, pomnijim promatranjem karte vjerojatnosti za graničnu vrijednost 19% (**slika 8.26**) te karte za graničnu vrijednost 20% (**slika 8.27**) moguće je rekonstruirati smjer donosa materijala. Na **slici 8.26** jako se dobro uočava taložni kanal smjera sjeverozapad-jugoistok, međutim, ako se granična vrijednost poveća za samo 1% taložni se kanal više ne može dobro vidjeti. Tada se jasno uočavaju samo povećane vrijednosti poroznosti na zapadnom dijelu karte.




Slika 8.30: Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 5 m



Slika 8.31: Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 9 m



Slika 8.32: Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 13m



Slika 8.33: Karta vjerojatnosti varijable debljine ležišta T manje od granične vrijednosti 17m

9. SEKVENCIJSKE GEOSTATISTIČKE SIMULACIJE LEŽIŠNIH VARIJABLI

Primjenom stohastike dobivamo više realizacija, koje mogu biti nalik jedna drugoj, no ipak se vizualno i statistički razlikuju. Osnovna karakteristika realizacija je da su sve jednako vjerojatne, stoga svrha simulacija nije dobivanje samo jednog rješenja te nije moguće izdvojiti samo jednu realizaciju kao najbolju. Stohastički sustavi karakterizirani su uvođenjem slučajnosti te samim time sadrže određene nesigurnosti. BARDOSSY & FODOR (2011) ukazuju da deterministička i stohastička rješenja mogu biti matematički točna, no nikako ne mogu biti potpuno sigurna. Izradom niza realizacija moguće je kartirati područja najvećih nesigurnosti, a to su ona područja na kojima postoje najveće razlike između realizacija, te su stohastički modeli vrlo primjenjivi u karakterizaciji ležišta (MALVIĆ, 2008).

Dvije metode simulacija primijenjene su za prikaz distribucije varijabli ležišta Beta i T. To su sekvencijske Gaussove simulacije i sekvencijske indikatorske simulacije. Obje pripadaju uvjetnim simulacijama, što znači da zadržavaju čvrste ulazne podatke, a procjena se radi samo na lokacijama na kojima nije bilo mjerenja. Postoje brojni radovi u kojima su opisane primjene simulacija u svijetu, kako sekvencijskih Gaussovih, tako i sekvencijskih indikatorskih, npr. HAND et al. (1994), DAMAYANTI & HICKS (1996), SAHIN & AL-SALEM (2001).

Varijable kartirane sekvencijskim Gaussovim simulacijama su poroznost, dubina i debljina ležišta Beta i T, a sekvencijskim indikatorskim simulacijama samo poroznost i debljina istih ležišta. Kartiranje je napravljeno u programu WinGslib, s ukupno stotinu realizacija za svaku varijablu, od kojig će u u sljedećim potpoglavljima biti prikazane samo realizacije dobivene kao prva, pedeseta i stota.

9.1. SEKVENCIJSKE GAUSSOVE SIMULACIJE

Osnovni preduvjet da bi se kartiralo sekvencijskim Gaussovim simulacijama je normalna razdioba ulaznih podataka. Ukoliko to nije slučaj i ulazni podatci ne slijede normalnu distribuciju potrebno ih je transformirati. Idući korak je variogramaska analiza podataka te izrada „nultog“ rješenja, koje čini deterministička karta dobivena metodom kriginga. Vrijednosti u ćelijama modela zatim se procjenjuju u intervalu ± 3 standardne devijacije oko

„nultog“ rješenja. Budući da su isti skupovi ulaznih podataka kartirani determinističkim interpolacijskim i stohastičkim metodama, primijenjene su iste variogramске analize opisane u poglavlju 8.

9.1.1. Kartiranje varijabli gornjopanonskog ležišta Beta

Varijable poroznosti, debljine i dubine ležišta Beta kartirane su sekvencijskim Gaussovim simulacijama. Prva, pedeseta i stota realizacija distribucije poroznosti prikazana je **slikama 9.1 a-c**, varijable debljine **slikama 9.2 a-c**, te varijable dubine **slikama 9.3 a-c**.

Najveće vrijednosti poroznosti i debljine ležišta Beta nalaze se u središnjem i jugoistočnom dijelu ležišta što se može dobro vidjeti na **slikama 9.1 i 9.2**. Na **slici 9.1** prikazane su prva realizacija distribucije poroznosti (**a**), zatim pedeseta (**b**) i stota (**c**). Na prvoj i pedesetoj realizaciji jasno se uočavaju područja s povećanim vrijednostima poroznosti (>18%) u središnjem dijelu ležišta sjeverno od bušotine Klo-78 (**slike 9.1 a i b**), kao i još veće područje poroznosti na jugoistočnom dijelu ležišta, koje se vidi na stotoj realizaciji (**slika 9.1 c**). Područja povećane debljine ležišta Beta prikazane na **slici 9.2 a-c** donekle se podudaraju s područjima povećane poroznosti, ali samo u smislu da je debljina povećana u jugoistočnom dijelu ležišta, dok je maksimum koji se uočava na kartama poroznosti u središnjem dijelu ležišta pomaknut malo prema jugozapadu u područje oko bušotine Klo-60. Sve karte distribucije poroznosti (**slike 9.1 a-c**), debljine (**slike 9.2 a-c**) i dubine (**slike 9.3 a-c**) imaju trend pružanja sjeverozapad-jugoistok, što je ujedno i pružanje glavne osi variograma. Područja najvećih dubina podudaraju se s najvećim debljinama sloja samo u središnjem dijelu ležišta, oko bušotine Klo-60 (usporedba **slike 9.3 a-c** sa slikom **9.2 a i 9.2 c**). Ono što je različito je položaj područja najvećih dubina u južnom dijelu ležišta, koje je u odnosu na područje najvećih debljina sloja redovito pomaknuto prema jugozapadu (usporedba **slike 9.2 c i 9.3 c**), a posebno činjenica da se na prvoj realizaciji distribucije dubine (**slika 9.3 a**) pojavljuje još jedan maksimum u sjevernom dijelu ležišta kod bušotine Klo-88, koji se ne uočava na drugim realizacijama (**9.3 b i c**), nego možda još jedino na prvoj realizaciji debljine ležišta na **slici 9.2 a**. Opisane razlike mogu se interpretirati utjecajem mlađih tektonskih pokreta (2. transpresijska faza), koji su promijenili odnose kakvi su bili u vrijeme taloženja, kada su najveće dubine prihvatile i najveće količine krupnozrnatih sedimenata. Izdizanjem Kloštarske antiklinale nakon taloženja sloja koji danas čini ležište Beta, jugozapadni su dijelovi ležišta spuštene, te je tako došlo do translacije područja najvećih dubina u smjeru jugozapada u odnosu na područja najvećih debljina sloja. Ostale razlike,

odnosno nepodudarnosti između karata debljina i dubina (**slike 9.2 i 9.3**) su posljedica nesigurnosti procjene s obzirom da je riječ o sjeverozapadnom rubnom dijelu ležišta.


Drugi važan doprinos ove geostatističke simulacije je da se na svim kartama debljine ležišta prikazanim na **slici 9.2** i na svim kartama dubine (**slika 9.3**) uočena pravilnost smanjivanja vrijednosti u smjeru sjeveroistoka, prema liniji bočne promjene facijesa. To se može smatrati potvrdom da je oblik dna taložnog bazena Kloštarske antiklinale u vrijeme taloženja pješčenjaka ležišta Beta (kasni panon) utjecao na prostorni raspored litofacijesa. Trend postupne bočne promjene litofacijesa od čistih pješčenjaka preko prijelaznih mješovitih sedimenata u čiste lapore označen je strelicama na **slici 9.2**. Uočeni trendovi pružanja izolinija posljedica su variogramskih modela, koji prate autokorelaciju ulaznih podataka.

9.1.2. Kartiranje varijabli donjopontskog ležišta T


Metodom sekvencijskih Gaussovih simulacija napravljeno je sto realizacija varijabli poroznosti, dubine i debljine ležišta T. Prva, pedeseta i stota realizacija distribucije poroznosti prikazane su **slikama 9.4 a-c**. Realizacije varijable debljine ležišta T prikazane su **slikama 9.5 a-c**, a varijable dubine istog ležišta **slikama 9.6 a-c**.

Na kartama distribucije poroznosti na svim realizacijama (**slike 9.4 a-c**) jasno se vide povećane poroznosti u zapadnom dijelu ležišta te jasno izražen trend pružanja sjever-jug. Taj trend je dijagonalan u odnosu na pružanje Kloštarskog rasjeda koji čini jugozapadni rub ležišta, a vjerojatno je posljedica neusmjerenog variograma. Zapadni je dio ležišta ujedno i najdublji dio, što se može vidjeti na **slici 9.6 a-c**, s malim razlikama u sjeveroistočnom dijelu polja, sjeverno od bušotine Klo-104, ali samo na prvoj i pedesetoj realizaciji distribucije dubine prikazanim na **slikama 9.6 a i 9.6 b**. Zaključak koji se prvi nameće je da su zadržani odnosi kakvi su bili u vrijeme taloženja, odnosno da se u najdubljem dijelu taložnog bazena nakupljao krupni detritus, dok se bočno, nešto pliće, na rubovima, taložio sitniji. Međutim, važno je naglasiti da su današnje dubine ležišta posljedica i kasnije, postsedimentacijske, tektonike, stoga ne treba promatrati te dvije varijable isključivo na takav način. Karte debljine (**slike 9.5 a-c**) ne daju jasnu sliku, odnosno pravilnost na temelju koje bi se moglo zaključivati o uvjetima taloženja sloja pješčenjaka koji danas čini ležište T, no pedeseta i stota realizacija (**slike 9.5 b i c**) istovremeno s izraženim trendom sjever-jug ukazuju na generalno smanjivanje debljine ležišta u smjeru istoka. Na prvoj realizaciji (**slika 9.5 a**) trend sjever-jug je zbilja blag, a ne može se uočiti niti pravilnost u promjeni debljine sloja.


Općenito, karte odabranog parametra dobivene Gaussovim simulacijama trebalo bi u prvom redu čitati kao indikacije područja s najvećom nesigurnosti procjene kartirane vrijednosti. Tako se može vidjeti npr. na **slikama 9.6 b i 9.6 c** da područje sjeverno od bušotine Klo-104 sadrži najveću nesigurnost zbog toga što je na **slici 9.6 b** tu najveća vrijednost (1050 m), a na **slici 9.6 c** najmanja vrijednost (750 m).




Slika 9.1: Distribucija poroznosti ležišta Beta kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.2: Distribucija debljine ležišta Beta kartirana sekvencijskim Gaussovim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.3: Distribucija dubine ležišta Beta kartirana sekvencijskim Gaussovima simulacijama: *a*-prva realizacija, *b*-pedeseta realizacija i *c*-stota realizacija



Slika 9.4: Distribucija poroznosti ležišta *T* kartirana sekvencijskim Gaussovima simulacijama: *a*-prva realizacija, *b*-pedeseta realizacija i *c*-stota realizacija



Slika 9.5: Distribucija debljine ležišta T kartirana sekvencijskim Gaussovima simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija



Slika 9.6: Distribucija dubine ležišta T kartirana sekvencijskim Gaussovim simulacijama: a- prva realizacija, b-pedeseta realizacija i c-stota realizacija

9.2. SEKVENCIJSKE INDIKATORSKE SIMULACIJE

Za razliku od sekvencijskih Gaussovih simulacija, za sekvencijske indikatorske simulacije nije nužna normalna razdioba ulaznih podataka. One podrazumijevaju, poput svih indikatorskih metoda, samo stacionarnost trećeg reda, što znači da je variogram jedino reprezentativno statističko obilježje podataka. Budući da koriste indikatorsku transformaciju, izvorni podatci skup su samo dviju kategoričkih vrijednosti (0 i 1). Variogrami za svaku graničnu vrijednost moraju biti standardizirani jer je izvorni skup podataka isti, što znači da je, bez obzira na graničnu vrijednost, ulazna varijanca uvijek ista, iako su se razlike izlaznog skupa dogodile zbog indikatorske transformacije. Jedan od rezultata sekvencijskih indikatorskih simulacija su realizacije koje prikazuju vrijednosti kartirane varijable (poput Gaussovih), ali glavni izlaz su karte vjerojatnosti za određenu graničnu vrijednost. U ovom radu kartiranje sekvencijskim indikatorskim simulacijama napravljeno je tako da dobivene karte prikazuju vjerojatnost da je kartirana varijabla veća od određene granične vrijednosti (kod indikatorskog kriginga bilo je suprotno, prikazale su se vjerojatnosti da je varijabla manja od granične vrijednosti).

Sekvencijskim indikatorskim simulacijama analizirane su varijable poroznosti i debljine ležišta Beta i T, koje su odabrane kao varijable koje posredno ocrtavaju i litofacies tih pješčenjačkih slojeva. Granične vrijednosti za svaku varijablu i eksperimentalni variogrami isti su kao i kod kartiranja indikatorskim krigingom i bili su opisani u osmom poglavlju. Napravljeno je stotinu realizacija, a prikazane su samo prva, pedeseta i stota s vrijednostima varijabli i vjerojatnostima za odabranu graničnu vrijednost.

9.2.1. Kartiranje varijabli gornjopontskog ležišta Beta

Varijable poroznosti i debljine ležišta Beta kartirane su metodom sekvencijskih indikatorskih simulacija, a prva, pedeseta i stota realizacija prikazane su **slikama 9.7 a-c** (poroznost) te **9.8 a-c** (debljina). Na prvoj realizaciji distribucije poroznosti ležišta Beta (**slika 9.7 a**) najveće vrijednosti poroznosti su u području oko bušotine Klo-60, Klo-81, Klo-84 te južno od bušotine Klo-88. Područja najvećih vrijednosti poroznosti na pedesetoj realizaciji (**slika 9.7 b**) su oko bušotina Klo-5, Klo-64, južno od bušotine Klo-50, oko bušotine Klo-81 te u području bušotine Klo-75. Na stotoj realizaciji (**slika 9.7 c**) izraženo je samo jedno područje najveće procijenjene poroznosti sjeveroistočno od bušotine Klo-62. Iako se područja najvećih poroznosti ne podudaraju u potpunosti na svim realizacijama, generalno podudaranje

povećanih poroznosti ipak postoji, a ono se nalazi dijelom u središnjem te u jugoistočnom dijelu ležišta. Najniže vrijednosti poroznosti na svim realizacijama (**slika 9.7 a-c**) uočavaju se u sjevernom dijelu karte, u području oko bušotine Klo-70, te na prvoj i pedesetoj realizaciji (**slika 9.7 a i b**) na jugozapadu. Područje s najmanje podudarnosti na svim realizacijama je u sjeveroistočnom dijelu ležišta, oko bušotina Klo-69 i Klo-50, gdje je u prvoj realizaciji (**slika 9.7 a**) procijenjena poroznost oko 17%, u pedesetoj (**slika 9.7 b**) između 18 i 19%, a u stotoj (**slika 9.7 c**) oko 15%.

Prva, pedeseta i stota realizacija distribucije debljine ležišta Beta prikazane su **slikom 9.8 a-c**. Usporede li se sve realizacije zajedno, odmah se može uočiti kako se područja najvećih i najmanjih debljina na različitim realizacijama uglavnom ne podudaraju. Podudarnost najvećih debljina na svim realizacijama (**slika 9.8 a-c**) je samo oko bušotine Klo-60 u istočnom dijelu ležišta, a najmanjih na sjevernom dijelu u području oko bušotina Klo-5 i Klo-70. Najniže vrijednosti debljina procijenjene su na stotoj realizaciji (**slika 9.8 c**), dok prva i pedeseta realizacija (**slika 9.8 b i c**) pokazuju otprilike jednake vrijednosti u omjeru povećanih i smanjenih debljina, no distribucija im je različita.


Usporede li se realizacije poroznosti i debljine dobivene sekvencijskim Gausovim simulacijama (**slike 9.1 a-c i 9.2 a-c**) i realizacije dobivene sekvencijskim indikatorskim simulacijama (**slike 9.7 a-c i 9.8 a-c**) mogu se uočiti nešto niže vrijednosti u realizacijama dobivenim sekvencijskim indikatorskim simulacijama. Središnji i jugoistočni dio ležišta u obje procjene pokazuje najveće vrijednosti. Na svim se realizacijama, kako sekvencijskim Gausovim, tako i sekvencijskim indikatorskim, može uočiti trend sjeverozapad-jugoistok, što je zapravo posljedica usmjerenosti glavne osi variograma.

Također su napravljene karte vjerojatnosti, a prikazane su **slikama 9.9, 9.10, 9.11 i 9.12** za varijablu poroznosti te **9.13, 9.14, 9.15 i 9.16** za debljinu. Prikazuju vjerojatnosti da su vrijednosti varijabli veće od graničnih vrijednosti. Budući da su korištene iste granične vrijednosti kao i prilikom kartiranja indikatorskim krigingom, karte vjerojatnosti dobivene sekvencijskim indikatorskim simulacijama odgovaraju kartama vjerojatnosti dobivenim indikatorskim krigingom, no obrnute su. Dakle, ona područja koja su na kartama indikatorskog kriginga bila prikazana kao maksimum, na sekvencijskim indikatorskim realizacijama dat će minimalne vrijednosti. Usporede li se **slike 8.14 i 9.9** koje prikazuju vjerojatnosti varijable poroznosti za graničnu vrijednost 15%, na obje karte mogu se uočiti tri maksimuma u slučaju kartiranja indikatorskim krigingom, odnosno tri minimuma kod kartiranja sekvencijskim indikatorskim simulacijama. Maksimumi, odnosno minimumi nalaze se na lokacijama oko bušotina Klo-64, Klo-71 i Klo-73. Na isti se način mogu


usporediti i sve ostale karte vjerojatnosti za granične vrijednosti 16, 18 i 19%. Područja koja prikazuju maksimume na kartama indikatorskog kriginga odgovaraju minimumima u sekvencijskim indikatorskim simulacijama (usporedba **slika 8.15 i 9.10, 8.16 i 9.11 te 8.17 i 9.12**).

Isto vrijedi i za karte vjerojatnosti varijable debljine (**slike 9.13, 9.14, 9.15 i 9.16**). Granične vrijednosti korištene prilikom kartiranja sekvencijskim indikatorskim simulacijama su iste kao i kod kartiranja indikatorskim krigingom. Usporedbom karata vjerojatnosti varijable debljine ležišta Beta, za graničnu vrijednost 7 m (**slike 8.19 i 9.13**) uočeno je da su najveće vjerojatnosti za debljine manje od 7 m oko bušotina Klo-70, Klo-5, Klo-89 i Klo-73. Na kartama vjerojatnosti varijable debljine za granične vrijednosti 9 i 15 m (**slike 8.20, 8.21, 9.14 i 9.15**) može se uočiti da su povećane vjerojatnosti za debljine veće od 9 i 15 m u središnjem i južnom dijelu ležišta. Na istim se kartama može vidjeti smanjenje vjerojatnosti u smjeru sjeveroistoka, što ukazuje na stanjivanje ležišta. Bočna promjena litofacijesa također je u istom smjeru. Područje oko bušotina Klo-60, Klo-62 i Klo-77 ima veliku vjerojatnost za debljinu veću od 21 m, a jasno se vidi na **slikama 8.22 i 9.16**. To je ujedno i najdeblji dio ležišta.


Ako se zanemari činjenica o obrnutosti prikaza, rezultati dobiveni sekvencijskim indikatorskim simulacijama u potpunosti odgovaraju onima dobivenim indikatorskim krigingom. Ipak, postoji razlika u rezoluciji prikaza karata dobivenih indikatorskim krigingom i sekvencijskim indikatorskim simulacijama. Naime, budući da se simulacijama procjenjuju vrijednosti u ćelijama, a indikatorski kriging je interpolacijska metoda, jasno je da će karte dobivene indikatorskim krigingom biti oštrije u odnosu na karte dobivene sekvencijskim indikatorskim simulacijama. Taložni kanal smjera sjeverozapad-jugoistok također je vidljiv i na kartama vjerojatnosti dobivenim sekvencijskim indikatorskim simulacijama, ali samo na **slikama 9.11, 9.30, 9.31 i 9.32** (granična vrijednost poroznosti 18% te debljine 9, 15 i 21 m).




Slika 9.7: Distribucija poroznosti ležišta Beta kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.8: Distribucija debljine ležišta Beta kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.9: Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 15%




Slika 9.10: Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 16%




Slika 9.11: Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 18%




Slika 9.12: Karta vjerojatnosti varijable poroznosti ležišta Beta veće od granične vrijednosti 19%




Slika 9.13: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 7 m



Slika 9.14: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 9 m



Slika 9.15: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 15 m



Slika 9.16: Karta vjerojatnosti varijable debljine ležišta Beta veće od granične vrijednosti 21 m

9.2.2. Kartiranje varijabli donjoponskog ležišta T

Prva, pedeseta i stota realizacija varijable poroznosti ležišta T, kartirana sekvencijskim indikatorskim simulacijama, prikazana je **slikom 9.17 a-c**. Realizacije prikazuju vrijednosti poroznosti u postocima. Na prvoj realizaciji distribucije poroznosti (**slika 9.17 a**) najveće vrijednosti poroznosti su u središnjem dijelu ležišta, a povećane sjeverno, u području oko bušotine Klo-129, te južno uz Kloštarski rasjed, oko bušotina Klo-1, Klo-14, Klo-15, Klo-132 i Klo-122. Područje povećane poroznosti u središnjem dijelu ležišta oko bušotine Klo-22 zapaža se i na ostalim realizacijama (**slika 9.17 b i c**). Najniža vrijednost poroznosti procijenjena na oko 5% prikazana je na stotoj realizaciji (**slika 9.17 c**) u sjevernom dijelu ležišta između bušotina Klo-98 i Klo-99 te u središnjem dijelu ležišta između bušotina Klo-120, Klo-40 i Klo-41. U istom području na ostalim realizacijama vrijednost poroznosti procijenjena je između 18 i 19%. U istočnom dijelu ležišta također se javljaju razlike u vrijednostima poroznosti između realizacija (**slika 9.17 a-c**). Takve razlike upućuju na područje najvećih nesigurnosti, a vjerojatno su uvjetovane bočnom promjenom litofacijesa u smjeru istoka.

Na **slici 9.18 a-c** prikazana je prva, pedeseta i stota realizacija distribucije debljine ležišta T kartirana sekvencijskim indikatorskim simulacijama. Na kartama su prikazane vrijednosti debljine u metrima. Realizacije debljine (**slika 9.18 a-c**) na cijelom kartiranom području prikazuje dosta uniformne vrijednosti, bliske srednjim vrijednostima. Iako nema značajnih razlika između realizacija, male razlike ipak postoje, a najviše su izražene u području između bušotina Klo-18, Klo-124, Klo-38, Klo-42 i Klo-135. U prvoj su realizaciji (**slika 9.18 a**) debljine na tom području procijenjene na oko 3 m, a u pedesetoj i stotoj (**slika 9.18 b i c**) oko 15 m. Niti na kartama poroznosti (**slika 9.17 a-c**), niti debljine (**slika 9.18 a-c**) se ne mogu dobro uočiti strukturni elementi ili taložni kanal.

Osim vrijednostima na izvornoj skali, sekvencijskim indikatorskim simulacijama mogu se prikazati i vjerojatnosti da je vrijednost varijable veća od određene granične vrijednosti. Takve karte prikazane su **slikama 9.19, 9.20, 9.21, 9.22 i 9.23** za poroznost i **slikama 9.24, 9.25, 9.26 i 9.27** za debljinu ležišta T. Granične vrijednosti korištene prilikom kartiranja sekvencijskim indikatorskim simulacijama jednake su onima korištenim prilikom kartiranja indikatorskim krigingom, stoga su karte dobivene sekvencijskim indikatorskim simulacijama vrlo slične kartama dobivenim indikatorskim krigingom, samo su obrnute, budući da karte dobivene sekvencijskim indikatorskim simulacijama prikazuju vjerojatnost da je kartirana varijabla veća od određene granične vrijednosti. Najmanja vjerojatnost da je


poroznost veća od 14% je u jugoistočnom dijelu karte, oko bušotina Klo-43 i Klo-35 (**slike 8.24 i 9.19**). Povećavajući graničnu vrijednost na 18% (**slike 8.25 i 9.20**) područje najnižih vjerojatnosti da je poroznost veća od 18% i dalje ostaje na jugoistoku, no proširuje se u smjeru sjeveroistoka, paralelno s Kloštarskim rasjedom. Slike **8.26 i 9.21** prikazuju vjerojatnosti da je poroznost veća od 19%. Na tim kartama može se uočiti područje najvećih poroznosti na zapadnom dijelu ležišta i glavni kanal pružanja sjeverozapad-jugoistok. Poveća li se granična vrijednost samo za 1%, odnosno na 20% poroznosti (**slike 8.27 i 9.22**) taložni kanal se više ne može vidjeti. Na tim kartama povećana poroznost uočava se na zapadnom dijelu ležišta te na samom jugoistočnom dijelu u području bušotine Klo-58. Na kartama vjerojatnosti da je poroznost veća od 22% (**slike 8.28 i 9.23**) uočavaju se samo dva maksimuma u području istočno od bušotina Klo-22 i Klo-95.

Na isti se način mogu uspoređivati i karte vjerojatnosti varijable debljine. Za najmanju graničnu vrijednost 5 m (**slike 8.30 i 9.24**) uočava se samo jedan minimum oko bušotine Klo-35, što znači da je s vjerojatnošću od oko 50% samo na toj lokaciji debljina manja od 5 m. Povećavajući graničnu vrijednost na 9 m (**slike 8.31 i 9.25**) broj takvih minimuma se povećava na 5. Dakle, na lokacijama oko bušotina Klo-104, Klo-95, Klo-59, Klo-58 i Klo-35 povećana je vjerojatnost da je debljina manja od 9 m. Na karti vjerojatnosti za graničnu vrijednost 13 m (**slike 8.32 i 9.26**) povećane vjerojatnosti za debljine veće od 13 m su oko bušotina Klo-48, Klo-28 i Klo-27. Te lokacije predstavljaju najveće debljine u ležištu. Na istim se kartama mogu pratiti povećane debljine u smjeru sjeverozapad-jugoistok, što odgovara smjeru glavnog kanala uočenog na kartama poroznosti (**slike 8.26 i 9.21**), međutim lokacije najvećih debljina ne podudaraju se s lokacijama najvećih poroznosti. Usporedbom karte vjerojatnosti debljine veće od 13 m dobivene sekvencijskim indikatorskim simulacijama (**slika 9.26**) i iste karte dobivene indikatorskim krigingom (**slika 8.32**) ipak se može uočiti jedna razlika, a to je povećana vjerojatnost da je debljina veća od 13 metara na samom jugu ležišta oko bušotine Klo-57, što se na karti dobivenoj indikatorskim krigingom ne vidi. Također postoji razlika između karata dobivenih indikatorskim krigingom i sekvencijskim indikatorskim simulacijama za graničnu vrijednost 17 m (**slike 8.33 i 9.27**). Na karti vjerojatnosti dobivenoj sekvencijskim indikatorskim simulacijama (**slika 9.27**) postoje dva maksimuma na kojima je vjerojatnost oko 30% da je debljina veća od 17 m. Ta dva maksimuma odgovaraju lokacijama oko bušotina Klo-27 i Klo-57. Na istoj karti dobivenoj indikatorskim krigingom (**slika 8.33**) uočava se samo jedan maksimum, koji pokazuje vjerojatnost od 40% da je debljina veća od 17 m. Maksimum je u području oko bušotine Klo-27.


9.2.3. Usporedba rezultata dobivenih sekvencijskim Gaussovima i sekvencijskim indikatorskim simulacijama

Realizacije varijabli poroznosti i debljine dobivene metodom sekvencijskih Gaussovih simulacija uspoređene su s realizacijama istih varijabli dobivenih metodom sekvencijskih indikatorskih simulacija (**slike 9.28, 9.29, 9.30 i 9.31**).


Općenito se može zaključiti da realizacije dobivene sekvencijskim Gaussovima simulacijama daju nešto veće vrijednosti varijabli u odnosu na indikatorske, što se posebno dobro može vidjeti na **slici 9.29**, gdje su uspoređene realizacije debljine u ležištu Beta. Na kartama debljina dobivenim sekvencijskim Gaussovima simulacijama veliki je broj maksimalnih vrijednosti od 25 m, dok iste karte dobivene sekvencijskim indikatorskim simulacijama imaju maksimalne vrijednosti do 23 m. Isto se može vidjeti i na kartama debljine ležišta T (**slika 9.31**), gdje su sekvencijskim Gaussovima simulacijama na pojedinim lokacijama procijenjene vrijednosti oko 30 m, a takvih vrijednosti nema na istim kartama dobivenim sekvencijskim indikatorskim simulacijama. Na tim je kartama maksimalna procijenjena vrijednost od oko 22 m. Nadalje, kod kartiranja indikatorskim simulacijama nema blagih prijelaza, nego su često u dodiru ćelije čije se vrijednosti razlikuju više od upotrijebljene ekvidistancije. To se svojstvo posebno može uočiti kod kartiranja debljine ležišta Beta, gdje su na kartama dobivenim sekvencijskim Gaussovima simulacijama blagi prijelazi, što je i prirodnije za sedimente s međuzrnskom poroznošću.




Slika 9.17: Distribucija poroznosti ležišta T kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.18: Distribucija debljine ležišta T kartirana sekvencijskim indikatorskim simulacijama: a-prva realizacija, b-pedeseta realizacija i c-stota realizacija




Slika 9.19: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 14%




Slika 9.20: Karta vjerojatnosti varijable poroznosti ležišta *T* veće od granične vrijednosti 18%




Slika 9.21: Karta vjerojatnosti varijable poroznosti ležišta *T* veće od granične vrijednosti 19%




Slika 9.22: Karta vjerojatnosti varijable poroznosti ležišta T veće od granične vrijednosti 20%




Slika 9.24: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 5 m




Slika 9.25: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 9 m




Slika 9.26: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 13 m




Slika 9.27: Karta vjerojatnosti varijable debljine ležišta T veće od granične vrijednosti 17 m




Slika 9.28: Usporedba realizacija distribucije poroznosti ležišta Beta dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija



Slika 9.29: Usporedba realizacija distribucije debljine ležišta Beta dobivenih sekvencijskim Gausovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija



Slika 9.30: Usporedba realizacija distribucije poroznosti ležišta T dobivenih sekvencijskim Gaussovim simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija



Slika 9.31: Usporedba realizacija distribucije debljine ležišta T dobivenih sekvencijskim Gaussovima simulacijama (lijevo) i sekvencijskim indikatorskim simulacijama (desno): a) prva realizacija, b) pedeseta realizacija i c) stota realizacija

10. RASPRAVA

Uloga i svrha izrade naftno-plinskih geoloških modela je što jasnije prikazati i opisati dubinske odnose, građu te uvjete taloženja i nastanka ležišta. U kasnijoj fazi istraživanja, jasna slika podzemlja svakako omogućuje preciznije proračune rezervi ugljikovodika. Ovom disertacijom napravljen je detaljni geološki model polja Kloštar. Rezultati modeliranja, s teorijske strane, mogu se promatrati u konceptu modelno-zavisnog realizma, unutar kojeg HAWKING i MLODINOW (2010) opisuju neki model kao dobar ako je:

- 1.elegantan,
- 2.sadrži malo proizvoljnih ili podesivih elemenata,
- 3.slaže se i objašnjava sva postojeća opažanja,
- 4.daje potanka predviđanja o budućim opažanjima, koja mogu opovrgnuti ili obezvrijediti model ako nisu potvrđena.

Dobiveni model gornjopanonskih i donjopontskih pješčenjačkih ležišta polja Kloštar zadovoljava sva četiri gore navedena svojstva dobrog modela. Elegantan je jer je uklopio sve vrijedeće teorije razvoja hrvatskog dijela Panonskoga bazenskoga sustava (HPBS), te hipoteze o lokalnom podrijetlu dijela materijala i postojanju hrptova današnjih gora izdignutih iznad razine vode kontinuirano tijekom neogena, pretvorio također u teorije. Skup procijenjenih vrijednosti elemenata u modelu obilježenih nesigurnošću, smanjen je na najmanji mogući broj, a pri tomu je granica pouzdanosti bila određena time što su ulazne vrijednosti bile točkaste, odnosno diskontinuirane. Prikazani geološki model u skladu je s objavljenim rezultatima ranijih istraživanja HPBS. Dobivene karte ležišnih varijabli izravno se mogu iskoristiti za nove izračune volumena pornoga prostora, a postavljajući granične vrijednosti poroznosti, propusnosti, zasićenja i iscrpka u pojedinačnim litofacijesima moguće je predvidjeti i trajanje te količine buduće proizvodnje.

Treba napomenuti kako je svaki geološki model, zbog ograničenja koje točkasto uzorkovanje ima, uvijek u konačnici stohastički i sadrži nesigurnosti. Naravno, unutar njega moguće je napraviti dodatne geostatističke analize, prvenstveno povećanjem broja ulaznih podataka pa i broja ležišnih varijabli koje se kartiraju (propusnost, mineralni sastav, zasićenje ili udio nepropusnih naslaga). Pouzdanost modela ovisi i o svojstvima uporabljenih programa. To su bili Variowin, Surfer8TM, PetrelTM i WinGslibTM. Iako postoje i drugi programski paketi slične namjene, ovo su danas možda najbolji alati za računalno modeliranje ležišta ugljikovodika, jer rabe algoritme koji daju vrlo pouzdana rješenja.

Program Variowin je korišten za izradu variograma, koji su osnova za geostatističke metode kartiranja. Jednostavan je za primjenu i daje jasne rezultate variogramskih analiza. Međutim, kod modeliranja eksperimentalnog variograma sadržane su nesigurnosti kod određivanja odstupanja, što nažalost ne može biti izbjegnuto niti jednim poznatim algoritmom. Nažalost variogram nije moguće izračunati u ishodišnoj točki, a podešavanje vrlo maloga koraka izračuna (na metarskoj skali) smanjilo bi broj parova podataka po variogramskom razredu na veličine manje od 10. Uz to premali korak (metarski) čini besmislenim modeliranje ležišta čije su dimenzije od dekametarskih do kilometarskih.

Surfer8TM također je danas vrlo korišten program za geostatističko kartiranje te su karte interpolirane metodom običnog kriginga izrađene upravo tim programom. Kako ovisi o dosezima variograma, ako se primjenjuje interpolacija krigingom, sve nesigurnosti vezane uz prethodni program prenose se i ovdje.

PetrelTM je program koji se danas koristi u znatnom broju tvrtki koje se bave modeliranjem ležišta ugljikovodika. Vrlo je kompleksan i daje niz različitih mogućnosti za opis građe ležišta i proračun rezervi. U disertaciji je korišten za izradu strukturnog modela gornjopanonskih i donjopontskih ležišta u polju Kloštar.

Program WinGslibTM, kao jedan od najboljih paketa za geostatističko kartiranje, odabran je za izradu karata metodama indikatorskog kriginga, sekvencijskim indikatorskim simulacijama i sekvencijskim Gaussovima simulacijama. Upravo tim programima konstruiraju se najbolje karte unutar pješčenjačkih ležišta, koja su i bila cilj analize ove disertacije.

Temeljni cilj istraživanja bio je izrada detaljnog geološkog modela ležišta polja Kloštar, koji bi ujedno predstavljao i tipski model za analizu pješčenjačkih ležišta starosti gornjeg panona i donjeg pontu u Savskoj depresiji u smislu praćenja prostornih promjena litološkog sastava, granulometrijskih parametara i definiranja taložnog modela – prostornog rasporeda istovremenih taložnih okoliša. Stoga su na početku istraživanja postavljene sljedeće hipoteze:

1. Pješčenjačka tijela treba analizirati kao sedimentacijske objekte s prijelaznim litofacijesima, budući da su do sada ležišta promatrana uglavnom kroz odnos litofacijesa pješčenjaka i lapora, te ograničena linijom bočne promjene facijesa;
2. Razlike u litofacijesima posljedica su taloženja različitih turbiditnih sekvencija i njihovih debljina te njihova prostornog rasporeda uvjetovanog paleobatimetrijskim odnosima;
3. Utjecaj bliskoga paleoreljefa, tj. Moslavačke gore, vrlo je vjerojatan tijekom gornjeg miocena, tako da treba pretpostaviti kako je manji dio materijala u ležište donešen s te

lokacije (uz većinu istaloženog mehanizmom povremenih turbiditnih struja i donešenog iz područja Istočnih Alpi);

4. Razdioba ležišnih varijabli može se prikazati nizom stohastičkih realizacija, umjesto determinističkim rješenjem. Primjerenost takva pristupa provjerena je za svaku kartiranu varijablu, tj. za poroznost pješčenjaka, debljinu i dubinu zalijeganja pješčenjačkih slojeva.

Kao kartirane varijable odabrane su one za koje je bio dostupan najveći broj izmjerenih i osrednjenih vrijednosti, a gdje je pogreška mjerenja i obradbe bila najmanja. To su bile vrijednost poroznosti, dubina zalijeganja i ukupna debljina ležišta Beta i T. Naravno, uzeta su u obzir i ranija strukturna rješenja (karte) te karotažni dijagrami. Seizmički profili promatrani su samo kao izvor opće slike podzemlja, dijelom zbog slabe kvalitete seizmičkih podataka uz rub Moslavačke gore.


Spomenuta dva ležišta odabrana su kao najrasprostranjenija i najdeblja, a ujedno i tipična gornjomiocenska ležišta u polju Kloštar. Ta „tipičnost“ znači da ona pokrivaju znatan dio područja polja i imaju debljine zbog kojih su se u njima mogli razviti svi očekivani prijelazni litofacijesi od kanalskih pješčenjaka do bazenskih lapora. Ležište Beta je najrasprostranjenije i najdeblje ležište starosti gornjeg panona, dok je ležište T najrasprostranjenije i najdeblje ležište starosti donjeg pont. Vrijednosti poroznosti za ta ležišta dobivene su interpretacijom karotažnih mjerenja spontanog potencijala uz korelaciju s vrijednostima poroznosti izmjerenim na jezgrama, te predstavljaju srednje poroznosti u bušotinama kroz ležišni interval. Kartiranje gornjopanonskog ležišta Beta načinjeno je pomoću 23 ulazna bušotinska podatka, ravnomjerno raspoređena po površini za varijablu debljine i dubine te 17 bušotinskih podataka za varijablu poroznosti. U donjopontskom ležištu T bilo je dostupno 20 bušotinskih podataka, čije su lokacije također ravnomjerno raspoređene u prostoru. Na temelju rezultata prethodnih istraživanja (npr. MALVIĆ, 2008) pokazano je da je s tolikim brojem podataka, sličnoga prostornoga rasporeda jednakih varijabli, ulazni skup za kartiranje i kasniju geološku interpretaciju pouzdan. Treba napomenuti kako debljine ležišta predstavljaju ukupne debljine od krovine do podine određene na karotažnim dijagramima, a dubine ležišta su mjerene dubine od referentne ravnine na +100 m do krovine ležišta. Promatrane bušotine su gotovo vertikalne, tako da mjerena dubina odgovara i relativnoj.

Rješenje problema dokaza više od dva ležišna litofacijesa dobiveno je kartiranjem varijabli poroznosti, debljine i dubine ležišta. Pri tomu je korištena pretpostavka kako veća poroznost označava neki od dominantno pješčenjačkih litofacijesa, a smanjena neki od laporovitih. Takvim kriterijem bilo je moguće razlikovati litofacijese čistih pješčenjaka, laporovitih

pješčenjaka, pjeskovitih lapora i čistih bazenskih lapora. Također je pretpostavljeno kako bi povećane debljine trebale ukazati na središnji dio taložnog kanala u kojem se taložio najkrupnozrnatiji materijal. Prilikom kartiranja gornjopanonskog ležišta Beta, područja s povećanim vrijednostima poroznosti uglavnom su se poklapala s područjima povećane debljine, što nije bio slučaj u kartiranju donjopontskog ležišta T, gdje su se povećane poroznosti samo djelomično poklapale s najvećim debljinama. Zbog razvedenog reljefa dna taložnog bazena u najdubljim dijelovima kanala taložili su se pješčenjaci, dok se prema rubovima kanala može očekivati sve više laporovite komponente.


Stoga je u početku bilo pretpostavljeno kako bi pomoć u interpretaciji usjednutih tektonskih jedinica unutar polja Kloštar mogle pružiti karte dubina. To nije bilo uspješno zato što se nakon nastanka gornjomiocenskih ležišta ovaj dio bazena preoblikovao tijekom 2. transpresijske faze prilikom koje je došlo do djelomične ili potpune inverzije struktura u tom prostoru, pa tako odnosi današnjih dubina ležišta nisu odraz njihovih odnosa u vrijeme taloženja.

Prema radu VRBANAC et al. (2010) glavni smjer donosa materijala u gornjem panonu bio je sjeverozapad-jugoistok, što je na području polja Kloštar vidljivo na kartama vjerojatnosti poroznosti veće od 18% i debljine veće od 15 m (**slika 10.1**). Interpretirano je da bočno stanjivanje ležišta ukazuje na prijelaz u lapore i pjeskovite lapore, taložene na padini do 200 m dubine. Najkrupniji materijal taložen je u lokalnim sinklinalama, a danas ih možemo prepoznati po najvećim debljinama pješčenjačkih slojeva (**slika 10.1**). U smjeru paleoizdignuća Moslavačke gore, odnosno u smjeru sjevera i sjeveroistoka, kontinuirano su se taložili lapori i glinoviti lapori s puno manjim debljinama.



Slika 10.1: Smjer donosa materijala u gornjem panonu interpretiran na karti vjerojatnosti poroznosti veće od 18% (lijevo) i debljine veće od 15m (desno)

Interpretacija prostornog rasporeda poroznosti na kartama vjerojatnosti u ležištima donjopontske starosti ukazala je da je krupniji materijal u ovome dijelu Savske depresije uglavnom dolazio sa sjevera (tako su interpretirali i VRBANAC et al., 2010). Dio toga materijala taložio se u lokalnim sinklinalama. Tijekom donjega pontsa, kada nastaje glavni Kloštarski rasjed, preostali dio suspendiranog materijala je nastavio migrirati do njegove granice (**slika 10.2**). Tu se istaložio srednjozrnati pješčenjački materijal, a zatim se transport srednjozrnatog materijala nastavio paralelno s rasjedom prema jugoistoku. Tako su interpretirane karte vjerojatnosti poroznosti veće od 19% i debljine veće od 13 m (**slika 10.2**). Međutim, zbog razlike položaja vjerojatnosti najvećih debljina i najvećih poroznosti (**slika 10.2**), očito je kako su turbiditne struje najkrupniji materijal taložile uz rasjed, dok su najveće debljine u područjima na kojima su taloženi pješčenjaci i bazenski lapori. Budući da područja najvećih debljina odgovaraju kontinuiranoj izmjeni pješčenjaka i lapora, zaključeno je da takva područja ne predstavljaju taložni kanal. Logično je zaključiti kako su turbiditne struje erodirale svoju podinu (odnosno bazenske lapore koji su se taložili u mirnom razdoblju između dva turbiditna događaja). Zbog takvog mehanizma u samome središtu kanala nalaze se samo srednjo i sitnozrnati pješčenjaci, a ne izmjena pješčenjaka i lapora. Prema tome, karta poroznosti (**slika 10.2** lijevo) točnije ocrta položaj taložnog kanala od karte debljina (**slika 10.2** desno).




Slika 10.2: Smjer donosa materijala u donjem pontu interpretiran na karti vjerojatnosti poroznosti veće od 19% (lijevo) i debljine veće od 13 m (desno)

Pregledan je i određeni broj jezgara s ciljem uočavanja razlika u mineralnom sastavu između gornjopanonskih i donjopontskih pješčenjačkih ležišta, a u svrhu što boljeg opisa litofacijesa i taložnih uvjeta tijekom gornjega panona i donjega pontu. Nažalost, jezgara nije bilo puno te je analizirano 13 uzoraka. Mineralni sastav pješčenjaka u njima, tek se djelomično razlikovao u povećanom udjelu tinjaca u gornjopanonskim ležištima i mogao je samo ukazati na utjecaj stijena Moslavačke gore kao lokalnog izvora detritusa. Naime, mineraloškom analizom jezgara gornjopanonskog ležišta od tinjaca su utvrđeni muskovit i kloritizirani biotit (VELIĆ et al., 2008*). Povećani udio muskovita, kao rezistentnog minerala svakako ukazuje na duži transport tijekom gornjega panona, tijekom kojeg je bilo moguće da su se manje rezistentni minerali potrošili ili izmijenili. Zbog toga je u ukupnom sastavu gornjopanonskih jezgara muskovit zastupljeniji negoli unutar donjopontskih ležišta. Nadalje, kloritizirani biotit je opisan u jezgrama oba podkata, a ukazuje na naknadnu alteraciju biotita u klorit, čije je podrijetlo iz magmatskih i metamorfnih stijena. To otvara mogućnost, zbog svojstva biotita da je mineral kratkog transportnog puta, da je njegovo podrijetlo vjerojatno vezano uz lokalni izvor detritusa, tj. uz transport aluvijalnim lepezama s obronaka Moslavačke gore. No, u donjopontskim jezgrama dokazan je i čisti biotit (VELIĆ et al., 2008*), koji dodatno potvrđuje teoriju o kratkom transportnom putu. Smanjeni postotni udio muskovita također može ukazati da su se međusobno miješali materijal donešen iz Istočnih Alpi i materijal lokalnog podrijetla. Mineraloškim analizama jezgara gornjopanonskih i donjopontskih ležišta u polju Kloštar nije dokazan lokalni utjecaj Moslavačke gore, no te su analize svakako dale čvrste indikacije da je takav utjecaj bio moguć.

Kako bi se pretpostavka o lokalnom utjecaju Moslavačke gore kao izvora materijala pokušala potvrditi, zajednički su promotrene dobivene karte i odabrane jezgre. Lokalni izvor materijala trebao bi na kartama iskazati smjer SSI-JJZ, uz onaj prevladavajući iz turbiditnih struja smjera S-J. Takav lokalni izvor pretpostavljen je tijekom donjega ponta zbog dvaju razloga: a) nastavljeno je oplicavanje slatkovodnog jezera, b) kontinuirano izdizanje sjevernohrvatskih gora s paleozojskom i mezozojskom osnovom.

Kako je ranije navedeno, na temelju podataka iz 13 dostupnih uzoraka jezgara, lokalni izvor materijala nije mogao biti izravno interpretiran na taj način te je on neizravno pretpostavljen na temelju ocrta na odabranim kartama donjopontskog ležišta T (slika 10.3).



Slika 10.3: Smjer donosa materijala u donjem pontu interpretiran na karti vjerojatnosti poroznosti manje (lijevo) i veće (desno) od 18% dobivenoj indikatorskim krigingom (lijevo) i sekvencijskim indikatorskim simulacijama (desno)

Na kartama vjerojatnosti da je poroznost manja (slika 10.3 lijevo), odnosno veća (slika 10.3 desno) od 18%, jasno se vidi da je na sjeveroistočnom dijelu ležišta velika vjerojatnost poroznosti veće od 18%, a to je u smjeru položaja paleoizdignuća Moslavačke gore u vrijeme donjeg pontu. Stoga je zaključeno kako je moguće da je paleoizdignuće Moslavačke gore dalo jedan dio pjeskovitog i siltnog materijala taloženog u prostoru aluvijalne lepeze, tj. u sjeveroistočnom dijelu ležišta (slika 10.3).

Na kraju, postavljeno je pitanje je li ležišne varijable bolje kartirati i analizirati rezultatima geostatističke determinističke interpolacije ili stohastičke procjene, odnosno postoji li bilo kakvo pravilo obzirom na broj podataka i promatrano svojstvo kod odabira jedne od te dvije skupine metoda. Geostatističke metode koje su korištene prilikom kartiranja bile su

determinističke interpolacijske (obični kriging i indikatorski kriging) i stohastičke (sekvencijske Gaussove simulacije i sekvencijske indikatorske simulacije).

Karte dubine dobivene metodom običnog kriginga dobro su prikazale današnju strukturu polja Kloštar te nadopunile rješenja dana na ranijim strukturnim kartama. Glede poroznosti, metode običnog kriginga te sekvencijskih Gaussovih simulacija pokazale su se najboljim alatom za izradu takve prostorne distribucije unutar ležišta Beta i T.

Obje vrste simulacija (sekvencijske Gaussove i sekvencijske indikatorske) dale su dobre rezultate, ovisno o tome koja se pojava rezultatima simulacije željela interpretirati. Pokazano je kako u slučaju kada se želi dobiti distribucija vrijednosti ležišne varijable treba uporabiti sekvencijske Gaussove simulacije. Za razliku od indikatorskih, one su dale bliskije vrijednosti u susjednim ćelijama te je time model polja realniji. Uz to, primjena sekvencijskih Gaussovih simulacija omogućila je određivanje područja najvećih nesigurnosti. Takva područja opisana su u središnjem dijelu ležišta Beta i istočnom dijelu ležišta T. Očekivano, područja najveće nesigurnosti u središnjem dijelu ležišta Beta upravo su na lokacijama s malim brojem bušotinskih podataka. No, kod ležišta T nesigurnost je bila vezana uz istočni dio gdje je opisana promjena litofacijesa pješčenjaka u laporovite pješčenjake i pjeskovite lapore, a time je bilo teže ocrtati „bolje“ i „lošije“ dijelove ležišta koji se izmjenjuju lateralno na puno manjoj skali negoli je to prosječna udaljenost između bušotina.

Sekvencijske indikatorske simulacije, kao i indikatorski kriging koristile su se za kartiranje pojedinih litofacijesa. Kartama vjerojatnosti za određene granične vrijednosti moguće je prikazati smjer donosa materijala i distribucijske kanale u ležištu.

Indikatorskim metodama, odnosno odabranim graničnim vrijednostima, ocrtan je prostorni raspored četiri litofacijesa, interpretiran smjer donosa materijala, te pružanje glavnoga taložnog kanala. Posebno je bilo važno uočavanje i nekoliko sporednih taložnih kanala, te promjena smjera donosa materijala (sjeverozapad-jugoistok za gornjopanonska i sjever-jug za donjopontska ležišta). To je opaženo na kartama indikatorskog kriginga i sekvencijskim indikatorskim simulacijama za granične vrijednosti poroznosti 18% (**slike 8.16 i 9.11**) i debljine 9, 15 i 21 m (**slike 8.20, 8.21, 8.22, 9.14, 9.15 i 9.16**) za gornjopanonsko ležište Beta, te poroznosti 19 i 20% (**slike 8.26, 8.27, 9.21 i 9.22**) i debljine 13 m (**slike 8.32 i 9.26**) za donjopontsko ležište T. Tako je regionalni smjer donosa materijala turbiditnim tokovima koje su opisali VRBANAC et al. (2010) dokazan i dopunjen lokalnim promjenama u području strukture Kloštar. U pliocenu i kvartaru, regionalne transpresijske strukturne promjene uzrokovale su na dijelu strukture Kloštar inverziju struktura, tako da su Kloštarska antiklinala i zamke u njoj poprimile današnji oblik.

Prikazani rezultati koji su dobiveni determinističkim kartiranjem i korištenjem stohastike bili su dovoljni za donošenje zaključaka pri interpretaciji uvjeta taloženja, izvora materijala, smjera toka turbiditnih struja kojima je materijal donesen, smjera i položaja taložnog kanala, definiranje postojanja različitih prijelaznih litofacijesa od čistih pješčenjaka taloženih u središtu kanala pa sve do čistih bazenskih lapora, te o utjecaju tektonike na današnju sliku podzemlja u odnosu na onu kakva je bila u vrijeme gornjeg panona i donjeg pont. Obzirom na dostupne podatke, alate kojima su podaci obrađivani, kao i dosadašnja znanja o kartiranom području ovim je radom vrednovan mogući doprinos metoda indikatorskog kriginga, sekvencijskih indikatorskih simulacija i sekvencijskih Gaussovih simulacija kao analitičkih alata u geologiji ležišta ugljikovodika u Hrvatskoj. Polje Kloštar je, u usporedbi s drugim proizvodnim poljima u Savskoj depresiji, tipično po litološkom sastavu ležišnih stijena, tipu poroznosti i geološkoj evoluciji koja uključuje taloženje, oblikovanje zamki i migraciju ugljikovodika. Tako se metode prikazane u disertaciji mogu primijeniti na bilo kojem naftnom ili plinskom polju, tj. unutar njihovih gornjomiocenskih pješčenjačkih ležišta, u Savskoj depresiji, ali i šire, npr. i na području Dravske depresije, budući da su mehanizmi taloženja bili isti. Naravno, za primjenu prikazanih metoda i vjerodostojnost rezultata vrlo je bitna ravnomjerna raspodjela bušotina u ležištu kao i dovoljan broj (oko 20) bušotinskih podataka. Prikaz i interpretacija građe ležišta polja Kloštar ujedno daje i tipski model za geostatističku analizu i opis razvoja pješčenjačkih ležišta u kojima su otkrivene najbrojnije akumulacije ugljikovodika u hrvatskom dijelu Panonskog bazenskog sustava.

11. ZAKLJUČAK

Primjena geostatističkih metoda u geologiji relativno je novi pristup interpretaciji geološke građe podzemlja. U ovoj disertaciji takve metode su uspješno uporabljene prilikom izrade detaljnog modela dvaju najvećih ležišta polja Kloštar, koja su slična po svojstvima ležišnih stijena, ali različita po rasprostiranju slojeva pa dijelom i po nastanku. Njihova starost je gornjopanonska i donjopontska, a kombinacijom triju varijabli (poroznosti, debljine i dubine ležišta) dobio se uvid u položaj taložnog kanala, postojanje različitih litofacijesa, smjer donosa detritusa, utjecaj bliskog paleoreljefa, distribuciju varijabli unutar pojedinog ležišta, te određivanje područja najvećih nesigurnosti. Analizirana su determinističkim interpolacijskim metodama (tehnika običnog i indikatorskog kriginga) i stohastičkim metodama (sekvencijskim Gaussovima i sekvencijskim indikatorskim simulacijama). Iako su determinističke interpolacijske metode još uvijek najčešći alat za kartiranje u geologiji, prirodno je da poznavanje građe podzemlja nikada ne može biti potpuno sigurno te stoga niti jedan geološki model ne može biti potpuno deterministički.

Metodologija koja je ispitana na polju Kloštar može se primijeniti na sva pješčenjačka ležišta starosti gornjeg panona i donjeg pontu u Savskoj depresiji, prvenstveno iz razloga jer su uvjeti taloženja, migracije i oblikovanja zamki bili približno jednaki. Karte dobivene tehnikom običnog kriginga prikazale su dobro oblik strukture Kloštar. Nadalje, dokazano je kako sekvencijske Gaussove simulacije daju vrlo dobre rezultate pri kartiranju varijabli poroznosti i debljine unutar ležišta te određivanju područja najvećih nesigurnosti. U tom slučaju uporabljivost sekvencijskih indikatorskih simulacija je ograničena i ne preporuča se zbog pojave oštih prijelaza između susjednih ćelija. Međutim, kod ocjene vjerojatnosti pojave određene vrijednosti za promatranu varijablu jedini pouzdani alat su upravo sekvencijske indikatorske simulacije ili indikatorski kriging.

Struktura Kloštar danas je antiklinala s većim nagibom krila u smjeru jugozapada. U vrijeme gornjeg panona i donjeg pontu u tom je području, kao i cijelom hrvatskom dijelu Panonskog bazena, prevladavala druga transtenzija. Manje rasjedne depresije predstavljale su pogodna mjesta za nakupljanje krupnijih (psamitskih) sedimenata. U takvim se uvjetima počinju taložiti gornjopanonski sedimenti i na području strukture Kloštar. Položaj Moslavačke gore tada je bio na sjeveroistoku, a materijal je donosan turbiditima iz Istočnih Alpi, pretaložavan nekoliko puta dok u konačnici nije istaložen u cijeloj Savskoj depresiji, kao i drugim

depresijama HPBS-a. Odlika tih turbiditnih tokova je pretežito nepotpuna Bouma sekvencija (Tb-Td) jer je i transport bio iznimno dug, tj. nekoliko stotina kilometara.

Dokazano je da je u gornjem panonu glavni smjer donosa materijala turbiditima bio sjeverozapad-jugoistok. Upravo je taj smjer lokalno, na području polja Kloštar potvrđen kartama vjerojatnosti dobivenim tehnikom indikatorskog kriginga i sekvencijskim indikatorskim simulacijama za varijable poroznosti i debljine. Uz potvrdu smjera donosa materijala, karte vjerojatnosti jasno pokazuju pojave različitih litofacijesa od čistih pješčenjaka do bazenskih lapora. Prilikom interpretacije tih karata uočeno je kako se najveće debljine i poroznosti nalaze u središnjem dijelu kanala, dok bočno stanjivanje ležišta ukazuje na prijelaz u pelitne sedimente (lapor i pjeskoviti lapor). Tako je najkrupniji materijal taložen u lokalnim sinklinalama, a danas se odlikuje i najvećim debljinama. U plitkom jezerskom okolišu prema sjeveru i sjeveroistoku, odnosno prema tadašnjem položaju Moslavačke gore, kontinuirano su se taložili lapori i glinoviti lapori posebice tijekom gornjega panona. Smjer taloženog kanala (sjeverozapad-jugoistok) može se uočiti na kartama vjerojatnosti poroznosti i debljina za gornjopanonska i donjopontska ležišta, dobivenim indikatorskim krigingom i sekvencijskim indikatorskim simulacijama. Međutim, na prijelazu gornjeg panona i donjeg pontaja nastaje regionalni normalni rasjed, koji je uzrokovao spuštanje sjeveroistočnog te izdizanje jugozapadnog dijela. Stvorio se novi prostor pogodan za sedimentaciju donjopontskih pješčenjačkih ležišta, međusobno odvojenih bazenskim laporima. Dominantan smjer transporta turbiditima u vrijeme donjeg pontaja postaje sjever-jug i prolazi pored Moslavačke gore. Također, najveće vrijednosti poroznosti ne podudaraju se s najvećim vrijednostima debljina ležišta. Razlog je tomu distribucija najkrupnijeg materijala koji je dolazio sa sjeverozapada i sjevera. Jedan se dio krupnog materijala istaložio neposredno uz rasjed, a drugi dio je nastavio tok prema jugoistoku, paralelno s Kloštarskim rasjedom, krećući se kroz tada najdublji dio kanala, a istovremeno i djelomično erodirajući svoju podinu. Tek najsitnija turbiditna frakcija mogla se istaložiti na rubnim dijelovima strukture Kloštar prekrivajući normalni bazenski pelitni sediment, bez njegove erozije.

Kartama indikatorskog kriginga i sekvencijskim indikatorskim simulacijama dokazano je postojanje više litofacijesa, odnosno heterogenost ležišta. Ti litofacijesi se od središta taloženog kanala prema rubu strukture mijenjaju od pješčenjaka, preko laporovitih pješčenjaka, pjeskovitih lapora do lapora. Indikatorske karte također daju i vjerojatnost njihove pojave na određenoj lokaciji. Stoga je na taj način moguće preciznije okonturiti samo ležište i time točnije procijeniti geološke rezerve ugljikovodika.

12. LITERATURA

12.1. OBJAVLJENI RADOVI

1. Bačani, A., Šparica, M., & Velić, J. (1999): Quaternary deposits as the hydrogeological systems of Eastern Slavonia. *Geologia Croatica*, 52, 2141-152.
2. Bakrač, K. (2005): Palinološka karakterizacija naslaga srednjeg i gornjeg miocena jugozapadnog dijela Panonskog bazena. Doktorska disertacija, Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu, 173 str., Zagreb.
3. Balić, D. (2007): Odabir najprimjerenije interpolacijske metode za pješčenjačka ležišta polja Kloštar. Diplomski rad, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 41 str., Zagreb.
4. Balić, D., Velić, J. & Malvić, T. (2008): Selection of the most appropriate interpolation method for sandstone reservoirs in the Kloštar oil and gas field. *Geologia Croatica*, 61, 1, 27-35.
5. Bardossy, G. & Fodor, J. (2001): Uncertainties and risks in geological activities and new ways of their handling. *Rudarsko-geološko-naftni zbornik*, 13, 15-24.
6. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulations. *AAPG Bulletin*, 29, 12, 1738-1755.
7. Brod, I.O. & Eremenko, N. A. (1957): Osnovi geologii njefti i gasa. Gostoptehizat, III izdanje, Moskva.
8. Csontos, L., Benkovics, L. Bergerat, F., Mansy, J-L. & Worum, G. (2002): Tertiary deformation history from seismic section study and fault analysis in a former European Tethyan margin (the Mecsek-Villany area, SW Hungary). *Tectonophysics*, 297, 51-57.
9. Cvetković, M. (2007): Naftnogeološka primjena neuronskih mreža na primjeru ležišta polja Kloštar. Diplomski rad, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 49 str., Zagreb.
10. Cvetković, M., Velić, J. & Malvić, T. (2009): Application of neural networks in petroleum reservoir lithology and saturation prediction. *Geologia Croatica*, 62, 2, 115-121.
11. 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.
12. Damayanti, M. C. & Hicks, P. J. (1996): A Geostatistical Study of a Pilot Area in the Griffithsvile Oil Field. *Society of Petroleum Engineers*, 37332, 93-106.
 13. Davis, B. M. (1987): Uses and Abuses of Cross-Validation in Geostatistics. *Mathematical Geology*, 19, 3, 241-248.
 14. Deutsch, C.V. & Journel, A.G. (1997): *GSLIB: Geostatistical Software Library and User's Guide*, 2nd edn. Oxford University Press, 369 str., New York.
 15. de Wijs, H.J. (1951): Statistics of ore distribution. Part I: frequency distribution of assay values. *Journal of the Royal Netherlands Geological and Mining Society*, 13, 365-375.
 16. Dubruble, O. (1998): *Geostatistics in Petroleum Geology*. AAPG Education Course Note, Series #38, AAPG and Geological Society Publishing House, 210 str., Tulsa.
 17. Filjak, R., Pletikapić, Ž. Nikolić, D. & Aksin, V. (1969): Geology of petroleum and natural gas from the Neogene complex and its basement in the southern part of the Pannonian basin, Yugoslavia. *Conference of the Institute of Petroleum and AAPG*, 113-130, Brighton.
 18. Frisch, W., Kuhleemann, J., Dunkl, I. & Brügel, A. (1998): A palinspastic reconstruction and topographic evolution of the Eastern Alps during the Tertiary tectonical evolution. *Tectonophysics*, 297, 1-15.
 19. Geiger, J. (2006): The behavior of Sequential Gaussian Simulation in the limits. Xth congress of Hungarian geomathematics, May 18-20 2006, Morahalom.
 20. Gringarten, E. & Deutsch, C. V. (1999): *Methodology for Variogram Interpretation and Modeling for Improved Reservoir Characterization*. *Society of Petroleum Engineers*, 56654, 1-13.
 21. Hand, J. L., Yang, C.-T. & Moritz, A. L. (1994): Ability of Geostatistical Simulations To Reproduce Geology: A Critical Evaluation. *Society of Petroleum Engineers*, 28414, 533-545.
 22. Haq, B.U. & Eysinga, F.W.B. (1998): *Geological Time Table, Fifth Edition (Wall Chart)*. Elsevier Science, Amsterdam.
 23. Hawking, S. & Mlodinow, L. (2010): *Velebni plan, Izvori*, 215 str., Zagreb
 24. Hernitz, Z. & Jurak, V. (1973): Application of palaeostructural and statistical analysis of Late Tertiary sediments in the Ivanić-Grad area (Northern Croatia). *Nafta*, 24, 7-8, 343-367.

25. Hohn, M. E. (1988): *Geostatistics and Petroleum Geology*. Van Nostrand Reinhold, 400 str., New York.
26. Horvath, F. (1995): Phases of compression during the evolution of the Pannonian basin and its bearing on hydrocarbon exploration. *Marine and Petroleum Geology*, 12, 837-844.
27. Horvath, F. & Tari, G. (1999): IBS Pannonian Basin Project: a review of the main results and their bearings on hydrocarbon exploration – u Durand, B., Jolivet, L., Horvath, F. & Seranne, M. (ur.): *The Mediterranean Basins: Tertiary extension within the Alpine Orogen*. Geol. Soc. London, Spec. Publ., 156, 195-213.
28. Isaaks, E. & Srivastava, R. (1989): *An Introduction to Applied Geostatistics*. Oxford University Press Inc., 580 str., New York.
29. Ivković, Ž., Matej, S. & Škoko, M. (2000): Seizmostratigrafska interpretacija gornjomiocenskih i pliocenskih sedimenata Savske depresije (Seismostratigraphic interpretation of Upper Miocene and Pliocene sediments of the Sava depression).- u Vlahović, I. & Biondić, R. (ur.): *Second Croatian Geological congress, Cavtat – Dubrovnik, 2000, Proceedings*, 219-222.
30. Journel, A.G. & Huijbregts, C. J. (1978): *Mining Geostatistics*. Academic Press, 600 str.
31. Juang, K. W., Chen, Y.S. & Lee, D. Y. (2004): Using sequential indicator simulation to asset the uncertainty of delineating heavy-metal contaminated soils. *Environmental Pollution* 127, 229-238.
32. Krige, D. G. (1951): A Statistical Approach to Some Basic Mine Valuation Problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, 52, 119-139.
33. Levorsen, A. I. (1956): *Geology of Petroleum*. Freeman, 703 str., San Francisco.
34. Liebhold, A. M., Rossi, R. E. & Kemp, W. P. (1993): Geostatistics and Geographic Information System in Applied Insect Ecology. *Annual Review of Entomology*, 38, 303-327.
35. Magyar, I. & Geary, D. H. (1999): Fossils and strata of Lake Pannon, a long-lived lake from the Upper Miocene of Hungary. *Acta Geologica Hungarica*, 42, 1, 108 str.
36. Magyar, I., Geary, D. H. & Muller, P. (1999): Paleogeographic evolution of the Late Miocene Lake Pannon in Central Europe. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 147, 151-167.
37. Malvić, T. (1998): Strukturni i tektonski odnosi te značajke ugljikovodika šireg područja naftnog polja Galovac-Pavljani. Magistarski rad, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 111 str., Zagreb.

38. Malvić, T. (2003): Vjerojatnost pronalaska novih zaliha ugljikovodika u bjelovarskoj uleknini. Doktorska disertacija, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 123 str., Zagreb.
39. Malvić, T. (2006): Middle Miocene Depositional Model in the Drava Depression Described by geostatistical porosity and thickness maps (case study: Stari Gradac-Barcs Nyugat Field). Rudarsko-geološko-naftni zbornik, 18, 63-70.
40. Malvić, T. (2008): Primjena geostatistike u analizi geoloških podataka. INA-Industrija nafte, 103 str., Zagreb.
41. Malvić, T. & Balić, D. (2009): Linearnost i Lagrangeov linearni multiplikator u jednadžbama običnoga kriginga. Nafta, 60, 1, 31-43.
42. Malvić, T. & Đureković, M. (2003): Application of methods: Inverse distance weighting, ordinary kriging and collocated cokriging in porosity evaluation, and comparison of results on the Beničanci and Stari Gradac fields in Croatia. Nafta, 54, 9, 331-340.
43. Malvić, T., Cvetković, M. & Balić, D. (2008): Geomatematički rječnik. Hrvatsko geološko društvo, 74 str., Zagreb.
44. 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.). InTech, 215-238, Rijeka.
45. Malvić, T., Velić, J. & Peh, Z. (2005): Qualitative-Quantitative Analyses of the Influence of Depth and Lithological Composition on Lower Pontian Sandstone Porosity in the Central Part of Bjelovar Sag (Croatia). Geologia Croatica, 58, 1, 73-85.
46. Matheron, G. (1965): Les Variables Regionalisees et leur estimation:une application de la theorie des fonctions aleatoires aux sciences de la nature. Masson, 306, Paris.
47. Muller, P., Geary, D. H. & Magyar, I (1999): The endemic molluscs of the Late Miocene lake Pannon: their origin, evolution, and family-level taxonomy. Lethaia, 32, 47-60.
48. Novak Zelenika, K., Malvić, T. & Geiger, J. (2010): Mapping of the Late Miocene sandstone facies using Indicator Kriging. Nafta, 61, 5, 225-233.
49. Pavelić, D. (2001): Tectonostratigraphic model for the North Croatian and North Bosnian sector of the Miocene Pannonian Basin system. Basin Research, 13, 359-376.
50. Pletikapić, Ž. (1969): Stratigrafija, paleogeografija i naftoplinonosnost Ivanić-Grad formacije na obodu Moslavačkog masiva. Doktorska disertacija, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 70 str., Zagreb.

51. Royden, L., H. (1988): Late Cenozoic Tectonics of the Pannonian Basin System. AAPG Memoir 45 (Chap. 3) - u The Pannonian Basin (eds. Royden, L., H. & Horváth, F.), 27-48.
52. Rögl, F. (1996): Stratigraphic Correlation of the Paratethys Oligocene and Miocene. Mitteilungen Ges. Geol. Bergbaustudenten Österreich, 41, 65-73.
53. Rögl, F. (1998): Palaeographic Consideration for Mediterranean and Paratethys Seaways (Oligocene to Miocene). Ann. Naturhist. Mus. Wien, 99A, 279-310.
54. Rögl, F. & Steininger, F. (1984): Neogene Paratethys, Mediterranean and Indo-pacific seaways; u Fossils and climate, Brenckey, P.J. (ur.), Geological Journal, special issue 11, 171-200.
55. Saftić, B. (1998): Genetska stratigrafska sekvencijska analiza u pontskim naslagama zapadnoga dijela Savske depresije. Doktorska disertacija, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 136 str., Zagreb.
56. Saftić, B., Velić, J., Sztano, O., Juhas, 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.
57. Sahin, A. & Al-Salem, A. A. (2001): Stochastic Modeling of Porosity Distribution in a Multi-Zonal Carbonate reservoir. Society of Petroleum Engineers, 68113, 1-11.
58. Šimon, J. (1970): Prilog stratigrafskoj analizi tercijarnih sedimenata na sjeverozapadnom predjelu Savske potoline. VII kongr. geol. SFRJ, Zagreb, knjiga 1, 347-360.
59. Šimon, J. (1973): O nekim rezultatima regionalne korelacije litostratigrafskih jedinica u jugozapadnom području Panonskog bazena. Nafta, 24, 12, 623-630.
60. Šimon, J. (1980): Prilog stratigrafiji u taložnom sustavu pješčanih rezervoara Sava-grupe naslaga mlađeg tercijara u Panonskom bazenu sjeverne Hrvatske. Doktorska disertacija, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 66 str., Zagreb.
61. Tari, G. (1994): Alpine tectonics of the Pannonian basin. Doktorska disertacija, Rice University, 501 str., Houston.
62. Tišljär, J. (1993): Sedimentary bodies and depositional models for the Miocene oil-producing areas of Ladislavci, Beničanci and Obod. Nafta, 44, 10, 531-542.
63. Velić, J. & Durn, G. (1993): Alternating lacustrine-marsh sedimentation and subareal exposure phases during Quaternary: Prečko, Zagreb, Croatia. Geologia Croatica, 46, 1, 71-90.

64. Velić, J., Malvić, T. & Cvetković, M. (2011): Palinspastic reconstruction of synsedimentary tectonics of Neogene and Quaternary sediments in the Kloštar Field (Sava depression, Pannonian Basin, Croatia). *Z. dt. Ges. Geowiss.*, 162, 2, 193-201.
65. Velić, J., Peh, Z. & Malvić, T. (1999): Lithologic composition and stratigraphy of Quaternary sediments in the area of the "Jakuševac" waste depository (Zagreb, Northern Croatia). *Geologia Croatica*, 52, 2, 119-130.
66. Velić, J. & Saftić, B. (1991): Subsurface spreading and facies characteristics of Middle Pleistocene deposits between Zaprešić and Samobor. *Geološki vjesnik*, 44, 69-82.
67. Velić, J., Weisser, M., Saftić, B., Vrbanac, B. & Ivković, Ž. (2002): Petroleum-geological characteristics and exploration level of the three Neogene depositional megacycles in the Croatian part of the Pannonian basin. *Nafta*, 53/6-7, 239-249.
68. Vrbanac, B. (1996): Paleostrukturne i sedimentološke analize gornjopanonskih naslaga formacije Ivanić-Grad u Savskoj depresiji. Doktorska disertacija, Prirodosl.-matem. fakultet Sveuč. u Zagrebu, 121 str., Zagreb.
69. Vrbanac, B., Velić, J. & Malvić, T. (2010): Sedimentation of deep-water turbidites in main and marginal basins in the SW part of the Pannonian Basin. *Geologica Carpathica*, 61, 1, 55-69.

12.2. IZ FONDA STRUČNE DOKUMENTACIJE I NEOBJAVLJENI RADOVI

- 1.* Domitrović, S. & Hinić, A. (2008): Elaborat o rezervama ugljikovodika eksploatacijskog polja Kloštar. Fond stručne dokumentacije INA-Naftaplin, Zagreb.
- 2.* Domitrović, S. & Vučković, V. (2003): Elaborat o rezervama ugljikovodika eksploatacijskog polja Kloštar. Fond stručne dokumentacije INA-Naftaplin, Zagreb
- 3.* Goić, M. & Cazin, V. (1985): Naftno-plinsko polje Kloštar - elaborat o rezervama nafte i plina. Fond stručne dokumentacije INA-Naftaplin, Zagreb
- 4.* Goić, M. & Celinščak, D. (1998): Elaborat o rezervama ugljikovodika - naftno-plinsko polje Kloštar. Fond stručne dokumentacije INA-Naftaplin, Zagreb
- 5.* Goić, M. & Đorđević, R (1981): Elaborat o rezervama. Fond stručne dokumentacije INA-Naftaplin, Zagreb
- 6.* Velić, J., Malvić, T., Babić Puntarec, T., Balić, D., Curi, V., Cvetković, M., Jeras, Z., Marić Đureković, Ž. Pleić, M. Saftić, B., Tadej, J. & Babić, S. (2008): Unapređivanje geoloških interpretacijskih metoda u cilju povećanja iscrpka unutar pješčenjačkih ležišta. Fond stručne dokumentacije INA-Naftaplin, knjiga 1 (179 str.), knjiga 2 (277 str.), Zagreb

7.* Dossieri bušotina eksploatacijskog polja Kloštar, INA-Naftaplin, Zagreb

8.* Petrel Introduction Course-Petrel 2009, Schlumberger, 604 str.

ŽIVOTIPIS

Kristina Novak Zelenika je rođena 2. studenoga 1978. u Vukovaru. Po završetku opće gimnazije "Tituša Brezovačkog" u Zagrebu 1997. god. upisala je Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu. Godine 2005. stekla je zvanje diplomiranog inženjera geologije, smjer Geologija mineralnih sirovina i geofizička istraživanja.

Od 2006. godine zaposlena je u tvrtki INA-Industrija nafte d.d., tj. njezinom dijelu koji se naziva Sektor za geologiju i upravljanje ležištima. Tamo trenutno radi na radnome mjestu starijega inženjera za geološka istraživanja. Poslijediplomski doktorski studij geologije na Rudarsko-geološko-naftnom fakultetu upisala je 2006. godine.

Kao autor i koautor objavila je osamnaest radova iz područja geostatistike te je sudjelovala na brojnim stručnim kongresima.

POPIS RADOVA

Poglavlja u knjizi

- Malvić, T., **Novak Zelenika, K.** & Cvetković, M. (2012): Indicator vs. Gaussian geostatistical methods in sandstone reservoirs – Case study from the Sava Depression, Croatia. U: Geiger, J., Pál-Molnár, E. & Malvić, T. (ur.): New Horizons in Central European Geomathematics, Geostatistics and Geoinformatics, GeoLitera Publishing House, 37-46, Szeged.
- **Novak Zelenika, K.**, Velić, J. & Malvić, T. (2012): Application of geostatistics in description of turbiditic depositional environments, case study Kloštar Field, Sava Depression. U: Geiger, J., Pál-Molnár, E. & Malvić, T. (ur.): New Horizons in Central European Geomathematics, Geostatistics and Geoinformatics, GeoLitera Publishing House, 61-72, Szeged.

Znanstveni radovi u drugim časopisima

- **Novak Zelenika, K.** & Malvić, T. (2011): Stochastic simulations of dependent geological variables in sandstone reservoirs of Neogene age: A case study of Kloštar Field, Sava Depression. *Geologia Croatica*, 64, 2, 173-183.
- **Novak Zelenika, K.**, Malvić, T. & Velić, J. (2011): Possible changes of clastic detritus source in the Kloštar structure during Late Pannonian and Early Pontian. *Naftaplin*, 65, 43-51.
- **Novak Zelenika, K.** & Malvić, T. (2010): Using of Ordinary Kriging for indicator variable mapping (example of sandstone/marl border). *Naftaplin*, 30, 2, 55-70.
- **Novak Zelenika, K.**, Malvić, T. & Geiger, J. (2010): Kartiranje gornjomiocenskih pješčenjačkih facijesa metodom indikatorskog kriginga. *Nafta*, 61, 5, 225-233.

Ostali radovi u drugim časopisima

- **Novak Zelenika, K.** & Malvić, T. (2010): O upotrebi indikatorskih varijabli i indikatorskog kriginga u kartiranju (paleo)facijesa. *Vijesti Hrvatskoga geološkog društva*, 46, 2, 43-45.

Znanstveni radovi u zbornicima skupova s međunar. rec.

- **Novak Zelenika, K.**, Velić, J., Malvić, T. & Cvetković, M. (2011): Geological Variables Fitting in Normal Distribution and Application in Indicator Geostatistical Methods. IAMG 2011 Conference, September 5-9 2011, 245-251, Salzburg.
- **Novak Zelenika, K.** & Malvić, T. (2010): Sequential Indicator simulations of sandstone reservoir thickness, Sava Depression, Croatia (SW Part of Pannonian Basin). IAMG 2010 Conference, August 29-September 2 2010, str. 15, Budimpešta.

Sažeci u zbornicima skupova

- Malvić, T., **Novak Zelenika, K.** & Cvetković, M. (2011): Indicator vs. Gaussian geostatistical methods in sandstone reservoirs - Case study from the Sava Depression, Croatia. 3rd Croatian-Hungarian and 14th Hungarian geomathematical congress, May 26-28 2011, str. 10, Morahalom.
- **Novak Zelenika, K.**, Malvić, T. & Velić, J. (2011): Possible changes of clastic detritus source in the Kloštar structure during Late Pannonian en Early Pontian. The first Central and Eastern European international oil and gas conference and exhibition, September 14-16 2011, str. 124, Siofok.
- **Novak Zelenika, K.**, Velić, J. & Malvić, T. (2011): Application of geomathematics in description of turbiditic depositional environments, case study Kloštar Field, Sava Depression. 3rd Croatian-Hungarian and 14th Hungarian geomathematical congress, May 26-28 2011, str. 15, Morahalom.
- Geiger, J., Malvić, T., Horvath, J. & **Novak Zelenika, K.** (2010): Statistical characters of realizations derived from sequential indicator simulation. IAMG 2010 Conference, August 29-September 2 2010, str. 5, Budimpešta.
- Geiger, J., Malvić, T., Horvath, J. & **Novak Zelenika, K.** (2010): Handling uncertainty in the case of lateral extension of log-porosity values in a turbidity reservoir. 4. hrvatski geološki kongres, 14.-16. listopada 2010., 259-260, Šibenik.
- **Novak Zelenika, K.** & Malvić, T. (2010): Procjena sekvencijskim Gaussovim simulacijama ležišnih varijabli pješčenjačkog donjopontskog ležišta nafte, polje

Kloštar, Savska depresija, Hrvatska. 4. hrvatski geološki kongres, 14.-16. listopada 2010., 263-264, Šibenik.

- Malvić, T., Rusan, I. & **Novak Zelenika, K.** (2009): Geomathematical section of the Croatian geological society. XIII. Congress of Hungarian Geomathematics and the II. Congress of Croatian and Hungarian Geomathematics, May 21-23 2009, str. 44, Morahalom.
- **Novak Zelenika, K.** & Malvić, T. (2009): Transformation of porosity into indicator dataset and interpretation of facies : Case study from Lower Pontian sandstone, Sava depression. XIII. Congress of Hungarian Geomathematics and the II. Congress of Croatian and Hungarian Geomathematics, May 21-23 2009, 40-41, Morahalom.
- **Novak Zelenika, K.** & Malvić, T. (2009): Using of Ordinary Kriging for Indicator Variable Mapping (example of sandstone/marl border). Imaju li nafta i plin energetske zamjene u ovom stoljeću? (Is There an Energy Alternative for Oil and Gas in This Century?), 40-41, Šibenik.

Druge vrste radova

- **Novak Zelenika, K.** & Malvić, T. (2009): Using of ordinary kriging for indicator variable mapping (example of sandstone/marl border). IAMG Student chapter, predavanje održano 8. listopada 2009., Geološki odsjek Sveučilišta u Segedu.