

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOLOŠKI ODSJEK

Ivana Mesić Kiš

**KARTIRANJE I REINTERPRETACIJA
GEOLOŠKE POVIJESTI BJELOVARSKJE
SUBDEPRESIJE UNIVERZALNIM
KRIGIRANJEM TE NOVI OPĆI
METODOLOŠKI ALGORITMI ZA
KARTIRANJE SLIČNIH PROSTORA**

DOKTORSKA DISERTACIJA

Zagreb, 2017.

UNIVERSITY OF ZAGREB
FACULTY OF SCIENCE
DEPARTMENT OF GEOLOGY

Ivana Mesić Kiš

**MAPPING AND REINTERPRETATION
OF THE GEOLOGICAL EVOLUTION OF
THE BJELOVAR SUBDEPRESSION BY
UNIVERSAL KRIGING AND NEW
GENERAL METHODOLOGICAL
ALGORITHMS FOR MAPPING IN
SIMILAR AREAS**

DOCTORAL THESIS

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOLOŠKI ODSJEK

Ivana Mesić Kiš

**KARTIRANJE I REINTERPRETACIJA
GEOLOŠKE POVIJESTI BJELOVARSKJE
SUBDEPRESIJE UNIVERZALNIM
KRIGIRANJEM TE NOVI OPĆI
METODOLOŠKI ALGORITMI ZA
KARTIRANJE SLIČNIH PROSTORA**

Doktorska disertacija
predložena Geološkom odsjeku
Prirodoslovno-matematičkog fakulteta
Sveučilišta u Zagrebu
radi stjecanja akademskog stupnja
doktora prirodnih znanosti
znanstveno polje geologija, grana geologija i paleontologija

Zagreb, 2017.

Ova doktorska disertacija izrađena je na Prirodoslovno-matematičkom fakultetu u Zagrebu, pod vodstvom izv. prof. dr. sc. Gordane Medunić Geološkog odsjeka Prirodoslovno-matematičkog fakulteta (PMF-a) u Zagrebu i izv. prof. dr. sc. Tomislava Malvića Rudarsko-geološko-naftnog fakulteta (RGNF-a) u Zagrebu, u sklopu Poslijediplomskog studija geoloških znanosti na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu.

Zahvala

Zahvaljujem mentorima na velikodušnoj pomoći, izv. prof. dr. sc. Gordani Medunić koja me vodila kroz poslijediplomski studij te mi omogućila upisivanje istog. Izv. prof. dr. sc. Tomislavu Malviću zahvaljujem na iznimno velikoj pomoći oko teme disertacije, ažurnosti, pomoći pri razumijevanju geomatematičke građe te općenito u pomoći pri svladavanju svake prepreke što je u konačnici i omogućilo dovršetak disertacije.

Veliko hvala ocjenjivačima prof. emer. Josipi Velić, izv. prof. dr. sc. Jasenki Sremac i dr. sc. Kristini Novak Zelenika koji su konstruktivnim komentarima i ispravcima učinili disertaciju boljom.

Hvala mojim prijateljima koji su bili uz mene, hvala na razumijevanju i podršci kroz druženja i društvene igre, osobito Natali koja je kao i uvijek bila neizmjerne podrška.

Beskonačno zahvaljujem svojim roditeljima Mirku i Gordani i bratu Nikoli koji su uvijek vjerovali u mene i pružali mi neizmjernu podršku za pisanje disertacije, ali i u svemu ostalom u životu što naumim.

I za kraj, najveće hvala mom suprugu Domagoju.

SADRŽAJ

1. UVOD	1
2. GEOGRAFSKA OBILJEŽJA ISTRAŽIVANOGA PROSTORA	5
2.1. Geografski smještaj i položaj	5
2.2. Regije	6
2.3. Važnija naselja i prometnice	6
2.4. Mjesta iz kojih su dobiveni bušotinski podatci	8
2.5. Hidrografska mreža	9
2.6. Klimatska obilježja.....	11
3. POVIJEST DOSADAŠNJIH ISTRAŽIVANJA	12
3.1. Razdoblje od drugog svjetskog rata do osamdesetih godina prošlog stoljeća.....	12
3.2. Razdoblje od osamdesetih godina prošlog stoljeća do danas	14
4. GEOLOŠKA OBILJEŽJA HRVATSKOGA DIJELA PANONSKOGA BAZENSKOG SUSTAVA I BJELOVARSKO SUBDEPRESIJE	15
4.1. Tektonska aktivnost	16
4.2. Razvoj i današnji izgled Bjelovarske subdepresije.....	18
4.3. Pregled geološke evolucije kartiranoga prostora	26
4.3.1. <i>Taložne stijene donjega i srednjega miocena – formacija Moslavačka gora</i>	28
4.3.2. <i>Taložne stijene gornjega panona – formacija Ivanić-Grad</i>	32
4.3.3. <i>Taložne stijene donjega ponta – formacija Kloštar-Ivanić</i>	33
4.3.4. <i>Taložne stijene gornjega ponta – formacija Bilogora</i>	36
4.3.5. <i>Taložne stijene dacija, romanija i kvartara – formacija Lonja</i>	39
5. ISTRAŽIVAČKA METODOLOGIJA	40
5.1. Metoda Thiessenovih poligona.....	41
5.2. Pregled teorije determinističkih geostatističkih metoda	45
5.2.1. <i>Variogramaska analiza</i>	45
5.2.2. <i>Tehnike krigiranja</i>	49
5.2.2.1. <i>Obično krigiranje</i>	51
5.2.2.2. <i>Univerzalno krigiranje</i>	52
5.2.3. <i>Postupak krosvalidacije</i>	55
6. KORIŠTENI RAČUNALNI PROGRAMI	57
6.1. Računalni program Variowin	57
6.2. Računalni program SAGA GIS	60
6.3. Računalni program Surfer	61

7. REZULTATI UPORABE ZONALNE PROCJENE I RAZLIČITIH TEHNIKA KRIGIRANJA NA PRIMJERU POLJA ŠANDROVAC KAO POJEDINAČNE STRUKTURE	63
7.1. Metoda Thiessenovih poligona na primjeru polja Šandrovac	65
7.2. Tehnika običnoga krigiranja na primjeru polja Šandrovac	69
7.3. Primjena tehnike univerzalnoga krigiranja na podacima polja Šandrovac	72
7.3.1. <i>Višestruka regresijska analiza kao dio izračuna tehnike univerzalnoga krigiranja</i>	73
7.3.2. <i>Variogrami ostataka</i>	78
7.3.3. <i>Karta dobivena tehnikom univerzalnoga krigiranja</i>	79
7.4. Metoda krosvalidacije na primjeru polja Šandrovac	80
8. REZULTATI UPORABE ZONALNE PROCJENE I ODABRANIH TEHNIKA KRIGIRANJA NA PRIMJERU BJELOVARSKJE SUBDEPRESIJE.....	83
8.1. Primjena Thiessenovih poligona na području Bjelovarske subdepresije	88
8.2. Primjena tehnike običnoga krigiranja na području Bjelovarske subdepresije.....	94
8.2.1. <i>Eksperimentalni i teorijski modeli variograma varijable dubine za glavnu i sporednu os</i>	95
8.2.2. <i>Karte dubina EK markera Bjelovarske subdepresije dobivene tehnikom običnoga krigiranja</i>	105
8.3. Primjena tehnike univerzalnoga krigiranja na području Bjelovarske subdepresije. 112	
8.3.1. <i>Eksperimentalni i teorijski modeli variograma za glavnu i sporednu os varijable ostatci</i> 118	
8.3.2. <i>Karte Bjelovarske subdepresije dobivene tehnikom univerzalnoga krigiranja</i> 128	
9. ODABIR TEHNIKE OBIČNOGA KRIGIRANJA ZA KARTIRANJE DEBLJINA FORMACIJA ISTRAŽIVANOG PROSTORA TE IZRADBA ODABRANIH PALINSPASTIČKIH PROFILA	136
9.1. Karta debljina intervala Pt/Tg – Rs7, član Mosti, formacija Moslavačka gora.....	137
9.2. Karta debljina intervala Rs7 – Rs5, član Križevci, formacija Moslavačka gora....	139
9.3. Karta debljina intervala Rs5 – Z', formacija Ivanić Grad.....	141
9.4. Karta debljina intervala Z' – delta, formacija Kloštar-Ivanić	144
9.5. Karta debljina intervala delta – D', formacija Bilogora.....	146
10. RASPRAVA ZAKLJUČCI.....	149
10.1. Poligonalna i matematičke metode, namjena i preporuka odabira	149
10.2. Uloga krosvalidacije kao numeričke provjere kvalitete rezultata kartiranja.....	151
10.3. Pretvorba i posljedice analognih u digitalne kartografske podatke te način odabira interpolacijskih metoda	152
10.4. Trendovi u geološkim podacima i njihovo opažanje kod kartiranja.....	153
10.5. Potvrda taložnoga modela naprednim metodama kartiranja.....	153
11. PROŠIRENI SAŽETAK	155
12. SUMMARY	158

13. POPIS LITERATURE	161
13.1. Objavljeni radovi	161
13.2. Neobjavljeni radovi.....	167
13.3. Iz fondova stručne literature	167
13.4. Internetske poveznice.....	168
14. PRILOZI.....	169
15. ŽIVOTOPIS	180
15.1. Popis radova.....	181
15.2. Otkrića i ostalo	182

POPIS SLIKA

<i>Slika 2.1. Geografski položaj Bjelovarske subdepresije</i>	<i>5</i>
<i>Slika 2.2. Glavna sjedišta i cestovni pravci Bjelovarsko-bilogorske županije.....</i>	<i>7</i>
<i>Slika 2.3. Položaji polja i istraživačkih bušotina s kojih su dobiveni podatci</i>	<i>9</i>
<i>Slika 4.1. Glavne geotektonske jedinice unutar Panonskoga bazenskog sustava</i>	<i>16</i>
<i>Slika 4.2. Skica paleosmjera turbiditnih struja tijekom gornjeg pontu u HPBS-u.....</i>	<i>17</i>
<i>Slika 4.3. Depresije i subdepresije unutar hrvatskoga dijela Panonskoga bazenskog sustava)</i>	<i>19</i>
<i>Slika 4.4. Paleoreljefna karta Bjelovarske subdepresije EK granice „Pt/Tg“</i>	<i>21</i>
<i>Slika 4.5. Strukturna karta Bjelovarske subdepresije po plohi EK markera Rs7</i>	<i>22</i>
<i>Slika 4.6. Strukturna karta Bjelovarske subdepresije po plohi EK markera Rs5</i>	<i>23</i>
<i>Slika 4.7. Strukturna karta Bjelovarske subdepresije po plohi EK markera Z'</i>	<i>24</i>
<i>Slika 4.8. Strukturna karta Bjelovarske subdepresije po plohi EK markera Δ</i>	<i>25</i>
<i>Slika 4.9. Strukturna karta Bjelovarske subdepresije po plohi EK markera D'</i>	<i>26</i>
<i>Slika 4.10. Litostratigrafske jedinice Dravske depresije.....</i>	<i>27</i>
<i>Slika 4.11. Karta debljina formacije Moslavačka gora, član Mosti, dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda</i>	<i>30</i>
<i>Slika 4.12. Karta debljina formacije Moslavačka gora, član Križevci, dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda.....</i>	<i>31</i>
<i>Slika 4.13. Karta debljina formacije Ivanić-Grad dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda</i>	<i>33</i>
<i>Slika 4.14. Konceptualni taložni model gornjopanonskih (A) i donjopontskih (B) naslaga polja Kloštar</i>	<i>34</i>

<i>Slika 4.15. Karta debljina formacije Kloštar-Ivanić dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda</i>	<i>36</i>
<i>Slika 4.16. Konceptualni taložni model gornjopontskih (C), pliocenskih i kvartarnih naslaga (D) polja Kloštar</i>	<i>37</i>
<i>Slika 4.17. Karta debljine formacije Bilogora dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda</i>	<i>38</i>
<i>Slika 5.1. Primjer izradbe simetrane između dvije susjedne točke</i>	<i>43</i>
<i>Slika 5.2. Izgled Thiessenovih poligona i elemenata potrebnih za njihovo definiranje</i>	<i>44</i>
<i>Slika 5.3. Parametri semivariograma</i>	<i>46</i>
<i>Slika 5.4. Teorijski modeli</i>	<i>48</i>
<i>Slika 5.5. Primjer područja pretraživanja. Na slici lijevo nema anizotropije, dok je na slici desno prikazan elipsoid pretraživanja omjera anizotropije 2, pod kutem od 140°</i>	<i>50</i>
<i>Slika 6.1. Programi unutar Variowina za izradbu variograma</i>	<i>57</i>
<i>Slika 6.2. Primjer priređivanja podataka za rad u programu Prevar 2D</i>	<i>58</i>
<i>Slika 6.3. Primjer rada u programu Vario 2D – izradba karte variogramske površine i eksperimentalnog variograma</i>	<i>59</i>
<i>Slika 6.4. Primjer rada u programu Model – variogramski aproksimacijski model</i>	<i>60</i>
<i>Slika 6.5. SAGA grafičko korisničko sučelje - GUI</i>	<i>61</i>
<i>Slika 6.6. Primjer sučelja u Surferu</i>	<i>62</i>
<i>Slika 7.1. Položaj polja Šandrovac</i>	<i>63</i>
<i>Slika 7.2. Strukturna karta Bjelovarske subdepresije po plohi EK markera Z' i položaj polja Šandrovac</i>	<i>64</i>
<i>Slika 7.3. Shematski geološki profil A-A' naftno-plinskog polja Šandrovac</i>	<i>65</i>
<i>Slika 7.4. Poligon polja Šandrovac i raspodjela 18 točaka s vrijednošću dubina izravno očitanih sa strukturne karte po EK markeru Z'</i>	<i>67</i>
<i>Slika 7.5. Thiessenovi poligoni unutar polja Šandrovac prikazani bojama koje odgovaraju vrijednosti dubine u određenim točkama</i>	<i>68</i>
<i>Slika 7.6. Karta variogramske površine za varijablu „dubina“ polja Šandrovac</i>	<i>69</i>
<i>Slika 7.7. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „dubina“, glavna os pružanja 135°-315°</i>	<i>70</i>
<i>Slika 7.8. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „dubina“, sporedna os pružanja 45°-225°</i>	<i>70</i>
<i>Slika 7.9. Karta dobivena običnim krigiranjem za varijablu „dubina“ u polju Šandrovac</i>	<i>71</i>
<i>Slika 7.10. Ovisnost dubine o x i y Gauss-Krügerovim koordinatama</i>	<i>72</i>

<i>Slika 7.11. Vrijednosti varijable „ostatci“ dobivene u Excelu</i>	<i>77</i>
<i>Slika 7.12. Karta variogramske površine za varijablu „ostatci“ polja Šandrovac</i>	<i>78</i>
<i>Slika 7.13. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „ostatci (residuals)“, glavna os pružanja 135°-315°.....</i>	<i>79</i>
<i>Slika 7.14. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „ostatci (residuals)“, sporedna os pružanja 45°-225°.....</i>	<i>79</i>
<i>Slika 7.15. Karta dobivena univerzalnim krigiranjem za varijablu „dubina“ u polju Šandrovac</i>	<i>80</i>
<i>Slika 7.16. Izlazne karte dobivene tehnikama običnog i univerzalnog krigiranja. Crvenom bojom označen je najprecjenjeniji, a plavom najpodcjenjeniji podatak.....</i>	<i>82</i>
<i>Slika 8.1. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz paleoreljefne karte EK granice Pt/Tg</i>	<i>84</i>
<i>Slika 8.2. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Rs7</i>	<i>85</i>
<i>Slika 8.3. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Rs5</i>	<i>85</i>
<i>Slika 8.4. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Z'</i>	<i>86</i>
<i>Slika 8.5. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru delta</i>	<i>87</i>
<i>Slika 8.6. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru D'</i>	<i>88</i>
<i>Slika 8.7. Thiessenovi poligoni vrijednosti dubina Pt/Tg granice unutar Bjelovarske subdepresije.....</i>	<i>89</i>
<i>Slika 8.8. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Rs7 unutar Bjelovarske subdepresije.....</i>	<i>90</i>
<i>Slika 8.9. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Rs5 unutar Bjelovarske subdepresije.....</i>	<i>91</i>
<i>Slika 8.10. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Z' unutar Bjelovarske subdepresije.....</i>	<i>92</i>
<i>Slika 8.11. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Δ unutar Bjelovarske subdepresije.....</i>	<i>93</i>
<i>Slika 8.12. Thiessenovi poligoni vrijednosti dubina po plohi EK markera D' unutar Bjelovarske subdepresije.....</i>	<i>94</i>

<i>Slika 8.13. Karta variogramske površine za varijablu „dubina“ Bjelovarske subdepresije ...</i>	95
<i>Slika 8.14. Eksperimentalni variogram glavne osi za varijablu „dubina“ EK granice Pt/Tg</i>	96
<i>Slika 8.15. Eksperimentalni variogram sporedne osi za varijablu „dubina“ EK granice Pt/Tg</i>	96
<i>Slika 8.16. Aproksimacija eksperimentalnog variograma dobivenog iz paleoreljefne karte EK granice „Pt/Tg“ pomoću Gaussovog modela</i>	97
<i>Slika 8.17. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Rs7</i>	97
<i>Slika 8.18. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Rs7</i>	98
<i>Slika 8.19. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Rs7 pomoću sfernog modela</i>	98
<i>Slika 8.20. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Rs5</i>	99
<i>Slika 8.21. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Rs5</i>	99
<i>Slika 8.22. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Rs5 pomoću sfernog modela</i>	100
<i>Slika 8.23. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Z'</i>	100
<i>Slika 8.24. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Z'</i>	101
<i>Slika 8.25. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Z' pomoću sfernog modela</i>	101
<i>Slika 8.26. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Δ</i>	102
<i>Slika 8.27. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Δ</i>	102
<i>Slika 8.28. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Δ pomoću sfernog modela</i>	103
<i>Slika 8.29. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera D'</i>	104
<i>Slika 8.30. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera D'</i>	104

<i>Slika 8.31. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru D' pomoću Gaussovog modela</i>	105
<i>Slika 8.32. Karta OK dobivena iz paleoreljefne karte Bjelovarske subdepresije EK granice Pt/Tg</i>	106
<i>Slika 8.33. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Rs7</i>	107
<i>Slika 8.34. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Rs5</i>	108
<i>Slika 8.35. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Z'</i>	109
<i>Slika 8.36. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Δ</i>	110
<i>Slika 8.37. Karta OK dobivena iz strukturne karte dubina Bjelovarske subdepresije po EK markeru D'</i>	111
<i>Slika 8.38. Ovisnost dubine Bjelovarske subdepresije na granici Pt/Tg o x i y Gauss-Krüger koordinatama</i>	113
<i>Slika 8.39. Ovisnost dubine Bjelovarske subdepresije na granici sarmat/panon o x i y Gauss-Krüger koordinatama</i>	114
<i>Slika 8.40. Ovisnost dubine Bjelovarske subdepresije na granici gornji panon/donji panon o x i y Gauss-Krüger koordinatama</i>	115
<i>Slika 8.41. Ovisnost dubine Bjelovarske subdepresije na granici gornji panon/donji pont o x i y Gauss-Krüger koordinatama</i>	116
<i>Slika 8.42. Ovisnost dubine Bjelovarske subdepresije na granici donji pont/gornji pont o x i y Gauss-Krüger koordinatama</i>	117
<i>Slika 8.43. Ovisnost dubine Bjelovarske subdepresije na granici pont/pliocen o x i y Gauss-Krüger koordinatama</i>	118
<i>Slika 8.44. Eksperimentalni variogram glavne osi za varijablu „ostatci“ EK granice Pt/Tg</i>	119
<i>Slika 8.45. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ EK granice Pt/Tg</i>	119
<i>Slika 8.46. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte EK granice „Pt/Tg“ pomoću Gaussovog modela</i>	120
<i>Slika 8.47. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Rs7</i>	120

<i>Slika 8.48. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Rs7</i>	121
<i>Slika 8.49. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru Rs7 pomoću sfernog modela</i>	121
<i>Slika 8.50. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Rs5</i>	122
<i>Slika 8.51. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Rs5</i>	122
<i>Slika 8.52. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru Rs5 pomoću sfernog modela</i>	123
<i>Slika 8.53. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Z'</i>	123
<i>Slika 8.54. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Z'</i>	124
<i>Slika 8.55. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru Z' pomoću sfernog modela</i>	124
<i>Slika 8.56. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Δ.....</i>	125
<i>Slika 8.57. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Δ</i>	125
<i>Slika 8.58. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru Δ pomoću sfernog modela.....</i>	126
<i>Slika 8.59. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera D'</i>	126
<i>Slika 8.60. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera D'.....</i>	127
<i>Slika 8.61. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru D' pomoću Gaussovog modela.....</i>	127
<i>Slika 8.62. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije EK granice Pt/Tg</i>	128
<i>Slika 8.63. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Rs7.....</i>	129
<i>Slika 8.64. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Rs5.....</i>	130

<i>Slika 8.65. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Z'</i>	131
<i>Slika 8.66. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru Δ</i>	133
<i>Slika 8.67. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru D'</i>	134
<i>Slika 9.1. Ukupan i načinjen broj paleostrukturalnih karata</i>	136
<i>Slika 9.2. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Moslavačka gora, član Mosti</i>	137
<i>Slika 9.3. Karta debljine formacije Moslavačka gora, člana Mosti, dobivena tehnikom OK, te uzdužni profil A-B</i>	139
<i>Slika 9.4. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Moslavačka gora, član Križevci</i>	139
<i>Slika 9.5. Karta debljine formacije Moslavačka gora, člana Križevci, dobivena tehnikom OK, te uzdužni profil A-B</i>	141
<i>Slika 9.6. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Ivanić Grad</i>	142
<i>Slika 9.7. Karta debljine formacije Ivanić Grad dobivena tehnikom OK te uzdužni profil A-B</i>	143
<i>Slika 9.8. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija sfernim teorijskim modelom (desno) za varijablu debljina, formacije Kloštar-Ivanić</i>	144
<i>Slika 9.9. Karta debljine formacije Kloštar-Ivanić dobivena tehnikom OK te uzdužni profil A-B</i>	146
<i>Slika 9.10. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija sfernim teorijskim modelom (desno) za varijablu debljina, formacije Bilogora</i>	146
<i>Slika 9.11. Karta debljine formacije Bilogora dobivena tehnikom OK te uzdužni profil A-B</i>	148
<i>Slika 10.1. Dijagram toka</i>	152

POPIS TABLICA

<i>Tablica 4.1. Vremenska skala glavnih tektonskih i taložnih razdoblja u neogenu i kvartaru unutar HPBS-a</i>	18
<i>Tablica 7.1. Koordinate poligona polja Šandrovac</i>	66
<i>Tablica 7.2. Ulazni podatci za izradbu karata dubina metodama Thiessenovih poligona i krigiranja.....</i>	66
<i>Tablica 7.3. Ulazne vrijednosti varijabli za višestruku regresijsku analizu</i>	75
<i>Tablica 7.4. Vrijednosti ostataka dobivenih višestrukom linearnom regresijom.....</i>	76
<i>Tablica 7.5. Usporedba metode Thiessenovih poligona i metode krigiranja</i>	81
<i>Tablica 8.1. Usporedba rezultata krosvalidacije dobivenih tehnikama OK i UK</i>	135

POPIS JEDNADŽBI

Jednadžba 5.1 : Procijenjena globalna sredina kod poligonalne metode

Jednadžba 5.2 : Variogram

Jednadžba 5.3 : Sferni model

Jednadžba 5.4 : Eksponecijalni model

Jednadžba 5.5 : Gaussov model

Jednadžba 5.6 : Linearnost procjene krigiranja

Jednadžba 5.7 : Matrična jednadžba jednostavnog krigiranja

Jednadžba 5.8: Jednadžba Lagrange funkcije

Jednadžba 5.9 : Matrična jednadžba običnog krigiranja

Jednadžba 5.10 : Vrijednost varijable Z izražene kao zbroj determinističke i stohastičke komponente

Jednadžba 5.11 : Osnovni model univerzalnog krigiranja

Jednadžba 5.12 : Vrijednost varijable Z za linearni model

Jednadžba 5.13 : Vrijednost varijable Z za kvadratni model

Jednadžba 5.14 : Procijenjena vrijednost $Z(s_0)$ na lokaciji s_0

Jednadžba 5.15 : Vrijednost $Z(s_0)$ temeljena na linearnom trendu

Jednadžba 5.16 : Vrijednost $Z(s_0)$ temeljena na linearnom trendu (drugi izraz)

Jednadžba 5.17 : Uvjeti za nepristranost procjene kod univerzalnog krigiranja

Jednadžba 5.18 : Minimaliziranje srednje kvadratne pogreške

Jednadžba 5.19 : Matrična jednadžba univerzalnog krigiranja na primjeru linearnog trenda

Jednadžba 5.20 : Konačan rezultat krosvalidacije; srednja kvadratna pogreška

Jednadžba 7.1 : Odnos zavisne i nezavisne varijable

Jednadžba 7.2 : Opći model višestruke linearne regresije

Jednadžba 7.3 : Model višestruke linearne regresije u slučaju linearne veze

Jednadžba 7.4 : Vektorska jednadžba linearne regresijske veze u obliku sustava od n jednadžbi

Jednadžba 7.5 : Procjena vrijednosti parametara

Jednadžba 7.6 : Normalne jednadžbe metode najmanjih kvadrata

Jednadžba 7.7 : Procijenjen model u slučaju dvije nezavisne varijable

Jednadžba 7.8 : Procjena varijance

Jednadžba 7.9 : Koeficijent varijacije regresije

Jednadžba 8.1 : Broj razreda

POPIS KORIŠTENIH OZNAKA I JEDINICA

a	doseg variograma
β	koeficijent regresije
"BLUE"	Best Linear Unbiased Estimator
C	varijanca
C_0	odstupanje variograma
δ	stacionarni nasumični proces sa semivariogramom (γ)
$\hat{\epsilon}$	ostatak (rezidual)
F(x)	procjenjena globalna sredina
GIS	geografski informacijski sustav, engl. <i>Geographic Information System</i>
h	udaljenost ili korak variograma
HPBS	hrvatski dio Panonskog bazenskog sustava
λ	težinski koeficijent
k	broj razreda
MSE	srednja kvadratna pogreška (kros-validacija) procjene odabrane metode
n	skup Thiessenovih poligona
N	skup centroida
N(h)	broj parova podataka eksp. variograma uspoređenih na udaljenosti 'h'
PBS	Panonski bazenski sustav
SSE	Suma kvadrata odstupanja empirijskih vrijednosti varijable y od \hat{y}
w_i	težine definirane površinom poligona
x	lokacija u kojoj se procjenjuje nova vrijednost
μ	Lagrangeov faktor ili konstantna sredina Z(s)
$2\gamma(h)$	vrijednost variograma
Z_n	vrijednost na lokaciji 'n'
Z_{n+h}	vrijednost varijable na lokaciji udaljenoj za 'h' od promatrane lokacije 'n'

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geološki odsjek

Doktorska disertacija

KARTIRANJE I REINTERPRETACIJA GEOLOŠKE POVIJESTI BJELOVARSKE SUBDEPRESIJE UNIVERZALNIM KRIGIRANJEM TE NOVI OPĆI METODOLOŠKI ALGORITMI ZA KARTIRANJE SLIČNIH PROSTORA

IVANA MESIĆ KIŠ

Rad je izrađen na Prirodoslovno-matematičkom fakultetu, Geološki odsjek, Horvatovac 102 a, 10 000 Zagreb

Sažetak: Analiziran je prostor Bjelovarske subdepresije na lokalnoj (polje Šandrovac) i regionalnoj razini (cijela subdepresija). Ulazni podatci bile su dubine EK granice Pt/Tg i EK markera Rs7, Rs5, Z', Δ i D'. Statistički je analizirano više od sedamsto podataka očitanih s pravilne mreže kojom su prekrivene postojeće paleostrukturalne karte, s ćelijama veličine 2x2 km. Kartirano je metodama Thiessenovih poligona (program SAGA GIS) i krigiranja (Surfer). Poligonalna, tj. zonalna procjena uporabljena je kao jednostavna i brza metoda prikaza dubina. Krigiranje je dalo znatno bolje regionalne karte. Obično krigiranje je dokazano u većini slučajeva kao najbolja moguća interpolacija podataka dubine (Pt/Tg, Rs7, Z' i D'), uz najmanje vrijednosti krosvalidacije. Njome su interpolirane karte debljina formacija iz kojih su reinterpretirani neogensko-kvartarni okoliši. Nadalje, unutar pojedinačnih struktura, tehnika univerzalnoga krigiranja određena je kao najprimjerenija interpolacijska metoda, jer je samo u takvim slučajevima bilo moguće izdvojiti jasan linearni trend u pružanju i dubinama promatrane strukture.

Ključne riječi: Bjelovarska subdepresija, kartiranje, obično krigiranje, Thiessenovi poligoni, univerzalno krigiranje, Hrvatska

Rad sadrži: 182 + XVIII stranica, 126 slika, 7 tablica, 1 prilog, 110 literaturnih navoda

Jezik izvornika: hrvatski

Rad je pohranjen u: knjižnici Hrvatskog geološkog instituta, Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, te Središnjoj knjižnici Geološkog odsjeka PMF-a

Mentori: izv. prof. dr. sc. Gordana Medunić, Geološki odsjek, PMF
izv. prof. dr.sc. Tomislav Malvić, RGNF

Ocjenjivači: prof. emer. dr. sc. Josipa Velić, znanstvena savjetnica, RGNF
prof.dr.sc. Jasenka Sremac, znanstvena savjetnica, Geološki odsjek, PMF
dr.sc. Kristina Novak-Zelenika, znanstvena suradnica, INA

Rad prihvaćen: 12. svibnja 2017.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geology

Doctoral Thesis

MAPPING AND REINTERPRETATION OF THE GEOLOGICAL EVOLUTION OF THE
BJELOVAR SUBDEPRESSION BY UNIVERSAL KRIGING AND NEW GENERAL
METHODOLOGICAL ALGORITHMS FOR MAPPING IN SIMILAR AREAS

IVANA MESIĆ KIŠ

Thesis completed in Faculty of Science, Department of Geology, Horvatovac 102 a, 10 000
Zagreb

Abstract: The area of Bjelovar subdepression was analyzed at the local (Šandrovac Field) and regional level (the entire subdepression). Input data were depths of Pt/Tg e-log border and Rs7, Rs5, Z', Δ and D' e-log markers. More than seven hundred data were statistically analyzed. The data were collected in a regular grid that covers the existing paleostructural maps, with cells 2x2 km in size. Mapping was carried out using Thiessen polygon method (program SAGA GIS) and Kriging (Surfer). The polygonal, i.e. the zonal assessment was used as a simple and fast method for displaying depths. Kriging gave significantly better regional maps. Ordinary Kriging has been proved in most cases to be the best possible interpolation of depth data (Pt/Tg, Rs7, Z' and D'), with the lowest cross-validation values. It was used for interpolation of formation thickness maps from which Neogene-Quaternary environments were reinterpreted. Furthermore, within the individual structures, Universal Kriging technique is determined as the most appropriate interpolation method, because it was only possible in such cases to extract a clear linear trend in extent and depths of the observed structure.

Keywords: Bjelovar subdepression, mapping, Ordinary Kriging, Thiessen polygon, Universal Kriging, Croatia

Thesis contains: 182 + XVIII pages, 126 figures, 7 tables, 110 references

Original in: Croatian

Thesis deposited in: library of the Croatian Geological Survey, National and University Library in Zagreb and Central library of Department of Geology, Faculty of Science

Supervisors: Dr. Gordana Medunć, Associate Professor, Department of Geology, Faculty of Science, University of Zagreb

Dr. Tomislav Malvić, Associate Professor, Faculty of Mining, Geology and Petroleum Engineering, University of Zagreb

Reviewers: Dr. Josipa Velić, Professor Emeritus, Faculty of Mining, Geology and Petroleum Engineering, University of Zagreb

Dr. Jasenka Sremac, Professor, Department of Geology, Faculty of Science, University of Zagreb

Dr. Kristina Novak-Zelenika, Research Associate, INA-Oil industry Plc.

Thesis accepted: May 12, 2017

1. UVOD

Panonski bazenski sustav (skr. PBS) okružen je planinskim lancima Alpa, Karpata i Dinarida. Hrvatski dio Panonskog bazenskog sustava (skr. HPBS) predstavlja jugozapadni dio navedenog područja omeđen rijekama Savom i Kupom na jugu, Murom i Dravom na sjeveru te Dunavom na istoku. Unutar njega postoje četiri velike depresije neogenskog podrijetla: Savska, Dravska, Murska i Slavonsko-srijemska. Upravo je Dravska depresija, odnosno njezin jugozapadni dio koju čini Bjelovarska subdepresija, tema istraživanja ove disertacije. Interpretaciju taložnog paleookoliša Bjelovarske subdepresije detaljno je učinio **Malvić (2003)** u disertaciji „*Naftnogeološki odnosi i vjerojatnost pronalaska novih zaliha ugljikovodika u Bjelovarskoj uleknini*“. Većina istraživanja neogenskih depresija HPBS-a učinjena je upravo sa svrhom pronalaska i određivanja zaliha ugljikovodika (e.g. **Velić i sur., 2002; Malvić, 2003; Saftić i sur., 2001; Saftić i sur. 2003**), koji se na tom području eksploatiraju od 1941. godine (**Velić i sur., 2012**).

U geologiji, ali i ostalim prirodnim znanostima poput meteorologije, geodezije, biologije i ekologije, prilikom istraživanja i analize prikupljenih podataka želja je predvidjeti vrijednosti varijable na mjestima gdje podatci nisu dostupni pomoću prikupljenih podataka iz okolnih područja. To se čini geostatističkim i geomatematičkim metodama prostorne procjene vrijednosti varijabli. Sve geoznanosti imaju korist od upotrebe matematike, pogotovo u moderno doba razvojem digitalnih računala budući da je moguće obraditi veliku količinu podataka (**Agterberg, 2014**). Računanje vjerojatnosti i statističkih zaključaka značajno su pridonijeli rješavanju mnogih geoloških nedoumica. Geomatematika u širem smislu uključuje primjenu matematike za rješavanje problema u istraživanjima Zemljine kore. Međutim, geolozima je potrebno mnoštvo geomatematičkih tehnika, osobito pri prikupljanju, obradbi i analizi podataka (prepoznavanje trenda, klastera, jednostavnih i složenih korelacija), uzorkovanju, testiranju hipoteza (računalnim simulacijskim modelima) te kvantitativnim predviđanjima.

U geologiji postoji skup češćih metoda koje se koriste u geološkom kartiranju računalnim paketima. **Malvić (2008)** je detaljno opisao uporabu naprednih statističkih metoda procjene krigiranja, kokrigiranja i simulacija kao čestih alata u geologiji. Tehnika običnog krigiranja potvrđena je brojnim radovima kao najbolja metoda prikaza prostorne distribucije ležišnih varijabli (npr. **Malvić i Đureković, 2003; Balić i sur., 2008; Malvić, 2008**). **Balić i sur. (2008)** su u kartiranju pješčenjačkih ležišta izdvojili metode najbližeg susjedstva, inverzne udaljenosti, pokretne sredine i krigiranja kao najčešće metode interpolacije geoloških varijabli u hrvatskoj

1. Uvod

geologiji. **Mesić Kiš i Malvić (2014)** su po prvi put kod nas detaljno opisali primjenu Thiessenovih poligona u geološkom kartiranju na primjeru naftno-plinskog polja Šandrovac smještenog u Bjelovarskoj subdepresiji. Navedena metoda poznata je i kao metoda najbližeg susjedstva, poligonalna interpolacija, a predstavlja zonalnu procjenu vrijednosti varijable koja dodjeljuje vrijednost najbliže točke svakom čvoru mreže. Dobivena karta ne predstavlja pouzdan prikaz, ali se putem zona može odrediti približna raspodjela vrijednosti varijabli u analiziranom području.

Tehnika univerzalnog krigiranja tek je nedavno u Hrvatskoj prvi puta upotrijebljena za izradbu dubinskogeološke karte polja Šandrovac po plohi EK markera Z' (**Mesić Kiš, 2016**).

Ciljevi istraživanja odnosit će se na uporabu tehnike univerzalnog krigiranja za kartiranje geoloških varijabli, a mogu se opisati kroz tri točke:

- 1) Razmotrit će se algoritam univerzalnog krigiranja kao najprimjereniji za regionalno kartiranje prostora u kojem postoji strukturni trend;
- 2) Takav algoritam bit će praktično iskorišten na podacima EK markera koji se pružaju u prostoru Bjelovarske subdepresije, a primijenit će se na lokalnoj i regionalnoj razini;
- 3) Rezultati će se usporediti s ranijim kartama istoga prostora na istim litostratigrafskim i kronostratigrafskim granicama, te naći opći model kartiranja i statističke obradbe takvih podataka uopće.

Cilj ovoga rada je i poticanje šire upotrebe tehnike univerzalnog krigiranja pri kartiranju geoloških varijabli s izraženim trendom gdje daje najprimjerenije rezultate te prikaz algoritma odabira najprimjerenije tehnike krigiranja regionalnih podataka (na kilometarskoj skali) čime se budućim korisnicima želi olakšati takav odabir.

Plan istraživanja može se svesti na sljedeće korake:

- 1) Prikupljanje podataka po krovini EK markera, kojima se ujedno aproksimira dubina na kojoj se nalazi ti markerni slojevi (takva aproksimacija je dopuštena jer je debljina tih slojeva regionalnoga prostiranja tek nekoliko metara, što je nekoliko redova veličine manje u usporedbi s dubinom na kojoj se nalaze (nekoliko stotina metara) te površinom na kojoj se pružaju (nekoliko tisuća kvadratnih kilometara)),
- 2) Statistička obradba podataka;
- 3) Variogramska analiza programom Variowin odabranih varijabli (za tehniku običnoga krigiranja, skr. OK) i ostataka (za tehniku univerzalnoga krigiranja, skr. UK);
- 4) Primjena metode Thiessenovih poligona pomoću programa SAGA GIS te tehnika OK-a i UK-a programom Surfer na lokalnoj (polje Šandrovac) i regionalnoj razini;
- 5) Usporedba metoda postupkom krosvalidacije;

1. Uvod

- 6) Određivanje kriterija o primjeni tehnika krigiranja glede ulaznoga skupa podataka i kvalitete, kako strukturne, tako i interpretacije taložnih okoliša.

Osim u opisanom slučaju analize, statističke obradbe i kartiranja varijable dubine, navedena metodologija može se primijeniti i na podatke prikupljene mjernim uređajima na površini (npr. mjerenje temperature termometrom, određivanje granulometrijskog i mineralošskog sastava na terenu), ali i u dubini (električna otpornost, prirodna radioaktivnost, apsorpcija zvuka itsl.).

Hipoteze istraživanja su sljedeće:

- (1) Kartiranje je moguće načiniti matematičkim algoritmima koji do sada nisu bili korišteni za ovaj prostor, a matematički su napredniji od onih do sada uporabljenih;
- (2) Rezultati će biti primjereniji i bolje prikazivati strukturne dubinske elemente, a time i taložne prostore, od ranijih dubinskih karata bilo načinjenih ručnom interpolacijom, bilo krigiranjem;
- (3) Pravila uporabe novih algoritama bit će ekstrapolirana na cijeli prostor hrvatskoga dijela Panonskoga bazenskog sustava;
- (4) Iz novih rezultata dodatno će se reinterpretirati regionalni strukturni i taložni uvjeti koji su vladali u prostoru Bjelovarske subdepresije tijekom geološkoga vremena od badena do holocena.

Rječnička baza geomatematike, kao mlade znanstvene grane, stalno se nadopunjuje i korigira. U hrvatskoj literaturi postoji već nekoliko rječnika i pojmovnika geomatematičkog nazivlja. Prvi iskorak u tome području bio je *Geomatematički rječnik* (Malvić i sur., 2008) s nizom prijevoda i objašnjenja u toj geoznanstvenoj grani. Slijedi *Geomatematički pojmovnik* (Malvić i Vrbanac, 2013) u kojem je detaljno opisano 377 izraza koji predstavljaju natuknice na engleskom i hrvatskom jeziku. Nazivlje iz područja geomatematike uneseno je u Strunu 2013. godine i temelji se na grani preuzetoj iz Geomatematičkoga rječnika objavljenoga 2008. godine. Tijekom siječnja 2014. nadopunjeno je geomatematičko nazivlje u Struni u sklopu istraživanja i popularizacije geomatematike, a kao izvor za popunjavanje nazivlja upotrijebljen je *Hrvatski rječnik odabranih geostatističkih pojmova* (Malvić i Novak Zelenika, 2013). Druga nadopuna geomatematičkoga nazivlja načinjena je u siječnju 2015. upotrebom hrvatsko-hrvatskoga rječnika novih pojmova, koji je priređen kao dio 2. doktorskoga seminara Ivane Mesić Kiš (Mesić Kiš i Malvić, 2015). Prilog 1 sadrži nadopunjeno geomatematičko nazivlje od sveukupno 23 pojma navedenih abecednim redom s pripadajućim definicijama, napomenama, stranim nazivljem, a gdje je moguće i jednadžbama i slikama. Navedena nadopuna geomatematičkog nazivlja priređena je za skup *Matematičke metode i nazivlje u geologiji 2016*,

1. Uvod


održan 29. listopada 2016. u prostorijama Rudarsko-geološko-naftnog fakulteta. Dio je treće nadopune baze geomatematičkog nazivlja pri Hrvatskom terminološkom portalu Instituta za hrvatski jezik i jezikoslovlje (<https://bib.irb.hr/datoteka/843987.Geomat3.pdf>).

2. GEOGRAFSKA OBILJEŽJA ISTRAŽIVANOGA PROSTORA

Prirodno-geografska obilježja terena prikazana su geografskim smještajem i položajem, hidrogeografskim, klimatološkim te geomorfološkim značajkama. Društveno-geografska obilježja odnose se na demogeografske karakteristike istraživana prostora, razvoj prometnica te gradskih i seoskih naselja.

2.1. Geografski smještaj i položaj

Geografski smještaj određuje se položajem unutar geografske mreže. Bjelovarska subdepresija nalazi se u sjevernom umjerenom pojasu između okvirno 45°20' i 46°5' sjeverne geografske širine, te 16°20' i 17°25' istočne geografske dužine. Smjestila se na najistočnijem dijelu Središnje Hrvatske te predstavlja jugozapadni dio Dravske depresije (**slika 2.1.**).



Slika 2.1. Geografski položaj Bjelovarske subdepresije

Granice subdepresije geografski su određene sljedećim gorama: Kalnikom (643 m) na sjeverozapadu, Bilogorom (288 m) na sjeveroistoku, Papukom (953 m), Ravnom gorom (854

2. Geografska obilježja istraživanoga prostora

m) i Psunjem (984 m) na istoku i jugoistoku te Moslavačkom gorom (489 m) na jugu (**Malvić, 2003**).

2.2. Regije

Bjelovarska subdepresija smjestila se u površinom najvećoj i stanovništvom najbrojnijoj prirodnoj regiji Republike Hrvatske, Nizinskoj Hrvatskoj. Pripada fizionomskoj regiji središnje Hrvatske te Zagrebačkoj nodalno-funkcionalnoj makroregiji.


Prema administrativno-teritorijalnoj regionalizaciji Republike Hrvatske prostor subdepresije prekriva cijelu površinu Bjelovarsko-bilogorske županije, a manjim dijelom i južni dio Koprivničko-križevačke županije te istok Zagrebačke županije.

Kao članica Europske unije, Hrvatska je uključena u nomenklaturu prostornih jedinica za statistiku (franc. *Nomenclature des unités territoriales statistiques* - NUTS). Prema takvoj statističkoj regionalizaciji, Bjelovarska subdepresija smještena je u Kontinentalnoj (Panonskoj) statističkoj regiji.

2.3. Važnija naselja i prometnice

Geografski položaj, veća naselja i značajnije prometnice prikazane su na **slici 2.2**. Bjelovarsko-bilogorska županija površine je 2640 km², a prema zadnjem popisu stanovništva iz 2011. godine broji 119 764 stanovnika s gustoćom naseljenosti od 45,37 st/km² što je ispod državnog prosjeka. Ona obuhvaća 5 gradova (Bjelovar, Čazma, Daruvar, Garešnica, Grubišno Polje), 18 općina (Berek, Dežanovac, Đulovac, Hercegovac, Ivanska, Kapela, Končanica, Nova Rača, Rovišće, Severin, Sirač, Šandrovac, Štefanje, Velika Pisanica, Velika Trnovitica, Veliki Grđevac, Veliko Trojstvo i Zrinski Topolovac) te 323 naselja (**slika 2.2**).

2. Geografska obilježja istraživanoga prostora



Slika 2.2. Glavna sjedišta i cestovni pravci Bjelovarsko-bilogorske županije (modificirano prema <http://lpz-bbz.com.hr/images/dokumenti/86/razvojna-strategija.pdf>)

Grad Bjelovar predstavlja županijsko središte i sjedište Bjelovarsko-križevačke biskupije te je s 40 276 stanovnika najmanje regionalno središte zagrebačke makroregije. Nije jako regionalno središte, ne postoji izrazita koncentracija stanovništva i radnih mjesta u jednom (dvojnog) naselju, već je izražena raspršenost u četiri veća (Bjelovar, Koprivnica, Virovitica, Križevci) i nekoliko manjih (Daruvar, Pakrac) (**Borovac, 2002**). U Zagrebačkoj županiji status grada ima Vrbovec, a u Koprivničko-križevačkoj, na samome rubu subdepresije, smjestio se grad Križevci.

Područje Bjelovarske subdepresije svojim položajem između širega Panonskog prostora i Zagreba nudi jednu od mogućnosti njihovog međusobnog povezivanja. Međutim, usprkos povoljnom prostornom položaju može se reći da je ovo područje prometno izolirano, što je vidljivo iz činjenice da ga svi najvažniji prometni pravci zaobilaze, odnosno prolaze rubnim

2. Geografska obilježja istraživanoga prostora

dijelom subdepresije. Podunavsko-sjevernojadranski pravac (Budimpešta-Zagreb-Rijeka) prolazi zapadnije, Koprivnicom i Varaždinom, dok su pravci koji povezuju Srednju i Zapadnu Europu s Bliskim istokom, izgrađeni uz Savu i Dravu. Cestovna mreža Bjelovarsko-bilogorske županije je dovoljno razgranata, ali niske prometne razvijenosti (**slika 2.2.**). Najvažniji cestovni pravci u regiji su Koprivnica-Zagreb i posebno Đurđevac-Bjelovar-Zagreb. Istočnim dijelom Bjelovarske subdepresije prolazi dio magistralne ceste koja povezuje sjevernu granicu Hrvatske na Dravi (Terezino polje) s južnom granicom na Savi (Stara Gradiška). Međutim, mnogo je napravljeno izgradnjom gradske obilaznice pa se iz središnje hrvatske Podravine u Zagreb putuje preko Bjelovara.


Željeznica je do polovice prošloga stoljeća bila najvažniji način prijevoza. Bjelovar je preko Križevaca povezan željezničkom prugom sa Zagrebom, a preko Kloštra s Viroviticom i Osijekom (**Dadić i sur., 2007**). Općenito prometno nepovoljna situacija mogla bi se popraviti izgradnjom kvalitetne željezničke pruge Gradec – Sveti Ivan Žabno čime bi se povezali Zagreb i Osijek te uvelike skratio put između ta dva velika grada.

2.4. Mjesta iz kojih su dobiveni bušotinski podatci

Sjeverozapadnim dijelom Bjelovarske subdepresije položena je trasa dijela Jadranskog naftovoda JANAF-a (Sisak – Virje – Makarska), a izgrađen je i naftovod Graberje – Bjelovar – Budrovac. Naftna polja, od kojih je najveće Šandrovac (3. po veličini naftno polje u Hrvatskoj), koncesijom su ustupljena INI d.d. Zagreb. Nafta se iz bušotina cijevnom mrežom šalje u otpremnu stanicu Šandrovac te zatim otprema dalje naftovodom preko Bjelovara prema Graberju i Sisku. Sustav je zadovoljavajući za potrebe Bjelovarsko-bilogorske županije, a tim istim sustavom se distribuira nafta iz bušotina u druge susjedne županije, Koprivničko-križevačku (<http://lpz-bbz.com.hr/images/dokumenti/86/razvojna-strategija.pdf>).

Bušotinski podatci dobiveni su iz istraživačkih polja ili mjesta s jednom, eventualno dvije, istraživačke bušotine. Polja s kojih su upotrijebljeni bušotinski podatci su sljedeća: Bačkovica, Čepelovac, Gakovo, Galovac-Pavljeni, Grubišno polje, Hampovica, Jagnjedovac, Lepavina, Letičani, Mosti, Šandrovac, Velika Ciglena. Mjesta s regionalnim istraživačkim bušotinama su: Ciglenica, Cremušina, Dežanovec, Farkaševac, Korenovo, Križevci, Narta, Novi Glog, Rovišće, Pavlovac, Sedlarica, Topolovac, Uljanik, Velika Trnovitica i Vis (**Malvić, 2003**). Položaji navedenih polja i smjesta prikazani su na **slici 2.3**.

2. Geografska obilježja istraživanoga prostora



Slika 2.3. Položaji polja i istraživačkih bušotina s kojih su dobiveni podatci (Malvić, 2003)

2.5. Hidrografska mreža

Mreža tekućica na području Bjelovarske subdepresije vrlo je razgranata, a kao najveći tokovi izdvajaju se rijeke Česma i Ilova. Rijeka Česma izvire na južnom dijelu Bilogore, a do svog utoka u Lonju, s obzirom da je pad rijeke malen, često poplavljuje pa je provedeno njezino uređenje i uređenje njezinih pritoka. Rijeka Ilova izvire u jugoistočnom dijelu Bilogore na 200 m nadmorske visine. Uz njezine plavljene močvarne obale izgrađeni su ribnjaci kod Končanice i Garešnice (Kos, 2014).

Donji tokovi Česme i Ilove omeđuju Moslavačku goru s dvije strane budući da zbog skretanja rijeka Česma protječe sjevernim i sjeverozapadnim dijelom, a rijeka Ilova istočnim i jugoistočnim dijelom Bjelovarske subdepresije (Malvić, 2003). Nešto veći tok kroz subdepresiju ima i rijeka Pakra koja izvire na južnim padinama Papuka te uskom dolinom

2. Geografska obilježja istraživanoga prostora

dijeli Papuk i Psunj. Izlaskom iz te doline skreće te zajedno s rijekom Ilovom urezuje dolinu između Moslavačke gore i Papuka te u konačnici utječu u Trebež.

Cijeli prostor Bjelovarske subdepresije smješten na lijevoj strani rijeke Save pripada savskom pojasu otjecanja i crnomorskom slijevu. Veliko bogatstvo voda ovoga prostora rezultat je pogodnog sastava zemljišta te njegovih hidrogeoloških osobina. **Miletić (1968)** s obzirom na hidrogeološke funkcije pojedinih stijena razlikuje *temeljno gorje* te *taložine tercijara i kvartara*. Prema **Ridanoviću (1974)** hidrogeološke jedinice čine *stijene u podlozi tercijarnog sistema* i *tercijarno-kvartarne naslage* (nap. danas je tercijar kao sustav/period u geologiji napušten).

Temeljno gorje ili stijene u podlozi mlađih paleogenskih i neogenskih naslaga (u starijoj literaturi „tercijarnog,, sistema) javljaju se u tzv. otočnim planinama te izgrađuju osnovu Papuka, Psunja i Moslavačke gore. Predstavljaju hidrogeološku sredinu stijena sekundarne (drugotne) šupljikavosti i različitih dubina do podzemne vode. Izvori su malih kapaciteta (rijetko većeg od 1 l/s), silaznog tipa i razbijenog izvorišta. Izvori većih kapaciteta najvećim se dijelom nalaze u karbonatnim stijenama, međutim u tim krajevima nema uvjeta za veću akumulaciju voda (**Miletić, 1968**).

Paleogenske, neogenske i kvartarne naslage hidromorfološki se dijele na rebrasto – brežuljkasta porječja savskih pritoka, potočne doline na padinama podinskih, predkenozojskih magmatsko-metamorfnih stijena (neformalne litostratigrafske jedinice "temeljno gorje") te na kvartarne vodonosne slojeve savske i dravske nizine. Rebrasto-brežuljkaste krajeve pretežno karakteriziraju vodonosne stijene prvotne šupljikavosti uglavnom istaložene u neogenu, a rjeđe u kvartaru. Na području Bjelovarske subdepresije to su porječja Česme i Ilove te manjih tekućica na prigorjima Kalnika, Bilogore i padinama Moslavačke gore (**Ridanović, 1974**). Dubina na kojoj se nalazi podzemna voda mijenja se u granicama od 1 do 30 m. Izdašnost izvora je mala (do 1 l/s) zbog česte izmjene stijena različite propusnosti, ali im je brojnost velika te na taj način opskrbljuju brojne tekućice. Najdublji bunari bušeni su do 180 m, a najveći izmjereni kapacitet bunara iznosi 10 l/s (**Ridanović, 1973**).

Vodonosnici kvartarne starosti smješteni su u nizinskim i ravničarskim predjelima uz veće rijeke (Česma, Ilova, Pakra). Taloženi su kao dio tipičnog kvartarnog sedimentnog slijeda u kojem se okomito i bočno mogu pratiti izmjene pijeska sa šljunkom, glinama i mnogobrojnim proslojcima treseta, dok je čisti šljunak rijedak (**Miletić i Urumović, 1975**). Prema **Miletiću (1968)** od zapada prema istoku se broj vodonosnih slojeva i tlak u njima povećava, dok kapacitet izvora i vodopropusnost naslaga pada.

2.6. Klimatska obilježja

Prema Köppenovoj klasifikaciji područje subdepresije kao i ostatak kontinentalne Hrvatske ima umjereno toplu vlažnu klimu s toplim ljetom – Cfb, koja se još naziva i klimom bukve (**Šegota i Filipčić, 1996**). Taj cijeli prostor predstavlja rub Panonske nizine na kojem klimu određuju zračna strujanja iz Panonske nizine i planinsko-gorskog sustava Alpi i Dinarida koji ograničavaju utjecaj Atlantskog oceana, a osobito Sredozemnoga mora (**Šegota, 1974**).

Na klimu Bjelovarske subdepresije, kao i cijele države, utječe smještaj u umjerenim geografskim širinama. S Atlantika dolazi oslabljen utjecaj glavnih zapadnih vjetrova zbog pružanja Alpi, a znatan utjecaj predstavlja i raspodjela kopna. Velik modifikatorski utjecaj ima reljef, a osim visokoga reljefa valja spomenuti i njegovu suprotnost, odnosno treba uputiti na utjecaj Panonske nizine koja je osobito važna u hladnom dijelu godine kada se u njoj akumulira hladni zrak, a u toplom dijelu godine brže se i jače zagrijava nego okolne gore.

Cijela Panonska nizina i njezin peripanonski rub imaju jednoliku srednju siječanjsku temperaturu unutar izoterma od -2 do 0 °C. Zbog konkavnog oblika reljefa temperatura zimi može biti i niža u odnosu na okolna viša područja pa često dolazi do temperaturne inverzije. Srednja srpanjska temperatura malo varira oko 21 °C, a kao najtoplija područja izdvajaju se niži reljefni oblici riječnih dolina Ilove, Česme i Pakre.

Veći udio padalina je u toplijem dijelu godine, odnosno riječ je o kontinentalnom maksimumu padalina u ljetnom razdoblju (travanj–rujan). Viši dijelovi subdepresije poput područja Kalnika, Bilogore, Moslavačke gore i ruba slavonskih gora imaju nešto više padalina (>900 mm/god) u odnosu na središnje dijelove (<900 mm/god).

3. POVIJEST DOSADAŠNJIH ISTRAŽIVANJA

Geološka istraživanja širega područja Bjelovarske subdepresije započela su još 1852. godine kada Vukotinović daje prvu geološku skicu Moslavačke gore na kojoj su izdvojeni graniti i gnajsevi okruženi mlađim paleogenskim i neogenskim naslagama. **Hauer** je u razdoblju od **1867. do 1871.** načinio prvu preglednu geološku kartu Bilogore kada je izdvojio kongerijske slojeve, belvederske i kvartarne šljunke te les. Prvu preglednu geološku kartu Moslavačke gore daje **Koch (1889)**, koji je kasnije (**1906**) opisao kristalaste škriljavce koji okružuju granitne jezgre te izdvojio les i aluvij. U razdoblju od 1922. do 1923. godine načinjeni su prvi radovi u cilju otkrivanja ležišta ugljikovodika na području Sedlarice i Marinovaca (npr. **Malvić, 2003**). Većina istraživanja na prostoru Bjelovarske subdepresije koja će biti opisana u nastavku imala su glavni zadatak odrediti geološke i naftnogeološke odnose u okolnim prostorima Savske i Dravske depresije. U novije vrijeme, odnosno zadnjih trideset godina, postoji više radova i istraživanja na navedenom prostoru kao posljedica otkrića novih ležišta.

3.1. Razdoblje od drugog svjetskog rata do osamdesetih godina prošlog stoljeća

Austrijska tvrtka Petrolej provela je prvo veće istraživanje pred početak drugog svjetskog rata koje je nastavljeno od strane njemačkih poduzetnika 1940.–1942. Istraživanjem južnog, jugoistočnoga i sjevernoga dijela Kalnika izdvojene su strukture Ludbreg i Subotica te antiklinala Lepavina. Načinjene su dvije istraživačke bušotine kod Ludbrega te po jedna kod Sedlarice i Grubišnog polja od kojih su sve bile negativne (**Ožegović, 1944**). Od svih lokaliteta kasnije će se najperspektivnijim pokazati Grubišno polje. Bušenja su se potom premjestila na drugu stranu Ilovske subdepresije, odnosno u područje Bjelovarske subdepresije.

Godine 1949. otkriveno je ležište nafte u badenskim pješčenjacima i paleozojskom serpentinitu dubokom bušotinom Lepavina-1 (937,4 m), koja je bila aktivna sve do 1987. Od 1956. godine započela je izradba većeg broja regionalnih dubokih istraživačkih bušotina s ciljem određivanja potencijalne naftnoplinoznosti cijele Dravske depresije pri čemu su u bilogorskoj zoni i središnjem dijelu subdepresije otkrivena sljedeća naftna i plinska polja: Cabuna, Ferdinandovac, Jagnjedovac i Šandrovac.

Navedena otkrića potakla su nova bušenja u središnjem i južnom dijelu Bjelovarske subdepresije. Načinjene su sljedeće bušotine: Uljanik-1 na prijelazu prema Savskoj depresiji, Korenovo-1 na sjevernomoslavačkoj antiklinali, Ciglenica-1 i Pavlovac-1 u jugoistočnom

3. Povijest dosadašnjih istraživanja

dijelu subdepresije, Križevci-1 na zapadnom rubu subdepresije, Farkaševac-1 u zapadnom dijelu subdepresije, Gr-2 i Gr-3 kod Grubišnog polja (npr. **Malvić, 2003**). Međutim, otkrića ugljikovodika nije bilo.

Unatoč tome, početak šezdesetih godina obilježen je pronalaskom novih ekonomskih zaliha nafte i plina uz rubnu Bilogorsku zonu. Godine 1961. bušotinom Jagnjedovac-1 otkriveno je bogato nalazište nafte na južnim obroncima Bilogore između dviju drugih naftno-geoloških poznatih struktura – Lepavine i Mosti (npr. **Malvić, 2003**).

Dvije godine kasnije dokazano je manje naftno-plinsko polje kod Hampovice, ali iz drugog pokušaja (prva bušotina bila je negativna). Jugoistočno od strukture Sedlarica iste godine otkriveno je i drugo malo plinsko polje – Gakovo. Najveće otkriće cijele Bjelovarske subdepresije i toga dijela Dravske depresije bilo je također 1963. godine kada je pronađeno naftno-plinsko polje Šandrovac na istoimenoj brahiantiklinali čijom razradbom je utvrđeno čak 18 ležišta u neogenskim pješčenjacima.

Na području Dravske depresije, ukupno je izdvojeno deset naftno-plinonosnih zona (**Pletikapić i sur., 1964**): zapadnobilogorska (34 % potencijalnih zaliha), papučko - krndijska (27 %), moslavačka (22,5 %), istočnobilogorska (6,5 %), podkalnička (4 %), vilanjsko - mečeška (3 %), južnogergeteška (1,5 %), podbilogorska (1 %), središnja potolinska (0,25 %) i legradski prag (0,25 %). Navedene zone izdvojene su temeljem rezultata geoloških kartiranja, a obilježene su geografskom cjelovitošću, približno jednakim debljinama sedimenata, dubinom ležišnih stijena i vrstom zamki. U zapadnobilogorskoj zoni pridodana je veća vjerojatnost novih otkrića budući da su tamo već otkrivena polja. **Pletikapić i sur. (1964)** su raspodijelili potencijalne zalihe ugljikovodika u cijeloj depresiji na način da je 56 % zaliha u ležištima sa stratigrafskim, 31 % u ležištima s rasjednim, 8 % u ležištima s antiklinalama i 5 % u ležištima s kombiniranim zamkama. Pri tome je predviđeno i da se 90 % potencijalnih zaliha nalazi na dubini manjoj od 1750 metara. Od značajnijih radova i istraživanja šezdesetih godina ističe se i fotogeološka obradba vrbovečko-moslavačkog i bilogorskog područja (**Hanich, 1964**) te morfometrijski prikaz strukture Bilogore (**Prelogović i sur., 1969**).

Sedamdesetih godina objavljeno je nekoliko radova vezanih za područje Bjelovarske subdepresije. **Hajnšek (1971)** opisuje tektonske odnose, a **Kranjec i sur. (1971)** litofacijsne odnose neogenskih i kvartarnih naslaga na području Bilogore te utvrđuju granice morfostrukturnih jedinica Bjelovarske subdepresije, Bilogore i dubokog dijela Dravske depresije. **Prelogović (1975)** objavljuje neotektonsku kartu Hrvatske na kojoj je prikazano i područje Bjelovarske subdepresije. Temeljem dobivenih rezultata, započeti su novi, ali malobrojni bušaći radovi.

3.2. Razdoblje od osamdesetih godina prošlog stoljeća do danas

Početak ovog razdoblja objavljuju se radovi koji obrađuju područje Bjelovarske subdepresije samostalno. **Najdenovski i Hajnšek (1980)** opisuju strukture i sedimentacijski razvoj subdepresije te izrađuju strukturne karte, karte izopaha i razvoja struktura za obrađene intervale, na temelju čega su planirani daljnji geofizički radovi. Godine **1982.** isti autori po prvi puta u potpunosti opisuju granicu Savske i Dravske depresije od Kalnika i Medvednice, preko Moslavačke gore do Psunja.

Devedesetih godina otkriveno je jedno manje naftno, dva plinska i jedno geotermalno polje. Tada su bila naznačajnija istraživanja u smislu provjeravanja i potvrđivanja nafto-plinonosti Bjelovarske subdepresije. Provjeren je ležišni i matični potencijal dijelova subdepresije u kojima se dotad nije uopće ili gotovo uopće bušilo. Izradbom bušotine Velike Ciglene-1 1989. godine smještene na strukturnom nosu u blizini najdubljeg dijela jugoistočnog dijela Bjelovarske subdepresije, prikupljeni su geološki podatci o stijenama neogena i podine te je otkriveno geotermijsko ležište i načinjena usmjerena bušotina (VC-1alfa) s ciljem iskorištavanja te energije. Na lokaciji Galovac-Pavljani načinjeno je šest bušotina u razdoblju od 1991. do 1994. godine gdje je u stijenama podine neogena te badenskim brečama i brečokonglomeratima otkriveno ležište nafte. Navedeno otkriće potaknulo je nastavak istraživanja kod Grubišnog polja gdje je 1993. godine izrađena bušotina kojom je otkriveno istoimeno plinsko ležište u badenskim klastitima i paleozojskim škriljancima. Godine 1997. kod sela Bačkovica oko 25 km južno od Bjelovara, načinjena je istraživačka bušotina Bac-1. Osim neznatnih pojava ugljikovodika konkretnijih rezultata nije bilo. Bušotinom Bac-2 dobiveni su slični negativni rezultati, ali je seizmički utvrđen (engl). "*bright spot*", što je bio dovoljan razlog za novu bušotinu Bac-1z kojom je otkriveno malo plinsko polje Bačkovica (**Malvić, 2003**).


4. GEOLOŠKA OBILJEŽJA HRVATSKOGA DIJELA PANONSKOGA BAZENSKOG SUSTAVA I BJELOVARSKO SUBDEPRESIJE

Bjelovarska subdepresija dio je Panonskog bazenskog sustava (skr. PBS) čije je stvaranje započeto u ranom miocenu zbog kontinentalne kolizije i subdukcije Europske ploče pod Afričku (Apulijsku) ploču (npr. **Pavelić, 2001**). Tada je započelo i stvaranje njegove južne granice (*perijadransko-varđarskog lineamenta*) i sjeverne granice (*Vanjski Karpati*). Subdukcija je uzrokovala termalne promjene u gornjem plaštu što je za posljedicu imalo slabljenje i širenje kore te nastanak pozadinskih bazena (**Horváth i Royden, 1981; Horváth, 1993, 1995; Royden, 1988, Kováč i sur., 1998**). Razlikuju se dva razdoblja razvoja bazena (**Pavelić, 2001**):

- a) Sin-riftna faza (otnang–srednji baden) karakterizirana tektonskim stanjivanjem kore i izostatičnom subsidencijom;
- b) Post-riftna faza (srednji baden–pont) obilježena prestankom širenja i spuštanja uzrokovanih hlađenjem litosfere (termijskom subsidencijom).

PBS je okružen Alpama, Karpatima i Dinaridima, a paleogeografski pripada području Središnjeg Paratethysa (**slika 4.1.**). Tijekom miocena su veze između središnjeg Paratethysa, Mediterana i Indo-Pacifičkog oceana nekoliko puta prekinute te ponovno uspostavljene posljedicom čega dolazi do oscilacija morske razine, različitih načina taloženja i paleoekoloških uvjeta. Morska transgresija nije preplavila cijeli bazen, pogotovo tijekom ranog miocena. Zbog toga je dno prekriveno naslagama različite starosti od ranog do kasnog miocena, nastalih u morskim, bočatim i slatkovodnim okolišima; dok su pojedini dijelovi bazena karakterizirani povremenim emerzijama (**Steininger i Rögl, 1979; Steininger i sur., 1978; Rögl, 1996, 1998**). Hrvatski dio Panonskoga bazenskog sustava (skr. HPBS) dio je PBS-a gdje se odvijala neogensko-kvartarna sedimentacija i tektonika u rubnim depresijama smještenim unutar većeg bazenskog sustava. Klastična sedimentacija nastavila se krajem miocena kroz prijelaz iz morskog u slatkovodni okoliš uzrokovan smanjenjem taložnog prostora. Danas HPBS zauzima cijeli jugozapadni dio PBS-a (npr. **Prelogović i sur., 1998; Saftić i sur., 2003; Malvić, 2012**).

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.1. Glavne geotektonske jedinice unutar Panonskoga bazenskog sustava (Malvić, 2003; Royden i Dövényi, 1988; Vrbanac, 1996)

4.1. Tektonska aktivnost


Prva transtenzija počela je lokalno prije 18,3–17,2 milijuna godina u otnangu. Osažena je u karpatu (17,2–16,4 mil. god.; **Rögl 1996, 1998**) kada su se taložili uglavnom jezersko-riječni sedimenti (**Steininger i sur., 1978**) na području između Apusena, Mezijske ploče, Karpata i Podolojskog masiva te na rubu Češkog masiva i Alpa. Transtenzija je nastavljena u badenu (16,4–13,0 mil. god.), kad je bila popraćena općom morskom transgresijom i, nakon toga, u sarmatu (13,0–11,5 mil. god.; **Rögl 1996, 1998**). Do srednjeg badena more je prekrilo prostore od Austrije (Bečki bazen) do Rumunjske (Transilvanijski bazen) i okolicu Karpata zbog opće transgresije pa su Karpati i Apuseni bili veliki otoci (**Steininger i sur., 1978**). U sjeverozapadnom dijelu oko Medvednice te u dijelovima Savske depresije i Slavonije postojala je morska sedimentacija (**Vrbanac, 1996**).

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Prema **Steiningeru i sur. (1978)** u gornjem dijelu srednjeg badena veza s Mediteranom biva po drugi puta prekinuta, ovoga puta trajno, a tijekom sarmata prekida se i veza s Indopacifikom te stoga dolazi do promjene facijesa. Talože se evaporiti na prostoru od Slovačke do Transilvanije, a i u području Karpata.

Prema **Roydenu (1988)** u donjem panonu (11,5–9,3 mil. god.) nastupa kraj transtenzijske faze u većem dijelu PBS-a. **Pavelić (2001)** smatra da je tijekom gornjega badena za područje sjeverne Hrvatske znakovit prijelaz iz ekstenzijske u postekstenzijsku fazu, iako **Vrbanac (1996)** smatra kako je u to vrijeme ovaj prostor i dalje u ekstenziji i prekriven morem.

Slijedi razdoblje transpresije kada tektonska aktivnosti slabi, a mjestimice dolazi do intenzivnog vulkanizma alkalnog tipa. Glavni izvor materijala na prostoru Hrvatske postaju Istočne Alpe zbog pomicanja taložnog prostora i izvorišta materijala na rubove bazenskog sustava (**Malvić, 2012; Velić i sur., 2015**), uz rijetka i prostorno mala lokalna izvorišta materijala (**Novak Zelenika i sur., 2013**). Prema **Röglu (1996, 1998)** u gornjem panonu (9,3–7,1 mil. god.) i pontu (7,1–5,6 mil. god.) taloženje se uglavnom odvijalo u bočatom i slatkovodnom jezerskom prostoru. Turbiditne struje predstavljale su glavni mehanizam prijenosa u smjeru jugoistoka (**slika 4.2.**) na udaljenosti od nekoliko stotina kilometara (npr. **Vrbanac i sur., 2010; Malvić, 2016**).



Slika 4.2. Skica paleosmjera turbiditnih struja tijekom gornjeg pontu u HPBS-u (modificirano prema Vrbanac i sur., 2010)

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Riječna i jezerska sedimentacija obilježila je najmlađe razdoblje pliocena (5,6–1,8 mil. god.) i kvartara (1,8–0,0 mil. god.). **Tablica 4.1.** prikazuje glavna razdoblja oblikovanja HPBS-a.

Tablica 4.1. Vremenska skala glavnih tektonskih i taložnih razdoblja u neogenu i kvartaru unutar HPBS-a (Malvić i 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		karpat	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			opičavanje i smanjenje saliniteta		udaljeni klastični izvor materijala i mehanizam donosa turbiditnim strujama				završno strukturno oblikovanje, migracija ugljikovodika, kontinentalni okoliši							

4.2. Razvoj i današnji izgled Bjelovarske subdepresije

Otvaranje prostora Bjelovarske subdepresije posljedica je aktivnosti glavnih depresijskih transkurentnih rasjednih sustava, zajedno s ostalim rasjednim sustavima koji su poprečni ili dijagonalni na pravac pružanja središnjega Dravskog rasjeda. Danas je subdepresija odvojena od Savske depresije Moslavačkom gorom, te Bilogorom od Dravske, a oblik joj je približno romboedarski (**slika 4.3.**).

Debljine neogensko-kvartarnih naslaga Bjelovarske subdepresije rijetko prelaze 3000 m, za razliku od 7000 m u glavnoj Dravskoj depresijskoj zoni. To je posljedica toga što Bjelovarska subdepresija nije bila na putu glavnog prijenosa materijala, posebno u postekstenzijskom razdoblju zbog čega je donos sedimenata bio značajno manji. Starije naslage čine sintranstenzijske taložine poput breča, konglomerata i krupnozrnatih pješčenjaka. Vapnenci i lapori najvećim dijelom obilježavaju prijelazno razdoblje između 1. transtenzije i 1. transpresije. Monotona izmjena pješčenjaka i lapora u različitim omjerima rezultat je 2. transtenzije. Tim vremenskim slijedom je ujedno i taložna sredina prešla iz morske u jezersku (Malvić, 2003), te kasnije u vrijeme 2. transtenzije i kopneno-riječnu.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



*Slika 4.3. Depresije i subdepresije unutar hrvatskoga dijela Panonskoga bazenskog sustava (modificirano prema **Balić i sur., 2008**, http://www.d-maps.com/carte.php?num_car=14899&lang=en)*

Markeri ili ključni slojevi bili su najvažniji odrazi taložnoga paleookoliša uporabljeni u tumačenju geološke evolucije Bjelovarske subdepresije. Marker je sloj koji ima obilježja granice između dviju taložnih ili magmatsko-metamorfničkih jedinica u krovini i podini. Nasuprot tomu, reper je erozijska granica ili ploha (a ne sloj) koji dijeli litološki dvije prepoznatljive skupine stijena, ponovno u krovini i podini. To su često diskordancije. U HPBS-u najmarkatniji reper predstavlja diskordancija između neogensko-kvartarnih sedimenata i starijih stijena u njihovoj podini (npr. **Velić i sur., 2015**). Ako se u podini nalaze magmatske i metamorfne stijene, tada je taj reper označen sa „Tg“ (skr. temeljno gorje). Ako su u podini sedimenti reper je označen sa „Pt“ (skr. podina „tercijara“).

Prefiks „elektrokarotažni“ (EK) znači da su prepoznatljiva svojstva markera ili repera opažena na karotaži električne otpornosti. U Dravskoj depresiji su izdvojeni sljedeći EK markeri (**Velić, 2007**):

- Rs7 koji dijeli članove Mosti i Križevci unutar formacije Moslavačka gora, tj. naslage sarmata i panona,
- Rs5 dijeli formacije Moslavačka gora i Ivanić Grad (donji i gornji panon),
- Z' dijeli formacije Ivanić Grad i Kloštar Ivanić (gornji panon i donji pont),

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije


- delta (Δ) približno dijeli formacije Kloštar Ivanić i Bilogora (donji i gornji pont),
- D' dijeli formacije Bilogora i Lonja (iznad su pliocen, pleistocen i holocen).

Posebno je izdvojena i jedna EK granica, kojoj su u podini paleozojsko-mezozojske magmatske i metamorfne (Tg) ili taložne (Pt) stijene čija je paleoreljefna karta poslužila kao izvor podataka u ovome radu (**slika 4.4.**). Ujedno su korištene i strukturne karte po plohama EK markera Rs7 (**slika 4.5.**), Rs5 (**slika 4.6.**), Z' (**slika 4.7.**), delta – Δ (**slika 4.8.**) i D' (**slika 4.9.**).

Paleoreljefna karta EK granice Pt/Tg (**slika 4.4.**, završna starost EK granice je približno 16,4 mil. god.) prikazuje paleozojske i mezozojske oblike s maksimalnim brojem struktura koje prekrivaju vršne dijelove stijena podine. Najveća razvedenost paleoreljefa bila je upravo na početku 1. transtenzije, na ulasku u baden. Razlog tomu je što je predkenozojski reljef bio jako dugo izložen trošenju i tektonici, nekoliko desetaka milijuna godina. Kasnije je sve bilo kraće i uz niz transgresivnih granica uzastopnih jedinica koje su postupno popunjavale velike (brahi)sinklinale. Zato je najveći broj struktura kartiran upravo na najstarijoj granici paleoreljefa.

Transverzalni rasjedni sustav je otprilike S/SI-J/JZ, a dijagonalni rasjedni sustav SZ-JI pravca pružanja. Normalni rasjedi su dominantni u transverzalnim sustavima. Mogu se uočiti: Zapadnobjelovarska sinklinala (>3100 m), Istočnobjelovarska sinklinala (>3700 m), Pavljani antiklinala (1200 m), Grubišno polje antiklinala (<900 m), Dežanovec antiklinala (< 1000 m) i strukturni nos Šandrovca (3000 m) (**Malvić, 2011**).


4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.4. Paleoreljefna karta Bjelovarske subdepresije EK granice „Pt/Tg“ (Malvić, 2011)

Strukturalna karta po EK markeru Rs7 (slika 4.5., taloženje u krovini EK markera odvijalo se prije 11,5 mil. god.) predstavlja granicu sarmata i panona, ali se značajno ne razlikuje u odnosu na prethodnu kartu. Glavni rasjedni sustavi i strukture su i dalje vidljivi, ali su antiklinale većinom na zapadu (osim Grubišnoga polja).


4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.5. Strukturna karta Bjelovarske subdepresije po plohi EK markera Rs7 (Malvić, 2011)

Strukturalna karta po EK markeru Rs5 (slika 4.6., taloženje u krovini EK markera odvijalo se prije 9,3 mil. god.) predstavlja granicu između donjega i gornjega panona. Razlikuje se u odnosu na prethodne dvije karte zbog diskordancije na istoku kod Papuka i Psunja i na jugozapadu kod Čazme (Malvić, 2011).

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije




Slika 4.6. Strukturna karta Bjelovarske subdepresije po plohi EK markera Rs5 (Malvić, 2011)

Strukturna karta po EK markeru Z' (slika 4.7., taloženje u krovini EK markera odvijalo se prije 7,1 mil. god.) predstavlja granicu između gornjega panona i donjega panona koji su klasičan primjer jezerskog taloženja u HPBS-u. Tektonski definira razdoblje 2. transtenzije kada su ogromne količine klastita transportirane iz Istočnih Alpi u HPBS (npr. Malvić, 2003, 2011; 2012; Malvić i Velić, 2011) što je rezultiralo taloženjem brojnih i debljih pješčenjačkih jedinica. Neke od njih su kasnije izdignute u antiklinale zasićene ugljikovodicima. U panonu je raspadom Paratethys-a na području Panonskog bazena nastalo bočato jezero Panon zapunjavano turbiditima koji su prekidali pelitnu bazensku sedimentaciju. Navedeni procesi nastavili su se i u donjem pontu (Malvić i Cvetković, 2013). Panonsko jezero se kasnije raspalo

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije


na manja jezera koja su se razvila u depresijama Panonskog bazena poput Dravske depresije na čijem se zapadnom dijelu smjestila Bjelovarska subdepresija.



Slika 4.7. Strukturna karta Bjelovarske subdepresije po plohi EK markera Z' (Malvić, 2011)

Strukturalna karta po EK markeru Δ (slika 4.8.; taloženje u krovini EK markera odvijalo se prije 6,3 mil. god.) čini granicu donji/gornji pont. Riječ je o plitkom okolišu gotovo svugdje plićem od 1000 m dubine. Uz granice subdepresije dubine iznose tek 100 – 200 m, s izuzetkom na području prema Savskoj depresiji u jugozapadnom dijelu gdje prelazi 2000 m. Tektonski definira prijelaz iz 2. transtenzijske u 2. transpresijsku fazu (tablica 4.1.).


4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.8. Strukturna karta Bjelovarske subdepresije po plohi EK markera Δ (Malvić, 2011)

Strukturalna karta po EK markeru D' (slika 4.9.; taloženje u krovini EK markera odvijalo se prije 5,6 mil. god.) predstavlja granicu pona i pliocena. Općenito, dubine su manje u odnosu na prethodnu kartu, a smanjuju se i prema rubnim dijelovima subdepresije. Bjelovarska subdepresija je tada bila takva sredina u kojoj su se mjestimice još nalazile dubljevodna područja, no ukupno se radi o plićevodnom sustavu (jezeru) koji je imao tendenciju okopnjavanja.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.9. Strukturna karta Bjelovarske subdepresije po plohi EK markera D' (Malvić, 2011)

4.3. Pregled geološke evolucije kartiranoga prostora

Na području Bjelovarske subdepresije stijene su podijeljene u dvije različite skupine. Prva skupina obuhvaća mlađe taložine neogensko-kvartarne starosti dok druga skupina obuhvaća starije stijene paleozoika i mezozoika. Te dvije skupine se osim po starosti razlikuju i po litološkom sastavu. Mlađe neogensko-kvartarne naslage su klastične dok stariju skupinu stijena u njihovoj podini izgrađuju mezozojski karbonati ili paleozojski magmatiti i metamorfiti. Kronostratigrafska podjela te dvije skupine stijena unutar Dravske depresije prikazana je na slici 4.10. (Malvić, 2003), uz navođenje litostratigrafije važeće za neogensko-kvartarni slijed.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

STAROST	LITOSTRATIGRAFSKE JEDINICE DRAVSKE POTONINE		Regionalni EK markeri	
K E N O Z O I K	K V A R T A R	PLIOCEN DACEI FORMACIJA	D'	
		0. PONT FORMACIJA		BILOGORA
	N E O G E N	DOLNI PONT FORMACIJA	KLOŠTAR-IVANIČ cabunski član cabunski lapor	Δ D ₁
			brezinski lapor pepelanski pješčenjaci graberski čl. graberski lap.	D ₂
		MIOCEN	lepsičko-graberski lapor poljanski pješčenjaci lepsički lapor	D ₃ R _{3a} D ₄
			zagrebački član okolski pješčenjaci	Z' Rs4
			lipovački lapor	R ₅ D ₅
	IVANIČ-GRAD koprivnički pješčenjaci križevački član	R ₅ Rs5		
	OCENIT PANON FORMACIJA	MOSLAVAČKA GORA član Mosti čeralijski član	R ₅ Rs7 Pt/Tg	
	MEZOZOIK I PALEOZOIK	STIJENE U PODLOZI TERCIJARNOG SISTEMA		

Slika 4.10. Litostratigrafske jedinice Dravske depresije (Šimon, 1968; preneseno iz Malvić, 2008)

Stijene u podini neogenskog sustava (Mz i Pz) predstavljaju tzv. „temeljno gorje“, tj. „podinu tercijsara“. U njima su otkrivena ležišta ugljikovodika. Paleozojska podloga izgrađena je od granitnih i gabroidnih intruzija te dijelova, tim intruzijama razbijenih i izmijenjenih metamorfni stijena. Metamorfne stijene su predstavljene različitim škriljavicima i gnajsevima. Regionalno su metamorfozirane do nivoa amfibolitskog facijesa. Taložine mezozojske starosti nazivaju se u stručnoj praksi „podlogom tercijsara“, a taložno predstavljaju podinu neogena u HPBS-u. Ovu skupinu stijena čine različiti vapnenci i dolomiti koji su često kataklazirani i trošeni do stupnja breče i konglomerata. Na temelju fosilnih nalaza te bušotinskih podataka, starost tih stijena određena je srednjotrijaskom. Litološki se radi o istovrsnom dolomitu, dolomitičnom vapnencu te dolomitno-vapnenačkoj breči (Malvić, 2003).

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Krupnoklastične taložine donjega i srednjega miocena nalježu na mezozojske ili paleozojske sedimente, magmatske i metamorfne stijene u podlozi neogenskog sustava. Sarmatske naslage uglavnom su predstavljene tankim i listićavim kalcitnim laporima, a taložine donjeg sarmata u starijoj su se literaturi nazivale „Tripoli naslagama“. Donjopanonske taložine čine tvrdi i čvrsti „bijeli“ lapori, a gornjopanonske predstavljaju žućkasti lapori u izmjeni s pješčenjacima (koji mogu biti ležišta za ugljikovodike). Donjopontski sedimenti većinom su lapori, dok pijesci, laporoviti pijesci, pjeskoviti i glinoviti lapori izgrađuju gornjopontske sedimente. Kvartarne sedimente čine taložine riječnih nanosa i terasa, les te obrončani nanosi gline, pijeska i šljunka (Velić i sur., 2015). Detaljnu korelaciju litostratigrafskih jedinica u hrvatskom i mađarskom dijelu Dravske depresije načinili su Malvić i Cvetković (2013). Upravo preko takve korelacije mogu se lako pratiti glavni taložni događaji te promjene izvorišta materijala.

4.3.1. Taložne stijene donjega i srednjega miocena – formacija Moslavačka gora

Sedimenti moguće donjega i regionalno istaloženog srednjega miocena taloženi su diskordantno na paleozojske te mezozojske stijene i sedimente u podini te označavaju početak sveobuhvatne transgresije na cijelom području subdepresije. „Moguć“ je zato što za njega ne postoje gotovo nikakvi fizički dokazi poput jezgri i fosilnog sadržaja. Ti okoliši su morali postojati, no bili su toliko mali u usporedbi s onime Paratethysa da ga je nemoguće sa sigurnošću dokazati, posebno bušenjem, jer prekriva možda tek nekoliko postotaka površine HPBS-a iznad granice Pt/Tg.

Litostratigrafski odgovaraju formaciji Moslavačka gora podijeljenu na stariji član Mosti približne starosti od donjeg miocena do uključivši sarmat te mlađi član Križevci približno donjopanonske starosti (Šimon, 1968). EK granica označena "Tg" ili "Pt" čini granicu prema paleozojskim i mezozojskim stijenama u podini, a EK marker Rs5 prema formaciji Ivanić-Grad u krovini. Zbog velikog značaja tih sedimenata u naftnogeološkom smislu su prilikom opisa taložina formacije Moslavačka gora detaljnije opisani i taložni okoliši te globalna tektonska povijest širega prostora.

Na temelju analogije s istovremenim događajima u većem dijelu Panonskoga bazenskog sustava, pretpostavlja se da je početak donjomiocenske transtenzijske tektonike bio u otnangu i karpatu (Royden, 1988). Prema Vrbancu (1996) u vrijeme početka neogenske transtenzije sedimentacijski prostor s marinskim naslagama zahvaća dijelove Medvednice, Savske depresije, Slavonije, a možda i rubne dijelove Pšunja.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

U badenu su zabilježeni jači transtenzijski pokreti na području cijele subdepresije. Razvija se nekoliko romboidnih (engl. *pull-apart*) bazena u kojima se talože sedimenti značajne debljine. U to vrijeme marinska sedimentacija se odvija u cijeloj subdepresiji, kao i u najvećem dijelu sjeverne Hrvatske. Veće gore poput Moslavačke, Kalnika, Papuka i Psunja su ostale dijelom iznad morske razine i postale otoci. Trošenjem kopnenih i plitkomorskih dijelova paleozojskih stijena u priobalju je taložen siliciklastični materijal, najčešće mehanizmom aluvijalnih lepeznih delti. Karbonatni detritus nastao razaranjem prigrebenskih i grebenskih zajednica crvenih algi (familija *Corallinaceae*) te briozoa strujama i valovima, bio je drugi važan izvor materijala. Kao posljedica takve dinamike došlo je do taloženja krupnoklastičnih sedimenata breča, konglomerata i krupnozrnatoga pješčenjaka. Krajem badena taložen je sitnozrnati pješčenjak, a zatim lapor i vapnenac. Transtenzijski pokreti su počeli slabiti, a taložna sredina je postala mirnija s obzirom na energiju vode pa je opala i veličina zrna.

Breča i konglomerat su taloženi u proksimalnom dijelu aluvijalnih lepezi, a krupnozrnati do srednjozrnati pješčenjak u središnjem dijelu lepeze. Srednjo i sitnozrnati pješčenjak taložen je u distalnom dijelu aluvijalne lepezne delte (Malvić, 2006).

Krajem badena počinje oplićavanje i smirivanje taložne sredine na što ukazuju pelitne, laporovite i laporovito-vapnenačke sekvencije. U takvim taložnim uvjetima nastaju sarmatske naslage. Površina mora i slanost postupno su se smanjili, a nastavlja se taloženje psamitsko-pelitnih klastičnih naslaga u prostoru litorala.


U donjem panonu taložna sredina je i dalje plitka te je nastavljeno njezino zapunjavanje. U zaštićenim plićacima, bočatim sredinama se u međusobnoj izmjeni talože tanji slojevi glinovitog vapnenca, kalcitnog, siltitnog ili pjeskovitog lapora, čistog lapora te ponekad pješčenjaka. Mjestimice dijelovi paleoreljeva izviruju iznad površine vode i predstavljaju izvor siliciklastičnog materijala, no puno siromašniji nego u badenu (Malvić, 2003).

Karte debljina formacije Moslavačka gora načinjene ručno prikazane su **slikama 4.11. i 4.12.** Karta debljine badenskih i sarmatskih sedimenata (**slika 4.11.**) ne prikazuje diskordanciju. Aktivno je nekoliko normalnih rasjeda i inverzna cvjetna struktura Berek. Maksimalna debljina je na području Zapadnobjelovarske sinklinale (>1200 m).

Član Mosti obuhvaća razdoblje od donjeg miocena do sarmata. Tijekom badena prva transtenzijska faza u HPBS-u ima maksimum kada je strike-slip tektonika glavni mehanizam strukturnoga razvoja. Tada se na području najvećeg dijela sjeverne Hrvatske odvijala marinska sedimentacija pa su veće gore ostale dijelom iznad morske razine kao otoci (npr. **Vrbanac, 2002**). Tome idu u prilog najveće debljine člana Mosti uz Papuk, Psunj i Kalnik.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Krajem badena počelo je oplićavanje te je početkom sarmata došlo do smanjenja površine mora pa su debljine sarmatskih naslaga male. Kasni baden predstavlja prijelaz između transtenzijske i posttranstenzijske faze u sjevernoj Hrvatskoj (Pavelić, 2002). Značajne paleoekološke promjene su se dogodile nakon pucanja veze između Paratethys-a i Tethys-a koji su uzrokovali velike facijesne promjene. Sarmatsko more se smanjilo. Kopneni utjecaj raste, a u blizini ušća velikih rijeka dolazi i do smanjenja slanosti (npr. Lučić i sur., 2001).




Slika 4.11. Karta debljina formacije Moslavačka gora, član Mosti, dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda (Malvić, 2011)

Karta debljine sedimenata donjega panona, tj. člana Križevci, (slika 4.12.) pokazuje značajne promjene duž normalnih i reverznih rasjednih zona. Lokalno je debljina veća od 500 m samo u

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

središnjem dijelu obrađivanoga terena, a najniže vrijednosti prate diskordanciju uz Papuk, Psunj, Moslavačku goru i granicu sa Savskom depresijom.

Član Križevci je donjopanonske starosti. To je razdoblje kada se u PBS-u odvijala druga transtenzijska faza lokalne strike-slip tektonike (Royden, 1988). U velikim jezerskim ili bočatim okolišima dubine do nekoliko stotina metara (Vrbanac i sur., 2010), slanost se smanjivala zbog svježeg dotoka vode i prekida veze s otvorenim morskim okolišima. U donjem panonu taložna sredina Bjelovarske subdepresije bila je plitka te se većinom zapunjavala laporom.



Slika 4.12. Karta debljina formacije Moslavačka gora, član Križevci, dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda (Malvić, 2011)

4.3.2. Taložne stijene gornjega panona – formacija Ivanić-Grad


Sedimenti formacije Ivanić-grad prema vremenu taloženja odgovaraju gornjem panonu. U starijim bušotinama često su označeni kao Banatica-naslage prema fosilnom školjkašu *Congeria banatica*. EK marker Rs5 predstavlja granicu u podini prema formaciji Moslavačka gora, a EK marker Z' prema formaciji Kloštar-Ivanić u krovini (Malvić, 2003).

Formacija započinje lipovačkim laporom, a nastavlja se zagrebačkim članom ili njegovim bočnim ekvivalentom okolskim pješčenjacima (Šimon, 1968). Prema Vrbancu (1996) u vrijeme gornjeg panona područja Panonskog bazenskog sustava u kojima se odvijalo taloženje prekrivala je slatka voda različite dubine.

Na mnogim mjestima je bilo teško odvojiti pojedine članove te odrediti granicu posebno prema formaciji Moslavačka gora zbog slabo očuvanih, oskudnih i neprovodnih fosilnih ostataka. Gornjopanonska starost određena je uglavnom na temelju rodova ostrakoda, silikoplacentina i foraminifera.

Karta debljina Ivanić-Grad formacije načinjena ručno prikazana je slikom 4.13. Uz bušotine su naznačeni i seizmički profili, a zabilježena je i diskordancija na istoku. Glavni normalni rasjedi uzrokovali su značajne promjene debljina s maksimumom (>800 m) unutar zapadno-bjelovarske sinklinale. U gornjem panonu središnji dijelovi subdepresije ponovno su izronili kao kopno pa npr. na strukturi Pavljani nedostaje lipovački lapor. U drugim dijelovima subdepresije nastavljena je neprekinuta sedimentacija kroz cijeli gornji panon (Malvić, 2003).

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.13. Karta debljina formacije Ivanić-Grad dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda (Malvić, 2011)


4.3.3. Taložne stijene donjega pontona – formacija Kloštar-Ivanić

Sedimenti formacije Kloštar-Ivanić često se nazivaju Abichi-naslagama prema fosilnom školjkašu *Paradacna abichi*. Vrijeme taloženja približno odgovara donjem pontu. Najstarije naslage pripadaju lepsićkom laporu, a zatim slijede poljanski pješčenjaci, graberski lapor, pepelanski pješčenjaci i cabunski lapor. Kod izrazite dominacije nepropusnih sedimenata svi ti članovi prelaze u jedan, nazvan lapor Kloštar-Ivanić (Šimon, 1968). EK marker Z' predstavlja granicu prema formaciji Ivanić-Grad u podini, a EK marker Δ granicu s formacijom Bilogora u krovini. Litotologiju karakterizira izmjena različitih tipova pješčenjaka i lapora. Laporoviti članovi pretežito su litološki homogeni, a izuzetak je povećanje pješčane komponente pri vrhu

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

lepsičkog lapora. U najmlađem članu, cabunskom laporu, prevladava glinovita komponenta. Pješčenjački članovi nisu homogeni i često sadrže proslojke lapora. Prema jugu i jugoistoku subdepresije pješčenjak gotovo potpuno nestaje (Malvić, 2003).

U najdubljim dijelovima prostora nalazi se velik udio propusnih sedimenata gdje su ih donijele turbiditne struje (Malvić 2003, 2012). Mali dio moguće potječe s uzdignutih, rubnih područja (Novak Zelenika i sur., 2013). Vrlo dobar prikaz neogensko-kvartarnoga okoliša u rubnim strukturama Savske depresije (slika 4.14.) dala je Novak Zelenika (2012).




Slika 4.14. Konceptualni taložni model gornjopanonskih (A) i donjopontskih (B) naslaga polja Kloštar (Novak Zelenika, 2012)

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Glavnina pješčanog detritusa prema **Roydenu (1988)** potječe iz Istočnih Alpi. U razdoblju između aktivnosti dviju turbiditnih struja većinom je taložen lapor. U vrijeme gornjega panona i donjega pontu prevladavala je transtenzijska tektonika na području HPBS-a (**Malvić i Velić, 2011**). Cijeli prostor je za vrijeme donjeg pontu bio prekriven vodom budući da su svugdje zabilježeni svi članovi. **Vrbanac (1996)** navodi da se u donjem pontu stvara veza između Panonskog i Dacijskog bazena, pa voda postaje „kaspibrakična“ (slanosti 5–10 ‰), a fauna slična. Fosili ukazuju na nastavak oslađivanja prema mlađim naslagama, što upućuje da taložna sredina prelazi iz bočate u slatkovodnu.

Karta debljina donjeg pontu ne pokazuje na diskordanciju na istoku i jugu (**slika 4.15.**), ali je u biti prisutna s obzirom da na tom prostoru nije istaložen EK marker Z' pa se u tom dijelu radi o karti debljina intervala Δ -Rs5, odnosno Δ -Tg/Pt. Ucertani su glavni normalni i reverzni rasjed. Najveće debljine (više od 2 000 m) nalaze se na sjeveroistoku, a najmanje (manje od 100 m) na sjeverozapadu i jugu. Turbiditne struje bile su izuzetno jake u gornjem panonu i donjem pontu. Čine glavni taložni mehanizam u depresijama sjeverne Hrvatske u kasnom miocenu (**Vrbanac, 2002**) te predstavljaju izvor srednjozrnatoga to sitnozrnatoga pješčenjaka, odnosno glavnih rezervoarskih litofacijesa u HPBS-u. Navedeni mehanizam taloženja bio je aktivan periodički, isprekidan tipičnim hemipelagičkim taloženjem u jezerskim okolišima HPBS-a što je rezultiralo ujednačenim izmjenama pješčenjaka i lapora.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije



Slika 4.15. Karta debljina formacije Kloštar-Ivanić dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda (Malvić, 2011)

4.3.4. Taložne stijene gornjega pont – formacija Bilogora


Starost naslaga formacije Bilogora je približno gornji pont, a sedimenti se još nazivaju i Rhomboidea-naslagama prema fosilnom školjkašu *Congerina rhomboidea*. Formacija je odvojena EK markerom Δ od sedimenata formacije Kloštar-Ivanić u podini, a EK markerom D' od formacije Lonja u krovini (Malvić, 2003).

Taloženje se nastavilo sličnim mehanizmima u slatkovodnom, jezerskom i deltnom okolišu, kao i u donjem pontu (Vrbanac, 1996; Rögl 1996, 1998). U prostoru Bilogore su debljine veće nego kod prethodne formacije što implicira da izdizanje tog masiva tada još nije započelo.

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Starije taložine su u najvećem dijelu subdepresije predstavljene glinovitim laporom, a ponegdje i slabovezanim pješčenjakom.

U najdubljem dijelu subdepresije kod Velike Ciglene i Patkovca zabilježen je najveći stupanj litifikacije. Mlađe taložine formacije predstavljene su laporovitom glinom, glinom, pješčenjakom i pijeskom uz dominaciju nepropusnih sedimenata. U središnjem dijelu cijela formacija je razvijena u nepropusnom facijesu glinovitog lapora, laporovite gline i gline. (Malvić, 2003). U vrijeme gornjega ponta započinje transpresija koja traje i danas (slika 4.16.).




Slika 4.16. Konceptualni taložni model gornjopontskih (C), pliocenskih i kvartarnih naslaga (D) polja Kloštar (Novak Zelenika, 2012)

4. Geološka obilježja HPBS-a i Bjelovarske subdepresije

Karta debljina formacije Bilogora prikazana je na **slici 4.17**. Na jugu se može uočiti diskordantna granica. Najveće debljine zabilježene su na jugoistoku subdepresije (izopaha od 1500 m), a najmanje na zapadu i sjeverozapadu gdje ne iznose niti 100 m.

Taloženje se nastavilo sličnim mehanizmima u slatkovodnom, jezerskom i deltnom okolišu, kao i u donjem pontu (**Vrbanac, 1996; Rögl 1996, 1998**). Kasni pont, pliocen i kvartar predstavljaju razdoblje 2. transpresijske faze karakterizirano jezerskim (većinom močvarnim), riječnim i kontinentalnim sedimentima (les). Takvo taloženje predstavlja razdoblje sveopće regresije i smanjenja taložnog područja u konačnoj kontinentalnoj fazi (**Malvić i Velić, 2011**).



Slika 4.17. Karta debljine formacije Bilogora dobivena iz bušotinskih i seizmičkih podataka ručnom interpolacijom i ucrtavanjem rasjeda (**Malvić, 2011**)

4.3.5. Taložne stijene dacija, romanija i kvartara – formacija Lonja

Formacija Lonja odvojena je od formacije Bilogora EK markerom D', a gornju granicu čini današnja površina terena pa tako ovu formaciju čine najmlađe naslage starosti dacij, romanij te kvartar. Prostor cijelog PBS-a je u razdoblju pliocena već podijeljen na niz slatkovodnih jezera koja se zapunjavaju pa se u pleistocenu taloženje nastavlja samo u fluvijalnim sredinama (**Vrbanac, 1996; Rögl 1996, 1998**). Taloži se pijesak i glina, a unutar dubljih jezera i silit, lapor i karbonat. Općenito se radi o jezerskom okolišu s taloženjem u deltama Gilbertovog tipa. Laporovita glina prisutna je u najdubljim dijelovima kod Velike Ciglene i Patkovca, a kod Ciglenice je riječ o pjeskovitom laporu.

Ostatak subdepresije zapunjen je glinom, mjestimično pjeskovitom ili s proslojcima pijeska. Jedino u središnjem dijelu istaloženi su u izmjeni šljunak, pijesak i glina s proslojcima lignita. Stupanj konsolidacije raste s dubinom, odnosno u mlađim dijelovima to su nekonsolidirani sedimenti, a uz površinu su istaloženi holocenski prapor, ilovača, humus, šljunak, pijesak, a dominira glina. Geološko praćenje bušotina najčešće je započinjalo dublje od markera D' pa je starost formacije na istraživanom području određena većinom superpozicijski. Nisu vađene jezgre niti rađena paleontološka istraživanja zbog nezanimljivosti u pogledu otkrića ugljikovodika (**Malvić, 2003**). Debljina formacije Lonja kreće se od 10-tak metara do preko 700 m.

5. ISTRAŽIVAČKA METODOLOGIJA

Kada se piše o začetcima geostatistike, jedan od pionira svakako je prof. dr. sc. Daniel Krige koji je u svom radu „*A statistical approach to some basic mine valuation problems on the Witwatersrand*“ (Krige, 1951) prvi upotrijebio krigiranje. Međutim, razvoj te nove znanstvene grane više je vezan za radove prof. dr. sc. **Georgesa Matherona** i njegovih kolega sa škole Fontainebleau u Francuskoj 60-ih godina prošloga stoljeća. Taj pojam koristili su za opisivanje metode razvijene za rješavanje problema procjene koncentracije zlata (npr. **Malvić, 2008**). **Matheron (1963)** je prvi objavio detaljno obrazloženje geostatistike kao „primjene probabilističkih metoda na regionalizirane varijable koja označava bilo koju funkciju prikazanu u realnom prostoru“ i metode krigiranja. **Cressie (1990)** detaljno analizira razvoj geostatistike i temelje metode krigiranja. Sve veća upotreba geostatistike usko je povezana s razvojem informatike i računarstva budući da se interpretacije geoloških podataka baziranih na geostatističkim metodama, rade pomoću računalnih programa.

Geostatističke metode dijele se na **determinističke** i **stohastičke**. Kod determinističkih metoda moraju biti poznati (prividno) svi uvjeti koji utječu na procjenu te deterministički sustav ne smije sadržavati slučajnost u opisu varijable. Međutim, na temelju točkastih bušotinskih podataka nikada nije moguće potpuno tvrditi da je rješenje dobiveno geostatističkim metodama apsolutno točno, odnosno sve geostatističke metode u sebi sadrže određenu nesigurnost. Determinističke interpolacijske metode daju samo jedno rješenje, tj. primjenom iste metode za isti skup podataka, uvijek će se dobiti ista karta. Međutim, stohastičkim metodama se za isti skup podataka dobije različit broj rješenja koja su vrlo slična i sva jednako vjerojatna.

U matematičkom polju numeričke analize, interpolacija je metoda izradbe novih točkastih podataka unutar raspona određenog skupa poznatih vrijednosti. U inženjerstvu i znanosti općenito, često raspolažemo s određenim brojem točkastih podataka dobivenim uzorkovanjem ili eksperimentiranjem koji predstavljaju vrijednosti funkcije za ograničeni broj vrijednosti nezavisne varijable. Često je potrebno interpolirati, odnosno procijeniti vrijednost te funkcije za srednju vrijednost nezavisne varijable, što se može postići regresijskom analizom ili prilagodbom krivulje.

Postoje brojne metode interpolacije od kojih mnoge uključuju prilagođavanje nekakve vrste funkcije podacima i zatim procjenu vrijednosti te funkcije na željenoj točki. Ovo ne isključuje ostale načine poput statističkih metoda izračuna interpoliranih podataka.

5. Istraživačka metodologija

Brojna su ležišta u hrvatskom dijelu Panonskoga bazenskog sustava (skr. HPBS) već interpretirana determinističkim interpolacijskim i stohastičkim metodama poput ležišta polja Ivanić, Molve, Kalinovac, Stari Gradac-Barcs Nyugat, Beničanci, Ladislavci, Galovac-Pavljani, Velika Ciglena i neka druga manja (npr. **Husanović i Malvić, 2014**) a posebice detaljno ležišta polja Kloštar (**Novak Zelenika, 2012**). Bjelovarska subdepresija kartirana je po plohama svih markera ručno (**Malvić, 2003, 2011**), a po plohama markera Rs7 (granica sarmata i panona) i Rs5 (granica donjega i gornjega panona) tehnikom običnoga krigiranja (**Špelić i sur., 2016**).

Uobičajena statistika često ne pruža pouzdana rješenja za problem izradbe reprezentativne prostorne distribucije. U stacionarnim sekvencijama (zajednička razdioba vjerojatnosti je nepromjenjiva u vremenu), ekstremne vrijednosti mogu se pojaviti u klasterima. Prvi korak u donošenju zaključaka predstavlja prepoznavanje klastera u podacima, postupkom poznatom kao deklasterizacija.

S obzirom na raspored podataka, deklasterizacija pridodaje težinske faktore raspoloživom skupu podataka te predstavlja prvi korak pri donošenju zaključaka u prepoznavanju klastera. Klasteriziranim podacima dodijeljeni su manji (ili zajednički) težinski faktori, a raspršeni podatci imaju veće takve vrijednosti. Time vrijednosti podataka ostaju nepromijenjene, samo im je dodan veći ili manji utjecaj na temelju njihovog rasporeda u analiziranom prostoru (**Oy Leuangthong i sur., 2008**). Međutim, u tehnikama krigiranja (osim jednostavnog krigiranja), zbroj svih težinskih faktora jednak je 1, što je svojevrsna optimizacija pogreške kartiranja.

U primjeni geostatistike u kartiranju tradicionalno se koriste dvije deklasterizacijske metode: poligonalna metoda (engl. *polygonal method*) i metoda deklasterizacije putem ćelija (engl. *cell-declustering method*). Obje koriste težinski faktor linerane kombinacije raspoloživih vrijednosti uzorka pri iscrpnoj procjeni srednje vrijednosti (cijelog uzorkovanog prostora).

5.1. Metoda Thiessenovih poligona

Metoda Thiessenovih poligona (poznata i kao proksimalna interpolacija, metoda najbližeg susjedstva, zonalna interpolacija, poligonalna interpolacija) je jednostavna metoda multivarijantne interpolacije u jednoj ili više dimenzija. Metoda dodjeljuje vrijednost najbliže točke svakom čvoru mreže tj. prikazuje zonalne raspodjele vrijednosti (https://en.wikipedia.org/wiki/Nearest-neighbor_interpolation).

Thiessenovi poligoni (npr. **Boots, 1987**) područja su (geometrijski likovi) stvorena oko točkastih objekata koji čine međusobno nepreklapajuća susjedstva objekata, a cjelokupni

5. Istraživačka metodologija

sadržaj jednog Thiessenova poligona nalazi se najbliže upravo onoj točki na temelju koje je taj poligon nastao. Broj i razmještaj poligona u nekom dijelu proučavanog prostora te njihova površina, oblik i broj stranica pomažu u analizi i percepciji prostornih odnosa između objekata iz kojih su nastali.

Godine **1911.** klimatolog **A.H. Thiessen** predložio je novi način predstavljanja padalinskih podataka iz neravnomjerno raspoređenih meteoroloških postaja. Definirao je područje na temelju skupa točaka u ravnini (meteorološke stanice) tako da su područja okružena linijom smještenom na pola puta između promatrane i susjednih postaja. Na temelju tog prijedloga, izraz *Thiessenov poligon* najčešće se koristi u geografiji za označavanje poligona definiranih kriterijem blizine s obzirom na niz točaka u ravnini (**Brassel i Reif, 1979**). U poligonalnoj metodi, svaki uzorak je pridružen poligonu utjecaja (poznat kao *Thiessenov* ili *Voronoiov* poligon), koji je konstruiran na takav način da će njegova geometrija uključivati sve točkaste podatke (engl. *data points*) koje su bliže uzorku u odnosu na bilo koja druga mjerenja. Kao rezultat toga, procijenjena globalna sredina (engl. *estimated global mean*), izražena funkcijom $F(x)$ skupa podataka definirana je prema **(5.1)**:

$$F(x) = \frac{\sum_{i=1}^n w_i \times x_i}{\sum_{i=1}^n w_i} \quad (5.1)$$

gdje su težine w_i definirane površinom poligona (**Isaaks i Srivastava, 1989**). Jasno, izolirane točke imat će veće poligone nego točke okupljene u klasteru (engl. *clustered points*).


Zanimljivo, to može biti uspoređeno s dodjeljivanjem težinskih koeficijenata kod krigiranja. Tamo će također „samostalne“ točke imati tu vrijednost veću, negoli one okupljene u klasteru. Tako veličina poligona, poput vrijednosti koeficijenta, može neizravno naglasiti „snagu“ utjecaja pojedine točke promatrano u cijelom skupu.

Nadalje, podrazumijeva se kako su vanjske granice poligona često konveksne, a u suprotnom postoje korektivne tehnike, koje se na primjer rabe u slučaju političkih granica koje određuju mrežu uzorkovanja. Također, programi pod nazivom geografski informacijski sustavi (GIS, engl. *geographic information system*) omogućuju korištenje dodatnih informacija te posljedično bolje određivanje rubova kartiranog područja.

Mreža svih Thiessenovih poligona definiranih skupinom točaka naziva se Thiessenov dijagram, ili alternativno Voronoiov dijagram, Wigner-Seitzove stanice ili Dirichletovo popločenje. Predložen je i više opisan te nazivno „nepristran“ termin "proksimalan poligon". Dvojni Thiessenov dijagram je triangulacija temeljena na kriteriju blizine. **Delaunay (1934)** je prvi


5. Istraživačka metodologija

prepoznao dvojni odnos zbog čega se izraz *Delaunay triangulacije* koristi za dvojni oblik proksimalnih dijagrama. Uobičajeno su proksimalni poligoni napravljeni pomoću simetrale između svih susjednih točaka u skupu (**slika 5.1.**). Glavni problem je definirati susjede svake točke skupa.



Slika 5.1. Primjer izradbe simetrale između dvije susjedne točke. Točke se spoje dužinom te se načine kružnice radijusa većeg od polovice njihove udaljenosti. Sjecište kružnica predstavlja simetralu koja će u konačnici predstavljati stranicu poligona.

Skupovi N od n točaka zovu se centroidi, a nalaze se u ravnini (**slika 5.2**). Potrebno je naći skup točaka V u ravnini tako da je svaki $V_i \in V$ jednako udaljen i najbliži najmanje tri centroida. Te točke nazvane su Thiessenovim vrhovima (engl. *vertices*). Thiessenov rub (engl. *edge*) može biti razdvojen s dva vrha ili neograničen u jednom smjeru. Predstavlja mjesto svih ravnomjernih točaka koje su najbliže dva centroida. Sam Thiessenov poligon definiran je kao položaj svih točaka bliže centroidu $C \in N$ nego bilo kojem drugom centroidu (**slika 5.2**). Ta definicija upućuje da su Thiessenovi poligoni konveksni. Skup centroida N određuje skup Thiessenovih poligona n . Skup svih poligona naziva se Thiessenov dijagram (**Brassel i Reif, 1979**).



Slika 5.2. Izgled Thiessenovih poligona i elemenata potrebnih za njihovo definiranje (Brassel i Reif, 1979)

Thiessenovi poligoni mogu biti zatvoreni ili otvoreni. Zatvoreni poligoni u cijelosti su omeđeni Thiessenovim rubovima, dok se otvoreni poligoni mogu produljiti u beskonačnost. Konveksni trup skupa centroida N definiran je kao najmanji konveksni poligon koji zatvara sve centroide. Svi centroidi na granici konveksnog trupa imaju otvorene Thiessenove poligone, a svi unutarnji centroidi imaju zatvorene poligone. Centroid B zove se Thiessenov susjed centroida C ako Thiessenovi poligoni oko dva centroida imaju zajednički rub (**slika 5.2.**), odnosno polu-susjed ako imaju jedan zajednički vrh (**Brassel i Reif, 1979**).

Prednost Thiessenovih poligona je što ih je jednostavno izraditi. Glavni nedostatak te metode je što se smatra da su mjerenja homogena unutar poligona i da mijenjaju vrijednosti jedino na granicama. Ova metoda se većinom koristi u klimatologiji kada mjesna mjerenja nisu dostupna pa se koriste mjerenja s najbliže meteorološke postaje. Međutim, metoda Thiessenovih poligona našla je mjesto i u drugim prirodnim znanostima. Tako se sve više koristi i u geologiji. Posebno je korisna ako raspolažemo s podacima koji su prilično klasterizirani kao što je slučaj kod polja Šandrovac na čijem je primjeru izrađena karta varijable dubina.

Najjednostavnija interpolacijska metoda je smještanje najbliže vrijednosti podataka i pridruživanje iste vrijednosti, odnosno metoda Thiessenovih poligona. Kod jedne dimenzije rijetki su dobri razlozi za izbor ove vrste interpolacije umjesto linearne. No kod viših dimenzija, u multivarijatnoj interpolaciji, prethodno opisana metoda je prikladan izbor zbog svoje brzine i jednostavnosti.

U GIS-u postojeće mogućnosti za stvaranje Thiessenovog ili Voronoiovog dijagrama uobičajeno se usredotočuju na normalne točke (kojima nisu dodijeljeni težinski koeficijenti).

Međutim, težinski dijagrami za linije i područja su korisniji u geoznanostima. Na primjer u području mineraloškog istraživanja mogu se ocrtati ovisno o veličini alteracijskih zona (**Dong, 2008**).

5.2. Pregled teorije determinističkih geostatističkih metoda

Glavni alat za procjenu, odnosno predviđanje varijabli u ležištu čine determinizam koji se koristi u razradbenoj fazi i stohastika koju koristimo u istraživačkoj fazi ležišta. Kod determinističkog sustava za isti skup ulaznih varijabli uvijek se dobije isti izlaz, odnosno karta. Stohastički sustav predstavlja hibridni model između determinizma i slučajnosti budući da jednim svojim dijelom sadržava nesigurnosti vezane uz karakterizaciju ležišta, ali i dovoljno podataka da se model može prikazati (**Malvić, 2008**).

Obzirom na ovakav pristup, moguće je napraviti klasifikaciju ležišta u tri kategorije (**Jensen i sur., 2000**):

- 1) Potpuno deterministička ležišta u kojima su unutrašnja građa i sastav dobro poznati, a međubušotinski prostor vrlo detaljno koreliran. To podrazumijeva veliki broj bušotina, tj. „čvrstih“ podataka na kojima se primjenjuju determinističke tehnike krigiranja ili kokrigiranja. U načelu su takva ležišta vrlo rijetka.
- 2) Stohastička ležišta su ona kod kojih su unutarnja građa i sastav relativno dobro upoznati i korelirani, ali postoji određeni stupanj nesigurnosti u poznavanju vrijednosti pojedinih geoloških varijabli u međubušotinskom prostoru. Takav je najveći broj ležišta te se u njima geostatistika najviše i primjenjuje.
- 3) Ležišta općenito nepredvidivih parametara su uglavnom rijetka te predstavljaju potencijalna ležišta ugljikovodika koja tek trebaju biti otkrivena.

5.2.1. Variogramska analiza

Variogram (2γ) je jedan od temeljnih geostatističkih alata koji služi za određivanje prostorne zavisnosti, a time i za bolje definiranje međusobne povezanosti točkastih podataka koji se žele zajednički kartirati. Često se naziva i semivariogramom (γ) koji ima potpuno jednaka svojstva, osim što se kod variogramske jednadžbe iz nazivnika eliminira broj 2. Matematički se izražava **jednadžbom 5.2**:

5. Istraživačka metodologija

$$2\gamma(h) = \frac{1}{N(h)} \times \sum_{n=1}^{N(h)} [z_n - z_{n+h}]^2 \quad (5.2)$$

gdje su:

$2\gamma(h)$ - vrijednost variograma;


$N(h)$ - broj parova podataka uspoređenih na udaljenosti 'h';

z_n - vrijednost na lokaciji 'n';

z_{n+h} - vrijednost varijable na lokaciji udaljenoj za 'h' od promatrane lokacije 'n'.

Rezultat izradbe variograma je eksperimentalni variogram kod kojeg se ne analiziraju sama mjerenja, već njihove razlike, čime se značajno povećava broj variogramskih podataka. Uz veći broj parova podataka povećava se i pouzdanost procjene. Eksperimentalni variogram se zatim aproksimira teorijskim modelom koji predstavlja ulaz za metodu krigiranja kojom se interpoliraju u prosjeku najtočnije karte (npr. **Malvić, 2008**).

Eksperimentalna (semi)variogramska krivulja (oznaka (h)) prikazana je na **slici 5.3**. Na takvoj krivulji može se očitati sljedećih pet parametara: (1) odstupanje – C_0 (engl. *nugget*), (2) prag ili varijanca – C (engl. *sill*), (3) doseg – a (engl. *range*), (4) udaljenost ili korak – h (engl. *distance*) i (5) odmak – Δ (engl. *lag*).



Slika 5.3. Parametri semivariograma

5. Istraživačka metodologija

Odstupanje (C_0) predstavlja slučajnu komponentu regionalizirane varijable, odnosno pojavu kada krivulja siječe os Y u nekoj pozitivnoj vrijednosti (C_0). Pojava odstupanja je obilježje velikog broja eksperimentalnih semivariograma, a upućuje na razliku u vrijednostima vrlo bliskih uzoraka koji se u praksi smatraju uzorcima s jedinstvene lokacije. Može se ukloniti smanjenjem površine ili povećanjem broja uzoraka, no u praksi se ono vrlo često ne može u potpunosti eliminirati.


Prag (C) je razlika pojedinačnih vrijednosti i srednje vrijednosti skupova podataka, odnosno odgovara vrijednosti varijance. Krivulja semivariograma nakon dosezanja praga najčešće prestaje pravilno rasti te nastavlja oko njega oscilirati. Međutim, svaki semivariogramski model ne treba uvijek imati prag.

Doseg (a) je vrijednost na kojoj semivariogram prvi put presijeca prag, tj. varijancu, a nakon toga ne postoji prostorna ovisnost podataka.

Udaljenost ili korak (h) je vrijednost na kojoj se podatci uspoređuju. Svaka vrijednost udaljenosti čini jednu klasu (na **slici 5.3.** klase su u rasponu od 0,5-1,5; 1,5-2,5...) kojoj se često dodjeljuje određena tolerancija kako bi se povećao broj ulaznih podataka, a nazvana je odmakom (Δ). To znači da granicama klase dodajemo vrijednost odmaka te na taj način širimo klasu. Odmak najčešće predstavlja polovicu vrijednosti koraka jer se na taj način maksimalno uvećava broj parova podataka, i površina jedne klase izravno graniči s površinom susjedne. Tako se povećava i pouzdanost prostorne analize (**Malvić, 2008**).

Gotovo se svi eksperimentalni (semi)variogrami mogu matematički aproksimirati s pet teorijskih modela: sfernim, eksponencijalnim, Gausovim, linearnim i logaritamskim (deWysovim). Razlikuju se prema tome sadržavaju li prag te po načinu ponašanja krivulje u blizini ishodišta. U većini geostatističkih knjiga, proces podešavanja teorijskog variograma dobivenom eksperimentalnom variogramu naziva se strukturnom analizom (**Hohn, 1988**).

U interpretaciji geoloških varijabli najčešće se upotrebljavaju sferni, eksponencijalni i Gaussov model jer sva tri sadrže prag (**slika 5.4.**).



Slika 5.4. Teorijski modeli

Sljedećim jednadžbama se određuje ponašanje varijable određene odabranim teorijskim modelom, odnosno oblici krivulja (npr. **Isaaks i Srivastava, 1989**):

$$\gamma(h) = C \left[\left(\frac{3h}{2a} \right) - \left(\frac{h^3}{2a^3} \right) \right] \quad h \leq a \quad \text{sferni model} \quad (5.3)$$

$$\gamma(h) = C \quad h > a$$

$$\gamma(h) = C \left[1 - \exp\left(\frac{-h}{a}\right) \right] \quad \text{eksponencijalni model} \quad (5.4)$$

$$\gamma(h) = C \left[1 - \exp\left(\frac{-h^2}{a^2}\right) \right] \quad \text{Gaussov model} \quad (5.5)$$

gdje su:

$\gamma(h)$ - vrijednost variograma na udaljenosti 'h';

C – konstanta;

h – udaljenost;

a – doseg.

Svaki variogram opisan je s nekoliko svojstava, od kojih je najvažnije svojstvo anizotropija koja opisuje promjenu prostorne zavisnosti varijable ovisno o smjeru u kojem se analizira. Na temelju rezultata semivariogramске analize može se odrediti smjer najvećega (glavna os) i najmanjega kontinuiteta (sporedna os). Njihov omjer predstavlja faktor anizotropije. U većini

5. Istraživačka metodologija


slučajeva se obje veličine mijenjaju sa smjerom te je tada riječ o zonalnoj anizotropiji. Međutim, semivariogrami mogu imati u različitim smjerovima isti prag, a različiti doseg pa se radi o geometrijskoj anizotropiji. Sljedeće često uočljivo svojstvo na brojnim variogramskim krivuljama jest osciliranje odnosno pojava približno pravilne promjene vrijednosti, najčešće oko praga, što kazuje da više ne postoji prostorna ovisnost podataka.

Na semivariogramski račun značajno utječu ekstremne vrijednosti koje se mogu pojaviti kao posljedica premaloga broja ulaznih podataka. Potrebno ih je izdvojiti i odbaciti na histogramu analizirane varijable jer se unutar semivariogramske jednadžbe računa kvadrat razlike vrijednosti, pa one značajno utječu na semivariogramski račun (**Malvić, 2008**).

5.2.2. Tehnike krigiranja

Metoda krigiranja predstavlja naprednu statističku metode procjene i jednu od najčešćih determinističkih interpolacijskih metoda kojom se procjenjuju vrijednosti regionalizirane varijable u odabranim točkama mreže. Regionalizirana varijabla često je i slučajna varijabla, jer mreža točkastih uzoraka za bilo koju varijablu nikada ne može sa sigurnošću predstavljati statistički potpuno reprezentativni uzorak za neki volumen (npr. stijene) koji se analizira.

Metodama krigiranja prethodi određivanje prostorne zavisnosti, odnosno variogramska analiza kojom se u obzir mogu uzeti i smjerovi promatranja (usmjereni variogrami), nakupljanje podataka (klasteri), te ponekad lokalna varijanca koju čini samo dio podataka unutar elipsoida pretraživanja. Područje pretraživanja definira prostor u kojem se vrijednosti varijable koriste za interpolaciju vrijednosti na novoj lokaciji (**slika 5.5.**). Elipsoid centriran u točki ili bloku čija se vrijednost procjenjuje predstavlja područje istraživanja gdje će samo mjerenja unutar elipsoida prostorne zavisnosti biti upotrijebljena za izračun matrice krigiranja. Elipsa se pomiče pri računanju procjene u sljedećoj točki pri čemu se najčešće uzima drugačiji skup mjerenih vrijednosti.



Slika 5.5. Primjer područja pretraživanja. Na slici lijevo nema anizotropije, dok je na slici desno prikazan elipsoid pretraživanja omjera anizotropije 2, pod kutem od 140° (<http://gro-1.itrcweb.org/characteristics-of-interpolation-methods/>).

Krigiranje i njegove izvedenice (kokrigiranje i stohastičke simulacije) zajednički su određene kao „najbolji linearni nepristrani procjenitelji“ (engl. *best linear unbiased estimators* – BLUE). Linearnost procjene dana je izrazom (5.6) koji se kasnije raspisuje u obliku matrice jednadžbi.

$$Z_k = \sum_{i=1}^n \lambda_i \times Z_i \quad (5.6)$$

Vrijednosti varijable na odabranoj lokaciji (Z_k) procjenjuju se na temelju postojećih okolnih vrijednosti (Z_i). Svakom podatku pridružen je i odgovarajući težinski koeficijent (λ) kojim se opisuje utjecaj tog mjerenog podatka na vrijednost varijable koja se procjenjuje (5.6). Što je vrijednost λ veća, točka je prostorno bliža točki procjene i jače utječe na nju. Zbroj svih težinskih koeficijenata jednak je 1 (osim kod tehnike jednostavnog krigiranja).

Metoda krigiranja obuhvaća brojne tehnike koje se razlikuju po obliku matrice jednadžbi, tj. prema vrsti i području podataka na koje se primjenjuju. To su, kao možda najčešće tehnike: jednostavno krigiranje (engl. *Simple Kriging*), obično krigiranje (engl. *Ordinary Kriging*), indikatorsko krigiranje (engl. *Indicator Kriging*), univerzalno krigiranje (engl. *Universal Kriging*) i disjunktivno krigiranje (engl. *Disjunctive Kriging*) (npr. **Malvić, 2008**). Kod jednostavnog krigiranja, kao osnovne tehnike, matrice jednadžba (5.7) glasi:

$$\begin{pmatrix} \gamma(Z_1 - Z_1) & \gamma(Z_1 - Z_2) & \dots & \gamma(Z_1 - Z_n) \\ \gamma(Z_2 - Z_1) & \gamma(Z_2 - Z_2) & \dots & \gamma(Z_2 - Z_n) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma(Z_n - Z_1) & \gamma(Z_n - Z_2) & \dots & \gamma(Z_n - Z_n) \end{pmatrix} \times \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \end{pmatrix} = \begin{pmatrix} \gamma(X_1 - X) \\ \gamma(X_2 - X) \\ \vdots \\ \gamma(X_n - X) \end{pmatrix} \quad (5.7)$$

5. Istraživačka metodologija

gdje su:

γ - vrijednost semivariograma na udaljenosti dviju točaka;

λ - težinski koeficijent za lokaciju 'i';

$Z_1 \dots Z_n$ - mjerene vrijednosti u točkama.

Međutim, kod jednostavnog krigiranja nije ispunjen uvjet da je procjena nepristrana (engl. *unbiased*). Sve ostale tehnike krigiranja imaju dodane neke „faktore ograničenja” (engl. *constraints*) čime je u potpunosti zadovoljen uvjet jednadžbi krigiranja nazvan BLUE (engl. *Best Linear Unbiased Estimator*).

5.2.2.1. Obično krigiranje

Jedna od tehnika korištenih u ovome radu je obično krigiranje (skr. OK). To je najčešće upotrebljavana tehnika krigiranja. Vrijedi pretpostavka da lokalna srednja vrijednost (podataka u elipsoidu) nije jednaka ili približno jednaka srednjoj vrijednosti svih podataka (**Malvić i sur., 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 OK minimiziran je iznos varijance krigiranja pomoću linearnog vanjskog parametra, nazvanog Lagrangeov faktor (μ). Navedeni faktor omogućuje određivanje maksimalne i minimalne vrijednosti multivarijabilne funkcije $f(x, y, \dots)$ kada postoje ograničenja ulaznih vrijednosti. Može se primijeniti kada su ograničenja oblika $g(x, y, \dots) = c$, gdje je g još jedna multivarijabilna funkcija istog ulaznog prostora kao f , a c je konstanta (<https://www.khanacademy.org/math/multivariable-calculus/applications-of-multivariable-derivatives/constrained-optimization/a/lagrange-multipliers-single-constraint>).

Obje funkcije trebaju imati kontinuirane parcijalne derivacije. Dodaje se nova varijabla, Lagrangeov faktor (μ), pa dobijemo Lagrange funkciju (L) definiranu prema (5.8):

$$L(x, y, \mu) = f(x, y) - \mu(g(x, y) - c) \quad (5.8)$$

gdje se μ može dodati ili oduzeti. Ako je $f(x_0, y_0)$ maksimum od $f(x, y)$ za originalno ograničenje, tada postoji μ_0 koji je stacionarna točka Lagrange funkcije (stacionarne točke su točke gdje su parcijalne derivacije L jednake 0). Međutim, ne daju sve stacionarne točke rješenje originalnog problema. Prema tome metoda Lagrangeovih faktora daje potreban uvjet za optimalnost

5. Istraživačka metodologija

ograničenja (https://en.wikipedia.org/wiki/Lagrange_multiplier). Faktor ograničenja minimizira pogrešku pa procjena postaje nepristrana. Uvjet prilikom procjene tehnikom običnog krigiranja je da je zbroj svih težinskih koeficijenata jednak 1 (Malvić i sur., 2008). Matrična jednadžba tehnike OK glasi (5.9):

$$\begin{bmatrix} \gamma(Z_1 - Z_1) & \gamma(Z_1 - Z_2) & \dots & \gamma(Z_1 - Z_n) & 1 \\ \gamma(Z_2 - Z_1) & \gamma(Z_2 - Z_2) & \dots & \gamma(Z_2 - Z_n) & 1 \\ \dots & \dots & \dots & \dots & \dots \\ \gamma(Z_n - Z_1) & \gamma(Z_n - Z_2) & \dots & \gamma(Z_n - Z_n) & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix} \times \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma(X_1 - X) \\ \gamma(X_2 - X) \\ \dots \\ \gamma(X_n - X) \\ 1 \end{bmatrix} \quad (5.9)$$

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 faktor.

Prema izrazu (5.9) procijenjena vrijednost je zbroj svih točaka otežanih odgovarajućim koeficijentom (Malvić i sur., 2008).

5.2.2.2. Univerzalno krigiranje

Cilj univerzalnog krigiranja (skr. UK) je također predvidjeti vrijednost $Z(x)$ na neuzorkovanim područjima. Dijeli slučajnu funkciju u linearnu kombinaciju determinističkih funkcija; nestacionarni trend, poznat kao i drift te slučajnu komponentu koja predstavlja ostatak (engl. *residual*) funkcije (Wackernagel, 2003). Varijabla Z tako se može prikazati kao zbroj determinističke komponente $m(x)$ (trenda) i stohastičke komponente $R(x)$ jednadžbom 5.10:

$$Z(x) = m(x) + R(x) \quad (5.10)$$

Obično i jednostavno krigiranje podrazumijevaju stacionarnost, tj. pretpostavlja se kako je sredina (engl. *mean*) nepromijenjena na cijelom području. Međutim, u stvarnosti se srednja vrijednost nekog prostornog podatka ne može smatrati konstantnom ili nepromjenjivom, ona varira budući da ovisi i o apsolutnom položaju uzorka pa se naziva nestacionarnom. Nestacionarna regionalizirana varijabla ima dvije komponente (Davis, 1973): trend (engl. *drift*;

5. Istraživačka metodologija

tj. prosječna ili očekivana vrijednost regionalizirane varijable) te ostatak (razliku između stvarnih mjerenja i trenda). Stoga se često tehnika UK naziva i krigiranje s trendom. Tehnikom UK pretpostavlja se kako sredina ima funkcionalnu ovisnost o prostornom položaju te se može aproksimirati odgovarajućim modelom oblika:

$$m(x) = \sum_{l=1}^k a_l f_l(x), \quad (5.11)$$

gdje su:

a_l - l -ti koeficijent koji će biti procijenjen iz skupa podataka,

f_l - l -ta osnovna funkcija prostornih koordinata koje opisuju prostorni trend,

k - broj funkcija upotrijebljenih pri modeliranju prostornog trenda (npr. **Kumar, 2007**).

Sredina može biti funkcija koordinata X i Y u linearnom, kvadratnom ili drugom obliku. Tako na primjer vrijednost varijable Z na lokaciji s može biti izražena kao:

$$Z(s_i) = \beta_0 + \beta_1 X_i + \beta_2 Y_i + \delta(s_i) \quad \text{za linearni model} \quad (5.12)$$

ili

$$Z(s_i) = \beta_0 + \beta_1 X_i + \beta_2 Y_i + \beta_3 X_i^2 + \beta_4 X_i Y_i + \beta_5 Y_i^2 + \delta(s_i) \quad \text{za kvadratni model} \quad (5.13)$$

gdje je β koeficijent regresije

(<https://www.yumpu.com/en/document/view/29351971/universal-kriging-ucla-statistics>).

U ovakvom slučaju kažemo da postoji trend polinomnog tipa. Procijenjena vrijednost $Z(s_0)$ na lokaciji s_0 opet će biti linearna kombinacija promatranih $Z(s_i)$, $i = 1, n$ vrijednosti:

$$Z(s_0) = \lambda_1 Z(s_1) + \lambda_2 Z(s_2) + \dots + \lambda_n Z(s_n) = \sum_{i=1}^n \lambda_i Z_i \quad (5.14)$$

gdje je zbroj težinskih koeficijenata jednak 1 kao i kod ostalih vrsta krigiranja (osim jednostavnog). Ukoliko postoji linearni trend, tada se vrijednost $Z(s_0)$ može izraziti kao:

$$Z(s_0) = \sum_{i=1}^n \lambda_i Z_i = \beta_0 + \beta_1 \sum_{i=1}^n \lambda_i X_i + \beta_2 \sum_{i=1}^n \lambda_i Y_i + \sum_{i=1}^n \lambda_i \delta s_i \quad (5.15)$$

5. Istraživačka metodologija

Vrijednost $Z(s_0)$ temeljena na linearnom trendu također se može izraziti kao:

$$Z(s_0) = \beta_0 + \beta_1 X_0 + \beta_2 Y_0 + \delta(s_0) \quad (5.16)$$

Sljedeći uvjeti trebaju biti zadovoljeni kako bi se ostvarila nepristranost procjene:

$$\begin{aligned} \sum_{i=1}^n \lambda_i X_i &= X_0 \\ \sum_{i=1}^n \lambda_i Y_i &= Y_0 \\ i \\ \sum_{i=1}^n \lambda_i &= 1 \end{aligned} \quad (5.17)$$

Kao i kod običnog krigranja kako bi našli težinske koeficijente kada je prisutan neki trend, potrebno je minimalizirati srednju kvadratnu pogrešku:

$$\min (Z(s_0) - \sum_{i=1}^n w_i Z s_i)^2 \quad (5.18)$$

podložnu gornjim ograničenjima. Navedeno minimaliziranje bit će neograničeno ukoliko uključimo 3 ograničenja u objektivnu funkciju rezultatom čega se dobije sustav od $n+3$ jednadžbe za linearni trend. Jednadžba univerzalnog krigranja na primjeru linearnog trenda u obliku matrice dana je **jednadžbom 4.19**:

$$\begin{pmatrix} \gamma(s_1 - s_1) & \gamma(s_1 - s_2) & \gamma(s_1 - s_3) & \cdots & \cdots & \gamma(s_1 - s_n) & x_1 & y_1 & 1 \\ \gamma(s_2 - s_1) & \gamma(s_2 - s_2) & \gamma(s_2 - s_3) & \cdots & \cdots & \gamma(s_2 - s_n) & x_2 & y_2 & 1 \\ \cdots & \cdots & \ddots & \cdots & \cdots & \cdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \cdots & \cdots & \vdots & \vdots & \vdots \\ \gamma(s_n - s_1) & \gamma(s_n - s_2) & \gamma(s_n - s_3) & \cdots & \cdots & \gamma(s_n - s_n) & x_n & y_n & 1 \\ x_1 & x_2 & \cdots & \cdots & \cdots & x_n & 0 & 0 & 0 \\ y_1 & y_2 & \cdots & \cdots & \cdots & y_n & 0 & 0 & 0 \\ 1 & 1 & \cdots & \cdots & \cdots & 1 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \\ \lambda_1 \\ \lambda_2 \\ \lambda_0 \end{pmatrix} = \begin{pmatrix} \gamma(s_0 - s_1) \\ \gamma(s_0 - s_2) \\ \vdots \\ \gamma(s_0 - s_n) \\ x_0 \\ y_0 \\ 1 \end{pmatrix} \quad (5.19)$$

Postupak uporabe univerzalnog krigiranja može se opisati kroz sljedeće korake:

1. Potrebno je razumjeti zašto određeni trend postoji obzirom na prirodu naših podataka,
2. Potrebno je uporabiti što jednostavniji oblik trenda te izbjegavati ekstrapolaciju izvan dostupnih podataka;
3. Nakon odabira trenda on se oduzima od promatranih podataka koji se svode na „ostatke“ (engl. *residuals*);
4. Zatim se ti ostatci koriste za izračun variograma te prostornu procjenu;
5. Na kraju se toj procjeni ponovno dodaje trend i dobiva završna karta (npr. **Isaaks i Srivastava, 1989**).

5.2.3. Postupak krosvalidacije

Pouzdanost napravljene karte može se odrediti numeričkim metodama od kojih je najpoznatija metoda krosvalidacije (engl. *cross-validation*) ili numerička procjena pogreške. Predstavlja jednostavnu numeričku metodu koja se upotrebljava za provjeru uspješnosti procjene određenom interpolacijskom metodom ili tehnikom (npr. **Husanović i Malvić, 2014**). Temelji se na uklanjanju vrijednosti mjerene na odabranome mjestu i određivanju nove vrijednosti na istome mjestu, uzevši u obzir preostale podatke. Uspoređuje se razlika izvorne i procijenjene vrijednosti na istoj lokaciji te se računa njezin kvadrat.

Na kraju se zbrajaju kvadrati razlika sa svih postojećih lokacija i dobije konačan rezultat krosvalidacije (5.20), poznat i kao numerička pogreška procjene ili srednja kvadratna pogreška procjene (engl. *mean square error – MSE*). Jednadžba krosvalidacije glasi:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\text{izmjerena vrijednost} - \text{procjena})_i^2 \quad (5.20)$$

gdje su:

MSE = srednja kvadratna pogreška (kros-validacija) procjene odabrane metode;

izmjerena vrijednost = izmjerena vrijednost odabrane varijable na bušotini 'i';

procjena = procijenjena vrijednost odabrane varijable na bušotini 'i'.

5. Istraživačka metodologija


Ne postoji okvirna vrijednost krosvalidacije koja određenu metodu definira kao pouzdanu ili prihvatljivu jer je metoda neosjetljiva na usporedbu rezultata s različitim brojem analiziranih smjesta. No, moguća je usporedba takvih vrijednosti za isti skup ulaznih podataka uporabljenih u dvije interpolacijske metode (npr. **Malvić, 2008**). Tada metoda procjene koja ima nižu vrijednost krosvalidacije predstavlja metodu s manjom pogreškom, odnosno bolju metodu za pojedinačni slučaj.

6. KORIŠTENI RAČUNALNI PROGRAMI

U sljedećim potpoglavljima opisani su računalni programi korišteni za geostatističku analizu i kartiranje. Riječ je o Variowinu i SAGI GIS (inačici 2.1.0), slobodnim programima (engl. *freeware*) za čiju uporabu nije potrebna plaćena licencija, te komercijalnom paketu Surfer.

6.1. Računalni program Variowin

Računalni program Variowin sastoji se od 4 programa koji rade zasebno budući da rezultat jednog programa predstavlja ulazni podatak za drugi program. Ovdje su korištena 3 programa sa svrhom izradbe variograma: Prevar 2D, Vario 2D i Model (npr. **Pannatier, 1996; Horvatinec, 2008**) koji su zaokruženi na slici 6.1.




Slika 6.1. Programi unutar Variowina za izradbu variograma

6. Korišteni računalni programi

Prevar 2D je program kojim se određuje matrica udaljenosti za sve parove podataka u skupu. Navedeni program prvi se pokreće, a zahtijeva ulazne podatke u specifičnom ASCII obliku kako bi ih pretvorio u „pcf“ zapis (**slika 6.2.**). Podatci moraju biti priređeni na sljedeći način:


- vrijednosti koje se unose su apsolutne, a ne relativne;
- treba biti naveden broj i naziv varijabli.



Slika 6.2. Primjer priređivanja podataka za rad u programu Prevar 2D


Zatim se pokreće program Vario 2D koji iz dobivenog pcf zapisa izrađuje eksperimentalni variogram (**slika 6.3.**). Prvo se izrađuje variogramska karta (**slika 6.3.**) koja služi za određivanje glavne osi koja daje najveći broj parova s velikim vrijednostima (što ukazuje na veliku prostornu zavisnost, na slici smjera pružanja 135°-315°) i sporedne osi koja daje parove s najmanjim vrijednostima (s najmanjom prostornom zavisnosti, na slici smjera 45°-225°). Navedene vrijednosti su nam potrebne za izradbu anizotropnog eksperimentalnog variograma, naravno ako je ona utvrđena. U navedenom primjeru korištene su sljedeće proizvoljne ulazne vrijednosti pri izradbi variograma: veličina koraka/ćelije (h) = 800 m i broj koraka = 5. Kutna tolerancija iznosi 45° (**slika 6.3.**) za odabranu varijablu “ostatci”.

6. Korišteni računalni programi



Slika 6.3. Primjer rada u programu Vario 2D – izradba karte variogramske površine i eksperimentalnog variograma

Posljednji program koji se pokreće je Model (slika 6.4.) u kojem se kao ulazni podatci koriste rezultati programa Vario 2D. Služi za izbor optimalnog teorijskoga variogramskog modela. Dobivene vrijednosti praga, dosega i odstupanja (na slici 6.4. redom: 2 470, 2 280 m, 0) teorijskih aproksimacijskih modela variograma koriste se kao ulazni podatci kod interpolacije metodom krigiranja odabranim računalnim programom, u ovom slučaju Surfer. U prikazanom slučaju sferni teorijski model pokazao se najprimjerenijim.



Slika 6.4. Primjer rada u programu Model – variogramski aproksimacijski model

6.2. Računalni program SAGA GIS

SAGA, odnosno „Sustav za automatiziranu geoznanstvenu analizu“ (engl. *System for Automated Geoscientific Analyses*) je besplatan, hibridan višepatformski GIS softver. Suština SAGA-e je programski jezik C++ i s time u vezi objektno orijentirano aplikacijsko programsko sučelje API (engl. *Application Programming Interface*) koje pruža značenje skupa podataka i računalne metode za raster, vektor i tablične podatke.


Ideja za razvoj SAGA-e razvila se kasnih 1990-ih za vrijeme rada na nekoliko istraživačkih projekata Odjela za fizikalnu geografiju u Göttingenu. Područje istraživanja bila je analiza rasterskih podataka, posebice digitalnih modela reljefa (DEM, engl. *Digital Elevation Model*), koji su korišteni za predviđanje svojstava tla, kao i klimatskih parametara. To je zahtijevalo razvoj i provedbu mnogih novih metoda za prostorne analize i modeliranja.

Geoznanstvene metode ugrađene su u različite SAGA module koji su u paketu takozvanih knjižničarskih modula. Ovi moduli dostupni su na različite načine: grafičkim korisničkim sučeljem (GUI SAGA, engl. *Graphical User Interface*) ili jednom od metoda skriptiranja.

GUI je najčešći način korištenja SAGE (slika 6.5.). Mogu se učitati rasterski, vektorski i tablični podatci i predočiti u karte, 3D prikaze, dijagrame, itd. GUI pruža veliku fleksibilnost u pogledu tablice boja, raslojavanja skupova i prikazu atributa. Korisnik ima potpuni pristup svim SAGA modulima za obradbu podataka i ispitivanje rezultata. To uključuje puno znanstvenih metoda kojih nema u drugim GIS aplikacijama. U slučaju automatizacije posebnog zadatka, potrebno je samo koristiti jednu od metoda skriptiranja. Ako nedostaje metoda u SAGA-i, može

6. Korišteni računalni programi

se izgraditi vlastiti modul (<http://sourceforge.net/apps/trac/sagagis/wiki/The%20Philosophy%20of%20SAGA>).



Slika 6.5. SAGA grafičko korisničko sučelje - GUI (<http://sourceforge.net/projects/saga-gis/>)

Interpolacija Thiessenovih poligona dostupna je unutar standardnih GIS paketa poput ESRI's ArcGIS-a i SAGA GIS-a. To je relativno jednostavan postupak koji zahtijeva pokrivenost točaka za unos i izvodi se pomoću SAGA GIS alatnih naredbi.


6.3. Računalni program Surfer

U ovom radu korištena je licencirana verzija programskog paketa Surfer za kartiranje tehnikama običnog i univerzalnog krigiranja. Surfer je programski paket namijenjen širokom spektru znanstvenika poput geologa, geofizičara, meteorologa i sl. Predstavlja napredni interpolacijski program koji se može koristiti za površinsko i dubinsko modeliranje, vizualizaciju, interpolaciju, itd. (<http://www.goldensoftware.com/products/surfer>).

6. Korišteni računalni programi

Kako je preduvjet za kartiranje metodom krigranja izradba eksperimentalnog variograma, isti je načinjen u Variowinu te su dobivene vrijednosti dosega, odstupanja, iznosa anizotropije te teorijski aproksimacijski model potom unosene u Surfer (**slika 6.6.**). Izbor između tehnike običnog i univerzalnog krigranja radi se mijenjanjem opcije trenda. U slučaju nepostojanja trenda, radi se tehnika običnog krigranja, a u slučaju lineranog ili kvadratnog, tehnika univerzalnog.


Ako postoji smjer u kojem podatci imaju veću međusobnu zavisnost, odnosno kada je u ulaznim podacima opažen prostorni trend, koristi se anizotropija. U slučaju najveće ovisnosti podataka u smjeru, recimo sjeveroistok-jugozapad, pravac anizotropije je 225° . Unutar programa postoji i opcija za kojom se mijenja radijus elipsoida pretraživanja, kojim je određena prosječna veličina skupa mjerenih podataka koji se koriste za izračun u svakoj točki mreže (engl. *grid*). Program automatski stvara mrežu koju koristi u izradbi karte te prikazuje mrežu procijenjenih vrijednosti točaka za izradbu karte metodom krigranja. Za svaku se točku unutar granica pretraživanja (čiji je radijus kružnica ili elipsoid) računa njezin utjecaj na točku čija se vrijednost procjenjuje.



Slika 6.6. Primjer sučelja u Surferu

7. REZULTATI UPORABE ZONALNE PROCJENE I RAZLIČITIH TEHNIKA KRIGIRANJA NA PRIMJERU POLJA ŠANDROVAC KAO POJEDINAČNE STRUKTURE


Polje Šandrovac smješteno je oko 18 km istočno od Bjelovara (**slika 7.1.**). Predstavlja oglednu izdignutu strukturu HPBS-a te je geološki smješteno u Bjelovarskoj subdepresiji. Površina polja iznosi oko 38 km².



Slika 7.1. Položaj polja Šandrovac (modificirano prema Novak Zelenika i Malvić, 2011)

Vrijednosti varijable dubine i koordinate smjesta bušotina polja Šandrovac izravno su očitane sa strukturne karte (**slika 7.2.**) EK markera Z' (koji predstavlja granicu između gornjega panona i donjega pona).

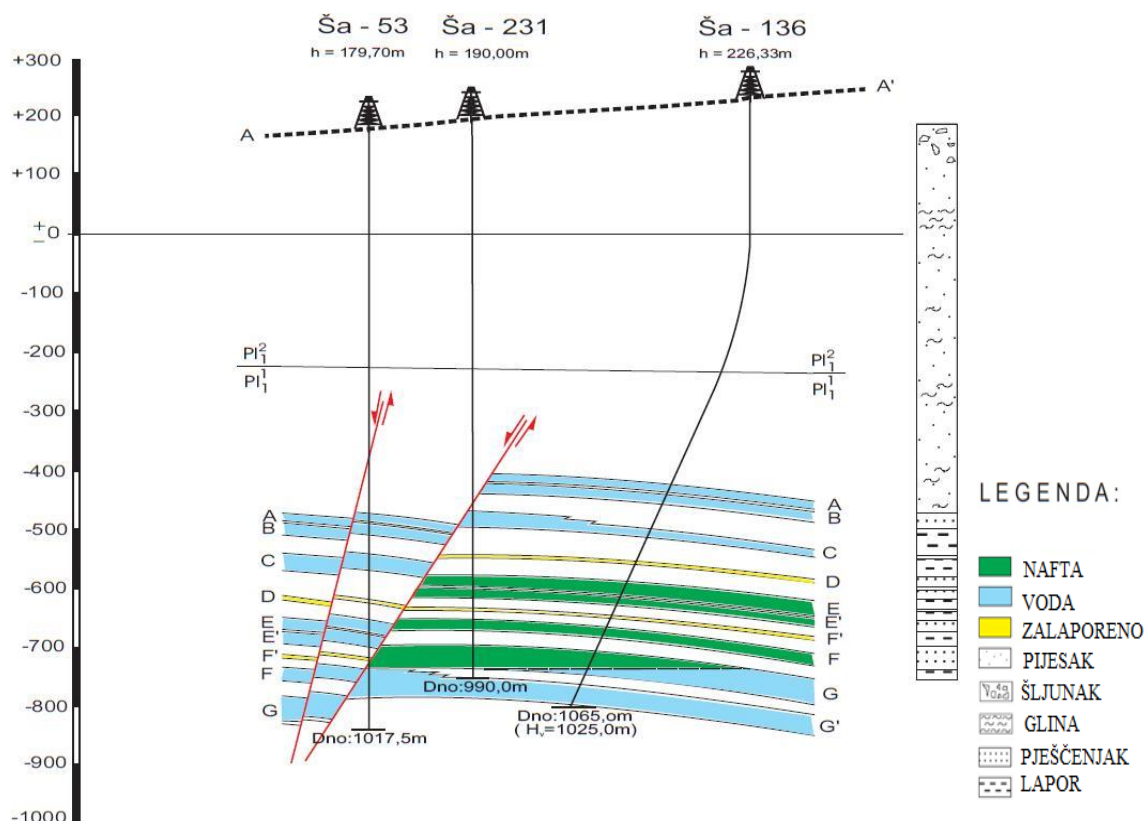
7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.2. Strukturna karta Bjelovarske subdepresije po plohi EK markera Z' (Malvić, 2011) i položaj polja Šandrovac

Eksploatacija naftnog polja Šandrovac započela je 1967. g. Stratigrafska pripadnost ležišnih stijena je donji pont. Zamka (ležište) je slojevita (Brod, 1945), a prema Levorsenu (1956) kombinirana. Pješčenjaci čine ležišne stijene (slika 7.3.). Raspon šupljikavosti iznosi od 14,0 do 33,0 %, dok je raspon efektivnih debljina od 0,65 do 9,2 m. Raspon propusnosti je od 2,0 do $336,0 \cdot 10^{-3} \mu\text{m}^2$ (Zornjak, 2009).

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.3. Shematski geološki profil A-A' naftno-plinskog polja Šandrovac
(Zornjak, 2009)

Interpretacijom seizmičkih mjerenja utvrđena je brahiantiklinala čija os ima glavni pravac pružanja sjever – jug. Struktura je rasjednuta uglavnom pravcem sjeveroistok – jugozapad. Glavne ležišne stijene su donjopontske. Podijeljene su u „serije“ nazvane po abecednom redu: A, B, C, D, E, E', F i G (G, G', G''). Nisu sve taložene u cijeloj strukturi, već neke isklinjuju ili se „spajaju“, npr. F i G.

7.1. Metoda Thiessenovih poligona na primjeru polja Šandrovac

Thiessenovi poligoni izrađeni su u programu SAGA GIS 2.1.0. Prvi korak u izradbi Thiessenovih poligona je očitavanje koordinata poligona za polje Šandrovac te koordinata bušotinskih točaka i njihovih dubina u čiju svrhu je korištena strukturna karta EK markera Z' (slika 7.2.). Pri izradbi početnog poligona koji u biti predstavlja okvir polja, koordinate se u program moraju unositi određenim redoslijedom, jer bi inače sve točke bile međusobno spojene. Upravo su zbog toga prva i zadnja koordinata identične te se u program unosi nova varijabla, a to je redoslijed (tablica 7.1.).

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

Tablica 7.1. Koordinate poligona polja Šandrovac

Šandrovac		
x	y	redoslijed
6418400	5089800	1
6418400	5086500	2
6417600	5086500	3
6417600	5084000	4
6423200	5084000	5
6424600	5086900	6
6422400	5089800	7
6418400	5089800	8

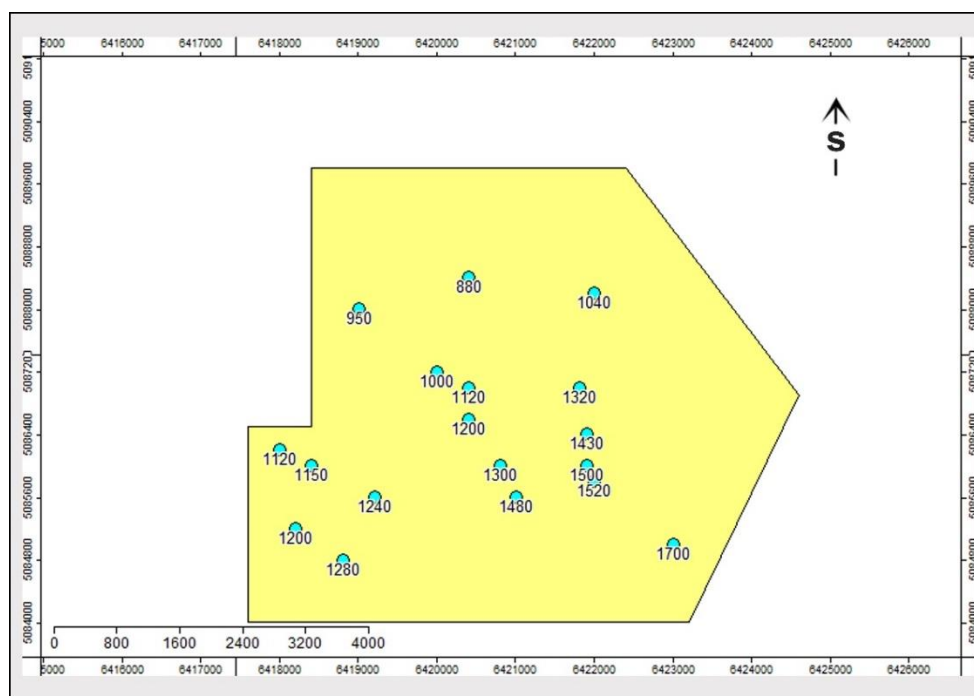
Nakon što je napravljen okvir polja, odnosno poligon Šandrovca, potrebno je unijeti koordinate bušotinskih podataka i njihove dubine (**tablica 7.2.**) koji su dobiveni izravnim očitavanjem koordinata i dubina sa strukturne karte EK markera Z' (**slika 7.2.**), gdje se unutar polja Šandrovac nalazi 18 točaka. U ovom slučaju nije korištena pravilna mreža veličine ćelija 2x2 km radi pravilnog rasporeda točaka koji rezultiraju pravokutnim oblikom Thiessenovih poligona.

Tablica 7.2. Ulazni podatci za izradbu karata dubina metodama Thiessenovih poligona i krigiranja

Gauss–Krüger (X)	Gauss–Krüger (Y)	Dubina ležišta [m] (Z)
6418000	5086200	1120
6418200	5085200	1200
6418400	5086000	1150
6418800	5084800	1280
6419200	5085600	1240
6419000	5088000	950
6420000	5087200	1000
6420400	5088400	880
6420400	5087000	1120
6420400	5086600	1200
6420800	5086000	1300
6422000	5088200	1040
6421800	5087000	1320
6421900	5086400	1430
6421900	5086000	1500
6422000	5085800	1520
6423000	5085000	1700
6421000	5085600	1480

Unošenjem navedenih podataka iz **tablice 7.1.** i **7.2.**, dobije se okvir polja s točkama i vrijednostima dubina unutar njega, kao što se može vidjeti na **slici 7.4.**


7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.4. Poligon polja Šandrovac i raspodjela 18 točaka s vrijednošću dubina izravno očitanih sa strukturne karte po EK markeru Z'

Zadnji korak predstavlja izradba samih Thiessenovih poligona koje je najbolje prikazati različitim bojama kako bi se jasnije uvidjela zonalna procjena dubinskih vrijednosti (**slika 7.5.**). Ovu metodu bi prema tome nazvali zonalnom procjenom, a ne interpolacijskom metodom. Izrađena karta daje kolorni prikaz vrijednosti dubine, odnosno svaki je poligon poprimio boju koja odgovara dubini točke koja se u njemu nalazi (**slika 7.5.**). Na temelju izrađenih poligona vidi se kako struktura polja Šandrovac lagano tone s najvećim dubinama (od 1700 m) na jugoistoku. Prema tome, dobivena zonalna procjena vrijednosti dubina odgovara vrijednostima dubine EK markera Z' (**slika 7.2.**) polja Šandrovac te prikazuje sličan oblik strukture (homoklinu). Takva karta podržava opći taložni model subdepresije u vrijeme donjega pontu kada su veće količine klastita transportirane iz Istočnih Alpi u HPBS turbiditnim strujama.

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.5. Thiessenovi poligoni unutar polja Šandrovac prikazani bojama koje odgovaraju vrijednosti dubine u određenim točkama

Metoda Thiessenovih poligona u pravilu prikazuje zonalne raspodjele vrijednosti budući da dodjeljuje vrijednost najbliže točke svakom čvoru mreže. Najbolje ju je koristiti u slučaju malog skupa podataka (recimo manje od 10) kada se bilo koja druga deterministička metoda ne može primijeniti sa sigurnošću. Preporučljivo ju je koristiti i u slučaju velikog broja podataka (npr. više od 100) te kada su podatci neravnomjerno raspodijeljeni. Glavna prednost poligonalne procjene je jednostavnost i brzina za izraditi te primjenjivost na relativno velike zone u kojima nema podataka, a potrebno ih je shematski kartirati.


Nedostatak je što nema prijelazne procjene između podataka te što se smatra da su mjerenja homogena unutar poligona i da mijenjaju vrijednosti jedino na granicama. Dobivena karta ne predstavlja pouzdan prikaz, ali se putem zona može odrediti približna raspodjela vrijednosti varijabli u analiziranom području. S obzirom na broj podataka (skup od 18 vrijednosti dubina) i površinu polja Šandrovac, jasno se mogu prepoznati glavne zone dubina strukture. Ukoliko bi broj raspoloživih podataka bio manji, zone bi bile površinom veće te manje precizne, ali bi ova metoda bila primjerenija u odnosu na krigiranje. Skup od 15 podataka je graničan broj za interpolaciju krigiranjem, a ujedno i za odabir metode Thiessenovih poligona ili interpolacije.

7.2. Tehnika običnoga krigiranja na primjeru polja Šandrovac

Preduvjet za kartiranje metodom krigiranja je izradba eksperimentalnog variograma. S obzirom na raspored koordinata položaja bušotina polja Šandrovac (**tablica 7.2.**) u programu Variowin napravljena je karta variogramske površine za varijablu „dubina“ EK markera Z' prikazana na **slici 7.6.**, uz sljedeće vrijednosti:

X: veličina ćelije: 1000 m broj ćelija: 6

Y: veličina ćelije: 1000 m broj ćelija: 6



Slika 7.6. Karta variogramske površine za varijablu „dubina“ polja Šandrovac

Na karti variogramske površine ističu se dva pravca pružanja. Njihovom usporedbom sa strukturnom kartom očitani su smjerovi glavne i sporedne variogramske osi od 135°-315° i 45°-225°. Navedeni pravci pružanja korišteni su za izračun eksperimentalnih variograma i opis anizotropije.


Na **slici 7.7.** prikazani su eksperimentalni variogram i Gaussov variogramski aproksimacijski model polja Šandrovac za varijablu „dubina“, te glavnu os pružanja (135°-315°), dobiveni uz sljedeće vrijednosti:

odstupanje 0

doseg 2 280 m

prag 45 000


7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.7. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „dubina“, glavna os pružanja 135°-315°

Na **slici 7.8.** prikazani su eksperimentalni variogram i Gaussov variogramski aproksimacijski model polja Šandrovac za varijablu „dubina“, te sporednu os pružanja (45°-225°), dobiveni uz sljedeće vrijednosti:

odstupanje 2 300
doseg 4 000 m
prag 33 120




Slika 7.8. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „dubina“, sporedna os pružanja 45°-225°

Vidi se da kod eksperimentalnog i Gaussovog teorijskog modela variograma sporedne osi za varijablu dubina nema presijecanja praga (vjerojatno zbog premalog broja parova podataka) što znači da postoji iznimno velika prostorna zavisnost. Povećanje broja razreda također nije dovelo do presijecanja praga pa je ekstrapolirana vrijednost od 4000 m za doseg.

Dobivena karta OK-a (**slika 7.9.**) s Gausovim variogramskim modelom ne poštuje pravilo kako linije neke vrijednosti ne smiju prolaziti između dvije točke (kao minimum i maksimum) gdje ne postoji neka međuvrijednost kroz koju ta linija može proći. To se smatra osnovnim

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

pravilom jednostavne («ručne») interpolacije. Drugo pravilo interpolacije glasi da se na karti ne mogu pojaviti izolocije čije su vrijednosti veće ili manje od najveće i najmanje izmjerene točke na karti. Oba ta pravila na ovoj karti nisu poštovana. Prvo vjerojatno zbog nesigurnosti sadržanih u doseg na sporednoj osi variograma i veličina ćelija, a drugo zbog dopuštanja ekstrapolacije u samome programu (što se može isključiti).




Slika 7.9. Karta dobivena običnim krigiranjem za varijablu „dubina“ u polju Šandrovac

Polje Šandrovac je ranije već analizirano tehnikom OK (Mesić Kiš i Malvić, 2014), ali tada je korišten linearni variogramski model koji se obično smatra priručnim jer pravcem opisuje regresijsku zavisnost. Zato se često takva krigiranja smatraju tek nešto boljima od inverzne udaljenosti ili takvih jednostavnijih metoda, jer jednostavna regresija može biti puno jednostavnije primijenjena u lakšim interpolacijskim algoritmima. Takvo krigiranje u stvari u sebi podrazumijeva da postoji opći trend u podacima opisan jednostavnom regresijom, znači jednom zavisnom varijablom. Stoga je ovo istraživanje ujedno i unaprijeđenje prostornoga modela za miocenske taložine u tom polju.

7.3. Primjena tehnike univerzalnoga krigiranja na podacima polja Šandrovac

U **tablici 7.2.** prikazane su x i y koordinate te vrijednosti dubina za pripadajuće koordinate. Ukoliko se želi vidjeti postoji li prostorna ovisnost između geografske širine/dužine (izražene u Gauss-Krügerovim koordinatama) i dubine, prikazuju se dijagramom raspršenja, što je ujedno i polazna točka u regresijskoj analizi (**slika 7.10.**).



Slika 7.10. Ovisnost dubine o x i y Gauss-Krügerovim koordinatama

Slika 7.10. ukazuje na linearni trend koji je pozitivan s geografskom dužinom, a negativan sa širinom. Dakle, u ovom slučaju postoje dvije nezavisne varijable (x i y koordinate) te zavisna varijabla, dubina. Ukoliko se želi ukloniti trend te dobiti ostatke temeljem kojih će se izračunati

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

semivariogramske ulazne vrijednosti potrebne za kartiranje UK, potrebno je izvršiti višestruku linearnu regresiju.

Kako je ranije napisano, potrebno je razumjeti zašto je određeni trend prisutan. Karta dobivena metodom Thiessenovih poligona već je pokazala kako se na strukturi polja vidi povećanje dubine u smjeru SZ-JI, zbog čega se na dijagramu raspršenja može uočiti pozitivan linearni trend s geografskom dužinom, a negativan sa širinom.

7.3.1. Višestruka regresijska analiza kao dio izračuna tehnike univerzalnoga krigiranja

Regresijska analiza predstavlja statistički postupak za procjenu odnosa među varijablama s ciljem utvrđivanja statističke ovisnosti, odnosno uključuje analizu varijabli s fokusom na odnos između zavisne varijable i jedne ili više nezavisnih varijabli. Najčešće procjenjuje prosječnu vrijednost zavisne varijable kada su nezavisne varijable fiksne. Postoje razne tehnike regresijske analize kao što su jednostavna, višestruka, linearna i nelinearna (npr. **Lulić, 2014**). Ako nezavisna varijabla X ima vrijednosti x_1, \dots, x_n , a zavisna varijabla y_1, \dots, y_n , odnos između dvije varijable X i Y može se prikazati preko modela:

$$y_i = f(x_i) + e_i \quad (i = 1, \dots, n) \quad (7.1)$$

gdje je $f(x)$ regresijska funkcija, a e_1, \dots, e_n nezavisne slučajne varijable. U slučaju jedne nezavisne varijable govorimo jednodimenzionalnom ili jednostavnom regresijskom modelu, a u slučaju više njih, riječ je višestrukim regresijskim modelom.

Opći oblik modela višestruke regresije je:

$$y = f(x_1, x_2, x_3, \dots, x_i, \dots, x_k) + e \quad (\text{aditivni oblik})$$

ili

$$y = f(x_1, x_2, x_3, \dots, x_i, \dots, x_k) \times e \quad (\text{multiplikativni oblik}) \quad (7.2)$$

gdje je y zavisna varijabla, što je u ovom slučaju dubina. Nezavisne varijable su x_1 i x_2 (x i y koordinate), dok varijabla e predstavlja nepoznata odstupanja od funkcionalnog odnosa. Ukoliko se pretpostavi kako je veza između zavisne i nezavisnih varijabli linearna, model iz gornje jednadžbe je model višestruke linearne regresije:

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_j + \dots + \beta_k x_k + e \quad (7.3)$$

gdje je y (dubina) opet zavisna varijabla, x_1, x_2, \dots, x_k nezavisne varijable, $\beta_1, \beta_2, \dots, \beta_k$ nepoznati parametri ili regresijski koeficijenti, a e je slučajna varijabla.

Ukoliko se pretpostavi kako se linearna regresijska veza između zavisne varijable i odabranog skupa nezavisnih varijabli utvrđuje na osnovi uzorka veličine n (npr. n mjerenja odabranih varijabli), u tom slučaju se vektorska jednadžba može napisati u obliku sustava od n jednadžbi:

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \dots + \beta_j x_{1j} + \dots + \beta_k x_{1k} + e_1 \\ y_2 &= \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \dots + \beta_j x_{2j} + \dots + \beta_k x_{2k} + e_2 \\ &\vdots \\ y_i &= \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_j x_{ij} + \dots + \beta_k x_{ik} + e_i \\ &\vdots \\ y_n &= \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \dots + \beta_j x_{nj} + \dots + \beta_k x_{nk} + e_n \end{aligned} \quad (7.4)$$

Procjena vrijednosti parametara može se izvršiti metodom najmanjih kvadrata. Ako uvrstimo u $Y = X\beta + e$ umjesto vektora parametara β vektor njihovih procjena, tada je:

$$\begin{aligned} Y &= X\hat{\beta} + \hat{e} \\ \hat{e} &= Y - X\hat{\beta} \end{aligned} \quad (7.5)$$

gdje \hat{e} predstavlja procjenu slučajne varijable na bazi uzorka e i zove se rezidualnim odstupanjem. Procjena koeficijenata β dobije se iz rješenja normalnih jednadžbi metode najmanjih kvadrata:

$$\begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik} &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{i1} + \hat{\beta}_1 \sum_{i=1}^n x_{yi1}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{i1} x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{i1} x_{ik} &= \sum_{i=1}^n x_{i1} y_i \\ \vdots & \\ \hat{\beta}_0 \sum_{i=1}^n x_{ik} + \hat{\beta}_1 \sum_{i=1}^n x_{ik} x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{ik} x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik}^2 &= \sum_{i=1}^n x_{ik} y_i \end{aligned} \quad (7.6)$$

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

U nastavku će navedene jednačbe biti primijenjene na primjeru podataka iz polja Šandrovac (**tablica 7.3.**). Kako imamo dvije nezavisne varijable, procijenjeni model ima sljedeću jednačbu:

$$\hat{y} = \hat{\alpha} + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 \quad (7.7)$$

Tablica 7.3. Ulazne vrijednosti varijabli za višestruku regresijsku analizu

i	y, dubina	x₁, x koordinate	x₂, y koordinate
1	1120	6418000	5086200
2	1200	6418200	5085200
3	1150	6418400	5086000
4	1280	6418800	5084800
5	1240	6419200	5085600
6	950	6419000	5088000
7	1000	6420000	5087200
8	880	6420400	5088400
9	1120	6420400	5087000
10	1200	6420400	5086600
11	1300	6420800	5086000
12	1040	6422000	5088200
13	1320	6421800	5087000
14	1430	6421900	5086400
15	1500	6421900	5086000
16	1520	6422000	5085800
17	1700	6423000	5085000
18	1480	6421000	5085600
Suma	22430	115567200	91555000

Iz **tablice 7.3.** dobiveni su sljedeći podatci:

$$\begin{aligned} \sum_{i=1}^{18} x_1 &= 115567200 & \sum_{i=1}^{18} x_2 &= 91555000 & \sum_{i=1}^{18} y &= 22430 \\ \sum_{i=1}^{18} x_1^2 &= 7,41988 * 10^{14} & \sum_{i=1}^{18} x_2^2 &= 4,65684 * 10^{14} & \sum_{i=1}^{18} y^2 &= 28763900 \\ \sum_{i=1}^{18} x_1 x_2 &= 5,8782 * 10^{14} & \sum_{i=1}^{18} x_1 y &= 1,44013 * 10^{11} & \sum_{i=1}^{18} x_2 y &= 1,14085 * 10^{11} \end{aligned}$$

Uvrštavanjem dobivenih konkretnih vrijednosti u normalne **jednačbe (7.6)** dobije se:

$$18\hat{\alpha} + 115567200\hat{\beta}_1 + 91555000\hat{\beta}_2 = 22430$$

$$115567200\hat{\alpha} + 7,41988 * 10^{14}\hat{\beta}_1 + 5,8782 * 10^{14}\hat{\beta}_2 = 1,44013 * 10^{11}$$

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

$$91555000\hat{\alpha} + 5,8782 * 10^{14}\hat{\beta}_1 + 4,6568 * 10^{14}\hat{\beta}_2 = 1,4085 * 10^{11}$$

Rješavanjem navedenih sustava jednadžbi dobiju se koeficijenti linearne regresije:

$$\hat{\alpha} = 218079,911121684, \hat{\beta}_1 = 0,0939341451009042 \text{ i } \hat{\beta}_2 = -0,16120053010644,$$

što znači da je procijenjena regresijska jednadžba:

$$\hat{y} = 218079,911121684 + 0,0939341451009042x_1 - 0,16120053010644x_2$$

Ako se u procijenjenu regresijsku jednadžbu za svaki $i = 1, 2, \dots, 18$, uvrste stvarne vrijednosti nezavisnih varijabli x , dobiju se regresijske vrijednosti \hat{y} zavisne varijable y . Prva regresijska vrijednost \hat{y} dobiva se uvrštavanjem varijabli x_1 i x_2 :

$$\hat{y} = 2218079,911121684 + 0,0939341451009042 * 6418000 - 0,16120053010644 * 5086200 = 1051,118152$$

Rezidualna odstupanja ili ostatci se dobiju oduzimanjem stvarne vrijednosti zavisne varijable od procijenjene. Konkretno, prvo rezidualno odstupanje iznosi:

$$\hat{e}_1 = y_1 - \hat{y}_1 = 1120 - 1051,118152 = 68,88184811$$

U **tablici 7.4** prikazane su sve ostale regresijske vrijednosti i rezidualna odstupanja.

Tablica 7.4. Vrijednosti ostataka dobivenih višestrukom linearnom regresijom

i	y, dubina	x₁, x koordinate	x₂, y koordinate	\hat{y}_i	e_i	e^2
1	1120	6418000	5086200	1051,118152	68,88184811	4744,709
2	1200	6418200	5085200	1231,105511	-31,10551102	967,5528
3	1150	6418400	5086000	1120,931916	29,06808405	844,9535
4	1280	6418800	5084800	1351,94621	-71,94621012	5176,257
5	1240	6419200	5085600	1260,559444	-20,55944407	422,6907
6	950	6419000	5088000	854,8913428	95,1086572	9045,657
7	1000	6420000	5087200	1077,785912	-77,78591198	6050,648
8	880	6420400	5088400	921,9189339	-41,9189339	1757,197
9	1120	6420400	5087000	1147,599676	-27,59967605	761,7421
10	1200	6420400	5086600	1212,079888	-12,07988809	145,9237
11	1300	6420800	5086000	1346,373864	-46,37386419	2150,535
12	1040	6422000	5088200	1104,453672	-64,45367208	4154,276
13	1320	6421800	5087000	1279,107479	40,89252081	1672,198
14	1430	6421900	5086400	1385,221212	44,77878824	2005,14
15	1500	6421900	5086000	1449,701424	50,2985762	2529,947
16	1520	6422000	5085800	1491,334944	28,66505566	821,6854
17	1700	6423000	5085000	1714,229514	-14,22951352	202,4791
18	1480	6421000	5085600	1429,640905	50,35909474	2536,038
Suma	22430	115567200	91555000		0	45989,63

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

Dobivene vrijednosti mogu se izračunati ručno, a preporučljivo ih je provjeriti Excel-om (**slika 7.11.**) pomoću programske naredbe analize podataka (engl. *data analysis*).

SUMMARY OUTPUT						RESIDUAL OUTPUT		
Regression Statistics						Observation	Predicted Y	Residuals
Multiple R	0,971326843					1	1051,118152	68,88184811
R Square	0,943475836					2	1231,105511	-31,10551102
Adjusted R Square	0,935939281					3	1120,931916	29,06808405
Standard Error	55,37124991					4	1351,94621	-71,94621012
Observations	18					5	1260,559444	-20,55944407
ANOVA						6	854,8913428	95,1086572
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>	7	1077,785912	-77,78591198
Regression	2	767638,1	383819,1	125,1866158	4,38E-10	8	921,9189339	-41,9189339
Residual	15	45989,63	3065,975			9	1147,599676	-27,59967605
Total	17	813627,8				10	1212,079888	-12,07988809
Coefficients						11	1346,373864	-46,37386419
	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>	12	1104,453672	-64,45367208
Intercept	218079,9111	81502	2,675761	0,017277801	44362,51	391797,3	44362,51	391797,3
x1	0,093934145	0,008845	10,61947	2,25333E-08	0,07508	0,112788	0,07508	0,112788
x2	-0,16120053	0,012661	-12,7317	1,91716E-09	-0,18819	-0,13421	-0,18819	-0,13421
y=218079,9+0,093934x1-0,1612x2						13	1279,107479	40,89252081
						14	1385,221212	44,77878824
						15	1449,701424	50,2985762
						16	1491,334944	28,66505566
						17	1714,229514	-14,22951352
						18	1429,640905	50,35909474

Slika 7.11. Vrijednosti varijable „ostatci“ dobivene u Excelu

Na konkretnom primjeru može se izračunati i procjena varijance $\hat{\sigma}$ prema sljedećoj jednadžbi:

$$\hat{\sigma} = \sqrt{\frac{SSE}{n-p}} = \sqrt{\frac{45989,63}{18-3}} = 55,37125 \quad (7.8)$$

gdje su:

SSE – suma kvadrata odstupanja empirijskih vrijednosti varijable y od \hat{y} (odstupanja ne protumačena modelom), ili u tablici 4.3. suma od e^2 ,

n – broj podataka,

p – broj parametara, u ovom slučaju 3 (dubina, x i y koordinate).

Dobivena vrijednost služi kako bi se odredio koeficijent varijacije regresije:

$$V = \frac{\hat{\sigma}}{\bar{y}} * 100 = \frac{55,37125}{\frac{22430}{18}} * 100 = 4,44 \% \quad (7.9)$$


Navedeni koeficijent predstavlja postotak standardne pogreške regresije od aritmetičke sredine varijable y . Često se uzima dogovorena granica reprezentativnosti od 30%, a što je bliži nuli, to je model reprezentativniji. Tako dobivena vrijednost koeficijenta varijacije regresije od 4,44% ukazuje kako je model dobar.

7.3.2. Variogrami ostataka

Iz ostataka dobivenih višestrukom linearnom regresijom dobivena je variogramaska površina u programu Variowin prikazana **slikom 7.12.**, uz sljedeće vrijednosti:

X: veličina ćelije: 800 m broj ćelija: 5

Y: veličina ćelije: 800 m broj ćelija: 5



Slika 7.12. Karta variogramske površine za varijablu „ostatci“ polja Šandrovac

Pogledom na kartu variogramske površine uočava se postojanje dvaju pravaca pružanja, glavne i sporedne osi 135° - 315° i 45° - 225° . Navedeni pravci pružanja korišteni su za izradbu eksperimentalnih variograma.


Na **slici 7.13.** prikazani su eksperimentalni variogram i sferni variogramski aproksimacijski model polja Šandrovac za varijablu „ostatci (residuals)“, te glavnu os pružanja (135° - 315°), dobiveni uz sljedeće vrijednosti:

odstupanje 0

doseg 1638 m

prag 2450


7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac



Slika 7.13. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „ostatci (residuals)“, glavna os pružanja 135°-315°

Na **slici 7.14.** prikazani su eksperimentalni variogram i sferni variogramski aproksimacijski model polja Šandrovac za varijablu „ostatci (residuals)“, te sporednu os pružanja (45°-225°), dobiveni uz sljedeće vrijednosti:


odstupanje 0
doseg 2280 m
prag 2470



Slika 7.14. Eksperimentalni variogram i variogramski aproksimacijski model polja Šandrovac, varijabla „ostatci (residuals)“, sporedna os pružanja 45°-225°

7.3.3. Karta dobivena tehnikom univerzalnog krigiranja

Slika 7.15. prikazuje kartu dobivenu tehnikom UK. Kao i kod metode Thiessenovih poligona, uočljivo je kako struktura tone prema JI, gdje su najveće dubine od 1700 m. Može se zaključiti da je riječ o homoklini koja je, ako se pogleda strukturna karta po plohi EK markera Z' (**slika 7.2.**), dio regionalne monokline.



Slika 7.15. Karta dobivena univerzalnim krigiranjem za varijablu „dubina“ u polju Šandrovac

7.4. Metoda krosvalidacije na primjeru polja Šandrovac

Izbor između najbolje odgovarajućih metoda najbolje je načiniti postupkom krosvalidacije. U prijašnjem radu (Mesić Kiš i Malvić, 2014) već je prikazano kako metoda krigiranja predstavlja bolju i točniju interpolacijsku metodu u usporedbi s metodom Thiessenovih poligona. Međutim, i ona ima prednosti budući da pruža zonalnu procjenu dubine unutar cijele subdepresije. Obje metode imaju svoje prednosti i nedostatke navedene u tablici 7.5., te ih je preporučljivo koristiti uporedo.

Tablica 7.5. Usporedba metode Thiessenovih poligona i metode krigiranja

Metoda	Prednosti	Nedostatci	Preporuka
Metoda Thiessenovih poligona	Jednostavno i brzo; Procjena neuzorkovanih područja; Pokazatelj strukturnih oblika i područja gdje se nalaze ekstremi.	Nema prijelazne procjene između podataka (oštre granice)	Koristiti u slučaju skupa podataka manjeg od 10, kada se bilo koja druga deterministička metoda ne može primijeniti sa sigurnošću
Interpolacija krigiranjem	Vrlo precizno, uglavnom najprecizniji interpolacijski deterministički algoritam	Zahtijeva pouzdan variogramski model te poznavanje algoritma	Koristiti za skupove od 15 ili više podataka, kada variogramski model može biti pouzdan

Metodom krosvalidacije izračunata je kvadratna pogriješka procjene (engl. *mean square error*, MSE), najpodcjenjeniji (engl. *most under-estimated data*) i najprecjenjeniji podatak (engl. *most over-estimated data*) za kartu dubina u polju Šandrovac izrađenom tehnikom OK. Rezultati krosvalidacije su:


- a) kvadratna pogriješka varijable „dubine“ 29269;
- b) korijen srednje kvadratne pogriješke (engl. *root mean square error*, RMSE) varijable „dubine“ 171;
- c) najpodcjenjeniji podatak nalazi se na $X = 6423000$, $Y = 5085000$, gdje je izmjerena vrijednost varijable „dubine“ $I=1700$, a procijenjena vrijednost varijable „dubine“ $P=1419$;
- d) najprecjenjeniji podatak nalazi se na $X = 6422000$, $Y = 5088200$, gdje je izvorna vrijednost varijable „dubine“ $I=1040$, a procijenjena vrijednost varijable „dubine“ $P=1552$.

Metodom krosvalidacije izračunata je kvadratna pogriješka procjene (MSE), najpodcjenjeniji (engl. *most under-estimated data*) i najprecjenjeniji podatak (engl. *most over-estimated data*) za kartu dubina u polju Šandrovac izrađenom i tehnikom UK. Rezultati krosvalidacije su:

7. Rezultati uporabe zonalne procjene i tehnika krigiranja na primjeru polja Šandrovac

- kvadratna pogreška varijable „dubine“ 3473;
- korijen srednje kvadratne pogreške varijable „dubine“ 59;
- najpodcjenjeniji podatak nalazi se na $X=6419000$, $Y=5088000$ gdje je izmjerena vrijednost varijable „dubine“ $I=950$, a procijenjena vrijednost varijable „dubine“ $P=815$;
- najprecjenjeniji podatak nalazi se na $X=6422000$, $Y=5088200$, gdje je izvorna vrijednost varijable „dubine“ $I=1040$, a procijenjena vrijednost varijable „dubine“ $P=1127$.

Rezultati krosvalidacije tehnike OK-a imaju veću vrijednost u usporedbi s UK što je potvrda tvrdnji kako je UK bolja interpolacijska tehnika za strukturu takve veličine s izraženim trendom u ulaznim podacima. Međutim, potrebno je usporediti i dobivene izlazne karte (**slika 7.16.**). Karta OK i u tom slučaju predstavlja lošije rješenje jer, kako je ranije navedeno, linija neke vrijednosti ne smije prolaziti između dvije točke (kao minimum i maksimum) gdje ne postoji neka međuvrijednost kroz koju ta linija može proći (linija 1800 na desnom rubu karte ne poštuje to pravilo).



Slika 7.16. Izlazne karte dobivene tehnikama običnog i univerzalnog krigiranja. Crvenom bojom označen je najprecjenjeniji, a plavom najpodcjenjeniji podatak

S obzirom na broj ulaznih podataka (ukupno 18) i veličinu polja Šandrovac, tehnika UK pokazala se najprimjerenijom za interpolaciju dubina donjopontskih naslaga. Metoda Thiessenovih poligona dala je prikaz slične strukture, dok se jasna homoklina vidi tek tehnikom UK.


8. REZULTATI UPORABE ZONALNE PROCJENE I ODABRANIH TEHNIKA KRIGIRANJA NA PRIMJERU BJELOVARSKJE SUBDEPRESIJE

Metode primijenjene u ovome poglavlju odnose se na procjenu vrijednosti dubina metodom Thiessenovih poligona te običnim i univerzalnim krigiranjem na području Bjelovarske subdepresije temeljene na postojećim podacima iz **Malvić, 2003**. Korišteni su podaci s vrijednostima apsolutnih dubina po granici Pt/Tg, te plohami EK markera Rs7, Rs5, Z', delta (Δ) i D'. Osnovna statistika načinjena je pomoću koordinata točaka s podacima dubine dobivenih iz baze koja je priređena na temelju pravilne mreže (2x2 km) kojom su prekrivene paleostrukturalne karte Bjelovarske subdepresije (uspješno na primjeru EK granice Pt/Tg i EK markera Rs7 i Rs5 u radu **Špelić i sur., 2016**) objavljene u **Malvić (2003, 2011)**). Navedena metoda prijenosa ručnih karata u računalno izrađene karte pomoću umjetne mreže podataka predstavlja učinkovito digitaliziranje starih karata. Novim kartama očuvani su glavni strukturni oblici te se tako dobiveni ulazni podaci mogu smatrati reprezentativnima.

Ukoliko se promatraju točkasti podaci u središtima ćelija veličine 2x2 km mreže kojom je prekrivena Bjelovarska subdepresija, a kojima se može načiniti analiza, tada postoje 742 točke vrijednosti apsolutne dubine očitane sa strukturne karte koje se nalaze na području Bjelovarske subdepresije na Pt/Tg granici koja je rezultat dugotrajne regionalne emerzije tijekom paleogena i donjeg neogena u HPBS-u. Minimalna dubina (MIN) je 80 m, a maksimalna (MAX) 3650 m. Vrijednost medijana je 1715 m, a on je i manje osjetljiv na ekstremne vrijednosti od aritmetičke sredine koja iznosi 1691,38 m (**slika 8.1**).

S obzirom na raspon vrijednosti minimuma i maksimuma, dubine su podijeljene u 10 razreda pri čemu veličina svakog ima raspon od 400 m. Prema izračunu najviše dubina na karti pripada razredu od 2000 do 2400 m dubine te je riječ o dubljevodnom području.


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.1. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz paleoreljefne karte EK granice Pt/Tg


Pravilna mreža veličine ćelija 2x2 km kojom je prekrivena strukturalna karta Bjelovarske subdepresije po plohi EK markera Rs7 sadrži 742 točkasta podatka vrijednosti dubina, od čega 34 podatka imaju vrijednost 0 m, što se odnosi se na dijelove pravilne mreže gdje nije bilo dovoljno podataka za interpolaciju i očitavanje vrijednosti dubina pa je koordinatama dodijeljena navedena vrijednost. Navedeni skup od 34 podatka s vrijednostima 0 nije korišten za računanje statističkih parametara prikazanih na histogramu (**slika 8.2.**), a isto će biti učinjeno i u slučaju EK markera Rs5, Z' i Δ na kojim je kartama također zabilježena diskordancija. Najmanja dubina iznosi 110 m, a najveća 3400 m. Vrijednost 0 odnosi se na dijelove pravilne mreže gdje nije bilo dovoljno podataka za interpolaciju i očitavanje vrijednosti dubina pa je koordinatama dodijeljena navedena vrijednost, odnosno tu nije bilo podataka. Na granici sarmat/donji panon dubine se očekivano smanjuju, a najviše podataka je unutar razreda dubine od 1600 – 2000 m. Vrijednost medijana je 1192,5 m, a aritmetičke sredine 1302,5 m (**slika 8.2.**).

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije



Slika 8.2. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Rs7

Broj točkastih podataka vrijednosti apsolutnih dubina dobiven iz pravilne mreže koja prekriva strukturnu kartu po plohi markera Rs5, iznosi 743 (**slika 8.3.**). Minimalna vrijednost dubine iznosi 260 m ne računajući vrijednosti diskordancije, a nedostaje puno više podataka za interpolaciju u odnosu na prošli marker (čak 232 od 743) zbog diskordancije. Maksimalna vrijednost dubine iznosi 3140 m. Vrijednost medijana je 900 m, a aritmetičke sredine 1104 m. Na granici donji/gornji panon najviše dubina na karti nalazi se unutar dubinskog razreda od 400 – 800 m dubine te je riječ o znatno plićem okolišu u odnosu na granicu sarmat/donji panon.



Slika 8.3. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Rs5

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije


Na području Bjelovarske subdepresije po plohi EK markera Z' nalazi se ukupno 497 točkastih podataka vrijednosti apsolutnih dubina gdje minimalna današnja dubina (MIN) iznosi 80 m, a maksimalna (MAX) 2800 m, ne računajući koordinate pravilne mreže s vrijednosti 0 m koje označavaju površinu diskordancije. U tom slučaju ima sveukupno 720 podataka koji će biti korišteni za kartiranje varijable dubine po plohi EK markera Z'.

Vrijednost medijana je 610 m, a aritmetičke sredine 855 m (slika 8.4.). Broj razreda k aproksimira se izrazom 8.1:

$$k = 1 + 3,3 \log N \quad (8.1)$$

gdje za konkretan slučaj ($N = 497$), k iznosi 9,9.

S obzirom na raspon vrijednosti minimuma i maksimuma, dubine su podijeljene u 10 razreda pri čemu veličina svakog ima raspon od 300 m. Prema izračunu najviše dubina na karti pripada razredu od 300 do 600 m dubine. Gotovo 50% (49,23%) podataka nalazi se na dubini do 600 m, nakon čega se broj podataka po razredu širine 300 m smanjuje. Navedeni podatci predstavljaju današnje dubine pa se može izvesti zaključak da je na području većih debljina Bjelovarske subdepresije u vrijeme gornjega panona i početka ponta prevladavao dublji prostor koji se sinsedimentacijski spuštao. Posljedično su debljine pratećih informacija veće, što se može razlučiti i na histogramu.




Slika 8.4. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru Z'

Po plohi EK markera Δ nalazi se ukupno 727 vrijednosti apsolutnih dubina kojom je prekriveno područje cijele Bjelovarske subdepresije, a na temelju koje je izrađena osnovna statistička analiza prikazana histogramom (slika 8.5.). U odnosu na prijašnji marker, prekrivena je gotovo

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije


cijela subdepresija, skupu od 70 podataka pridodana je vrijednost 0 m prekrivanjem subdepresije pravilnom mrežom podataka. Najveća dubina je 2100 m, a najmanja 80 m. Srednja vrijednost iznosi 550 m, dok je vrijednost medijana 610. Vrijednosti su podijeljene u dubinske razrede širne 250 m, a najviše podataka pripada dubinskom razredu od 250 do 500 m. Na granici gornjeg i donjeg Ponta smanjuje se maksimalna dubina što ukazuje na oplićavanje (vidi **potpoglavlje 4.2., slika 4.8.**).



Slika 8.5. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru delta

Na području Bjelovarske subdepresije po plohi EK markera D' nalazi se ukupno 739 točkastih podataka vrijednosti apsolutnih dubina pravilne mreže, od čega je 36 podataka pridodana vrijednost 0 m koja ne ulaze u statističku analizu prikazanu histogramom (**slika 8.6.**). Minimalna dubina (MIN) iznosi 10 m, a maksimalna (MAX) 850 m. Očito je smanjenje dubine i taložnog prostora. Vrijednost medijana je 235 m, a aritmetičke sredine 260 m (**slika 8.6.**). S obzirom na raspon vrijednosti minimuma i maksimuma, dubine su i u ovom slučaju podijeljene u 10 razreda, ali zbog manjih vrijednosti dubina veličina svakog razreda ima raspon od 100 m. Prema izračunu najviše dubina na karti pripada razredu od 200 do 300 m dubine, a čak 80 % je do 400 m dubine što ukazuje na daljnje oplićavanje te okopnjavanje (vidi **potpoglavlje 4.2, slika 4.9.**).

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.6. Histogram statističkih vrijednosti dubina i dubinskih razreda dobiven iz strukturne karte po EK markeru D'

8.1. Primjena Thiessenovih poligona na području Bjelovarske subdepresije

Istraživano područje Bjelovarske subdepresije ograničeno je poligonom čiji su vrhovi na sljedećim Gauss-Krügerovim koordinatama (X,Y): 6377800 – 5091900, 6390900 – 5108400, 6404000 – 5108400, 6409800 – 5106600, 6418000 – 5102800, 6437800 – 5085000, 6458100 – 5050400, 6444600 – 5056200, 6441200 – 5055800, 6439000 – 5040900, 6429100 – 5040600, 6433000 – 5031500, 6409900 – 5048600, 6408400 – 5050500, 6411000 – 5059300, 6410200 – 5064900, 6400000 – 5062300, 6392000 – 5068500.

Karte Thiessenovih poligona izrađene su u programu SAGA GIS 2.1.0. **Slika 8.7.** prikazuje zonalnu procjenu vrijednosti dubina Bjelovarske subdepresije Pt/Tg granice. Kao izvor podataka korištena je pravilna mreža vrijednosti apsolutnih dubina kojima je prekrivena paleoreljefna karta Pt/Tg EK granice. Kako je riječ o pravilnoj mreži, poligoni su pravilnih, zatvorenih oblika. Svaki poligon poprimio je vrijednost točke u njemu što je prikazano odgovarajućom bojom. Najveće vrijednosti dubina (od 3600 – 4000 m) smještene su u središnjem dijelu subdepresije, a najmanje u zapadnom.


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.7. Thiessenovi poligoni vrijednosti dubina Pt/Tg granice unutar Bjelovarske subdepresije

Karta Thiessenovih poligona Bjelovarske subdepresije po plohi EK markera Rs7 prikazana je na **slici 8.8**. Najveće dubine na granici sarmat/donji panon i dalje su u središnjem dijelu subdepresije, dok su sjevernom i jugozapadnom dijelu plići okoliši. Na strukturnoj karti po plohi EK markera Rs7 (**slika 4.5.**), zapadni dio je odvojen diskordancijom i krajnji jugoistočni dio. Zbog toga su u pravilnoj mreži tim koordinatama pridružene vrijednosti 0 (što je označeno tamnoplavom bojom Thiessenovih poligona).


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.8. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Rs7 unutar Bjelovarske subdepresije

Karta Thiessenovih poligona Bjelovarske subdepresije po plohi EK markera Rs5 prikazana je **slikom 8.9**. Diskordancija je jasno izražena tamnoplavom bojom Thiessenovih poligona u južnom dijelu subdepresije.


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.9. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Rs5 unutar Bjelovarske subdepresije

Karta Thiessenovih poligona Bjelovarske subdepresije po plohi EK markera Z' izrađena je u programu SAGA GIS 2.1.0. (slika 8.10.). Navedeni marker dijeli formacije Ivanić Grad i Kloštar Ivanić, odnosno predstavlja granicu gornjeg panona i donjeg pontka kada su ogromne količine klastita mehanizmom turbiditnih struja transportirane iz Istočnih Alpi u HPBS. Kako su za izradbu karte korišteni podatci pravilne mreže 2x2 km kojima je prekrivena Bjelovarska subdepresija, Thiessenovi poligoni su pravilnog kvadratičnog oblika. Dio subdepresije koji prekrivaju Thiessenovi poligoni tamnoplave boje i u ovom slučaju predstavljaju diskordanciju.


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.10. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Z' unutar Bjelovarske subdepresije

Broj podataka vrijednosti dubine područja Bjelovarske subdepresije po plohi EK markera delta (Δ) iznosi 727. Taj marker predstavlja granicu gornjega i donjega ponta te dijeli formacije Kloštar-Ivanić i Bilogora. Vremenski je to i prijelaz iz 2. transtenzijske u 2. transpresijsku fazu (**tablica 4.1.**). Navedeni marker prekriva i južni dio subdepresije gdje više nema diskordancije, a tamo su i najveće dubine do 2000 m prikazane tamno crvenom bojom Thiessenovih poligona (**slika 8.11.**).


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.11. Thiessenovi poligoni vrijednosti dubina po plohi EK markera Δ unutar Bjelovarske subdepresije

Broj podataka vrijednosti dubine područja Bjelovarske subdepresije po plohi EK markera D' iznosi 739, a prekrivaju cijelu subdepresiju. Rezultat je izrazito pravilan oblik Thiessenovih poligona prikazan **slikom 8.12**. Lako se uočavaju dva dubljevodna područja u središnjem u jugozapadnom dijelu subdepresije, dok je na granici pont/pliocen veći dio prostora bio plići do kopneni. Dobivena karta opet daje zonalnu procjenu, a zbog pokrivenosti cijele subdepresije pravilnom mrežom podataka, predstavlja i dobar način provjere kasnije izrađenih karata tehnikama krigiranja.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije



Slika 8.12. Thiessenovi poligoni vrijednosti dubina po plohi EK markera D' unutar Bjelovarske subdepresije


8.2. Primjena tehnike običnoga krigriranja na području Bjelovarske subdepresije

Kao što je već ranije objašnjeno, preduvjet za tehniku krigriranja izradba je eksperimentalnoga variograma nakon čega slijedi njegova aproksimacija odabranim teorijskim modelom. U nastavku slijede prikazi izrađenih eksperimentalnih i iz njih izvedenih teorijskih modela variograma glavne i sporedne osi varijable dubine Pt/Tg granice i EK markera Rs7, Rs5, Z' i D', a na razini cijele subdepresije. Prikazani su i eksperimentalni te teorijski modeli variograma za varijablu ostatci, budući su uporabljeni kao ulaz za tehniku UK.

Korištene su sljedeće ulazne vrijednosti (vidi **potpoglavlje 5.2.**) pri izradbi svih variograma: veličina koraka/ćelije (h) = 2000 m; broj koraka = 20; kutna tolerancija = 45° . Smjer za glavnu os iznosio je 120° , a za sporednu 210° . U slučaju granice Pt/Tg, markera Rs7 i Rs5, kod sporedne osi veličina koraka (h) iznosila je 2500 m, a broj koraka 15. Navedeni smjerovi određeni su pomoću karata variogramskih površina izrađenih u Variowinu i strukturnih karata markera. Primjer variogramske površine prikazan je **slikom 8.13.** za što su korištene vrijednosti

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

dubine EK granice Pt/Tg. Slika prikazuje dvije osi, a odabir između glavne i sporedne osi radi se na temelju te i strukturne karte.




Slika 8.13. Karta variogramske površine za varijablu „dubina“ Bjelovarske subdepresije


8.2.1. Eksperimentalni i teorijski modeli variograma varijable dubine za glavnu i sporednu os

Eksperimentalni variogrami glavne (**slika 8.14.**) i sporedne osi (**slika 8.15.**) varijable dubine na EK granici Pt/Tg imaju značajnu razliku u dosegu. Glavna os smjera 120°-300° ima doseg od 29 000 m, dok prag iznosi oko 600 000. Sporedna os smjera 30°-210° ima doseg u iznosu od 15 000 m. Smjer glavne i sporedne osi odgovara geološkoj osi strukture Bjelovarske subdepresije. Pt/Tg granica odražava oblik pred-neogenskog paleoreljefa, odnosno početak regionalne transgresije.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.14. Eksperimentalni variogram glavne osi za varijablu „dubina“ EK granice Pt/Tg



Slika 8.15. Eksperimentalni variogram sporedne osi za varijablu „dubina“ EK granice Pt/Tg


Eksperimentalni variogram glavne osi aproksimiran je Gausovim teorijskim modelom (slika 8.16.) uz sljedeće vrijednosti: odstupanje 54 000, doseg 30 040 m i prag 600 000.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.16. Aproximacija eksperimentalnog variograma dobivenog iz paleoreljefne karte EK granice „Pt/Tg“ pomoću Gaussovog modela

Dobiveni eksperimentalni variogrami glavne (slika 8.17.) i sporedne osi (slika 8.18.) varijable dubine po plohi EK markera Rs7 također pokazuju razliku u dosegu, ali je znatno manja u odnosu na prethodni slučaj. Glavna os smjera 120°-300° ima doseg od 24 000 m, dok prag iznosi oko 500 000. Sporedna os smjera 30°-210° ima doseg u iznosu od 18 000 m. Smanjenje dosega može se interpretirati kao posljedica smanjenja površine taložnog okoliša, prijelazom iz morskog u veliki jezerski okoliš što za posljedicu ima i smanjenje kontinuiteta pružanja slojeva.




Slika 8.17. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Rs7

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.18. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Rs7


Eksperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.19.) uz sljedeće vrijednosti: odstupanje 0, doseg 29 600 m i prag 500 000.




Slika 8.19. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Rs7 pomoću sfernog modela

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

Strukturna karta po plohi EK markera Rs5 (slika 4.6.) prikazuje izraženu diskordanciju na istoku subdepresije što je smanjilo broj podataka pa je time i manji doseg. Eksperimentalni variogram glavne osi (slika 8.20.) prikazuje doseg od 15 000 m, a sporedne osi 13 000 m (slika 8.21.) Smanjenje taložnog bazena se nastavilo predstavljajući zadnju fazu promjene iz morskog u jezerski okoliš.




Slika 8.20. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Rs5



Slika 8.21. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Rs5


8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije

Ekperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.22.) uz sljedeće vrijednosti: odstupanje 11 200, doseg 18 000 m i prag 560 000.




Slika 8.22. Aproximacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Rs5 pomoću sfernog modela

Dobiveni eksperimentalni variogrami glavne (slika 8.23.) i sporedne osi (slika 8.24.) varijable dubine po plohi EK markera Z' ne pokazuju razliku u dosegu. Glavna os smjera 120°-300° i sporedna os smjera 30°-210° imaju doseg od 14 000 m, dok prag iznosi oko 440 000.




Slika 8.23. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Z'

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije



Slika 8.24. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Z'


Eksperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.25.) uz sljedeće vrijednosti: odstupanje 72 000, doseg 24 000 m i prag 450 000. Nešto veći doseg rezultat je djelovanja turbiditnih struja koje su na granici panon/pont bile glavni mehanizam transporta.




Slika 8.25. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Z' pomoću sfernog modela

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije

Eksperimentalni variogrami glavne (slika 8.26.) i sporedne osi (slika 8.27.) varijable dubina po plohi EK markera Δ imaju različite dosege, ali je u ovom slučaju veći za sporednu os (40 000 m) u odnosu na glavnu os (36 000 m), dok je vrijednost praga oko 140 0000. To su najveće vrijednosti dosega, krivulja tek na kraju siječe prag što upućuje na veliku prostornu zavisnost podataka.




Slika 8.26. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera Δ



Slika 8.27. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera Δ

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije


Ekperimentalni variogram glavne osi varijable dubine Δ markera smjera 120° - 300° , aproksimiran je sfernim teorijskim modelom uz sljedeće vrijednosti: odstupanje 0, doseg 40 000 m , prag 150 000 (slika 8.28.).




Slika 8.28. Aproksimacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru Δ pomoću sfernog modela

Dobiveni eksperimentalni variogrami glavne (slika 8.29.) i sporedne osi (slika 8.30.) varijable dubine po plohi EK markera D' također pokazuju razliku u dosegu. Glavna os smjera 120° - 300° ima doseg od 19 000 m, a sporedna os smjera 30° - 210° ima doseg u iznosu od 12 500 m. Vrijednosti dosega su značajno smanjene u odnosu na variograme dobivene iz strukturnih karata po EK markeru Δ . Navedeno ukazuje na smanjenje taložnog prostora na granici gornjeg pontaa i pliocena.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.29. Eksperimentalni variogram glavne osi za varijablu „dubina“ po plohi EK markera D'



Slika 8.30. Eksperimentalni variogram sporedne osi za varijablu „dubina“ po plohi EK markera D'

Eksperimentalni variogram glavne osi aproksimiran je Gausovim teorijskim modelom (slika 8.31.) uz sljedeće vrijednosti: odstupanje 1 160, doseg 19 229 m i prag 29 000.




Slika 8.31. Aproximacija eksperimentalnog variograma dobivenog iz strukturne karte po EK markeru D' pomoću Gaussovog modela

8.2.2. Karte dubina EK markera Bjelovarske subdepresije dobivene tehnikom običnoga krigiranja

Dobivene karte izrađene su u Surferu tehnikom OK-a. Izradbi karata prethodila je variogramska analiza objašnjena u prijašnjem potpoglavlju. Dobivene vrijednosti dosega, odstupanja i praga unešene su u program te su dobivene izlazne karte koje su objašnjene i prikazane u nastavku. Kao ulazni podatci korištene su vrijednosti varijable dubine sa strukturnih karata Bjelovarske subdepresije (slike 4.4. – 4.9.) priređene u pravilnoj mreži 2x2 km.

Slika 8.32. predstavlja kartu paleoreljefa pred-neogenske podloge Bjelovarske subdepresije smjera pružanja SZ-JI. Plava boja predstavlja najpliće dijelove, dok su crvenom bojom označeni dublji dijelovi do 3600 m dubine smješteni u središnjem dijelu subdepresije koji predstavljaju ostatke manjih taložnih centara.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije




Slika 8.32. Karta OK dobivena iz paleoreljefne karte Bjelovarske subdepresije EK granice Pt/Tg

Rasjedi na karti nisu ucrtani, ali se glavna rasjedna zona može prepoznati po obliku i gustoći startoizohipsa koja je transverzalna na glavnu os subdepresije.

Na granici sarmat/panon najdublji dijelovi subdepresije do 3200 m zadržali su se u središnjem dijelu te prate pružanje subdpresije u smjeru SZ-JI (**slika 8.33.**). Vidljiva su dva taložna centra; manji u središnjem dijelu i veći koji se širi prema jugoistoku odvojen antiklinalom duž Psunja. Najplići dijelovi su u sjevernom (što je objašnjeno pomakom rasjeda od 1000 m) i krajnjem jugoistočnom dijelu subdepresije koji su na površini duž graničnih planina. Tehnika OK je i u ovom slučaju dala vjeran prikaz vrijednosti dubina i struktura po plohi EK markera Rs7.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije




Slika 8.33. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Rs7

Pretpostavljena rasjedna zona uočena na EK granici „Pt/Tg“ uočljiva je i na ovoj slici. U sjeverozapadnom i jugoistočnom dijelu subdepresije izolinijom od 0 m odvojeno je područje gdje nije bilo dovoljno podataka za interpolaciju.

Slikom 8.34. prikazane su vrijednosti dubina i strukture po plohi EK markera Rs5 dobivene tehnikom OK. Na karti se uočava diskordancija koja prekriva istočni dio subdepresije po čemu se razlikuje od prethodnih karata. Odražava smanjenje sedimentnog bazena što je uzrokovalo znatno manji doseg variograma. Sinklinale u središnjem dijelu su ostatak struktura s prethodne karte.




Slika 8.34. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Rs5

Na starijoj strukturnoj karti po plohi EK markera Z' (slika 4.7.) ucrtani su i rasjedi, ali na karti prikazanoj slikom 8.35. oni nedostaju. Međutim, promatrajući pružanje stratoizohipse može se zaključiti gdje bi se mogli nalaziti. Tako je izrazito zgušnjavanje izolinija vidljivo u središnjem dijelu karte oko stratoizohipse 1800 m što se poklapa s pozicijom glavnog reverznog rasjeda i na samoj strukturnoj karti. Najveće dubine od 2800 m zabilježene su u središnjem dijelu subdepresije gdje se na prijelazu iz panona u pont nalazilo dubljevodno jezero, dok je rubni dio, osobito na sjeveru, bio plitkovodni do kopneni.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije




Slika 8.35. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Z'

Slika 8.36. prikazuje raspodjelu vrijednosti varijable dubina po plohi EK markera Δ dobivenu tehnikom OK. Vrijednosti dubina na granici donji/gornji pont na većinskoj površini subdepresije iznose do 1000 m dubine pa su i strukture slabije izražene u odnosu na prijašnje karte. Dubine iznose 100–200 m u sjevernom i sjeverozapadnom dijelu i rastu prema Bjelovaru (> 800 m), Grubišnom polju (>900 m), a vrijednosti iznad 1000 m nalaze se na krajnjem južnom i pogotovo jugozapadnom dijelu subdepresije prema Savskoj depresiji gdje prelaze i 2000 m. Na izvornoj karti dubina po plohi EK markera Δ (slika 4.8.) ucrtani su i rasjedi, a po pružanju stratoizohipsi može se prepoznati glavni reverzni rasjed smjera SZ-JI koji prolazi kroz središnji dio subdepresije te manji reverzni rasjedi na jugoistoku. U pontu se taloženje odvijalo u slatkovodnim jezersko-riječnim okolišima gdje izvor materijala više nije bio lokalnog podrijetla, a spuštanje prostora odvijalo se uglavnom uz ranije formirane rasjedne sustave


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

(Malvić, 2003). U odnosu na prijašnju kartu gdje je u središnjem dijelu subdepresije na granici panon/pont bilo dubljevodno jezero, dubine su tri puta manje što ukazuje na daljnje oplićavanje.



Slika 8.36. Karta OK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru A

Karta dubina po EK markeru D' izrađena tehnikom OK-a prikazana je na **slici 8.37**. Kao ulazni podatci korištene su vrijednosti varijable dubine sa strukturne karte Bjelovarske subdepresije po EK markeru D' (**slika 4.9.**) priređene u pravilnoj mreži 2x2 km. Promatranjem promjene pravca pružanja izolinja možemo pretpostaviti mogući položaj rasjeda. U sjevernom dijelu uz izolinku 400 m vidi se nagla promjena orijentacije stratoizohipsi, a u južnom dijelu karte su oko stratoizohipse 400 m izrazito guste postavljene izolinkije. U oba slučaja je na istom mjestu smješten rasjed na strukturnoj karti subdepresije.




Slika 8.37. Karta OK dobivena iz strukturne karte dubina Bjelovarske subdepresije po EK markeru D'

Narančastom bojom na karti označene su zone većih dubina, sjeverna zona s dubinom do 712 m i južna od 850 m. Dubine su znatno manje u odnosu na prijelaz iz panona u pont, dok je na prijelazu iz pontu u pliocen veći dio prostora bio kopneni. Na pojedinim mjestima većih dubina nalazili su se ostatci pontskog jezera. Između preostalih vodenih površina povremeno je mogla postojati veza. Krajem kvartara dolazi do konačnog isušivanja močvarnih područja subdepresije, a dijelom su jezera zapunjena i transportom erodiranog materijala tekućicama kroz kopneni prostor.


8.3. Primjena tehnike univerzalnoga krigiranja na području Bjelovarske subdepresije

Tehnika UK podrazumijeva trend u podacima. Kao što je ranije objašnjeno, prostornu ovisnost podataka najjednostavnije je prikazati običnim dijagramom raspršenja. Dijagrami raspršenja svih markera pokazuju na linearni trend dubine s geografskom širinom i dužinom izraženom u Gauss-Krügerovim koordinatama (slike 8.38. – 8.43.). Dakle, može se pristupiti tehnici UK-a. Prvi korak je višestruka regresijska analiza (budući da postoje dvije nezavisne varijable) kojom se dobije varijabla „ostatci“ za izradbu variograma.

Slika 8.38. prikazuje odnos geografske dužine i širine izražene u Gauss-Krügerovim koordinatama, i varijable dubine EK granice Pt/Tg. Uočava se linearni trend, pozitivan s geografskom dužinom koji je izraženiji, i širinom (slabije izražen). Tome ide i u prilog nizak Pearsonov koeficijent korelacije sa širinom ($r = 0,08$, dok je $R^2 = 0,006$), dok je s dužinom znatno veći ($r = 0,42$, a $R^2 = 0,18$). Prema Chaddockovoj ljestvici riječ je o slaboj linearnoj vezi. Ovaj dijagram raspršenja razlikuje se od svih ostalih po tome što je linearni trend pozitivan i sa širinom i s dužinom.




8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.38. Ovisnost dubine Bjelovarske subdepresije na granici Pt/Tg o x i y Gauss-Krüger koordinatama

Slika 8.39. prikazuje odnos geografske dužine i širine izražene u Gauss-Krügerovim koordinatama, i varijable dubine po plohi EK markera Rs7. Uočava se linearni trend, pozitivan s geografskom dužinom, a negativan sa širinom. I u ovom slučaju, trend je jače izražen s dužinom ($r = 0,47$; $R^2 = 0,22$), nego sa širinom gdje je i negativan ($r = -0,09$, $R^2 = 0,008$).




8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.39. Ovisnost dubine Bjelovarske subdepresije na granici sarmat/panon o x i y Gauss-Krüger koordinatama

Jedino u slučaju dubina po plohi EK markera Rs5 (slika 8.40.) linearni trend je pozitivan s geografskom širinom, iako slabo izražen. Negativan linearni trend opažen je s geografskom dužinom pa u slučaju vrijednosti dubina EK markera Rs5, iste se smanjuju s geografskom dužinom. I dalje je riječ o dvije nezavisne varijable, samo sa suprotnim trendom, pa se i u ovom slučaju može pristupiti tehnici UK. Dijagramom raspršenja prikazane su vrijednosti 743 točkastih podataka gdje sa geografskom širinom Pearsonov koeficijent korelacije iznosi 0,31 ($R^2 = 0,096$), a s dužinom -0,02. Od tih 743 podataka, 511 se odnosi na vrijednosti apsolutnih dubina očitanih sa strukturne karte, a ostale vrijednosti su 0 (dijelovi pravilne mreže gdje nije bilo dovoljno podataka za interpolaciju i očitavanje vrijednosti dubina pa je koordinatama dodijeljena navedena vrijednost). Ukoliko se u obzir uzmu samo vrijednosti apsolutnih dubina, tada Pearsonov koeficijent korelacije širine i dubine iznosi -0,35 ($R^2 = 0,13$), a dužine i dubine 0,66 ($R^2 = 0,44$) što znači da je linearna veza u tom slučaju srednje jakosti.


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.40. Ovisnost dubine Bjelovarske subdepresije na granici gornji panon/donji panon o x i y Gauss-Krüger koordinatama

Slika 8.41. prikazuje odnos geografske dužine i širine izražene u Gauss-Krügerovim koordinatama, i varijable dubine po plohi EK markera Z'. Uočava se linearni trend, pozitivan s geografskom dužinom, a negativan sa širinom, kao i kod markera Rs7. U ovom slučaju, prikazane su vrijednosti samo 497 vrijednosti apsolutnih dubina očitanih sa strukturne karte. Tako linearna veza dolazi jače do izražaja, riječ je o čvrstoj vezi dubine s geografskom dužinom gdje je $r = 0,76$ ($R^2 = 0,57$), a sa širinom je srednje jakosti gdje je $r = -0,49$ ($R^2 = 0,23$).


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.41. Ovisnost dubine Bjelovarske subdepresije na granici gornji panon/donji pont o x i y Gauss-Krüger koordinatama

Vrijednosti dubina po plohi EK markera Δ pokazuju jasno izražen pozitivan linearan trend (slika 8.42.) s geografskom dužinom ($r = 0,68$; $R^2 = 0,47$), a negativan s geografskom širinom ($r = -0,58$; $R^2 = 0,34$).


8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.42. Ovisnost dubine Bjelovarske subdepresije na granici donji pont/gornji pont o x i y Gauss-Krüger koordinatama

Sličan trend uočen je i za vrijednosti dubine po plohi EK markera D' (slika 8.43.). Računanjem koeficijenta korelacije, uočena je slaba linearna veza (s dužinom $r = 0,25$; $R^2 = 0,06$, dok sa širinom iznosi $r = -0,29$; $R^2 = 0,081$)

Kako je za kartiranje vrijednosti dubine po EK granici Pt/Tg i plohi EK markera Rs7 korišten skup od 742 podataka, po plohi EK markera Rs5 743 podatka, po plohi EK markera Z' skup od 720 podataka, po plohi EK markera Δ 727 podatka, a po plohi EK markera D' skup od 739 podataka, sam postupak višestruke regresijske analize (vidi **potpoglavlje 7.3.1.**) neće biti nanovo objašnjen, već će se odmah pristupiti izradbi variograma izračunate varijable „ostatci“.




Slika 8.43. Ovisnost dubine Bjelovarske subdepresije na granici pont/pliocen o x i y Gauss-Krüger koordinatama

8.3.1. Eksperimentalni i teorijski modeli variograma za glavnu i sporednu os varijable ostatci


Za izradbu variograma varijable „ostatci“ korištene su iste ulazne vrijednosti: veličina koraka (h) = 2000 m; broj koraka = 20; kutna tolerancija = 45° . U slučaj Pt/Tg granice, markera Rs7 i Rs5 za sporednu os korištene su vrijednosti: veličina koraka (h) = 2500 m; broj koraka = 15. Smjer za glavnu os iznosio je 120° , a za sporednu 210° .

Eksperimentalni variogrami i aproksimacije teorijskim modelima varijable ostatci izrađeni su programom Variowin. Dobiveni eksperimentalni variogrami glavne i sporedne osi varijable ostatci Pt/Tg granice prikazani su slikama 8.44. i 8.45.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.44. Eksperimentalni variogram glavne osi za varijablu „ostatci“ EK granice Pt/Tg




Slika 8.45. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ EK granice Pt/Tg

Prag u oba slučaja iznosi 410 000, dok je doseg glavne osi smjera 120°-300° 20 000 m, a sporedne osi smjera 30°-210° 12 000 m. Eksperimentalni variogram glavne osi aproksimiran je Gausovim teorijskim modelom (slika 8.46.) uz sljedeće vrijednosti: odstupanje 49 200, doseg 22 400 m i prag 410 000, koje su korištene kao ulazni podatci pri izradbi karte dubine po plohi EK granice PT/Tg tehnikom UK-a.




Slika 8.46. Aproximacija eksperimentalnog variograma varijable "ostatci" dobivenog iz strukturne karte EK granice „Pt/Tg“ pomoću Gaussovog modela

Eksperimentalni variogrami glavne (slika 8.47.) i sporedne osi (slika 8.48.) varijable ostatci po plohi EK markera Rs7 pokazuju razliku u dosegu, kao i u ostalim primjerima. Doseg glavne osi iznosi 19 000 m, sporedne 13 000 m, dok je iznos praga 360 000.




Slika 8.47. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Rs7

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.48. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Rs7


Eksperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.49.) uz sljedeće vrijednosti: odstupanje 0, doseg 26 400 m i prag 420 000.




Slika 8.49. Aproksimacija eksperimentalnog variograma varijable „ostatci“ dobivenog iz strukturne karte po EK markeru Rs7 pomoću sfernog modela

Eksperimentalni variogrami glavne i sporedne osi varijable ostatci po plohi EK markera Rs5 prikazani su slikama 8.50. i 8.51. Doseg ima još manju vrijednost te po glavnoj osi iznosi 13 000 m, a po sporednoj 10 000 m. Iznos praga je 480 000.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.50. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Rs5



Slika 8.51. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Rs5


Eksperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.52.) uz sljedeće vrijednosti: odstupanje 0, doseg 17 200 m i prag 490 000.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



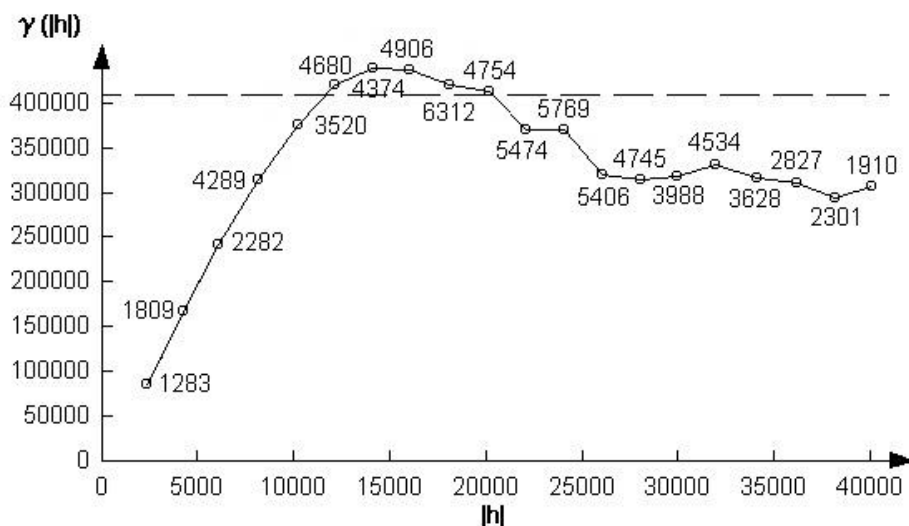
Slika 8.52. Aproximacija eksperimentalnog variograma varijable "ostatci" dobivenog iz strukturne karte po EK markeru Rs5 pomoću sfernog modela

Dobiveni eksperimentalni variogrami glavne (slika 8.53.) i sporedne osi (slika 8.54.) varijable ostatci po plohi EK markera Z' pokazuju razliku u dosegu. Glavna os smjera 120°-300° ima doseg od 13 000 m, dok prag iznosi oko 410 000. Sporedna os smjera 30°-210° ima doseg u iznosu od 12 000 m.




Slika 8.53. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera Z'

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije



Slika 8.54. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Z'


Eksperimentalni variogram glavne osi aproksimiran je sfernim teorijskim modelom (slika 8.55.) uz sljedeće vrijednosti: odstupanje 12 300, doseg 17 200 m i prag 410 000. Navedeni podatci korišteni su kao ulazni pri izradbi karte dubine po plohi EK markera Z' tehnikom UK.



Slika 8.55. Aproksimacija eksperimentalnog variograma varijable „ostatci“ dobivenog iz strukturne karte po EK markeru Z' pomoću sfernog modela


Eksperimentalni variogrami glavne (slika 8.56.) i sporedne osi (slika 8.57.) varijable ostatci po plohi EK markera Δ kao i u većini slučajeva imaju različite dosege. U smjeru glavne osi iznosi oko 20 000 m, a u smjeru sporedne 12 000 m. Prag ima vrijednost od 65 000.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije



Slika 8.56. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera


Δ



Slika 8.57. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera Δ


Eksperimentalni variogram glavne osi varijable ostatci po plohi EK markera Δ aproksimiran je sfernim teorijskim modelom (slika 8.58.) uz sljedeće vrijednosti: odstupanje 1340, doseg 22 400 m, prag 67 000.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.58. Aproksimacija eksperimentalnog variograma varijable "ostatci" dobivenog iz strukturne karte po EK markeru Δ pomoću sfernog modela

Dobiveni eksperimentalni variogrami glavne (slika 8.59.) i sporedne osi (slika 8.60.) varijable ostatci po plohi EK markera D' također pokazuju razliku u dosegu. Glavna os smjera 120°-300° ima doseg od 16 000 m, a sporedna os smjera 30°-210° ima doseg u iznosu od 12 000 m.




Slika 8.59. Eksperimentalni variogram glavne osi za varijablu „ostatci“ po plohi EK markera D'

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije



Slika 8.60. Eksperimentalni variogram sporedne osi za varijablu „ostatci“ po plohi EK markera D'


Eksperimentalni variogram sporedne osi aproksimiran je Gausovim teorijskim modelom (slika 8.61.) uz sljedeće vrijednosti: odstupanje 2 700, doseg 20 200 m i prag 27 000. Dobivene vrijednosti korištene su kao ulazni podatci pri izradbi karte dubine po plohi EK markera D' tehnikom UK.



Slika 8.61. Aproksimacija eksperimentalnog variograma varijable “ostatci” dobivenog iz strukturne karte po EK markeru D' pomoću Gaussovog modela

8.3.2. Karte Bjelovarske subdepresije dobivene tehnikom univerzalnoga krigiranja

Dubinska karta Bjelovarske subdepresije EK granice Pt/Tg dobivena tehnikom UK prikazana je na **slici 8.62**. Usporedbom s kartom dobivenom tehnikom OK (**slika 8.32**), karte su gotovo identične, jedino je u krajnjem jugoistočnom dijelu subdepresije pružanje stratoizohipse vrijednosti 600 m nešto drukčijeg oblika.



Slika 8.62. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije EK granice Pt/Tg

Dobivene vrijednosti krosvalidacije potvrđuju kako većih razlika između tehnika OK i UK u ovome slučaju nema. Tehnika OK-a daje neznatno manju vrijednost krosvalidacije (RMSE = 167,57), u odnosu na UK-a (RMSE = 167,83).


Najpodcjenjeniji podatak tehnike OK-a nalazi se na $X = 6413993$, $Y = 5075986$, gdje je izmjerena vrijednost varijable „dubine“ $I=3120$, a procijenjena vrijednost varijable „dubine“

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

$P = 2440,4$. Najprecjenjeniji podatak nalazi se na $X = 6433993$, $Y = 5081986$, gdje je izvorna vrijednost varijable „dubine“ $I = 400$, a procijenjena vrijednost varijable „dubine“ $P = 2394$.

Najpodcjenjeniji podatak tehnike UK-a nalazi se na istim koordinatama $X = 6413993$, $Y = 5075986$, gdje je izmjerena vrijednost varijable „dubine“ $I = 3120$, a procijenjena vrijednost varijable „dubine“ $P = 2444,3$. U slučaju obje tehnike, najpodcjenjeniji podatak ima smjestašte na glavnom reverznom rasjedu subdepresije (vidi **potpoglavlje 4.2.**, **slika 4.3.**). Najprecjenjeniji podatak isto je na istim koordinatama u istočnom dijelu subdepresije, gdje je izvorna vrijednost varijable „dubine“ $I = 400$, a procijenjena vrijednost varijable „dubine“ $P = 2394,6$.

Slika 8.63. prikazuje dubinsku kartu Bjelovarske subdepresije po plohi EK markera Rs7 dobivenu tehnikom UK. Opet je jedina razlika u pružanju stratoizohipsi u jugoistočnom dijelu subdepresije.




Slika 8.63. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Rs7

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

Tehnika OK-a i u ovom slučaju daje neznatno manju vrijednost krosvalidacije (RMSE = 141,93), u odnosu na UK (RMSE = 142,12). Najpodcjenjeniji i najprecjenjeniji podatci obje tehnike opet su na istim koordinatama. U ovom slučaju riječ je o smjestištima uz diskordanciju. Najpodcjenjeniji podatak nalazi se na $X = 6425993$, $Y = 5037986$ gdje je izmjerena vrijednost varijable „dubine“ $I = 2250$, a procijenjena vrijednost varijable „dubine“ tehnikom OK $P = 1622,5$, a tehnikom UK $P = 1622,8$. Najprecjenjeniji podatak nalazi se na $X = 6437993$, $Y = 5083986$, gdje je izvorna vrijednost varijable „dubine“ $I = 820$, a procijenjena vrijednost varijable „dubine“ tehnikom OK $P = 1889$, dok tehnikom UK $P = 1871$.

Karta dubina po plohi markera Rs5 dobivena tehnikom UK (slika 8.64.) razlikuje se od karte dobivene tehnikom OK (slika 8.34.) po pružanju diskordancije. Za sada je jedino u ovom slučaju iznos krosvalidacije tehnike UK (RMSE = 267,9) manji od tehnike OK (RMSE = 268,2) pa prema tome predstavlja bolju metodu za kartiranje ovog markera.




Slika 8.64. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Rs5

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije

Vrijednosti najvećih pogrešaka u procjenjivanju podataka opet su na istim koordinatama. Najpodcjenjeniji podatak nalazi se na $X = 6435993$, $Y = 5057986$ gdje je izmjerena vrijednost varijable „dubine“ $I = 1880$, a procijenjena vrijednost varijable „dubine“ tehnikom OK P = 157,7, a tehnikom UK P = 152,8. Najprecijenjeniji podatak nalazi se na $X = 6421993$, $Y = 5077986$, gdje je izvorna vrijednost varijable „dubine“ $I = 0$, a procijenjena vrijednost varijable „dubine“ tehnikom OK P=1568,8, dok tehnikom UK P = 1567,6.

Dubinska karta Bjelovarske subdepresije po plohi EK markera Z' dobivena tehnikom UK prikazana je na **slici 8.65**. Većih razlika koje bi se mogle uočiti vizualno s kartom dobivenom tehnikom OK (**slika 8.35.**), nema. Zbog toga je napravljena krosvalidaciju koja ukazuje na moguće razlike.



Slika 8.65. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru

Z'

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

U ovom slučaju, tehnika OK-a daje nešto manju vrijednost krosvalidacije (RMSE = 237,9), u odnosu na tehniku UK-a (RMSE = 238,6) što znači da bi to trebala biti primjerenija metoda za kartiranje dubina Bjelovarske subdepresije po plohi EK markera Z'.

Najpodcjenjeniji podatak tehnike OK-a nalazi se na $X = 6422000$, $Y = 5078000$, gdje je izmjerena vrijednost varijable „dubine“ $I = 2750$, a procijenjena vrijednost varijable „dubine“ $P = 1327,17$. Najprecjenjeniji podatak nalazi se na $X = 6424000$, $Y = 5078000$, gdje je izvorna vrijednost varijable „dubine“ $I = 0$, a procijenjena vrijednost varijable „dubine“ $P = 1416,2$.


Slično kao i u slučaju EK markera Rs5, najprecjenjeniji i najpodcjenjeniji podatci obje tehnike na istim su koordinatama, uz diskordanciju. Kod najpodcjenjenijeg podatka tehnike UK-a izmjerena je vrijednost varijable „dubine“ $I = 1210$, a procijenjena vrijednost varijable „dubine“ $P = 1320,5$. Najprecjenjenijem podatku izvorna je vrijednost varijable „dubine“ $I = 0$, a procijenjena vrijednost varijable „dubine“ $P = 1424,1$.

Slika 8.66. prikazuje dubinsku kartu Bjelovarske subdepresije po plohi EK markera Δ dobivenu tehnikom UK. Uspoređujući vizualno, karte dobivene tehnikom OK (**slika 8.36.**) i UK (**slika 8.66.**) izgledaju identično, vrijednosti dubina te pružanje i oblik izobata su isti. Jedino rezultati krosvalidacije ukazuju na razliku, ali ona je isto neznatna. U ovom slučaju tehnika UK ima neznatno nižu vrijednost krosvalidacije (RMSE = 79,3) u odnosu na tehniku OK (RMSE = 79,6).

Najpodcjenjeniji podatak tehnike OK po plohi EK markera Δ nalazi se na koordinatama $X = 6440000$, $Y = 5054000$ uz obronke Papuka, gdje je izmjerena vrijednost varijable „dubine“ $I = 1800$, a procijenjena $P = 1286,9$. Najprecjenjeniji podatak je na koordinatama $X = 6418000$, $Y = 5062000$ s izmjerenom vrijednošću dubine $I = 195$, a procijenjenom $P = 543,2$.

Na primjeru tehnike UK, najpodcjenjeniji podatak po plohi EK markera Δ nalazi se na istim koordinatama, ali je procijenjena vrijednost varijable „dubina“ nešto niža i iznosi 1285,8. Isto je slučaj i s najprecjenjenijim podatkom gdje se procijenjena vrijednost nešto razlikuje i iznosi $P = 543$.

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije




Slika 8.66. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru A

Dubinska karta Bjelovarske subdepresije po plohi EK markera D' dobivena tehnikom UK-a prikazana je na **slici 8.67**. Vizualno karte dobivene tehnikama OK-a (**slika 8.37.**) i UK-a (**slika 8.67.**) po plohi markera D' izgledaju slično, ne mogu se zamijetiti veće razlike. Međutim, i u ovom slučaju tehnika OK-a ima bolje rezultate dobivene metodom krosvalidacije (RMSE = 85) u odnosu na tehniku UK-a (RMSE = 96), iako je razlika manja nego kod karte dubina po plohi EK markera Z'.

Najpodcjenjeniji podatak tehnike OK-a po plohi EK markera D' nalazi se na $X = 6430000$, $Y = 5038000$, gdje je izmjerena vrijednost varijable „dubine“ $I=820$, a procijenjena vrijednost varijable „dubine“ $P = 634$. Najprecjenjeniji podatak nalazi se na $X = 6434000$, $Y = 5032000$, gdje je izvorna vrijednost varijable „dubine“ $I = 350$, a procijenjena vrijednost varijable „dubine“ $P = 2375$.

8. Rezultati uporabe zonalne procjene i krigriranja na primjeru Bjelovarske subdepresije

Najpodcjenjeniji podatak tehnike UK-a po plohi EK markera D' nalazi se na X = 6432000, Y = 5034000, gdje je izmjerena vrijednost varijable „dubine“ I = 398, a procijenjena vrijednost varijable „dubine“ P = 354. Najprecjenjeniji podatak nalazi se na X = 6434000, Y = 5032000, gdje je izvorna vrijednost varijable „dubine“ I = 350, a procijenjena vrijednost varijable „dubine“ P = 2349.



Slika 8.67. Karta UK dobivena iz strukturne karte Bjelovarske subdepresije po EK markeru D'

Rezultati krosvalidacije tehnika OK i UK, EK granice i svih EK markera, prikazani su u **tablici 8.1**. Zanimljivo je da su najveće vrijednosti krosvalidacije za obje metode u slučaju EK markera Rs5 i Z', tj. markera koje obilježava velika diskordancija u jugoistočnim dijelima subdepresije. U većini slučajeva tehnika OK pokazala se primjerenijom za kartiranje varijable dubina, osim u slučaju EK markera Rs5 i D'. Razlike vrijednosti krosvalidacije tehnika OK i UK prikazane u

8. Rezultati uporabe zonalne procjene i krigiranja na primjeru Bjelovarske subdepresije

tablici 8.1. nisu statistički značajne (osim u slučaju EK markera D') te ne bi pogriješili prilikom odabira jedne ili druge metode za kartiranje neogensko-kvartarnih naslaga prostora Bjelovarske subdepresije.

Tablica 8.1. Usporedba rezultata krosvalidacije dobivenih tehnikama OK i UK

EK granica/marker	Broj podataka	RMSE (OK)	RMSE (UK)
Pt/Tg	742	167,6	167,8
Rs7	742	141,9	142,1
Rs5	743	268,2	267,9
Z'	720	237,9	238,6
Delta	727	79,6	79,3
D'	739	85	96

9. ODABIR TEHNIKE OBIČNOGA KRIGIRANJA ZA KARTIRANJE DEBLJINA FORMACIJA ISTRAŽIVANOG PROSTORA TE IZRADBA ODABRANIH PALINSPASTIČKIH PROFILA

Karte debljine formacija čije granice čine regionalni EK markeri izrađene su tehnikom OK. Prijašnji rezultati pokazali su kako na razini subdepresije većih razlika između tehnike OK i UK nema, a u većini slučajeva tehnika OK pokazala se boljom prema vrijednosti krosvalidacije. Iz tog razloga odabrana je za izradbu karata debljina formacija, i time upotpunjavanja skupa paleostrukturalnih karata Bjelovarske subdepresije, a općenito navedena je tehnika i jednostavnija za korištenje.

Ukupan broj paleostrukturalnih karata koje je moguće izraditi za neki skup kartiranih površina definiran je **jednadžbom 9.1 (Hernitz i Jurak, 1973)**:


$$N = \frac{(n^2 + n)}{2} \quad (9.1)$$

gdje su:

N – ukupan broj karata;

n – broj kartiranih površina.

S obzirom kako je na području Bjelovarske subdepresije kartirana 1 EK granica te 5 EK markera, moguće je ukupno načiniti 21 paleostrukturalnu kartu (**slika 9.1.**). U ovome radu ukupno je izrađeno 11 paleostrukturalnih karata, od kojih je 6 izrađeno tehnikama OK i UK (označenim zelenom bojom na **slici 9.1.**) prikazanim u **poglavlju 8**, a opis 5 karata debljina formacija (označenih narančastom bojom na **slici 9.1.**) slijedi u sljedećim potpoglavljima.



Slika 9.1. Ukupan i načinjen broj paleostrukturalnih karata


9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

Vrijednosti debljina formacija Moslavačke gore (član Mosti i Križevci), Ivanić Grad, Kloštar Ivanić i Bilogora izračunate su pomoću podataka dubina dobivenih iz baze koja je priređena na temelju pravilne mreže (2x2 km) kojom su prekrivene paleostrukturalne karte Bjelovarske subdepresije opisane u **poglavlju 8**. Debljina formacije dobije se oduzimanjem vrijednosti dubina regionalnih EK markera koji čine granice formacije (vrijednosti dubina „starijeg“ EK markera oduzimaju se od „mlađeg“).

Tehnici OK prethodila je variogramaska analiza načinjena programom Variowin. Korištene su sljedeće ulazne vrijednosti pri izradbi svih variograma: veličina koraka/ćelije (h) = 2000 m; broj koraka = 20. Za izradbu svih karata debljina formacija korišteni su neusmjereni variogrami. Na svakoj karti debljina formacija ucrtana su 3 profila, jedan uzdužni (A-B) dužine 80 km te dva poprečna (C-D i E-F) dužine 40 km. Za prikaz ispod karata formacija, odabran je palinspastički profil smjera A-B, a na kojem su ucrtana sjecišta profila C-D i E-F.

9.1. Karta debljina intervala Pt/Tg – Rs7, član Mosti, formacija Moslavačka gora

Eksperimentalni variogram varijable debljina, formacije Moslavačka gora, člana Mosti (**slika 9.2.**), aproksimiran je eksponencijalnim teorijskim modelom uz sljedeće vrijednosti: odstupanje 12 000, doseg 35 200 m i prag 150 000.




Slika 9.2. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Moslavačka gora, član Mosti


Unošenjem vrijednosti variogramskih parametara u računalni program Surfer, izrađena je karta debljine formacije Moslavačka gora, član Mosti, prikazana na **slici 9.3**. Na ovoj karti izražen je najveći raspon vrijednosti debljina. Izohore istočno od Bjelovara okružuju područja debljina iznad 1500 m. Sjeverozapadno od Bjelovara nalazi se područje najveće debljine od preko 2000 m. Općenito, najveće vrijednosti debljine smještene su u sjevernom dijelu subdepresije.

9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

Debljina se smanjuje prema jugu, već kod Bereka i Grubišnog polja iznosi 100 do 200 m debljine. Veće debljine od 1000 m prisutne su još samo u jugozapadnom dijelu između Papuka i Psunja. Član Mosti obuhvaća razdoblje od donjeg miocena do sarmata. Na području najvećeg dijela sjeverne Hrvatske tijekom badena se odvijala marinska sedimentacija pa su veće gore ostale dijelom iznad morske razine kao otoci čemu idu u prilog najveće debljine člana Mosti uz Papuk, Psunj i Kalnik. To se može primjetiti i na uzdužnom profilu A-B (slika 9.3.) gdje je najveća debljina formacije (oko 1000 m) između Papuka i Psunja što dokazuje da je to područje bilo jedno od depocentara, odnosno taložnih središta tijekom taloženja te formacije. Svi maksimumi i na profilima ostalih formacija predstavljaju taložna središta. Nagli pad debljine formacije uočljiv je na mjestu presjecišta s poprečnim profilom C-D iz razloga što na tom mjestu subdepresiju siječe normalni rasjed. Rasjed se smjestio nesporedno uz depocentar s maksimumom od 500 m debljine što znači da je taloženje bilo sinsedimentacijsko.



9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila




Slika 9.3. Karta debljine formacije Moslavačka gora, člana Mosti, dobivena tehnikom OK, te uzdužni profil A-B

Na slici 5.11. prikazana je karta debljine člana Mosti izrađena ručnom interpolacijom i ucrtavanjem rasjeda (Malvić, 2003). Na njoj su ručno ucrtani rasjedi, svi normalnog karaktera. Prema pružanju izohora na ovoj slici može se prepoznati glavni normalni rasjed subdepresije kojeg u sjeveroistočnom dijelu siječe bilogorski normalni rasjed. Većih razlika između ručno interpolirane karte i karte izrađene tehnikom OK nema, vrijednosti debljina prikazanih pomoću računalnog programa su jedino nešto veće u sjevernom dijelu subdepresije gdje su na obje karte najveće vrijednosti debljina formacije Moslavačka gora, člana Mosti.

9.2. Karta debljina intervala Rs7 – Rs5, član Križevci, formacija Moslavačka gora


Eksperimentalni variogram varijable debljina, formacije Moslavačka gora, člana Križevci (slika 9.4.), aproksimiran je eksponencijalnim teorijskim modelom uz sljedeće vrijednosti: odstupanje 0, doseg 16 400 m i prag 27 000.




Slika 9.4. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Moslavačka gora, član Križevci

9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

Raspon debljine na karti debljine formacije Moslavačke gore člana Križevci znatno je manji u odnosu na prijašnju kartu i iznosi oko 900 m (**slika 9.5.**). To je razumljivo budući da član Mosti predstavlja taloženje u trajanju od 5 milijuna godina, dok je član Križevci mlađi i vremenski dosta kraći, predstavlja taloženje u rasponu od 2 milijuna godina (panonske naslage). Član Križevci je donjopanonske starosti, a tada je na prostoru Bjelovarske subdepresije taložna sredina bila plitka te se nastavilo njezino zapunjavanje, većinom laporom.





Slika 9.5. Karta debljine formacije Moslavačka gora, člana Križevci, dobivena tehnikom OK, te uzdužni profil A-B

Debljine nije bilo moguće odrediti u istočnom, južnom dijelu subdepresije i na zapadu kod Moslavačke gore, budući da na tom području nedostaju taložine donjopanonske starosti, odnosno zabilježena je diskordantna granica na karti po plohi EK markera Rs5 (slika 4.6.). Najveće vrijednosti debljina su sjeverozapadno od Bjelovara i na području zapadnobjelovarske sinklinale (iznad 500 m). Navedena područja izvirivala su iznad površine vode te predstavljala izvor siliciklastičnog materijala. Na uzdužnom profilu A-B (slika 9.5.) može se primijetiti prekid taloženja markera Rs5 (dolazi na nulu), što je na karti obilježeno diskordancijom. Ovakav profil označava stanje kada je upravo završeno taloženje EK markera Rs5. Profil nije presjekao glavne depocentre (> 500 m) nastale tijekom taloženja te formacije, najveći maksimum je 400 m, smješten sjeverno od naselja Sv. Ivan Žabno.


Za razliku od karte debljine člana Križevci (slika 4.12.) izrađenom ručnom interpolacijom, veće vrijednosti debljine su i jugoistočno od Grubišnog polja te je navedeno područje isto moglo biti iznad razine vode i činiti izvor siliciklastičnog materijala. Na navedenoj karti ucrtani su normalni i reverzni rasjedi. U ovom razdoblju bila je slaba aktivnost glavnog normalnog rasjeda, a od dijagonalnih rasjeda zabilježena je aktivnost glavnog i sporednog reverznoga rasjeda približno sjeverozapadno od strukture Berek. Većinu subdepresije prekrivaju izohore vrijednosti od 100 i 200 m.

9.3. Karta debljina intervala Rs5 – Z', formacija Ivanić Grad

Eksperimentalni variogram varijable debljina, formacije Ivanić Grad (slika 9.6.), aproksimiran je eksponencijalnim teorijskim modelom uz sljedeće vrijednosti odstupanje 0, doseg 26 184 m i prag 43 000. U sva tri dosadašnja slučaja eksponencijalni teorijski model pokazao se

9. Kartiranje debljina formacija tehnikom OK te izrada palinspastičkih profila

najprimjerenijim, što je općenito i čest slučaj u geologiji. U odnosu na prethodni teorijski model, došlo je do povećanja dosega i praga.



Slika 9.6. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija eksponencijalnim teorijskim modelom (desno) za varijablu debljina, formacije Ivanić Grad


Parametri dobivenog variograma predstavljaju ulazne vrijednosti za tehniku OK. Izohora vrijednosti 0 m i na ovoj karti (**slika 9.7.**) predstavlja diskordantnu granicu koja omeđuje gotovo jednaku površinu kao i na prijašnjoj karti. Vrijednost debljine formacije dobije su oduzimanjem vrijednosti dubina određenih markera. Budući da je na kartama dubina po plohama EK markera Rs5 (**slika 4.6.**) i Z' (**slika 4.7.**) zabilježena diskordantna granica, ona se nalazi i na karti debljine formacije Ivanić Grad.

Najveće vrijednosti debljine zabilježene su na području zapadno i jugoistočno od Bjelovara gdje dosežu i preko 1000 m. Sjeverno od Bjelovara najveće vrijednosti debljina iznose oko 600 m. Najmanje vrijednosti debljine su uz rub Moslavačke gore na zapadu, zatim na sjeveroistoku i istoku subdepresije s vrijednostima izohora od 50 i 100 m te na južnom kartiranom dijelu uz granicu diskordancije. Smanjenje debljine formacije smjera SZ–JI može se primijetiti i na uzdužnom profilu A-B (**slika 9.7.**) gdje se debljina smanjuje od početka profila (>500 m) prema JI dijelu subdepresije (100 m), a na kraju je vidljiv i prekid taloženja (vrijednosti debljine dolaze na nulu), što je na ovoj karti obilježeno diskordancijom. Usporedbom s prethodnim profilom člana Križevci (**slika 9.5.**), depocentri su na približno istim mjestima (ali većih maksimuma, > 400 m) što znači da je taloženje većine materijala bilo u gotovo istim prostorima.

Formacija Ivanić Grad odgovara starosti gornji panon kada su središnji dijelovi subdepresije ponovno izronili kao kopno, a u drugim dijelovima subdepresije nastavljen je neprekinuta sedimentacija kroz cijeli gornji panon. Izrađena karta debljine formacije podržava opće taložne

9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

značajke toga razdoblja. Izranjanje središnjih dijelova kao kopna vidljivo je i na profilu uz kartu debljine formacije (**slika 9.7.**) uz najveće vrijednosti debljine (> 400 m).



Slika 9.7. Karta debljine formacije Ivanić Grad dobivena tehnikom OK te uzdužni profil A-B


9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

Usporedbom s kartom debljine formacije Ivanić Grad dobivene ručnom interpolacijom i ucrtavanjem rasjeda (**slika 4.14.**), vrijednosti debljina većinom se poklapaju u odnosu na kartu dobivenu tehnikom OK. Na navedenoj karti nešto su manje vrijednosti debljine u sjeverozapadnom dijelu gdje iznose 100 do 200 m, kao i na području istočno/jugoistočno od Šandrovca. Na izvornoj karti ucrtani su glavni i sporedni normalni rasjed između kojih se oblikovala inverzna cvjetna struktura Berek, a zabilježena je i aktivnost zapadnog normalnog rasjeda.

Utjecaj aktivnosti glavnog normalnog rasjeda može se prepoznati na **slici 9.7.** na temelju značajne promjene debljine unutar zapadnobjelovarske sinklinale. Na karti dobivenoj tehnikom OK maksimum debljine je nešto veći (>1000 m) u odnosu na ručno interpoliranu kartu (**slika 4.14.**) gdje je veći od 800 m.

9.4. Karta debljina intervala Z' – delta, formacija Kloštar-Ivanić

Slika 9.8. prikazuje eksperimentalni variogram varijable debljina formacije Kloštar-Ivanić te aproksimaciju sfernim teorijskim modelom uz sljedeće vrijednosti: odstupanje 49 400, doseg 33 200 m i prag 190 000.




Slika 9.8. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija sfernim teorijskim modelom (desno) za varijablu debljina, formacije Kloštar-Ivanić


Slika 9.9. prikazuje kartu debljine formacije Kloštar Ivanić intervala Z' - delta. Budući da na karti dubine po plohi EK markera Z' isti diskordantno izostaje (**slika 4.7.**), izohora od 0 m kao i na prethodnim kartama predstavlja diskordanciju koja ograničava približno istu površinu, što je vidljivo i na uzdužnom A-B profilu. Vrijednosti debljine rastu u odnosu na prijašnju kartu, najviše iznose oko 2000 m istočno od Bjelovara. Turbiditne struje bile su izuzetno jake u kasnom panonu i ranom pontu. Tada su značajne količine klastita transportirane iz Istočnih Alpi

9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila

u HPBS. Turbiditne struje čine glavni taložni mehanizam u depresijama sjeverne Hrvatske u kasnom miocenu te predstavljaju izvor srednjeznatog to sitnozrnatog pješčenjaka, odnosno glavnih rezervoarskih litofacijesa u HPBS-u.

U sjevernom i zapadnom dijelu su najniže vrijednosti debljine od 100 m, što odgovara vrijednostima na karti debljine formacije izrađene ručnom interpolacijom (**slika 4.16.**). Na navedenoj karti ucrtani su rasjedi gdje je između glavnog i sporednog normalnog rasjeda spuštano područje u inverznu cvjetnu strukturu Berek, a oba rasjeda presijeca mlađi glavni reverzni rasjed subdepresije. Navedeno se može prepoznati na uzdužnom A-B profilu na mjestu odmah poslije presjecišta s poprečnim C-D profilom (**slika 9.9.**). Taloženje je u tom području bilo sinsedimentacijsko. Glavni depocentar na profilu (> 500 m) premješten je južnije u odnosu na profil prethodne formacije, između presjecišta s poprečnim C-D i E-F profilima.






Slika 9.9. Karta debljine formacije Kloštar-Ivanić dobivena tehnikom OK te uzdužni profil A-B

9.5. Karta debljina intervala delta – D', formacija Bilogora

Eksperimentalni variogramski model varijable debljina formacije Bilogora prikazan je na slici 9.10. Aproximiran je sfernim teorijskim modelom uz sljedeće vrijednosti: odstupanje 0, doseg 40 000 m i prag 74 000.




Slika 9.10. Eksperimentalni neusmjereni variogram (lijevo) i aproksimacija sfernim teorijskim modelom (desno) za varijablu debljina, formacije Bilogora


Na karti debljine formacije Bilogora (slika 9.11.) diskordancija obuhvaća znatno manje područje u odnosu na prijašnje karte budući da je prenesena sa strukturne karte po EK markeru delta (slika 4.8.), a prisutna je uz Moslavačku goru. Mogu se pratiti promjene debljine na cijeloj površini subdepresije. Debljina se postupno povećava od sjevera gdje su debljine u prosjeku oko 100 m, prema središnjem dijelu gdje dosežu 500 m kod Velike Pisanice i 600 m kod Grubišnog polja, a dalje se povećavaju prema jugu gdje prelaze 1000 m debljine. Povećanje debljine formacije prema južnom dijelu subdepresije može se pratiti i na uzdužnom A-B profilu.

9. Kartiranje debljina formacija Bilogora te izradba palinspastičkih profila

Vrijednosti debljine formacije Bilogora te pružanje izohora odgovaraju ručno interpoliranoj karti (slika 4.18.). Rasjedna aktivnost u ovom razdoblju zabilježena je rubnim reverznim rasjedom na jugoistoku subdepresije. Može se prepoznati i na profilu A-B (slika 9.11.) naglim smanjenjem debljine formacije na mjestu između presjecišta s poprečnim E-F profilom i kraja profila (točke B) gdje je taloženje bilo sinsedimentacijsko. Maksimalna debljina na profilu od oko 800 m, veća je u odnosu na prethodnu formaciju, ali je i smještena i području gdje je na prijašnjim kartama (i profilima) zabilježena diskordantna granica.



9. Kartiranje debljina formacija tehnikom OK te izradba palinspastičkih profila



Slika 9.11. Karta debljine formacije Bilogora dobivena tehnikom OK te uzdužni profil A-B

10. RASPRAVA I ZAKLJUČCI

Ciljevi istraživanja bili su vezani za uporabu univerzalnog krigiranja, tehnike koja još nije bila korištena za kartiranje geoloških varijabli prostora HPBS-a. Navedena tehnika, skupa s metodom Thiessenovih poligona i tehnikom običnog krigiranja iskorištena je na podacima dubina EK granice Pt/Tg i regionalnih EK markera prostora Bjelovarske subdepresije, a na lokalnoj (polje Šandrovac) i regionalnoj razini (cijele subdepresije). Rezultati su uspoređeni s ranijim kartama istoga prostora kako bi se našao opći model kartiranja dubinskogeoloških podataka prostora Bjelovarske subdepresije. Hipoteze navedene u uvodnom poglavlju, potvrđene su ovim radom, a objašnjene u sljedećim potpoglavljima.

10.1. Poligonalna i matematičke metode, namjena i preporuka odabira

Metoda Thiessenovih poligona je kao zonalna procjena vrijednosti dubina, u ovom slučaju, dala brzu procjenu vrijednosti analizirane varijable u područjima gdje podatci nisu bili dostupni. Svaki poligon poprimio je vrijednost točke u njoj tako da izrađene karte ne predstavljaju postupnu interpolaciju nizom izolinja (engl. *smoothing interpolation*), već su granice oštre. Upravo su takve granice, na kojima nema prijelazne procjene između podataka, glavni nedostatak metode Thiessenovih poligona (npr. **Zhou i sur., 2009**). Navedena metoda često se koristi u meteorologiji prilikom procjene količine padalina (npr. **Thiessen, A.H., 1911.; Schumann, 1998; Fiedler, 2003**), ali ima čestu primjenu i u hidrogeologiji (npr. **Han i Bray, 2006**) i drugim geoznanostima gdje je potrebna brza procjena vrijednosti analizirane varijable na neuzorkovanim područjima.

Na temelju usporedbe karata interpoliranih Thiessenovim poligonima i krigiranjem zaključeno je da se vrijednosti dubinskih podataka poklapaju. Karta polja Šandrovac s dubinskom prikazom Thiessenovih poligona omogućila je procjenu dubinskih vrijednosti područja na kojima nema bušotinskih podataka. Ovisno o udaljenosti među točkama i granicama samih polja, svaki poligon je poprimio odgovarajuću veličinu. Metodom Thiessenovih poligona je prema tome dobivena zonalna procjena dubina područja koja nemaju bušotinskih podataka. Svaki poligon dobiva vrijednost točke u njoj te tako dobivene karte nisu izlazne, već ih je potrebno još interpolirati. Karta cijele Bjelovarske subdepresije s dubinskom prikazom Thiessenovih poligona priređena pomoću podataka pravilne mreže 2x2 km rezultirala je izrazito pravilnim oblikom Thiessenovih poligona budući da podatci ispunjavaju cijeli okvirni poligon

10. Rasprava i zaključci

subdepresije. Dobivena karta korisna je za izradbu prije krigiranja nakon čega se odlučuje želi li se pristupiti naprednijoj metodi.

U strukturnom kartiranju hrvatskog dijela Panonskog bazena preporučljivo je usporedo koristiti i uspoređivati zonalnu procjenu te geostatističke determinističke metode interpolacije radi boljeg uvida u strukturne oblike i područja gdje se nalaze ekstremi, a gdje je broj podataka malen. Interpolacija krigiranjem daje vrlo preciznu procjenu vrijednosti varijabli te je uglavnom najprecizniji interpolacijski deterministički algoritam (npr. **Zimmerman i sur., 1999; Čubaković, 2012; Husanović i Malvić, 2014; Šiljeg i sur., 2015**). Nedostatak je što zahtijeva pouzdan variogramski model te poznavanje algoritma. Variogram služi za utvrđivanje važnosti ili utjecaja susjednih točaka na procjenu u odabranoj lokaciji. Kako bi bio pouzdan, potrebno je imati skup od 15 ili više podataka budući da manji skupovi onemogućavaju anizotropno variogramsko modeliranje (npr. **Malvić, 2008**). Variogrami se rade uz pomoć računalnih programa koji zbog interpretacije eksperimentalnih krivulja sadrže određenu nesigurnost. Druga nesigurnost odnosi se na jednadžbe običnoga krigiranja koje uzimaju u obzir udaljenost točaka od mjesta procjene te tzv. lokalnu varijancu. Međutim, krigiranje najčešće uspješno minimizira varijancu krigiranja, što znači da je razlika između očekivanih i procijenjenih vrijednosti minimalna.

Tako se na primjeru polja Šandrovac gdje su ulazni podatci po plohi EK markera Z' obilježeni izrazitim linearnim trendom tehnika univerzalnog krigiranja pokazala kao najbolja za kartiranje varijable dubine. Razlog tomu je što je trend lakše pratiti na manjoj površini, a u ovom slučaju riječ je o homoklini koja je dio regionalne monokline, a koja tone prema jugoistoku polja. Krigiranje pruža brojne prednosti pred ostalim interpolacijskim metodama, a u ovom slučaju gdje je metoda Thiessenovih poligona nazvana zonalnom procjenom, a ne interpolacijskom metodom, sigurno je kako metoda krigiranja pruža kvalitetniju prostornu procjenu vrijednosti dubina. No, s obzirom na mali broj ulaznih podataka, što se odražava u određivanju njihove prostorne zavisnosti, zonalna procjena ima svoje prednosti, u najmanju ruku kao provjera općenitog rješenja bilo kakvom interpolacijom.

Ovim se radom prema svemu navedenome može potvrditi prva hipoteza „Kartiranje je moguće načiniti matematičkim algoritmima koji do sada nisu bili korišteni za ovaj prostor, a matematički su napredniji od onih do sada uporabljenih“. Tehnika UK nije dosad bila korištena za kartiranje geoloških varijabli u Hrvatskoj. Riječ je o naprednijem algoritmu za koji je potrebna dodatna priprema podataka, određivanje trenda, računanje reziduala te u konačnici variogramska analiza koja prethodi svim tehnikama krigiranja. Rezultat uporabe navedene

tehnike su karte koje odgovaraju ručno interpoliranim kartama te predstavljaju dobar način digitalizacije starih karata.

10.2. Uloga krosvalidacije kao numeričke provjere kvalitete rezultata kartiranja

Metoda krosvalidacije preporučena je od strane brojnih autora za usporedbu točnosti interpolacijskih metoda u predviđanju vrijednosti odabranih varijabli (npr. **Cressie, 1993; Webster i Oliver, 2007**). Na površini cijele subdepresije tehnika običnog krigiranja imala je nešto manju srednju kvadratnu pogrešku u slučaju EK granice Pt/Tg, EK markera Rs7, Z' i D' te bi prema tome trebala biti primjerenija za kartiranje varijable dubine cijele subdepresije po plohama navedenih markera. Međutim, u slučaju kartiranja vrijednosti varijable dubina po plohama EK markera Rs5 i Δ , tehnika UK imala je nešto manju vrijednost krosvalidacije (za EK marker Rs5 iznosila je $RMSE(OK) = 268,2$ i $RMSE(UK) = 267,9$; za EK marker Δ $RMSE(OK) = 79,6$ i $RMSE(UK) = 79,3$).

Tehnika UK je, kao što je ranije objašnjeno, primjerenija kada su ulazni podatci obilježeni trendom. Upravo je problem više regionalnih trendova unutar jednoga većega prostora uočen i u prikazanoj analizi. Rezultati dobiveni OK i UK nalikuju, no kada se usporede numeričkom pogreškom OK češće dovodi do rješenja s manjom vrijednošću. Razlog tomu je što unutar Bjelovarske subdepresije, na razini kartiranih EK markera, postoji više opisivih trendova, uglavnom u prostorima između glavnih depresijskih rasjeda. Upravo ti rasjedi "razbijaju" jedan regionalni trend koji bi se inače mogao pratiti unutar toga prostora. Statistički gledano problem primjene UK se lako razumije ako se:

1. Uoči vrlo raspršen oblak podataka koji je aproksimiran pravcem na **slikama 8.38. - 8.43.**
2. Činjenicu da eksperimentalni variogrami stabiliziraju tek iznad praga (tada počinju oscilirati) pa je njihov doseg relativno mali (**slike 8.44.-8.61.**).


Druga hipoteza „Rezultati će biti primjereniji i bolje prikazivati strukturne dubinske elemente, a time i taložne prostore, od ranijih dubinskih karata bilo načinjenih ručnom interpolacijom, bilo krigiranjem“ isto se može potvrditi. Tehnika UK pokazala se primjerenijom u slučaju polja Šandrovac, ali i kartiranja varijable dubine po plohama EK markera Rs5 i Δ . Na razini cijele subdepresije vrijednosti krosvalidacije za obje tehnike krigiranja bile su dosta slične za sve markere te je neopravdano jednu tehniku predstaviti kao najprimjereniju. Zbog sličnih vrijednosti krosvalidacije, preporučljivo je u slučaju skupa podataka s izraženim trendom koristiti obje metode. Na lokalnoj razini trend je lakše pratiti, a kod dubinskogeoloških karata

većih površina rasjedi razbijaju trend pa će se ovisno o površini, strukturnim odnosima i rezultatima krosvalidacije koristiti najprimjerenija tehnika krigiranja.

10.3. Pretvorba i posljedice analognih u digitalne kartografske podatke te način odabira interpolacijskih metoda

Digitalizacija ručno interpoliranih karata može se uspješno izvršiti mrežom (npr. Špelić i sur., 2016) što je vidljivo i na primjeru svih karata dobivenim tehnikama OK i UK po plohama regionalnih EK markera. Međutim, navedene karte ne pokazuju rasjede, iako se mogu prepoznati po pružanju izolinija. Izlazne karte dubina po plohama EK markera i debljina informacija vjerno prikazuju strukturne odnose te omogućuju interpretaciju taložnog okoliša od badena do holocena. Ručno interpolirane karte moguće je digitalizirati i uporabom 3D modela koji uključuju rasjede (npr. Baketarić i Cvetković, 2015) što omogućuje detaljnije geomodeliranje.

Pravila uporabe novih algoritama ekstrapolirana su na prostor HPBS, čime je potvrđena treća hipoteza. Pri kartiranju neogenskih subdepresija HPBS-a, preporučljivo je koristiti i metodu zonalne procjene (bar kao provjeru točnosti interpoliranih karata) i tehnike krigiranja korištene u radu. Odabir između tehnika OK i UK može se opisati dijagramom toka prikazanim na **slici 10.1.**



Slika 10.1. Dijagram toka

10.4. Trendovi u geološkim podacima i njihovo opažanje kod kartiranja

Dubinskogeološke karte često pokazuju trend u ulaznim podacima budući da kartirane plohe imaju strukturni nagib prema određenoj strani svijeta, ili niz geoloških struktura može biti dio veće strukturne jedinice poput monokline. Stoga je s takvim skupom podataka koje obilježava neki trend preporučljivo koristiti univerzalno krigiranje u odnosu na obično, jer je ta tehnika razvijena upravo s ciljem da prepozna trend u podacima (u geologiji je to česta pojava), izračuna ga, tj. opiše regresijom i u konačnici bolje kartira (npr. **Veronesi, 2012**).

Tehniku UK preporučljivo je koristiti i u slučaju kada zavisna varijabla ne ispunjava uvjet stacionarnosti drugog reda potrebnog za većinu tehnika krigiranja. Stacionarnost drugog reda znači da su sredina i varijanca jednake na cijelom području te da korelacija između bilo koja dva opažanja ovisi samo o njihovom relativnom položaju u prostoru. Nadalje, bitna je i površina područja koje se procjenjuje. Ukoliko je riječ o nekoj velikoj površini tipa cijelog kontinenta ili neke velike države, teško se može pratiti neki trend duž cijelog pravca pružanja pa u tome slučaju nije preporučljivo koristiti UK. Suprotno tomu, kada se opisuje neka «lokalna» pojava, najčešće strukturna, ova tehnika bi trebala biti primijenjena te rezultat uspoređen s drugim tehnikama krigiranja čime se odlučuje hoće li se koristiti za predmetni zadatak.

Variogrami nisu rađeni za isti skup podataka kod tehnika običnog i univerzalnog krigiranja, odnosno kod OK korištene su izvorne vrijednosti varijable dubine, a kod UK reziduala. Kako točnost teorijskih variograma ovisi o vještinama i iskustvu interpretatora, rezultati krosvalidacije mogu ovisiti o tomu tko postavlja teorijske variograme. Dobivene vrijednosti krosvalidacije za obje tehnike prikazuju brojčano vrlo bliske vrijednosti, što upućuje na to da na obrađenim primjerima obje tehnike daju pouzdan prikaz raspodjele vrijednosti analiziranih varijabli.

10.5. Potvrda taložnoga modela naprednim metodama kartiranja

Podatci dobiveni primjenom pravilne mreže olakšali su pristup tehnikama krigiranja budući da je broj ulaznih podataka bio veći, što je rezultiralo i jasnijom raspodjelom dubinskih zona metodom Thiessenovih poligona. Algoritmi odabira bili su korisna nadopuna primjene mreže te su napredne metode kartiranja potvrdile raniji taložni model Bjelovarske subdepresije.

Za izradbu karata debljina formacija korištena je tehnika OK budući da je jednostavnija za korištenje, a rezultati obje tehnike krigiranja na regionalnoj razini, odnosno prostoru cijele subdepresije pokazuju slične vrijednosti krosvalidacije. Karte debljine formacija mogu se

10. Rasprava i zaključci

koristiti za reinterpretaciju strukturnih i taložnih uvjeta od badena kada je u Bjelovarskoj subdepresiji prevladavala marinska sedimentacijama (s otočnim planinama kao otocima), oplićavanja taložnog okoliša u sarmatu, plitke taložne sredine u donjem panonu sa zapunjavanjem subdepresije, izdizanjem središnjih dijelova subdepresije kao kopna u gornjem panonu, turbiditnih struja kao glavnog taložnog mehanizma kasnog miocena, sve do smanjenja taložnog područja u konačnoj kontinentalnoj fazi u kasnom pontu, pliocenu i kvartaru. Time je potvrđena i zadnja hipoteza da će se iz „novih rezultata dodatno reinterpretirati regionalni strukturni i taložni uvjeti koji su vladali u prostoru Bjelovarske subdepresije tijekom razdoblja od badena do holocena“. Osim potvrde taložnog modela, izrađene karte daju i dodatno znanje o istom. Karte su točnije u odnosu na ručno interpolirane karte što znači da su i profili bolje načinjeni te je interpretacija položaja depocentara i mogućeg sinsedimentacijskog taloženja pouzdanija.

11. PROŠIRENI SAŽETAK

Područje Bjelovarske subepresije smješteno je u jugozapadnom dijelu Dravske depresije. Dio je Panonskog bazenskog sustava (skr. PBS) čije je stvaranje započeto u ranom miocenu zbog kontinentalne kolizije i subdukcije Europske ploče pod Afričku (Apulijsku) ploču. Stijene su prema starosti i litologiji podijeljene na dvije skupine. Mlađe su klastične i neogensko-kvartarne starosti, dok starije stijene u podini izgrađuju mezozojski karbonati (vapnenci i dolomiti) ili paleozojski magmatiti (granitne i gabroidne intruzije) i metamorfiti (škriljavci i gnajsevi).

Geološka istraživanja Bjelovarske subepresije započela su polovicom 19. stoljeća, dok su u 20. stoljeću istraživanja bila usmjerena prema otkrivanju ležišta ugljikovodika. U tumačenju geološke evolucije korišteni su elektrokarotažni markeri (skr. EK) koji predstavljaju slojeve između dviju taložnih ili magmatsko-metamorfnih jedinica u krovini i podini. U posljednjih 15 godina subepresija je kartirana po plohama svih EK markera (Rs7, Rs5, Z', Δ i D') i jedne EK granice (Pt/Tg) koja dijeli neogensko-kvartarne sedimente i starije stijene u njihovoj podini. Karte su rađene ručno, dok su pojedini markeri i granica (Pt/Tg, Rs7 i Rs5) kartirani tehnikom običnoga krigiranja.

S razvojem računala i sve naprednijih računalnih programa, geostatističke i geomatematičke metode postale su neizostavan alat u analizi i interpretaciji vrijednosti geoloških varijabli. Metoda krigiranja predstavlja naprednu statističku metodu procjene kojom se procjenjuju vrijednosti regionalizirane varijable u odabranim točkama mreže. Postoje različite tehnike krigiranja, ovisno o obliku matricne jednadžbe, a najčešće korištena je tehnika običnoga krigiranja. Metodi krigiranja prethodi određivanje prostorne zavisnosti, odnosno variogramaska analiza. Druga tehnika krigiranja korištena u ovom radu, tehnika univerzalnog krigiranja, podrazumijeva trend u podacima te je razvijena sa svrhom da prepozna taj trend, opiše ga regresijom i pruži bolji rezultat.

Cilj ovog istraživanja bio je uporabiti novu tehniku krigiranja geoloških varijabli (u ovom slučaju dubine) na području HPBS-a, tehniku univerzalnoga krigiranja te naći opći model kartiranja navedenog prostora. Tehnika UK još nije korištena u kartiranju geoloških varijabli u Hrvatskoj, a pogodna je za kartiranje prostora u kojem postoji strukturni trend. Primijenjena je na lokalnoj (polje Šandrovac) i regionalnoj razini (cijela subepresija) te uspoređena s običnim krigiranjem, najčešće korištenom tehnikom krigiranja te metodom Thiessenovih poligona.

Prvo je kartirano naftno-plinsko polje Šandrovac. Korištene su vrijednosti dubina po plohi EK markera Z' (granica gornji panon/donji pont). Metoda Thiessenovih poligona dala je jasan

11. Prošireni sažetak

prikaz raspodjele zona dubina te se može prepoznati homoklina koja tone prema JI i dio je regionalne monokline. U donjem pontu veće količine klastita transportirane su iz Istočnih Alpi u HPBS turbiditnim strujama te takva karta podržava opći taložni model donjeg pontu subdepresije. Karta je izrađena u programu SAGA GIS. Prednost te metode je što je brza i jednostavna za izraditi, ali nema prijelazne procjene između podataka. Kartiranje metodom krigiranja izvršeno je u programu Surfer 13 kojem je prethodila variogramska analiza u programu Variowin 2.1.0. Tehnika običnog krigiranja u ovom slučaju nije se prikazala boljom u odnosu na tehniku univerzalnog krigiranja što potvrđuje i rezultat krosvalidacije (RMSE (OK) = 171, RMSE (UK) = 59). Tome ide u prilog što su ulazni podatci obilježeni jasnim linearnim trendom.

Kartiranje cijele subdepresije rađeno je pomoću pravilne mreže podataka veličine 2 x 2 km. Kartirani su svi EK markeri i 1 EK granica. Vrijednosti varijable dubine pokazivale su linearni trend s geografskom širinom i dužinom te, ali budući da je riječ o većoj površini, taj trend nije toliko bio izražen kao na primjeru polja Šandrovac. Rasjedi „razbijaju“ trend što je rezultiralo da je tehnika OK imala manje vrijednosti krosvalidacije u većini slučajeva (osim kod kartiranja EK markera Rs5 i Δ). U navedenim primjerima, vrijednosti krosvalidacije bile su slične za obje tehnike te je za kartiranje debljina formacija odabrana tehnika OK jer je jednostavnija za korištenje. Za svaku kartu debljine formacije izrađen je i paleotektonski profil pomoću kojeg je izvršena reinterpretacija taložnog okoliša Bjelovarske subdepresije.

Karta debljine člana Mosti (intervala Pt/Tg-Rs7), formacije Moslavačka gora, obuhvaća razdoblje od donjeg miocena do sarmata. Tada je prevladavala marinska sedimentacija pa su veće gore (Papuk, Psunj i Kalnik) ostale kao otoci. Manje debljine formacije zabilježene su kod člana Križevci (intervala Rs7-Rs5) kada je u donjem panonu taložna sredina bila plitka i nastavilo se njeno zapunjavanje laporom. Budući da vrijednosti dubine EK markera Rs5 u JI dijelu subdepresije diskordantno izostaju, diskordancija je zabilježena i na karti debljine formacije (kao i u slučaju sljedeće dvije formacije). Karta debljine formacije Ivanić Grad (intervala Rs5-Z') podržava opće taložne značajke gornjega panona kada su središnji dijelovi subdepresije ponovno izronili kao kopno, a u drugim dijelovima subdepresije nastavljen je neprekinuta sedimentacija kroz cijeli gornji panon. Formacija Kloštar Ivanić intervala Z'- Δ obuhvaća razdoblje donjeg pontu kada su turbiditne struje bile izuzetno jake u depresijama sjeverne Hrvatske pa su debljine veće u odnosu na prijašnju formaciju s maksimumom od >2000 m istočno od Bjelovara. Karta debljine formacija Bilogora (intervala Δ -D') odgovara približnoj starosti gornjeg pontu kada se taloženje nastavilo sličnim mehanizmima u slatkovodnom, jezerskom i deltnom okolišu, kao i u donjem pontu. Tijekom donjega pontu još

11. Prošireni sažetak

traje vrlo jaka 2. transtenzija kada se talože najveće količine turbidita U gornjem pontu je započela transpresija koja traje i danas.

12. SUMMARY

Bjelovar Subdepression is situated in the south-western part of Drava Depression. It is a part of the Pannonian basin system (abbr. PBS), creation of which began in the Early Miocene due to continental collision and subduction of the European plate under the African (Apulia) plate. The rocks are divided into two different groups according to lithology and age. The younger rocks are clastic and of Neogene-Quaternary age, while the older ones in the basement are built from Mesozoic carbonates (limestone and dolomite) or Palaeozoic magmatites (granite and gabbro intrusions) and metamorphic rocks (schists and gneisses).

Geological explorations of the Bjelovar Subdepression began in the mid-19th century, and in the 20th century the research was directed towards detecting hydrocarbon reservoirs. E-log markers were used for the interpretation of the geological evolution. They represent layers between two sedimentary or igneous-metamorphic units in the overlying cover and basement. Over the last 15 years the Subdepression has been mapped on surfaces of all e-log markers (Rs7, Rs5, Z', Δ and D') and one e-log border (Pt/Tg) that divides the Neogene-Quaternary sediments and older rocks in their basement. Maps were interpolated by hand, while some e-log markers (Rs7 and Rs5) and e-log border (Pt/Tg) were interpolated using Ordinary Kriging technique.

With the development of computers and advanced computer programs, geostatistical and geomathematical methods have become an indispensable tool in the analysis and interpretation of values of geological variables. Kriging method is an advanced statistical method by which are the values of regionalized variables in selected network points estimated. There are different techniques of Kriging, depending on the form of a matrix equation, and the most commonly used technique is Ordinary Kriging. Kriging method is preceded by the determination of spatial dependence, that is variogram. Another Kriging technique was used in this paper, the Universal Kriging, which implies a trend in the data, and is developed with the purpose of recognizing this trend, to describe it with regression and provide a better result.

The purpose of this study was to use a new Kriging technique on geological variables (in this case depth) in CPBS, a Universal Kriging technique, and to find a general model of mapping in this area. Universal Kriging has not been used yet in mapping of geological variables in Croatia, and is suitable for mapping of the area in which there is a structural trend. It was applied at the local (Šandrovac Field) and regional level (the entire Subdepression) and compared with Ordinary Kriging, the most commonly used Kriging technique, and Thiessen polygon method.

12. Summary

Oil and gas Šandrovac Field was mapped first. Depth values of e-log marker Z' (border between Late Pannonian/Early Pontian rocks) were used as input data. Thiessen polygon method gave a clear overview of depth distribution, in which a homocline that sinks towards SE can be recognized and is part of a regional monocline. In Early Pontian, large amounts of clastics were transported from the Eastern Alps to CPBS by turbidite currents. Such map supports general depositional model in Early Pontian of the Subdepression. The map was made using the SAGA GIS program. The advantage of this method is that it is quick and easy to make, but there is no transition estimation between the data. Kriging was performed by using Surfer 13 program which was preceded by variogram analysis that was carried out using Variowin 2.1.0. program. In this case, Ordinary Kriging did not appear better in comparison to the Universal Kriging, which is confirmed by cross-validation result (RMSE (OK) = 171, RMSE (UK) = 59). This was expected as the input data was marked by a clear linear trend.

Mapping of the entire Subdepression was done using the square grid cells (2x2 km in size) that were laid over the hand interpolated maps of e-log borders and e-log markers. The values of depth variable showed a linear trend with longitude and latitude, and because it is a large area, this trend was not as expressed as in the case of Šandrovac Field. The faults "break" the trend, which resulted in Ordinary Kriging having lesser cross-validation value in most cases (except for e-log markers Rs5 and Δ). In the aforementioned examples, cross-validation values were similar in both OK and UK techniques. Therefore, the formation thickness maps were interpolated using OK because it was simpler to use. Paleotectonic profile made for each map was used to make the interpretation of deposition in Bjelovar Subdepression.

Thickness map of Mosti Member (interval Pt / Tg-Rs7), of the Moslavačka Mountain Formation, covers the period from the Lower Miocene to Sarmatian. At that time, the marine sedimentation prevailed and therefore higher mountains (Papuk, Psunj and Kalnik) remained as islands. Lesser thickness was observed in Križevci Member (interval Rs7-Rs5) as in the Lower Pannonian the sedimentary environment was shallow and continued its filling with marl. Since the depth values of e-log marker Rs5 in the SE part of the Subdepression are discordantly absent, a discordance was observed in the formation thickness map (as in the case of the following two formations). Thickness map of Ivanić Grad Formation (interval Rs5-Z') supports the general depositional features of the Upper Pannonian when the central parts of Subdepression re-emerged as mainland, while in other parts of the Subdepression an uninterrupted sedimentation throughout the Upper Pannonian continued. Kloštar Ivanić Formation (interval Z'- Δ) covers the period of Lower Pontian when turbidite currents were extremely strong in the depressions of the Northern Croatia. Therefore, thickness is higher,

12. Summary

compared to the previous formation, with a maximum of >2000 m east of the city of Bjelovar. Thickness map of Bilogora Formation (interval Δ -D ') corresponds to the approximate age of the Upper Pontian when sedimentation continued by similar mechanisms in freshwater, lake and deltaic environment, as in the Lower Pontian. During the Lower Pontian, 2nd transtension is still very strong, when largest amounts of turbidites were deposited. The transpression has begun in the Upper Pontian, and continues today.

13. POPIS LITERATURE

13.1. Objavljeni radovi

Agterberg, F. (2014): Geomathematics: Theoretical Foundations, Applications and Future Developments. Quantitative geology and geostatistics. Vol. 18, Springer, 553 str.

Baketarić, T., Cvetkvić, M. (2015): Subsurface Modelling of the Neogene-Quaternary Sediments in Part of the Sava Depression Based on Digitalization of Legacy Map Data. Rudarsko-geološko-naftni zbornik, 30/2, 67–84.

Balić, D., Velić, J., Malvić, T. (2008): Selection of the most appropriate interpolation method for sandstone reservoirs in the Kloštar oil and gas field. Geologica Croatica, 61/1, 23–75.

Boots, B.N. (1987): Modifying Thiessen Polygons. The Canadian Geographer, 31/2, 160–169.

Borovac, I. (2002): Veliki atlas Hrvatske, Zagreb, Mozaik knjiga.

Brassel K.E., Reif D. (1979): A Procedure to Generate Thiessen Polygons. Geographical Analysis, 11/3, 289–303.

Brod, I.O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29/12, 1738–1755.

Cressie, N. (1990): The Origins of Kriging. Mathematical Geology, 22, 239–252.

Cressie, N. (1993): Statistics for Spatial Data, Revised Edition, John Wiley and Sons, New York, 900 str.

Čubaković, A. (2012): Geostatistički model glinene podine akumulacije HE Tihaljina, Diplomski rad, Geotehnički fakultet, Sveučilište u Zagrebu, 36 str.

Dadić, I., Badanjak, D., Jurum-Kipke, J. (2007): Prometno značenje Bjelovarsko-bilogorske županije. Radovi Zavoda za znanstvenoistraživački i umjetnički rad u Bjelovaru, 1, 99–109.

Davis, J.C. (1973): Statistics and Data Analysis in Geology. Wiley, 550 p., New York.

Delaunay, B. (1934): Sur la sphere vide. Bulletin of the Academy of Sciences of the USSR, Classe Sci. Mat. Nat., 793–800.

Dong, P. (2008): Generating and updating multiplicatively weighted Voronoi diagrams for point, line and polygon features in GIS. Computers and Geosciences, 34, 411–421.

Fiedler, F.R. (2003): Simple, Practical Method for Determining Station Weights Using Thiessen Polygons and Isohyetal Map. Journal of Hydrologic Engineering, 8/4, 219–221.

Han, D., Bray, M. (2006): Automated Thiessen polygon generation. Water resources research, 42, W11502, doi:10.1029/2005WR004365.

13. Popis literature

Hauer, F. (1867-71): Geologische übersichts - karte der Oesterreich-Ungarischen monarchie, Wien.

Hernitz, Z., Jurak, V. (1973): Primjena paleostrukturalne i statističke analize naslaga mlađega tercijara u području Ivanić-Grada (Sjeverna Hrvatska). Nafta, 24, 7/8, 343–367.

Hohn, M. E. (1988): Geostatistics and Petroleum Geology. Van Nostrand Reinhold, New York, 400 str.

Horváth, F. (1993): Towards a mechanical model for the formation of the Pannonian basin. Tectonophysics, 226, 333–357.

Horváth, F. (1995): Phases of compression during the evolution of the Pannonian Basin and its bearing on hydrocarbon exploration. March. Petrol. Geol., 12, 837–844.

Horváth, F., Royden, L.H. (1981): Mechanism for the Formation of the Intra-Carpathian Basins: a Review. Earth Sci. Rev., 3–4, 307–316.

Horvatinec D. (2008): Računalno geološko modeliranje gornjopanonskih naftno-plinskih ležišta u Savskoj depresiji. Diplomski rad, Sveučilište u Zagrebu, 30 str.

Husanović, E., Malvić, T. (2014): Pregled dosadašnjih determinističkih geostatističkih kartiranja ležišta ugljikovodika u Republici Hrvatskoj te prednosti takvoga pristupa. Nafta, 65/1, 64–68.

Isaaks, E., Srivastava, R. (1989): An Introduction to Applied Geostatistics. Oxford University Press Inc., 243–247 p., New York.

Jensen, J. L., Lake, L. W., Corbett, P. W. M., Goggin, D. J. (2000): Statistics for Petroleum Engineers and Geoscientists. Prentice Hall PTR, 390 p., New Jersey.

Koch, F. (1889): Prilog geološkom poznavanju Moslavačke gore. Rad JAZU, knj. 92, Zagreb.

Koch, F. (1906): Tumač geološke karte Ivanić Kloštar i Moslavina. Geološka prijegledna karta Kraljevine Hrvatske i Slavonije 1:75000, arhiva NSK, Zagreb.

Kos, G. (2014): Model vođenja cikloturističkih ruta na primjeru Bjelovarsko-bilogorske županije. Podravina, 13/26, 76–98.

Kováč, M., Nagymarosy, A., Oszczytko, N., Csontos, L., Slaczka, A., Marunteanu, M., Matenco, L., Márton, E. (1998): Palinspastic reconstruction of the Carpathian- Pannonian region during the Miocene. In: Geodynamic Development of the Western Carpathians (Ed. by M. Rakús), Mineralia Slov. Monogr., 189–217.

Kranjec, V., Prelogović, E., Hernitz, Z. i Blašković, I. (1971): O litofacijelnim odnosima mlađih neogenskih i kvartarnih sedimenata u širem području Bilogore (sjeverna Hrvatska). Geološki vjesnik, 24, 47–55.

13. Popis literature

- Krige, D. (1951):** A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, 119–139.
- Kumar, V. (2007):** Optimal contour mapping of groundwater levels using universal kriging - a case study. *Hydrological Sciences-Journal-des Sciences Hydrologiques*, 52/5, 1038–1050.
- Levorsen, A.I. (1956):** *Geology of petroleum*. Freeman, San Francisco, 703 str.
- Lučić, D., Saftić, B., Krizmanić, K., Prelogović, E., Britvić, V., Mesić, I. & Tadej, J. (2001).** The neogene evolution and hydrocarbon potential of the Pannonian Basin in Croatia. *Marine and petroleum Geology*, 18/1,133–147, ISSN 0264-8172.
- Lulić, I. (2014):** Uporaba metode regresijske analize u rješavanju problema vezanih za inženjersku praksu. Završni rad, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, 52 str.
- Malvić, T. (2003):** Naftnogeološki odnosi i vjerojatnost pronalaska novih zaliha ugljikovodika u Bjelovarskoj uleknini. Disertacija, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 123 str.
- 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.
- Malvić, T. (2008):** Primjena geostatistike u analizi geoloških podataka. INA, SD Istraživanje i proizvodnja nafte i plina, Grupa za tiskarske i grafičke poslove, 105 str., Zagreb.
- Malvić, T. (2011):** Geological maps of Neogen sediments in the Bjelovar Subdepression (northern Croatia). *Journal of Maps*, 304–317.
- Malvić, T. (2012):** Review of Miocene shallow marine and lacustrine depositional environments in Northern Croatia. *Geological Quarterly*, 56/3, 493–504.
- Malvić, T. (2016):** Regional turbidites and turbiditic environments developed during Neogene and Quaternary in Croatia. *Materials and Geoenvironment*, 63, 1, 39–54.
- Malvić, T., Cvetković, M. (2013):** Lithostratigraphic units in the Drava Depression (Croatian and Hungarian parts) – a correlation. *Nafta*, 64/1, 27–33.
- Malvić, T., Cvetković, M., Balić, D. (2008):** *Geomatematički rječnik*. HGD, Zagreb 77 str.
- Malvić, T., Đureković, M. (2003):** Application of the 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.
- Malvić, T., Novak Zelenika, K. (2013):** Hrvatski rječnik odabranih geostatističkih pojmova. *Rudarsko-geološko-naftni zbornik*, 26, 1–9

13. Popis literature

- Malvić, T., Velić, J. (2011):** Neogene tectonics in Croatian Part of the Pannonian Basin and Reflectance in Hydrocarbon Accumulations. In: *New Frontiers in Tectonic Research: At the Midst of Plate Convergence* (ed. Schattner, U.), InTech, 215–238, Rijeka.
- Malvić, T., Vrbanac, B. (2013):** Geomatematički pojmovnik. *Hrvatski matematički elektronički časopis*, 23, 1–49.
- Matheron, G. (1963):** Principles of Geostatistics. *Economic Geology*, 58, 1246–1266.
- Mesić Kiš, I. (2016):** Comparison of Ordinary and Universal Kriging interpolation techniques on a depth variable (a case of linear spatial trend), case study of the Šandrovac Field. *Rudarsko-geološko-naftni zbornik*, 31/2, 41–58.
- Mesić Kiš, I., Malvić, T. (2014):** Zonal estimation and interpolation as simultaneous approaches in the case of small input data set (Šandrovac Field, Northern Croatia). *Rudarsko-geološko-naftni zbornik*, 29/1, 9–16.
- Mesić Kiš, Malvić, T. (2015):** Druga nadopuna baze geomatematičkoga nazivlja u terminološkoj bazi Struna Instituta za hrvatski jezik i jezikoslovlje, <http://struna.ihjj.hr>
- Miletić, P. (1968):** Hidrogeologija sjevernog dijela SR Hrvatske. Disertacija, Sveučilište u Zagrebu, 150 str.
- Miletić, P., Urumović, K. (1975):** O geološkom okviru hidrogeoloških značajki Savske doline u Hrvatskoj. *Zbornik radova RGN fakulteta (1939-1974)*, Sveučilište u Zagrebu, 101–105, Zagreb.
- Novak Zelenika, K. (2012):** Deterministički i stohastički geološki modeli gornjomiocenskih pješčenjačkih ležišta u naftno-plinskom polju Kloštar. Disertacija, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 190 str.
- Novak Zelenika, K., Malvić, T. (2011):** Stochastic simulations of dependent geological variables in sandstone reservoirs of Neogene age: A case study of the Kloštar Field, Sava Depression. *Geologia Croatica*, 64/2, 173–183.
- Novak Zelenika, K., Velić, J., Malvić, T. (2013):** Local sediment sources and palaeoflow directions in Upper Miocene turbidites of the Pannonian Basin System (Croatian part), based on mapping of reservoir properties. *Geological quarterly*. 57/1, 17–30.
- Ožegović, F. (1944):** Prilog geologiji mlađeg tercijara na temelju podataka iz novijih dubokih bušotina u Hrvatskoj. *Vjesnik HDGZ i HDGM*, Svezak II/III, Zagreb.
- Oy Leuangthong, Khan, K.D., Deutsch, C.V. (2008):** Solved Problems in Geostatistics. John Wiley & Sons, Inc., New Jersey, 208 str.
- Pannatier, Y. (1996):** Variowin: Software for Spatial Data Analysis in 2D. Springer, The Netherlands, 91 str.

13. Popis literature

- Pavelić, D. (2001):** Tectonostratigraphic Model for the North Croatian and North Bosnian sector of the Miocene Pannonian Basin system. Blackwell Science, Basin Research, 13, 359–376.
- Pavelić, D. (2002):** The south-western boundary of Central Paratethys. *Geologia Croatica*, 55/1, 83–92, ISSN 1330-030X.
- Pletikapić, Ž., Gjetvaj, I., Jurković, M., Urbiha, H., Hrnčić, Lj. (1964):** Geologija i naftoplinonosnost Dravske potoline. *Geološki vjesnik*, 17, 49–78, Zagreb.
- Prelogović, E. (1975):** Neotektonska karta SR Hrvatske. *Geol. vjesnik*, 28, Zagreb.
- Prelogović, E., HERNITZ, Z. i Blašković, I. (1969):** Primjena morfometrijskih metoda u rješavanju strukturno-tektonskih odnosa na području Bilogore (sjev. Hrvatska). *Geol. vjesnik*, 22, Zagreb.
- Prelogović, E., Saftić, B., Kuk, V., Velić, J., Dragaš, M., Lučić, D. (1998):** Tectonic activity in the Croatian part of the Pannonian basin. *Tectonophysics*, 297, 283–293.
- Riđanović, J. (1973):** Hidrogeografske značajke središnje Hrvatske. *Geografski glasnik*, 35, 51–65.
- Riđanović, J. (1974):** Obilježja prirodne osnove - vode. *Geografija SR Hrvatske (pogl. 3)* (ed. Crkvenčić, I.), Školska knjiga, Zagreb, 67–76.
- Royden, L., H. (1988):** Late Cenozoic Tectonics of the Pannonian Basin System. *AAPG Memoir 45 (Chap. 3) - The Pannonian Basin* (eds. Royden, L., H. & Horváth, F.), 27–48.
- Royden, L.H., Dövényi, P. (1988):** Variations in Extensional Styles at Depth Across the Pannonian Basin System. *AAPG Memoir 45 (Chap. 17) - The Pannonian Basin* (eds. Royden, L.H. & Horváth, F.), 235–255, Tulsa.
- Rögl, F. (1996):** Stratigraphic Correlation of the Paratethys Oligocene and Miocene, *Mitteilungen Ges. Geol. Bergbaustudenten Österreich*, 41, 65–73.
- Rögl, F. (1998):** Palaeographic Consideration for Mediterranean and Paratethys Seaways (Oligocene to Miocene). *Ann. Naturhist. Mus. Wien*, 99A, 279–310.
- Schumann, A.H. (1998):** Thiessen polygon. In: *Encyclopedia of Hydrology and Water Resources*, Kluwer Academic Publishers, Dordrecht, Netherlands, 648–649.
- Špelić, M., Malvić, T., Saraf, V., Zalović, M. (2016):** Remapping of depth of e-log markers between Neogene basement and Lower/Upper Pannonian border in the Bjelovar Subdepression. *Journal of Maps*, 12/1, 45–52.
- Saftić, B., Peh, Z., Velić, J. & Jüttner, I. (2001):** Interdependence of Petrophysical Properties and Depth: Some Implications of Multivariate Solution on Distinction Between the Lower Pontian Hydrocarbon-bearing Sandstone Units in the Western Part of the Sava Depression. *Geologia Croatica*, 54/2, 259–277.

13. Popis literature

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.

Steininger, F.F., Rögl, F. (1979): The Paratethys history - a contribution towards the Neogene dynamics of the Alpine Orogene (an abstract). *Ann. Géol. Pays Hellén.*, Tome Hors Serie, Fasc., III, 1153–1165, Athens.

Steininger, F.F., Rögl, F., Müller, C. (1978): Geodynamik und paläogeographische Entwicklung des Badenien. *Chronostratigraphie und Neostatotypen Miozän der Zentralen*. Bd. VI, Verlag der Slowak. Akad. der Wissenschaften, 110–127, Bratislava.

Thiessen, A.H. (1911): Precipitation for large areas. *Monthly Weather Review*, 39, 1082–1084.

Šegota, T. (1974): Obilježja prirodne osnove - klima. *Geografija SR Hrvatske (pogl. 3)* (ed. Crkvenčić, I.), Školska knjiga, 61–66, Zagreb.

Šegota, T., Filipčić A. (1996): Klimatologija za geografe (pogl. 4), Školska knjiga, 375–452, Zagreb.

Velić, J. (2007): Geologija ležišta nafte i plina. Rudarsko-geološko-natni fakultet, Zagreb, 342 str.

Velić, J., Malvić, T., Cvetković, M. (2015): Geologija i istraživanje ležišta ugljikovodika, Rudarsko-geološko-naftni fakultet, Zagreb, 144 str.

Velić, J., Malvić, T., Cvetković, M., Vrbanac, B. (2012): Reservoir geology, hydrocarbon reserves and production in the Croatian part of the Pannonian Basin System. *Geologia Croatica*, 65/1, 91–101.

Veronesi, F. (2012): 3D Advance mapping of soil properties. Dissertation, Cranfield University, 159 str.

Vrbanac, B. (1996): Paleostrukturalne i sedimentološke analize gornjopanonskih naslaga formacije Ivanić grad u Savskoj depresiji. Doktorska disertacija, Sveučilište u Zagrebu, 121 str.

Vrbanac, B. (2002): Facies and facies architecture of the Ivanić Grad Formation (late Pannonian)—Sava Depression, NW Croatia. *Geologia Croatica*, 55/1, 57–77, ISSN 1330-030X.

Vrbanac, B., Velić J. i 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, ISSN 1335-0552.

Wackernagel, H. (2003): *Multivariate Geostatistics: An Introduction with Applications*, (3rd ed.) Heidelberg: Springer, Berlin, 388 str.

13. Popis literature

Zhou, Q., Liu, G., Zhang, Z. (2009): Improvement and optimization of Thiessen polygon method boundary treatment program. 17th International Conference on Geoinformatics, August, 12–14, 2009, Fairfax, Virginia, USA, doi:10.1109/GEOINFORMATICS.2009.5293458.

Zimmerman, D., Pavlik, C., Ruggles, A., Armstrong M.P. (1999): An Experimental Comparison of Ordinary and Universal Kriging and Inverse Distance Weighting. *Mathematical Geology*, 31/4, 375–390.

Zornjak, D. (2009): Poroznost i propusnost ležišnih stijena u Savskoj i Dravskoj depresiji. Diplomski rad, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 54 str.

Webster, R., Oliver, M. A. (2007): *Geostatistics for Environmental Scientists*, 2nd Edition., John Wiley & Sons Ltd, Chichester, 330 str.

13.2. Neobjavljeni radovi

Šimon, J. (1968): Informativne litostratigrafske jedinice tercijarnog kompleksa u profilima dubokih bušotina na području Dravske potoline. Fond struč. dok., INA-Industrija nafte d.d., Zagreb

13.3. Iz fondova stručne literature

Hajnšek, S. (1971): Tektonika zapadne i istočne Bilogorske zone. Fond struč. dok., INA-Industrija nafte d.d., Zagreb.

Hanich, M. (1964): Izvještaj o rezultatima izrade fotogeološke karte Vrbovačke, Moslavačke i Bilogorske zone. Fond struč. dok., INA-Industrija nafte d.d., Zagreb.

Najdenovski, J., Hajnšek, S. (1980): O strukturnim odnosima i konsedimentacijskom razvoju struktura u bjelovarskoj sinklinali dravske potoline. Fond struč. dok., INA-Industrija nafte d.d., Zagreb.

Najdenovski, J., Hajnšek, S. (1982): Strukturni odnosi Bjelovarskog sinklinorija i graničnog područja Savske i Dravske depresije. Fond struč. dok., INA-Industrija nafte d.d., Zagreb.

13. Popis literature

13.4. Internetske poveznice

<http://lpz-bbz.com.hr/images/dokumenti/86/razvojna-strategija.pdf> (28. veljače 2015.)

https://en.wikipedia.org/wiki/Nearest-neighbor_interpolation (3. studenog 2014.)

<https://www.yumpu.com/en/document/view/29351971/universal-kriging-ucla-statistics>
(15. ožujka 2015.)

<http://sourceforge.net/apps/trac/sagagis/wiki/The%20Philosophy%20of%20SAGA> (9. siječnja 2014.)

<http://sourceforge.net/projects/saga-gis/> (9. siječnja 2014.)

<http://www.goldensoftware.com/products/surfer> (14. srpnja 2016.)

<https://bib.irb.hr/datoteka/843987.Geomat3.pdf> (29. studenog 2016.)

<http://gro-1.itrcweb.org/characteristics-of-interpolation-methods/> (24. siječnja 2017.)

<https://www.khanacademy.org/math/multivariable-calculus/applications-of-multivariable-derivatives/constrained-optimization/a/lagrange-multipliers-single-constraint> (27. siječnja 2017.)

https://en.wikipedia.org/wiki/Lagrange_multiplier#Nonlinear_programming (27. siječnja 2017.)


http://www.d-maps.com/carte.php?num_car=14899&lang=en (29. siječnja 2017.)

14. PRILOZI

Prilog 1: Rječnik geomatematičkih i geostatističkih pojmova, razvijen tijekom doktorskoga istraživanja, s definicijama, napomenama i natuknicama:

centroid – centar gravitacije ili mase opisan kao geometrijski centar 2D područja gdje predstavlja aritmetičku sredinu (prosjeak) položaja svih točaka unutar određenog područja.

Primjer:



Vidi: poligon; Thiessenov poligon

Engl. *centroid*

Njem. *schwerpunkt*

Franc. *centre de gravité*

deklasterizacija – geostatistička metoda koja pridodaje težinske faktore raspoloživom skupu podataka te predstavlja prvi korak pri donošenju zaključaka u prepoznavanju klastera. Klasteriziranim podacima dodijeljeni su manji težinski faktori, a raspršeni podatci imaju veće vrijednosti.

Napomena: U primjeni geostatistike u kartiranju tradicionalno se koriste dvije deklasterizacijske metode: poligonalna metoda (engl. *polygonal method*) i metoda deklasterizacije putem ćelija (engl. *cell-declustering method*). Obje koriste težinski faktor linearne kombinacije raspoloživih vrijednosti uzorka pri iscrpnoj procjeni srednje vrijednosti (cijelog uzorkovanog prostora).

Engl. *declustering*

Njem. *Declustering*

Franc. *Declustering*

14. Prilozi

doseg - vrijednost na kojoj semivariogram prvi put presijeca prag, a nakon toga ne postoji prostorna ovisnost podataka.

Vidi: variogram, parametri

Engl. *range*


Njem. *Aussageweite*

Franc. *rangée*

kolorni prikaz vrijednosti – prikaz vrijednosti određene varijable ljestvicom boja.

Napomena: Uobičajeno se koristi u metodi Thiessenovih poligona gdje svaka boja odgovara vrijednosti točke unutar poligona.

Primjer:



konveksni trup – najmanji konveksni poligon koji zatvara sve centroide. Svi centroidi na granici konveksnog trupa imaju otvorene Thiessenove poligone, a svi unutarnji centroidi imaju zatvorene poligone.

Vidi: poligon; centroid; Thiessenov poligon

Engl. *convex hull*

Njem. *konvexe Hülle*

Franc. *coque convexe*

krigiranje – napredna statistička metode procjene i deterministička interpolacijska metoda kojom se procjenjuju vrijednosti regionalizirane varijable u odabranim točkama mreže.

14. Prilozi

Napomena: Krigiranju prethodi određivanje prostorne zavisnosti, odnosno variogramska analiza. Krigiranje i njegove izvedenice (kokrigiranje i stohastičke simulacije) zajednički su određene kao „najbolji linearni nepristrani procjenitelji“ (engl. *best linear unbiased estimators* – BLUE). Linearnost procjene dana je izrazom koji se kasnije raspisuje u obliku matričnih jednadžbi:

$$Z_k = \sum_{i=1}^n \lambda_i \times Z_i$$

Vrijednosti varijable na odabranoj lokaciji (Z_k) procjenjuju se na temelju postojećih okolnih vrijednosti (Z_i). Svakom podatku pridružen je i odgovarajući težinski koeficijent (λ) kojim se opisuje utjecaj tog mjenog podatka na vrijednost varijable koja se procjenjuje. Što je vrijednost λ veća, točka je prostorno bliža točki procjene i jače utječe na nju. Zbroj svih težinskih koeficijenata jednak je 1 (osim kod tehnike jednostavnog krigiranja). Prema obliku matričnih jednadžbi razlikujemo jednostavno, obično, univerzalno, indikatorsko i disjunktivno krigiranje.

Vidi: obično krigiranje; univerzalno krigiranje; variogram

Engl. *Kriging*

Njem. *Kriging*

Franc. *Krigeage*

krigiranje, obično – najčešće upotrebljavana tehnika krigiranja gdje vrijedi pretpostavka da lokalna srednja vrijednost nije jednaka ili približna srednjoj vrijednosti svih podataka.

Napomena: U tehnici OK minimiziran je iznos varijance krigiranja pomoću linearnog vanjskog parametra, nazvanog Lagrangeov faktor (μ). Faktor ograničenja minimizira pogrešku pa procjena postaje nepristrana. Uvjet prilikom procjene tehnikom običnog krigiranja je da je zbroj svih težinskih koeficijenata jednak 1. Matrična jednadžba tehnike OK glasi:

$$\begin{bmatrix} \gamma(Z_1 - Z_1) & \gamma(Z_1 - Z_2) & \dots & \gamma(Z_1 - Z_n) & 1 \\ \gamma(Z_2 - Z_1) & \gamma(Z_2 - Z_2) & \dots & \gamma(Z_2 - Z_n) & 1 \\ & & & & 1 \\ \gamma(Z_n - Z_1) & \gamma(Z_n - Z_2) & \dots & \gamma(Z_n - Z_n) & 1 \\ & 1 & & & 0 \end{bmatrix} \times \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \lambda_n \\ \mu \end{bmatrix} = \begin{bmatrix} \gamma(X_1 - X) \\ \gamma(X_2 - X) \\ \dots \\ \gamma(X_n - X) \\ 1 \end{bmatrix}$$

Vidi: krigiranje

Engl. *Ordinary Kriging*

Njem. *Ordinary Kriging*

Franc. *Krigeage Ordinaire*

14. Prilozi

krigiranje, univerzalno – metoda krigiranja korištena na podacima sa značajnim prostornim trendom. Dijeli nasumičnu funkciju u linearnu kombinaciju determinističkih funkcija; nestacionarni trend, poznat kao i *drift* te nasumičnu komponentu koja predstavlja ostatak (engl. *residual*) nasumične funkcije.

Napomena: Obično i jednostavno krigiranje podrazumijevaju stacionarnost, pretpostavlja se da je sredina (engl. *mean*) nepromijenjena na cijelom području. Međutim, u stvarnosti se srednja vrijednost nekog prostornog podatka ne može smatrati konstantnom ili nepromjenjivom, ona varira budući da ovisi i o apsolutnom položaju uzorka pa se naziva nestacionarnom. Nestacionarna regionalizirana varijabla ima dvije komponente: trend (engl. *drift*; prosječna ili očekivana vrijednost regionalizirane varijable) te ostatak (razliku između stvarnih mjerenja i trenda), a često se metoda UK naziva i krigiranje s trendom.

Primjer:

Metoda UK pretpostavlja kako sredina ima funkcionalnu ovisnost o prostornom položaju te se može aproksimirati odgovarajućim modelom oblika:

$$m(x) = \sum_{l=1}^k a_l f_l(x)$$

gdje su:

a_l l-ti koeficijent koji će biti procijenjen iz skupa podataka, f_l je l-ta osnovna funkcija prostornih koordinata koje opisuju prostorni trend, a k je broj funkcija upotrijebljenih pri modeliranju prostornog trenda.

Vidi: krigiranje, ostatak

Engl. *universal kriging*

Njem. *Universelles Krigen*

Franc. *krigeage universel*

metoda najbližeg susjedstva – interpolacijska metoda koja dodjeljuje vrijednost najbliže točke svakom čvoru mreže.

Napomena: Poznata i kao proksimalna interpolacija ili metoda Thiessenovih poligona.

Vidi: Thiessenov poligon

Engl. *nearest neighbor*

Njem. *nächster Nachbar interpolation*

Franc. *plus proche voisin interpolation*

14. Prilozi

odstupanje – predstavlja slučajnu komponentu regionalizirane varijable, odnosno pojavu kada krivulja siječe os Y u nekoj pozitivnoj vrijednosti (C_0).

Napomena: Pojava odstupanja je obilježje velikog broja eksperimentalnih semivariograma, a upućuje na razliku u vrijednostima vrlo bliskih uzoraka koji se u praksi smatraju uzorcima s jedinstvene lokacije. Može se ukloniti smanjenjem površine ili povećanjem broja uzoraka, no u praksi se ono vrlo često ne može u potpunosti eliminirati.

Vidi: variogram, parametri

Engl. *nugget*

Njem. *Abweichung*

Franc. *Écart*

ostatak – razlika između promatrane vrijednosti zavisne varijable (y) i predviđene vrijednosti (\hat{y}). Svaki podatak ima jedan ostatak.

$$e = y - \hat{y}$$

Napomena: variogram ostataka radi se kod tehnike univerzalnog krigiranja. U tome slučaju ostatci predstavljaju ulaznu varijablu za kartiranje.

Vidi: univerzalno krigiranje

Engl. *residual*

Njem. *Residuum*

Franc. *résidu*

prag - razlika pojedinačnih vrijednosti i srednje vrijednosti skupova podataka, odnosno odgovara vrijednosti varijance.

Napomena: Krivulja semivariograma nakon dosezanja praga najčešće prestaje pravilno rasti te nastavlja oko njega oscilirati. Međutim, svaki semivariogramski model ne treba uvijek imati prag.

Vidi: variogram, parametri

Engl. *sill*

Njem. *Schwelle*


Franc. *seuil*

poligon – geometrijski oblik ograničen konačnim nizom ravnih linijskih dijelova koji zatvaraju petlju te formiraju zatvoreni krug. Ti ravni linijski dijelovi nazivaju se rubovima, a točke gdje se rubovi spajaju nazivaju se vrhovima.

14. Prilozi

Primjer:

Poligon sastavljen od ravnih linijskih dijelova između N vrhova (x_i, y_i) , $i = 0$ do $N-1$.



Engl. *polygon*

Njem. *Vieleck*

Franc. *Polygone*

proksimalna interpolacija – vidi metodu najbližeg susjedstva.

Engl. *proximal interpolation*

Njem. *proximale Interpolation*

Franc. *interpolation proximale*


Thiessenov dijagram – mreža svih Thiessenovih poligona definiranih grupom točaka.

Napomena: poznat i kao Voronoiov dijagram, Wigner-Setzove ćelije i Dirichletovo popločenje.

Voronoiovi dijagrami koji se koriste u geofizici i meteorologiji za analizu prostorno raspoređenih podataka nazivaju se Thiessenovim dijagramima po meteorologu A.G.Thiessenu.

Thiessenovi dijagrami koji se koriste u matematici i računalnim znanostima nazivaju se Voronoiovi dijagrami po matematičaru Georgyju Voronoyu.

Primjer:



Engl. *Thiessen diagram*

Njem. *Thiessen Diagramm*


Franc. *Thiessen diagramme*

Thiessenov poligon – područja (geometrijski likovi) stvorena oko točkastih objekata koji čine međusobno nepreklapajuća susjedstva objekata, a cjelokupni sadržaj jednog Thiessenova poligona nalazi se najbliže upravo onoj točki na temelju koje je taj poligon nastao.

Napomena: poznat i kao Voronoiov poligon.

Primjer:

Thiessenov poligon definiran je kao položaj svih točaka bliže centroidu $C \in N$ nego bilo kojem drugom centroidu.



Vidi: Thiessenov dijagram, Thiessenov rub, Thiessenov vrh

Engl. *Thiessen polygon*

Njem. *Thiessen Polygone*


Franc. *Thiessen polygone*

14. Prilozi

Thiessenov rub – mjesto svih ravnomjernih točaka koje su najbliže dva centroida.

Napomena: Svaki dio konveksne granice koji je povezan s dva Thiessenova vrha naziva se Thiessenov rub te predstavlja stranicu Thiessenova poligona.

Primjer: Izradba Thiessenova ruba / stranice poligona simetralom između točaka. Točke se spoje dužinom te se načine kružnice radijusa većeg od polovice njihove udaljenosti. Sjecište kružnica predstavlja simetralu.



Vidi: Thiessenov poligon, Thiessenov dijagram


Engl. *Thiessen edge*

Njem. *Thiessen Kanten*

Franc. *Thiessen bord*

Thiessenov vrh – vrh Thiessenovog poligona. Predstavlja spojište duž opsega lokalnih poligona gdje proizvedeni centroidi mijenjaju vrijednost susjednih centroida.

Primjer:



Vidi: Thiessenov poligon, Thiessenov dijagram

Engl. *Thiessen vertex*

Njem. *Thiessen Knoten*

Franc. *Thiessen sommet*

14. Prilozi

udaljenost - vrijednost na kojoj se podatci (semi)variograma uspoređuju.

Napomena: Svaka vrijednost udaljenosti čini jednu klasu kojoj se često dodjeljuje određena tolerancija kako bi se povećao broj ulaznih podataka, a nazvana je odmakom. To znači da granicama klase dodajemo vrijednost odmaka te na taj način širimo klasu. Odmak predstavlja veličinu koja se slobodno određuje, a najčešće predstavlja polovicu vrijednosti koraka jer se na taj način maksimalno uvećava broj parova podataka, a time i pouzdanost prostorne analize.

Vidi: variogram, parametri

Engl. *distance*

Njem. *Entfernung*

Franc. *distance*

variogram - jedan od temeljnih geostatističkih alata koji služi za određivanje prostorne zavisnosti i definiranje međusobne povezanosti točkastih podataka koji se žele zajednički kartirati.

Napomena: Često se naziva i semivariogramom (γ) koji ima potpuno jednaka svojstva, osim što se kod variogramске jednađbe iz nazivnika eliminira broj 2.

Vidi: eksperimentalni variogram, teorijski modeli variograma, parametri semivariograma

Engl. *variogram*

Njem. *Variogramm*

Franc. *variogramme*

variogram, eksperimentalni – variogram izražen jednađbom:

$$2\gamma(h) = \frac{1}{N(h)} \times \sum_{n=1}^{N(h)} [z_n - z_{n+h}]^2$$

gdje su:

$2\gamma(h)$ - vrijednost variograma;

$N(h)$ - broj parova podataka uspoređenih na udaljenosti 'h';


z_n - vrijednost na lokaciji 'n';

z_{n+h} - vrijednost varijable na lokaciji udaljenoj za 'h' od promatrane lokacije 'n'.

Napomena: Variogramsku analizu čini izračun eksperimentalnog variograma podataka koji je aproksimiran jednim od teorijskih modela. Takav model predstavlja ulaz za metodu krigiranja.

Primjer:

14. Prilozi



Vidi: variogram; parametri; teorijski modeli


Engl. *variogram, experimental*

Njem. *Variogramm, experimentelle*

Franc. *variogramme, expérimental*

variogram, parametri – vrijednosti (semi)variograma koje se mogu očitati s eksperimentalne krivulje.

Primjer:



Vidi: variogram; doseg; odstupanje; prag; udaljenost

Engl. *variogram, parameters*

Njem. *Variogramm, Parameter*

Franc. *variogramme, paramètres*

14. Prilozi

variogram, teorijski model – aproksimacija eksperimentalnog variograma koja daje ulazne podatke za metodu krigiranja.

Napomena: U interpretaciji geoloških varijabli najčešće se upotrebljavaju sferni, eksponencijalni i Gaussov model od kojih sva tri sadržavaju prag. Sljedećim jednadžbama se određuje ponašanje varijable određene odabranim teorijskim modelom, odnosno oblici krivulja:

$$\gamma(h) = C \left[\left(\frac{3h}{2a} \right) - \left(\frac{h^3}{2a^3} \right) \right] \quad h \leq a \quad \text{sferni model}$$

$$\gamma(h) = C \quad h > a$$

$$\gamma(h) = C \left[1 - \exp\left(\frac{-h}{a}\right) \right] \quad \text{eksponencijalni model}$$

$$\gamma(h) = C \left[1 - \exp\left(\frac{-h^2}{a^2}\right) \right] \quad \text{Gaussov model}$$

gdje su:


$\gamma(h)$ - vrijednost variograma na udaljenosti 'h';

C – konstanta;

h – udaljenost;

a – doseg.

Primjer:



Vidi: variogram, eksperimentalni

Engl. *variogram, theoretical model*

Njem. *Variogramm, theoretisches Modell*

Franc. *variogramme, modèle théoriqu*

15. ŽIVOTOPIS

Rođena sam u Banja Luci (BIH) 18. svibnja 1985. godine. Tijekom osnovnoškolskog i srednjoškolskog obrazovanja sudjelovala sam pet puta na državnom natjecanju iz geografije, a dobila sam i priznanje kao najbolji učenik OŠ Ivana Brnjika Slovaka u Jelisavcu i SŠ Isidora Kršnjavoga u Našicama gdje sam završila opću gimnaziju.

Dodiplomski studij upisujem 2004. godine na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu, smjer prof. geologije i geografije. Na trećoj godini studija upisujem razliku predmeta za inženjera geologije. Proforski smjer sam diplomirala 27. studenog 2009. godine na Mineraloško-petrografskom zavodu s radom „*Uzroci, razmjeri i moguće posljedice klimatskih promjena*“, pod vodstvom mentorice izv. prof. dr. sc. Gordane Medunić. Na četvrtoj godini studija dobivam pohvalnicu Fakultetskog vijeća za izuzetan uspjeh na studiju. Inženjerski smjer završavam 28. siječnja 2011. godine na Geološko-paleontološkom zavodu s radom „*Konodonti u peperitnom facijesu jastučastih lava Vareša, srednja Bosna i Hercegovina*“, a pod vodstvom mentora izv. prof. dr. sc. Jasenske Sremac i izv. prof. dr. sc. Ladislava Palinkaša. Oba rada obranjena su s izvrsnim, a takav je i opći uspjeh na studijima.

Od 2011. godine radim kao profesor geografije, u početku na određeno i nepuno radno vrijeme, a trenutno sam zaposlena na neodređeno i puno radno vrijeme na tri škole. U navedenom razdoblju predavala sam u osam škola te sam 2013. godine položila stručni ispit iz geografije.

U akademskoj godini 2013./2014. upisujem doktorski studij iz geologije na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu pod vodstvom studijske savjetnice izv. prof. dr. sc. Gordane Medunić. Od 2014. godine pripremam doktorsku disertaciju naslova „*Kartiranje i reinterpretacija geološke povijesti Bjelovarske subdepresije univerzalnim krigiranjem te novi opći metodološki algoritmi za kartiranje sličnih prostora*“ pod vodstvom mentora izv. prof. dr. sc. Gordane Medunić i izv. prof. dr. sc. Tomislava Malvića. Sve kolegije i seminare položila sam s izvrsnim uspjehom. U suradnji s izv. prof. dr. sc. Tomislavom Malvićem održala sam dva predavanja: „*Znanstveni kolokvij o univerzalnom krigiranju*“ održan 15. siječnja 2016. na Rudarsko-geološko-naftnom fakultetu te „*Krigiranje - odabir tehnike, obradbe i kartiranja geoloških podataka*“ održan 29. travnja 2016. na Prirodoslovno-matematičkom fakultetu u organizaciji Hrvatskog geološkog društva. Sudjelovali smo na Sajmu inovacija – INOVA 2016

održanom 09.11. – 12.11. 2016. gdje smo na međunarodnoj izložbi osvojili srebrnu medalju s radom „Način izdvajanja varijabli i izračuna linearnih jednadžbi kod opisa regionalnih nagiba geoloških površina“. Od početka 2017. godine član sam Geomatematičkog odsjeka.

15.1. Popis radova

Znanstveni i stručni radovi:

- **Mesić Kiš, I. (2016):** Comparison of Ordinary and Universal Kriging interpolation techniques on a depth variable (a case of linear spatial trend), case study of the Šandrovac Field. Rudarsko-geološko-naftni zbornik, 31/2, 41–58.
- **Mesić Kiš, I., Malvić, T. (2014):** Zonal estimation and interpolation as simultaneous approaches in the case of small input data set (Šandrovac Field, Northern Croatia). Rudarsko-geološko-naftni zbornik, 29/1, 9–16.
- **Mesić Kiš, I., Karaica, B., Medunić, G., Romić, M., Šabarić, J., Balen, D., Šoštarko, K. (2016):** Soil, bark and leaf trace metal loads related to the war legacy (The Prašnik rainforest, Croatia). Rudarsko-geološko-naftni zbornik, 31/2, 13–28.

Znanstveni radovi i sažeci u zbornicima skupova te konferencijska sudjelovanja:

- **Mesić I., Medunić, G. (2013):** Is global warming a scientific certainty or a political liability? Challenges in Meteorology 3, Extreme Weather and its Impact on Society. Zagreb: Croatian Meteorological Society, November, 21–22, 2013, Zagreb. <http://www.meteohmd.hr/files/file/Aktivnosti/MeteoIzazovi/MI3/PDF/PR4.pdf>
- **Mesić, I., Medunić, G. (2014):** Declustering of field's data located on northern margin of the Bjelovar Subdepression. 6th HR-HU and 17th HU geomathematical congress “Geomathematics - from theory to practice”. Conference book: Cvetković, M.; Novak Zelenika K.; Geiger, J. (ur.). Zagreb: Croatian Geological Society, May, 21-23, 2014, 183-189, Opatija.
- **Mesić, I., Balen, D., Romić, M., Medunić, G., Bakić, H., Kampić, Š., Šoštarko, K. (2014):** Trace metal contamination of the Prašnik rain forest soil as a consequence of the war legacy. BIOGEOMON 2014, 8th International Symposium on Ecosystem Behavior. Book of Abstracts: Holzheu, S.; Thies, B. (eds.). University of Bayreuth: July, 13-17, 2014, 259–259, Bayreuth.

15. Životopis autora s popisom radova

- **Mesić Kiš, I. (2016):** Hrvatski rječnik odabranih geostatističkih i geomatematičkih pojmova. Matematičke metode i nazivlje u geologiji. Zbornik radova: Malvić, T.; Velić, J. (ur.), Zagreb: Rudarsko-geološko-naftni fakultet, 29. listopada, 2016, 1–11, Zagreb.

15.2. Otkrića i ostalo

- *Malvić T., Mesić Kiš, I. Druga nadopuna baze geomatematičkoga nazivlja u terminološkoj bazi Struna Instituta za hrvatski jezik i jezikoslovlje (2015), enciklopedijska natuknica*
- *Malvić, T., Mesić Kiš, I. Krigiranje – odabir tehnike, obradbe i kartiranje geoloških podataka (2016), predavanje*
- *Malvić, T., Velić, J., Mesić Kiš, I. Treća nadopuna baze geomatematičkoga nazivlja (Hrvatski terminološki portal Instituta za hrvatski jezik i jezikoslovlje), (2016) enciklopedijska natuknica*
- *Mesić Kiš, I., Malvić, T. Znanstveni kolokvij o univerzalnom krigiranju (2016), predavanje*
- *Mesić Kiš, I., Malvić, T. Način izdvajanja varijabli i izračuna linearnih jednadžbi kod opisa regionalnih nagiba geoloških površina (2016), otkriće*