Variografska analiza prostorne raspodjele olova u Dugopolju

Vugrinec, Jelena

Master's thesis / Diplomski rad

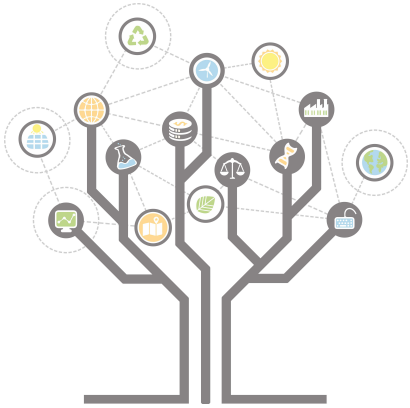
2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Geotechnical Engineering / Sveučilište u Zagrebu, Geotehnički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:130:289741

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

Repository of Faculty of Geotechnical Engineering - Theses and Dissertations

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Variografska analiza prostorne raspodjele olova u Dugopolju

Vugrinec, Jelena

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Geotechnical Engineering / Sveučilište u Zagrebu, Geotehnički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:130:289741

Rights / Prava: In copyright

Download date / Datum preuzimanja: **2020-11-05**

Repository / Repozitorij:

Repository of Faculty of Geotechnical Engineering

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
GEOTEHNIČKI FAKULTET

Jelena Vugrinec

VARIOGRAFSKA ANALIZA PROSTORNE RASPODJELE OLOVA U DUGOPOLJU

DIPLOMSKI RAD

VARAŽDIN, 2017.

SVEUČILIŠTE U ZAGREBU
GEOTEHNIČKI FAKULTET

VARIOGRAFSKA ANALIZA PROSTORNE RASPODJELE OLOVA U DUGOPOLJU

DIPLOMSKI RAD

KANDIDAT:
Univ. bacc. ing. amb. Jelena Vugrinec

MENTOR:
Dr. sc. Ivan Kovač
KOMENOR
Dr.sc.Sanja Kapelj
NEPOSREDNI VODITELJ:
Dr.sc. Željka Fiket

VARAŽDIN, 2017.

Sveučilište u Zagrebu
Geotehnički fakultet

ZADATAK ZA DIPLOMSKI RAD

Pristupnica: JELENA VUGRINEC

Matični broj: 138 - 2015./2016.

Smjer: UPRAVLJANJE VODAMA

NASLOV DIPLOMSKOG RADA:

VARIOGRAFSKA ANALIZA PROSTORNE RASPODJELE OLOVA U DUGOPOLJU

Rad treba sadržati: 1. Uvod
2. Značajke šireg promatranog područja
3. Geografske, geološke, hidrogeološke, pedološke i klimatske značajke istraživanog terena
4. Metoda procjene prirodne ranjivosti vodonosnika
5. Geostatistika
6. Rezultati
7. Rasprava
8. Zaključak
9. Literatura

Pristupnica je dužna predati mentoru jedan uvezen primjerak diplomskog rada sa sažetkom. Vrijeme izrade diplomskog rada je od 45 do 90 dana.

Zadatak zadan: 20.03.2017. Rok predaje: 11.09.2017.

Mentor:	Drugi mentor/komentor:	Predsjednik Odbora za nastavu:
Doc.dr.sc. Ivan Kovač	Prof.dr.sc. Sanja Kapelj	Doc.dr.sc. Igor Petrović

Neposredni voditelj:
Dr.sc. Željka Fiket

REPUBLIKA HRVATSKA - GEOTEHNIČKI FAKULTET - SVEUČILIŠTE U ZAGREBU - VARAŽDIN

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad pod naslovom

VARIOGRAFSKA ANALIZA PROSTORNE RASPODJELE OLOVA U DUGO POLJU

rezultat mog vlastitog rada koji se temelji na istraživanjima te objavljenoj i citiranoj literaturi te je izrađen pod mentorstvom prof. dr. sc. Ivana Kovača i komentora prof. dr. sc. Sanje Kapelj.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem takoder, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

U Varaždinu, 11.09.2017.

JELENA VUGRINEC

(Ime i prezime)

Vugrinec

(Vlastoručni potpis)

SAŽETAK

AUTOR: Jelena Vugrinec
NASLOV RADA: Variografska analiza prostorne raspodjele olova u Dugopolju
KLJUČNE RIJEČI: tlo, podzemna voda,krš, variografska analiza, variogram, olovo

Tlo ili pedosfera predstavlja više ili manje tanki, rahli sloj na površini Zemlje koji može biti vrlo značajan čimbenik u sprečavanju onečišćenja podzemnih voda vode. Područje istraživanja obuhvaćeno ovim radom je Dugopolje, smješteno sa sjeverne strane Mosora. Radi se o izrazito krškom području kojeg odlikuje prirodna ranjivost vodonosnika, zbog čega je vrlo važno dobro poznavati geološke,hidrogeološke i pedološkeznačajke terena. Na temelju prethodno izmjerenih koncentracija olova u tlu na 53 lokacijena području Dugopoljaprovedena je variografska analiza prostorne raspodjele olova.Koncentracije olova u tlu se kreću unutar očekivanih raspona i niže su od maksimalnih dopuštenih koncentracija (MDK) propisanih Pravilnikom o zaštiti poljoprivrednog zemljišta od onečišćenja. Na temelju dobivenih mapa prostorne raspodjele olova određenasu područja s povećanim koncentracijama. Uočena povećanja razine olova u tlu mogu se pripisati blizini važnih regionalnih prometnica i autocesti koje prolazi tim područjem. Vrlo je bitno održavati dobro stanje kakvoće tla na području Dugopolja zbog blizine vrlo velikog krškog izvora Jadro, koji opskrbljuje pitkomvodom veliko područje i praktički nema alternative za njega ukoliko se on onečisti.

SADRŽAJ

1. UVOD ... 1
2. ZNAČAJKE ŠIREG PROMATRANOG PODRUČJA (Splitsko-dalmatinska županija) ... 3
2.1. Geografske značajke ... 3
2.2. Klimatske karakteristike ... 4
2.3. Osnovne geološke karakteristike te obilježja tla, vegetacije i faune ... 4
3. GEOGRAFSKE, GEOLOŠKE, HIDROGEOLOŠKE, PEDOLOŠKE I KLIMATSKE KARAKTERISTIKE ISTRAŽIVANOG TERENA ... 5
3.1. Prostorno razvojne i resursne značajke ... 5
3.2. Geografske i reljefne karakteristike područja ... 7
3.3. Geološka građa terena ... 8
3.4. Hidrogeološke značajke terena ... 8
3.5. Hidrografske značajke terena ... 9
3.6. Pedološke karakteristike ... 10
3.7. Klimatske karakteristike ... 11
4. METODA PROCJENE PRIRODNE RANJIVOSTI KRŠKIH VODONOSNIKA ... 12
4.1. KARTA RANJIVOSTI ... 13
4.1.1. SINTACS metoda ... 13
4.1.2. EPIK metoda ... 13
4.1.3. PI metoda ... 14
4.1.4. COP metoda ... 14
5. GEOSTATISTIKA ... 15
5.1. Variografija ... 16
5.1.1. Eksperimentalni variogram ... 16
5.1.2. Uklapanje teorijskih variograma u eksperimentalni ... 18
5.1.3. Baza podataka ... 20
6. REZULTATI ... 21
7. RASPRAVA ... 29
8. ZAKLJUČAK ... 31
9. LITERATURA ... 32
POPIS SLIKA ... 34
POPIS TABLICA ... 35

1. UVOD

U današnje vrijeme potrebe za pitkom vodom su sve veće, stoga je potrebno očuvanje kvalitete i kvantitete podzemnih voda koje se postiže mnogobrojnim istraživanjima tla i sedimenata. Krški vodonosnici su izrazito osjetljivi na onečišćenja zbog svojih specifičnosti kao što su tanak pokrov, koncentrirana infiltracija, ponori te koncentriranje toka u epikrškoj i vadoznoj zoni. Iako su dubine do podzemne vode u visokoj zoni krša vrlo velike (čak i preko 200 m), prirodna ranjivost ovih vodonosnika vrlo je visoka zbog morfoloških pojava (jame, vrtače, ponori) s praktički izravnom vezom površine i vodonosnika. Također, velike brzine podzemnih tokova ukazuju na vrlo brzi pronos potencijalnog onečišćenja što ove vodonosnike izdvaja u vrlo ranjive. Zbog svoje reaktivnosti, tlo i sediment predstavljaju značajan čimbenik u zadržavanju i usporavanju potencijalnog onečišćenja na njegovom putu prema podzemnoj vodi.

Tlo je rastresiti sloj Zemljine kore, sastavljeno od krute, tekuće i plinovite faze, različito od litološke podloge prema morfološkim, kemijskim, fizičkim i biološkim značajkama te određeno dubinom dosega procesa pedogeneze [1].

Republika Hrvatska još uvijek nema temeljni zakon, ni strategiju kojom se štiti tlo. *Zakonom o zaštiti okoliša (NN 110/07)* tlo se definira kao neobnovljivo dobro koje se mora koristiti održivo uz očuvanje njegovih funkcija te se zahtjeva da se nepovoljni učinci na tlo moraju izbjegavati u najvećoj mogućoj mjeri. Također se navodi da zaštita tla obuhvaća očuvanje zdravlja i funkcija tla i da se onečišćenje, odnosno oštećenje tla smatra štetnim utjecajem na okoliš.

Količina metala u tlu ovisi o mnogobrojnim čimbenicima kao što su mineralni sastav ishodišnog materijala, pedogenetski čimbenici te odnos tvari s vodom, vjetrom i ledom. Metali su najčešće vezani za organsku materiju, minerale glina te Mn – Fe oksihidrokside. Prisutnost pojedinih kemijskih vrsta elemenata ovisi o pH i redoks potencijalu. Pritom je važno napomenuti da svi kemijski oblici nekog metala nemaju jednak utjecaj na okoliš [2] te se ukupna koncentracija ne može koristiti kao kriterij procjene mogućih negativnih učinaka pojedinog metala. Olovo je teški metal koji se koristi u proizvodnji akumulatora, boja, benzina i dr., a zbog svoje postojanosti, visoke toksičnosti [3] i činjenice da se tijekom godina akumulira u organizmu, olovo je opasno kako za čovjeka tako i za biljni i životinjski svijet. Trovanje olovom nastaje nakon

dugotrajnoga unosa malih količina u organizam. Olovo se u tlu i vodi najčešće nalazi u obliku Pb^{2+} anorganskih i organskih specija [3]. Ion olova, Pb^{2+}, se u vodonosnoj sredini vrlo često veže kao kation na otopljene anione nastale procesom oksidacije kao što su kromati, fosfati, arsenati, uraniti itd. U oksičnim i alkanim uvjetima Pb^{2+} može oksidirati u Pb^{4+}.

Olovo u okoliš dospijeva iz antropogenih i prirodnih izvora. Prirodni izvori olova su trošenje stijena, emisije vulkana, šumski požari, biogeni materijali itd. Antropogeni izvori olova u okolišu su izgaranje fosilnih goriva, olovni benzini, mineralna gnojiva, odlagališta komunalnog otpada itd. [4]. Olovo se, kao i brojni drugi teški metali, prenosi atmosferom na velike udaljenosti te je onečišćenje tla uglavnom posljedica atmosferske depozicije[3].U današnje vrijeme emisija olova u okoliš se smanjila zbog korištenja bezolovnog benzina.Povećane koncentracije olova se mogu najčešće naći u tlu i vegetaciji uz rubove prometnica. To je posljedica donosa zrakom te površinskog tečenja [4].

U ovom diplomskom radu zadatak je bila variografska analiza koncentracije olova u tlu na području Općine Dugopolje. Cilj rada je uz pomoć variografskeanalize odrediti prostornu raspodjelu koncentracija olova u tlu na istraživanom području.Svrha rada je na temelju provedenih analiza odrediti mjesta koja su izloženija utjecaju povišenih koncentracija olova, te na temelju toga odrediti mjere ili postupke koji bi pogodovali njihovom smanjenju. U slučaju povišenja koncentracija olovau podzemnim vodama javlja se direktna opasnost za zdravlje ljudi, ukoliko bi se takva voda eksploatirala. Zato je bitno odrediti korake smanjivanja koncentracije olova, jer sami procesi remedijacije podzemnih voda su vrlo skupi, a moguće ih je izbjeći pravilnim upravljanjem vodnim resursima.

2. ZNAČAJKE ŠIREG PROMATRANOG PODRUČJA(Splitsko-dalmatinska županija)

2.1. Geografske značajke

Splitsko dalmatinska županija zauzima površinu od 14,045 km^2, od čega 4,520 km^2otpada na kopno.. Na tom prostoru, prema popisu stanovništva iz 2011. godine, živi 454 798 stanovnika. Sjedište županije je u gradu Splitu. Osim kopnenog dijela kojeg čine obalni i zaobalni dio županije, pripadaju joj još i otoci Brač, Hvar, Šolta, Vis, Drvenik Veliki i Mali i niz manjih otočića. Kao dio južne Hrvatske zauzima najveći dio srednje Dalmacije. Splitsko dalmatinsku županiju prema teritorijalnom ustroju Republike Hrvatske čini 15 gradova i 39 općina. Dugopolje je udaljeno od Splita 12 km, a od grada Solina, kojemu neposredno gravitira, 10 km. Općina Dugopolje zbog blizine grada Splita te prometnica koje je povezuju, kako sa Splitom tako i sa ostalim prostorima županije, ima izuzetno značajangeoprometnipoložaj. Položaj Splitsko-dalmatinske županije i općine Dugopolje prikazan je slici 1[5].



Slika 1.Geografski položaj Splitsko dalmatinske županije i općine Dugopolje [5]

2.2. Klimatske karakteristike

Županija se nalazi u zoni jadranskog tipa mediteranske klime čije su osnovne osobine suha i vruća ljeta te blage i vlažne zime. Krećući se od otočnog preko obalnog do zaobalnog područja, srednje godišnje temperature opadaju, a povećava se ukupna količina oborina. Klima otočkog područja je topla s obiljem sunca, malo oborina i temperaturama koje rijetko padnu ispod nule, za razliku od klime zaobalnog područja gdje temperature tijekom jesenskih i zimskih mjeseci često padaju ispod nule, a prisutna je i veća količina oborina. Klima priobalja je karakterizirana maksimalnim oborinama u hladno doba godine te vrućim i suhim, izrazito vedrim ljetom. Temperatura najhladnijeg mjeseca se kreće između –3°C i +18°C, dok je srednja temperatura najtoplijeg mjeseca veća od 22°C. Prevladavajući vjetrovi su bura i jugo čija učestalost iznosi 35 % do 55 % godišnje. Jadransko more kao prirodni rezervoar relativno tople vode s temperaturom od 10°C do 26°C najvažniji je indikator klimatskih karakteristika na širem području Županije [5].

2.3. Osnovne geološke karakteristike te obilježja tla, vegetacije i faune

Geomorfološki, dominira krševit i vapnenački sastav terena, s brojnim krškim formama od kojih su najvažnija krška polja (Cetinsko, Hrvatačko, Sinjsko, Mućko-postinjsko, Konjsko, **Dugopoljsko**, Dicmansko i Imotsko polje, Rastok i Vrgoračko jezero). Atmosferski i ostali utjecaji rezultirali su pojavama abrazije, erozije, denudacije, akumulacije, klizanja, odronjavanja i osipanja. U pogledu rudnih bogatstava, na području Županije iskorištavaju se kamen, cementni lapor, glina, gips, šljunak, pijesaki dolomit. Rezultat raznolikosti krša u reljefskom i klimatskom pogledu, geološko-petrografskoj građi, načinu uslojenosti, čvrstoći i sastavu stijena jest velika pedološka raznovrsnost, koja se ogleda u nagloj izmjeni različitih tipova hidromorfnih i automorfnih tala na relativno malom prostoru. U pogledu hidrogeologije i vodnih resursa, u zaobalnom dijelu ističu se krška polja kao slivna područja iz kojih se voda drenira podzemnim tokovima. Na obali, osim površinskih vodotoka (rijeke Cetina, Jadro i Žrnovnica) postoje veći dotoci podzemnih voda iz kraškog zaobalja (npr. ponornica Vrlike i Matice u Imotskom odnosno Vrgoračkom polju). Na otocima nema površinskih voda, a i podzemne vode su skromnih količinačesto pod utjecajem mora,

odnosno zone miješanja slatke i slane vode.Flora i fauna na području Županije bogate su i raznolike, s velikim brojem endemskih, ugroženih i zaštićenih vrsta. Kod flore se razlikuju područja šumske vegetacije, (antropogeni) travnjaci (livade i pašnjaci), vegetacija pukotina stijena, vegetacija točila, obalne pjeskovite i šljunkovite sipine te vegetacija u zoni prskanja mora. Bogata je i podmorska fauna, a posebno ističemo područja morskih cvjetnica. Specifična karakteristika faune Županije predstavlja bogatstvo različitih podzemnih staništa, špilja i jama te podzemnih voda, osobito u području krša, bogatih reliktnim oblicima. Često spominjanjasu vodena staništa s reliktom čovječje ribice (Vrgoračko polje). Zakonom su zaštićene i velike zvijeri, primjerice vuk, ris i medvjed (planinsko područje). Na području Županije obitavaju i posljednji primjerci npr. Eleonorinogsokola i nekih vrsta šišmiša [5].

3. GEOGRAFSKE, GEOLOŠKE, HIDROGEOLOŠKE, PEDOLOŠKE I KLIMATSKE KARAKTERISTIKE ISTRAŽIVANOG TERENA

3.1. Prostorno razvojne i resursne značajke

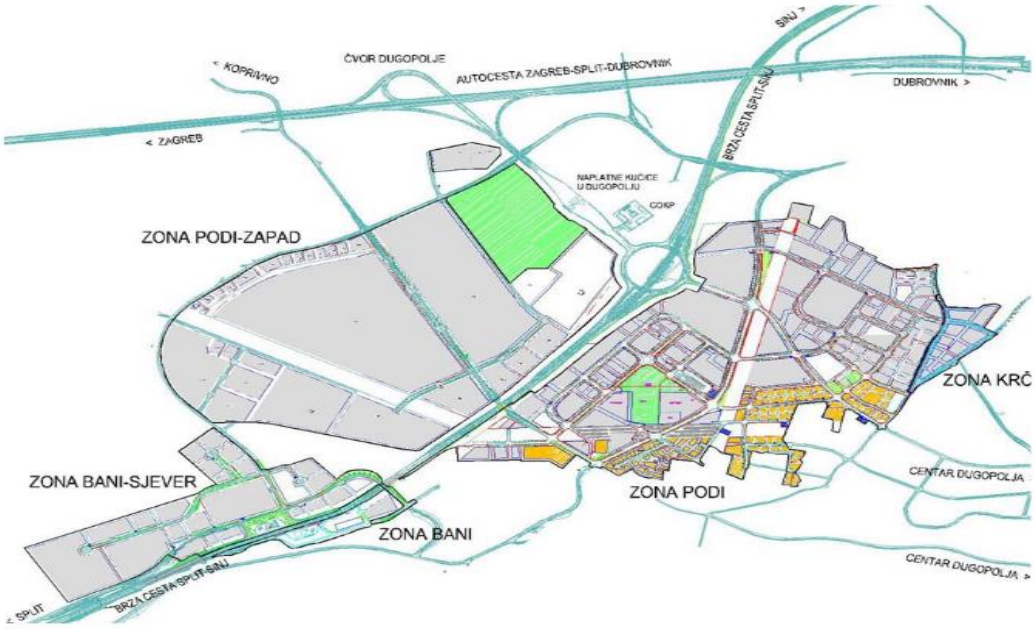
Općina Dugopolje, iako spada u skupinu srednjih općina u Republici Hrvatskoj, može se okarakterizirati kao općina s dosta izraženim različitostima i neravnomjernostima i po rasporedu stanovništva i po rasporedu prirodnih potencijala. O neravnomjernosti između površine naselja i broja stanovnika zorno svjedoči podatak da Dugopolje prekriva 59 % površine općine, a ostala naselja Koprivno, Kotlenice i Liska 41 %, dok u broju stanovnika Dugopolje sudjeluje s 85,7 %, a naselja Koprivno, Kotlenice i Liska s 14,3 % stanovnika[5].

Od značajnijih gospodarskih subjekata na ovom području nalazi se asfaltna baza i kamenolom. S uređenjem poslovnih zona u Dugopolju, kojih je danas čak pet (Slika 2) iako su zapravo povezana funkcionalna cjelina, krenulo se od zone Podi koja se prostire na 95,6 ha te uključuje oko 70 obrtnika i malih poduzetnika, uglavnom trgovačkog – ugostiteljskog profila. Najveća vrijednost ovog prostora je njegova iznimna prometnapovezanost s ostalim dijelovima Županije i većim gradovima, jer je osim državne ceste D1 otvoren i prolaz autoceste Zagreb - Split – Dubrovnik [5].

Danas je u poduzetničkoj zoni Podi izgrađeno preko pedesetak gospodarskih građevina.Poduzetnička je zona Krč mnogo manja i nalazi se na istočnom rubu zone Podi i s njom dijeli dobru komunalnu i prometnu povezanost. Zapadno od zone Podi su zone Bani i Bani – sjever, a dijeli ih cesta Split – Sinj. Najnovija je zona Podi – zapad (2).

Kada se započelo s izradom planske dokumentacije, najvažnija je bila studija utjecaja na okoliš za cijelo područje jer se dugopoljska dolina nalazi u drugoj zoni sanitarne zaštite izvorišta rijekeJadro[6] glavnog vodozahvata i vodocrpilišta za cijelo splitsko područje, što je znatno utjecalo na planiranje, gradnju i tehnološku namjenu sadržaja u poslovnoj zoni.

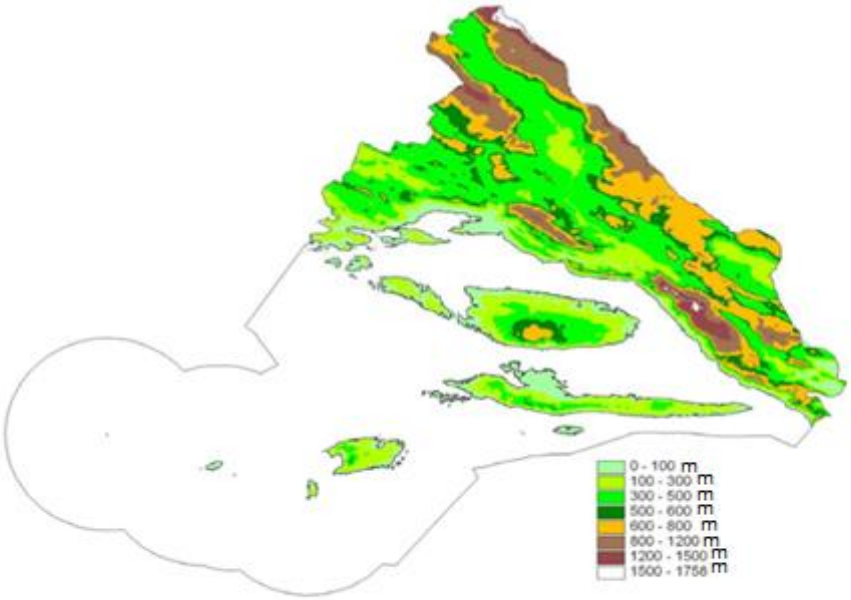
Dugopolje dobiva vodu od *Vodovoda i kanalizacije* d.o.o. iz Splita, Regionalnog vodovoda Zagore koji obuhvaća općine Dugopolje, Muć i Lećevicu te dio Klisa, sa zahvatom u Rudama na sinjskom području (HE *Orlovac*). Uz navedenoizgrađen jei kanalizacijski kolektor koji je s podsustavom Dugopolje – Klis dio kanalizacijskog sustava Split – Solin čije se otpadne vode pročišćavaju na uređaju Stupe i odvode u Bračko kanal. Dugopoljsko područje se nalazi i na raskrižju velikih elektroenergetskih pravaca, između velike 400/220/110 kV trafostanice Konjsko, Splita kao velikog potrošača i dviju hidroelektrana *Zakučac* i *Đale*.



Slika 2. Tlocrt svih poduzetničkih zona u Dugopolju [5]

3.2. Geografske i reljefne karakteristike područja

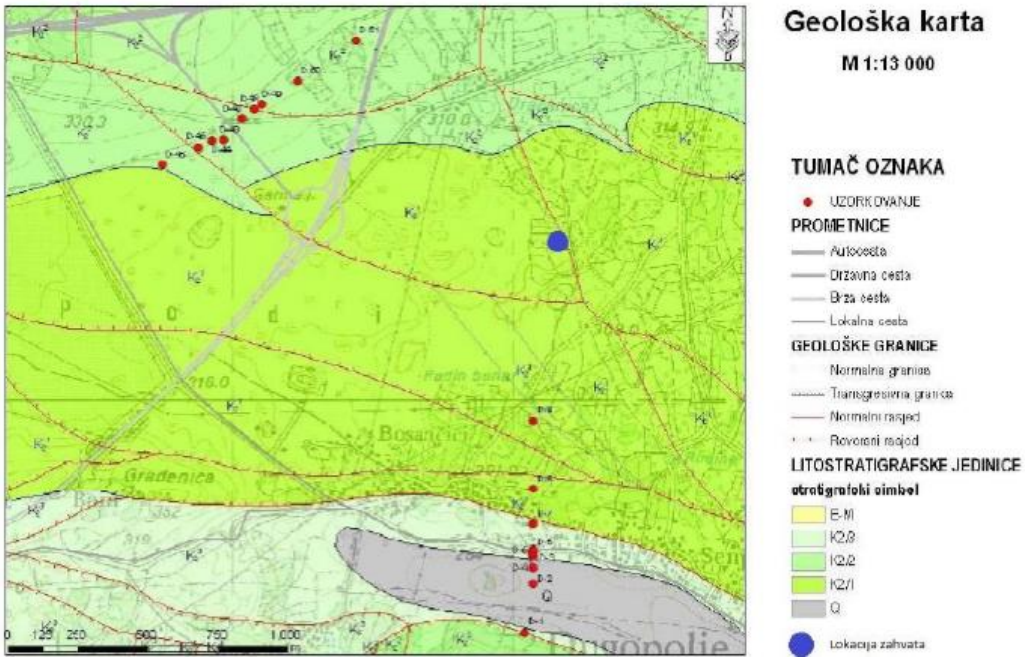
Prostor Općine Dugopolje prvenstveno obilježava vapnenački krški reljef, kojega karakteriziraju vapnenački grebeni te krške uvale i udoline (Slika 3). Krške udoline čine polja prekrivena plodnim zemljištem koja se obrađuju i koriste za uzgoj. Mosor je najznačajniji planinski greben s najvećim vrhom od 1330 m, najveće polje je Dugopolje s površinom od 160 ha, dok je najveća krška zaravan područja Koprivno – Dugopolje.Uska obrađena dolina karakterizira središte Općine, takozvano Dupoljsko polje po kojem je i naselje dobilo ime. Naselje Dugopolje smjestilo se na sjevernoj strani istoimenog polja. U naselju koje prvenstveno karakteriziraju industrijske zone, stambene kuće su raštrkane, a između njih dominiraju gajevi hrastova, ostaci nekadašnjih šuma hrasta medunca. Geografska obilježja Općine Dugopoljeuvjetovala su, kroz povijest pa i danas, prolazak glavnih trasakopnenih komunikacija [6].Upravo zbog izgradnje cestovne infrastrukture te poduzetničke zone danas je ovo područje ekonomski i gospodarski značajno razvijeno. Međutim, zbog gospodarskog razvitka, ovom području prijeti opasnost od zagađenja tla, a i time zagađenje podzemnih voda.



Slika 3. Reljefna karta Splitsko – dalmatinske županije[5]

3.3. Geološka građa terena

Područje Općine Dugopolje je izgrađeno od klastičnih i karbonatnih naslaga mezozojske i kenozojske starosti. Jugozapadno područje Mosora izgrađeno je od dolomita i breča. Gornju kredu nalazimo u vapnencima i dolomitima što se može vidjeti na slici 4 [7].



Slika 4. Geološka karta istraživanog s ucrtanom lokacijom zahvata od strane izrađivača studije [8]

3.4. Hidrogeološke značajke terena

Prema vodopropusnosti, stijene na području Dugopolja (Slika 5) podijeljene su u četiri osnovne kategorije:

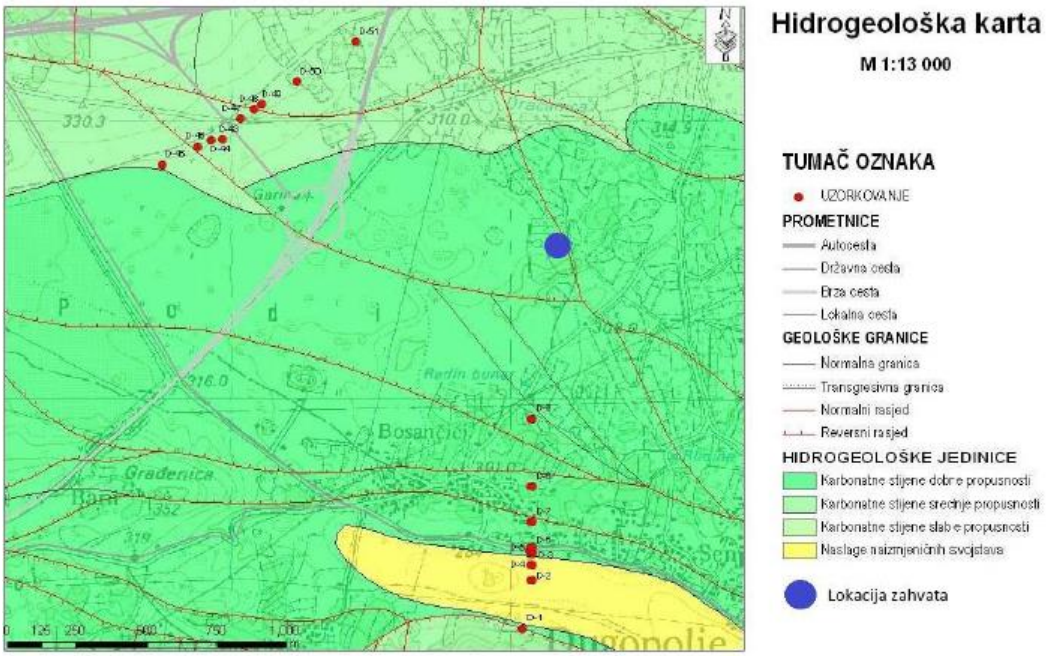
- propusne stijene,
- djelomično propusne stijene,
- djelomično nepropusne stijene,
- nepropusne stijene.

Dobro propusne karbonatne stijene sastoje se od karbonatnih stijena eocena te mlađeg paleozoika i mezozoika. Područje izvora Jadra i Žrnovnice uglavnom izgrađuju gornjokredni, dobro uslojeni vapnenci s dobrom vertikalnom i horizontalnom uslojenošću. Sekundarnog su poroziteta nastalog kao posljedica razlomljenosti uzduž pukotina i rasjeda. Zbog velike vertikalne i horizontalne propusnosti omogućuju infiltraciju oborinskih te horizontalnu cirkulaciju podzemnih voda.

Karbonatne stijene srednje propusnosti sastoje se od glinovitih vapnenca, anizičkih dolomita, klastita, breča i laporovitih vapnenca paleocena.

*Karbonatne stijene slabe propusnosti*tvore dolomitni vapnenci, vapnenci cenomana te pločasti vapnenci turona. Karakterizira ih sekundarna propusnost, dok je bolja horizontalna nego vertikalna vodljivost.

Nepropusne stijene grade klastične naslage donjeg trijasa i eocenskog fliša [7].



Slika 5. Hidrogeološka karta istraživanog područjas ucrtanom lokacijom zahvata [8]

3.5. Hidrografske značajke terena

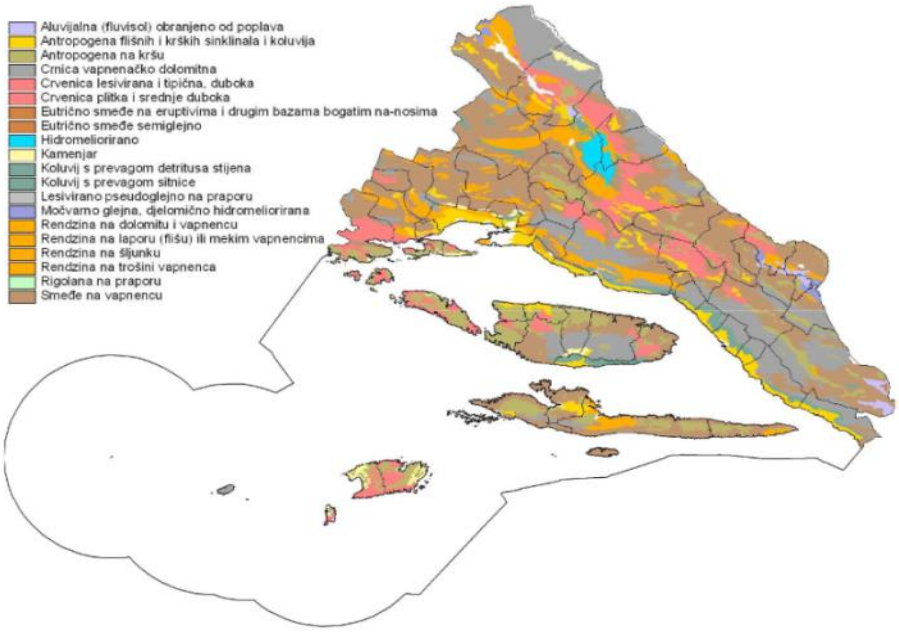
Prostor same Općine je bezvodni kraj, dok Dugopoljsko polje spada u tzv. suha polja jer njime ne protječu vodotoci te nema ni izvora vode. Područje Općine se nalazi u II. zoni sanitarne zaštite izvorišta rijeka Jadro i Žrnovnica što je od županijskog značaja glede

zaštite navedenih izvora, s obzirom da se vodoopskrbni sustav Split, Kaštela i Trogir opskrbljuju s izvora rijeke Jadro. Općina Dugopoljeopskrbljuje se iz vodoopskrbnog sustava Zagore, odnosno crpne stanice Sinj, vodosprema „Vučipolje“, lociranoj na koti 394 m n.m. [7].

Rijeka Jadro je tipična krška rijeka koja se formira od podzemnog dotoka s gornjih horizonta i površinskih dotoka s direktnog sliva. Izvor rijeke Jadro se nalazi u podnožju jugozapadnih padina planine Mosor na 33 m n.m.
Prema klasifikaciji voda, rijeka Jadro pripada I. kategoriji voda cijelim tokom od izvora do vodenih pragova nizvodno od centra grada Solina. Nizvodni dio rijeke koji je pod utjecajem mora i samo ušćepripadaju II. kategoriji voda [6].

3.6. Pedološke karakteristike

Najznačajnije poljodjelske površine na području Općine su Dugopoljsko polje, Vučepolje, polje na sjevernoj strani naselja Liska i polje s južne strane naselja Koprivno. Najveće polje je Dugopoljsko poljeispunjeno antropogenom crvenicom, što je rezultat tisućljetne obrade zemljišta. Tlo takvih karakteristika se formira na čvrstim mezozojskim vapnencima i dolomitima u području krša. Tlo se zbog velike izloženosti erozije obično nalazi na zaravnima i udubljenima te je najčešće dubine 30 –70 cm.
Ostala tla koja nalazimo na području Dugopolja su smeđa primorska tla i antropogena teresirana tla kamenjara (Slika6), dokna nadmorskim visinama iznad 600 m prevladavaju planinske vapneno – dolomitne crnice [6].



Slika 6. Rasprostranjenost pojedinih tipova tala u Splitsko – dalmatinskoj županiji [9]

3.7. Klimatske karakteristike

Područje Dugopolja ima izmijenjeni jadranski tip mediteranske klime. To se očituje u srednjim vrijednostima temperature i količini padalina. Temperature zaobalnog dijela županije su u prosjeku za 3°C niže nego uz obalni dio županije, naročito u zimskom periodu, a količina padalina je veća nego u priobalju. Kiše padaju uglavnom u zimskom periodu godine, pa tako skoro dvije trećine ukupnih oborina pada u navedenom razdoblju. Za općinu Dugopolje izrazito je malo podataka što se tiče klime područja, te se navedeni podaciodnose na obalni dio Splitsko – dalmatinske županije. Pretpostavlja se da planinske barijere priobalja sprječavaju veći utjecaj mediteranske klime na područje Zagore[6].

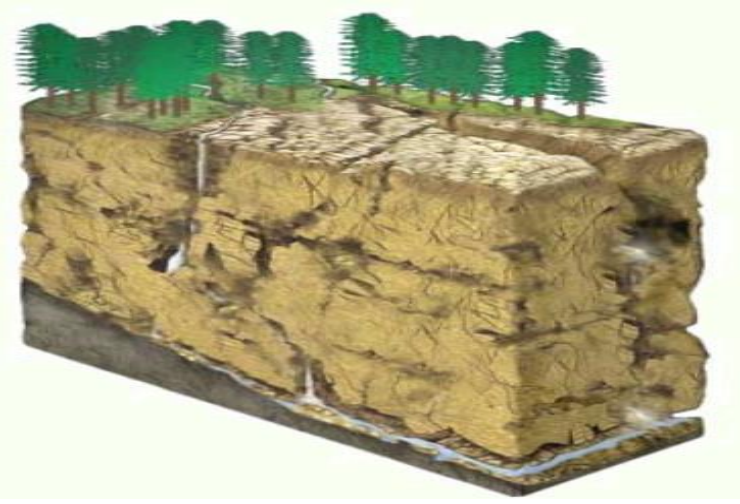
4. METODA PROCJENE PRIRODNE RANJIVOSTI KRŠKIH VODONOSNIKA

Promatrano područje je prekriveno s krškim karbonatnim stijenama, što omogućuje zadržavanje velike količine visoko kvalitetne podzemne vode. Podzemna voda prolazi kroz kanale i pukotine (Slika 7)velikom brzinom i relativno kratkim vremenom zadržavanja, što omogućuje brzo širenje potencijalnog površinskog zagađenja. Iz tog razloga krški vodonosnik je izrazito osjetljiv i vrlo ugrožen s ljudskim aktivnostima.

Kroz godine, znanstvenici su razvili brojne metode kojima je moguće procijeniti ranjivost podzemnog vodonosnog sustava. Procjenjivanje ranjivosti je ponekad vrlo subjektivan proces te uvelike ovisi o metodi koja se koristi, jer na jednom terenu koji se ispituje s različitim metodama može doći do velikih razlika u rezultatima.

Početkom 21. stoljeća, u sklopu projekta COST 620 „Ranjivost i karte rizika za zaštitu karbonatnih krških vodonosnika " znanstvenici su predložili okvirni pristup s kojim bi se ujednačio postupak odabira podataka i njihovo vrednovanje te omogućila usporedba rezultata dobivenih primjenom metoda na različitim područjima. Metoda koja se razvila nazvana je „Europski pristup" i predložena su tri parametra koja utječu na „punjenje" vodonosnika od podine do razine podzemne vode: preklapanje slojeva (O), koncentracija protoka (C) i režim padalina (P).

„Europski pristup" nam ne može dati točnu metodologiju kao ni ocjenu svakoga faktora, ali nam može dati grube smjernice koje svaka zemlja može prilagoditi svojim posebnim uvjetima te raspoloživim podacima.



Slika 7. Trodimenzionalni grafički prikaz vertikalnog profila krškog vodonosnika

4.1. KARTA RANJIVOSTI

Karte ranjivosti podzemnih voda predstavljaju karte koje na više ili manje subjektivan način pokazuju sposobnost prirodne sredine da zaštiti podzemne vode, prije svega njihovu kvalitetu.

4.1.1. SINTACS metoda

Ova metoda procjene ranjivosti se temelji na sedam pokazatelja odnosno parametara:

- dubina na kojoj se nalazi podzemna voda (S),
- utjecaj efektivnog filtriranja (I),
- koeficijent stišljivosti u tlu/sedimentu (T),
- hidrogeološke osobine vodonosnika (A),
- hidrogeološka provodljivost vodonosnika (C) i
- hidrogeološka uloga u nagibu terena (S).

Svaki parametar ima opseg vrijednosti između 1 i 10, gdje vrijednostraste s porastom ranjivostivodonosnika. Standardnim postupkom, vrijednost parametra C procijenjena je na temelju koeficijenta hidrauličke vodljivosti (K), a on ovisi isključivo o vrsti stijene koja izgrađuje vodonosnik. Stoga je u analizu uključen još jedan pokazatelj, odnosno stupanj raspucanosti stijene. Posebnom analizom dobiven je prostorni raspored ponora na karti, i broj ponora na području od 250x250 m, s kojim je kombinirana mapa parametra C, dobivena standardnom metodom. Tako dobiveni modificirani parametar C uključen je u izravno dobivanja indeksa ranjivosti i na kraju za kartu ranjivosti dobivenu SINTACS metodom [9].

4.1.2. EPIK metoda

Ova metoda je izravno razvijena za krške vodonosnike te predstavlja temelj „Europskog pristupa“. Njome se može procijeniti ranjivost s određivanjem 4 glavna atributa:

- epikrška zona (E),
- zaštitni sloj (P),
- uvjeti infiltracije (I)

- razvoj krške mreže (K).

Na kraju se svaki faktor množi s faktorom ponderiranja (u rasponu od 1 do 3), kako bi se dobio utjecaj svakog atributa u izračunu zaštitnog faktora, te se na kraju pomoću njega dobije karta ranjivosti. Kada se ova metoda koristila za procjenu ranjivosti sliva Jadro i Žrovnice, bilo je problematično određivanje faktora E. Zbog toga je vrlo visoki stupanj ranjivosti značajno smanjen, što je mnogo realističnija situacija [10].

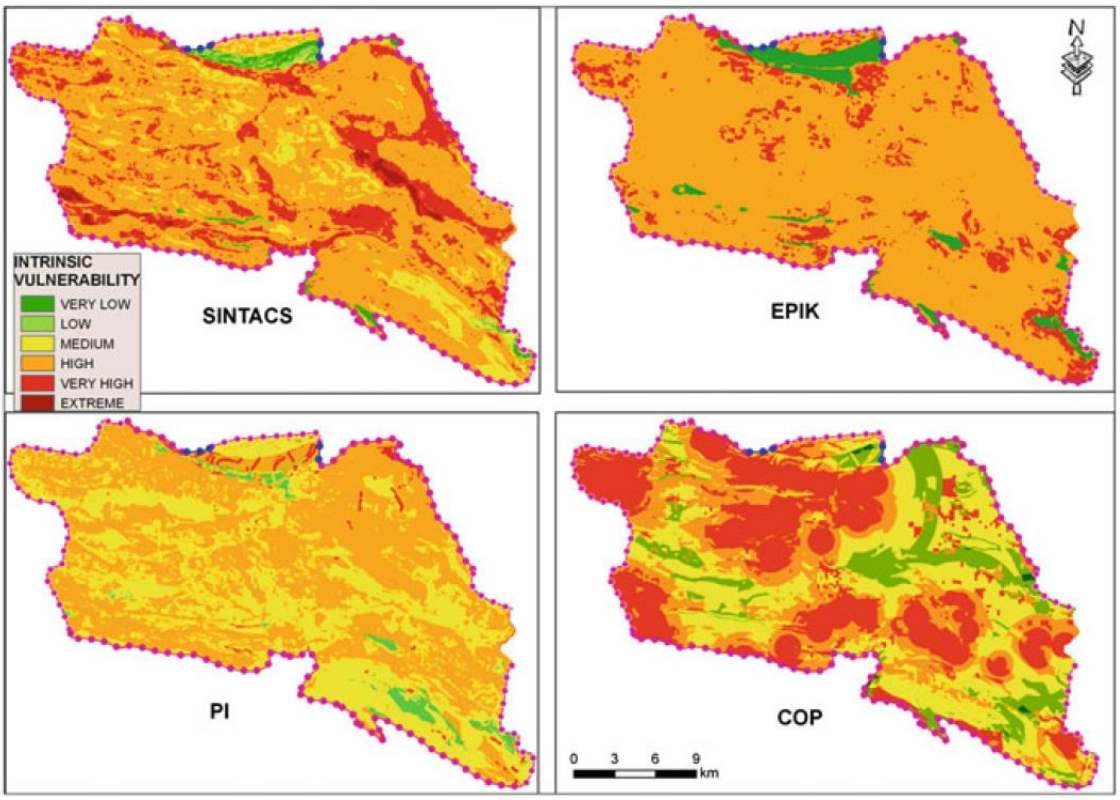
4.1.3. PI metoda

Ova metoda je razvijena za vrijeme trajanja projekta COST 620.Čini se vrlo jednostavna jer je potrebno procjenjivati samo dva parametra, funkciju zaštitnih slojeva (P) i uvjete filtriranja (I).Međutim, ona uključuje mnogo više faktora nego prethodne metode.npr. za parametar P je potrebno određivanje čak sedam faktora. Stupanj ranjivosti dobije se na temelju faktora sigurnostiπ (π= P * I). Prilikom procjene subfaktora, ovdje je također u izračun uzeta i gustoća ponora.Prirodna ranjivost PI metodom dobiva se množenjem pojedinačnih faktora P i I. Kao umnožak predstavljen je faktor sigurnosti –π, s rasponom vrijednosti od 0 do 5, gdje veće vrijednosti prikazuju veću prirodnu zaštitu, odnosno manju ranjivost vodonosnika od onečišćenja s površine [10].

4.1.4. COP metoda

Ova metoda je najmlađa od svih metoda te u potpunosti zadovoljava sve smjernice „Europskog pristupa“. Procjena parametra O je ista kao i kod PI metode, ali je bolja za procjenu na krškom području[10].

Usporedba karata ranjivostivodonosnikaza slivno područje Jadro i Žrnovnica dobivenih različitim metodama (SINTACS, EPIK, PI i COP) [10] prikazana je na slici 8.



Slika 8. Karta prirodne ranjivosti podzemnih voda dobivena s jednom od metoda (SINTACS, EPIK, PI i COP, [10])

5. GEOSTATISTIKA

Geostatistika je grana Primijenjene statistike kojase najviše koristi u primijenjenoj geoznanosti i geološkom inženjerstvu(geologiji, hidrogeologiji, hidrologiji, geokemiji, rudarstvu itd.), ali nalaziprimjenu i u drugim područjima kao što su šumarstvo, ekologija, poljoprivreda i sl. Izraz geostatistika potječe od prof. GeorgesaMathérona i njegovih kolega iz Centra za morfološku matematiku (franc. Centre de MorophologieMathematique), iz grada Fontainebleau u Francuskoj. Ovim pojmom opisane su metode, koje surazvijene za rješavanje problema procjene koncentracije ruda – prvenstveno zlata, a zatim i drugih vrsta sirovina [11].

Osnovni koncept geostatistike temelji se na mjerenju prostorne raznolikosti koja je manja od varijance svih podataka koji čine jedan skup mjerenja. Prostorno neovisni podaci opisuju se isključivo njihovom ukupnom varijancom, odnosno srednjom vrijednošću za koju se podrazumijeva da odgovara očekivanju cijele populacije. Ipak,

prostorni podaci u većini slučaja nisu prostorno neovisni. Vrijednosti podataka koji su prostorno bliski pokazuju manju promjenjivost od vrijednosti podataka koji su udaljeniji jedni od drugih. Naravno, što je podatak udaljeniji pretpostavka je da će on manje opisivati očekivanu vrijednost u točki procjene [12].

U geostatističkoj praksi najčešće se rješavaju problemi u dvodimenzionalnom istražnom prostoru. Pri tome su x i y prostorne koordinate, dok je z oznaka za mjereni parametar.

5.1. Variografija

5.1.1. Eksperimentalnivariogram

Utjecaj regionalizirane varijable na nekom istražnom prostoru grafički se prikazuje eksperimentalnim variogramom. Variogram ne analizira same rezultate mjerenja već njihove međusobne razlike. Izračun vrijednosti semivarijance može ići u svim smjerovima. Zbog jednostavnosti, za sada se pretpostavlja kako je prostor izotropan, prema tome regionalizirana varijabla ima ista svojstva u svim smjerovima. U rješavanju problema broj podataka je od nekoliko desetaka do nekoliko stotina. Zbog toga se u geostatističkim izračunima koristi računalo i adekvatni software. Prostorni rasporedi rezultata mjerenja ponovno su međusobno vrlo različiti kao i međusobna povezanost podataka iz istog istražnog prostora. Zbog toga je neophodno izraditi eksperimentalni variogram za svaki prostor.Međusobna povezanost podataka iz istog istraživanog prostora može se odrediti i na osnovi razlika između podataka. Podaci koji su najbliži, u prosjeku se najmanje razlikuju. S povećanjem udaljenosti između rezultata mjerenja, razlike se u prosjeku povećavaju [12].
U analizi razlika između podataka, slično kao i autokoleracijskoj analizi potrebno je kvantitativno izraziti međusobnu povezanost podataka za svaku udaljenost unutar istraživanog prostora, te utvrditi oblik i domet te povezanosti.
Svaki zbroj kvadrata razlika dijeli se s pripadnim dvostrukim brojem parova podataka:

$$y(h) = \frac{N(h)}{2N(h)} \sum_{i=1}^{N(h)} (x_i - x_{i+h})^2$$

y(h) je semivarijanca i jedna je od osnovnih mjera u geostatistici [13].

Odstupanje (C_0), ili „efekt grumena“ je pojava kada krivulja siječe os ordinata u nekoj pozitivnoj vrijednosti C_0, (Slika 9) odnosno vrijednost variograma na nultoj udaljenosti *h*. Upućuje na razliku u vrijednostima vrlo bliskih uzoraka koji se u praksi smatraju uzorcima s jedinstvene lokacije [13]. Može se također pojaviti kao posljedica varijabilnosti na udaljenosti manjoj od udaljenosti uzorkovanja i zbog grešaka u mjerenju.

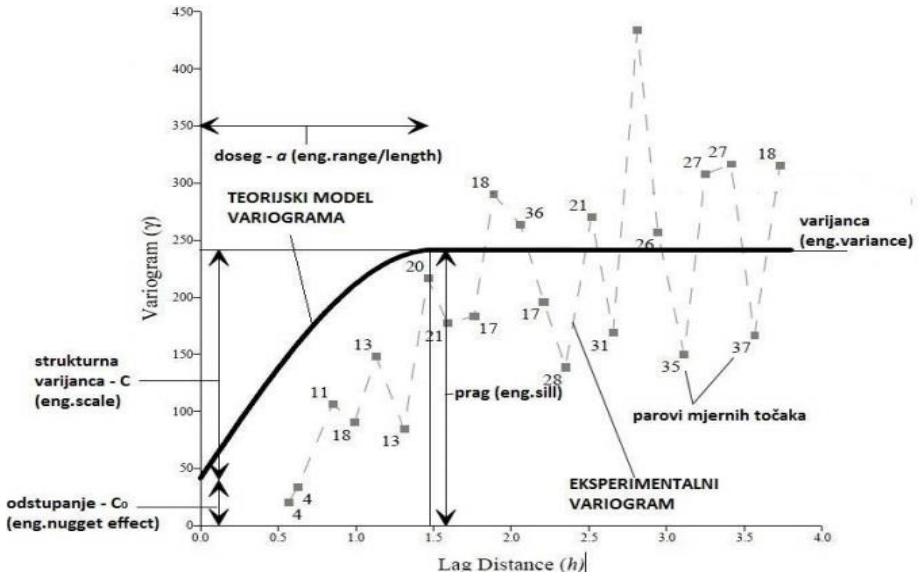
Prag (σ) odgovara vrijednosti stvarne varijance podataka (Slika 10). Ukupna vrijednost praga jednaka je zbroju vrijednosti odstupanja i strukturne varijance [12].

Treba napomenuti da je podudarnost između greške procjene i praga variograma sasvim slučajna. Nakon dosezanja praga (ako ga postiže) variogramska krivulja najčešće prestaje pravilno rasti te nastavi oko njega oscilirati [13].

Domet ili doseg (a) je horizontalna udaljenost (h) na kojoj semivariogram prvi put presijeca prag [13].

Pretpostavlja se da u horizontalnom smjeru iznad dometa ne postoji prostorna korelacija podataka, odnosno kovarijanca je jednaka nuli.

Udaljenost ili korak (h) se odnosi na udaljenost među varijablama, odnosno mjernim točkama. Svaka udaljenost čini jedan razred. Toj vrijednosti udaljenosti često je dodijeljena određena tolerancija kako bi se povećao broj ulaznih podataka, a nazvana je odmakom. To znači da se granicama razreda dodaje vrijednost odmaka, šireći tako interval razreda. Odmak se u najvećem broju primjena semivariogramskog računa postavlja na 1/2 vrijednosti udaljenosti h, jer se na taj način maksimalno povećava broj parova podataka, a time i pouzdanost prostorne analize [13].



Slika 9. Variogram i njegove komponente [12]

5.1.2. Uklapanjeteorijskihvariograma u eksperimentalni

Gotovo svi eksperimentalni variogrami mogu se matematički aproksimirati s nekoliko teorijskih modela, npr.: sfernim, eksponencijalnim, Gaussovim, linearnim ili logaritamskim (deWysovim). Razlikuju se prema tome sadržavaju li prag, te po načinu ponašanja krivulje u blizini ishodišta [13]. Prva tri modela (sferni, eksponencijalni, Gaussov) najčešće se upotrebljavaju u interpretaciji geoloških varijabli. Modeli bez praga rijetki su npr. u naftno-geološkoj praksi. Surfer 8 nam nudi različite metode interpolacije kao što su: eksponencijalni model, Gaussov model, linearan model, logaritamski model, Power,Quadratic, RationalQuadratic, Spherical – Sferični, Wave (Hole Effect), Cubic– kubični i Pentaspherical model.

Postupak krosvalidacije koristimo kao metode za provjeru uspješnosti interpolacije u različitim sredinama. Takav postupak posebno se uspješno upotrebljava kada se žele ocijeniti rezultati dobiveni s dvjema interpolacijskim metodama ili više njih za isti ulazni skup mjerenih vrijednosti [14]. Pojam krosvalidacije uobičajen je u matematičkoj terminologiji (engl. cross-validation), a ovdje je preveden i kao numerička procjena pogreške kako bi najbolje opisao ulogu u ocjeni kvalitete kartiranja. Načelo metode:

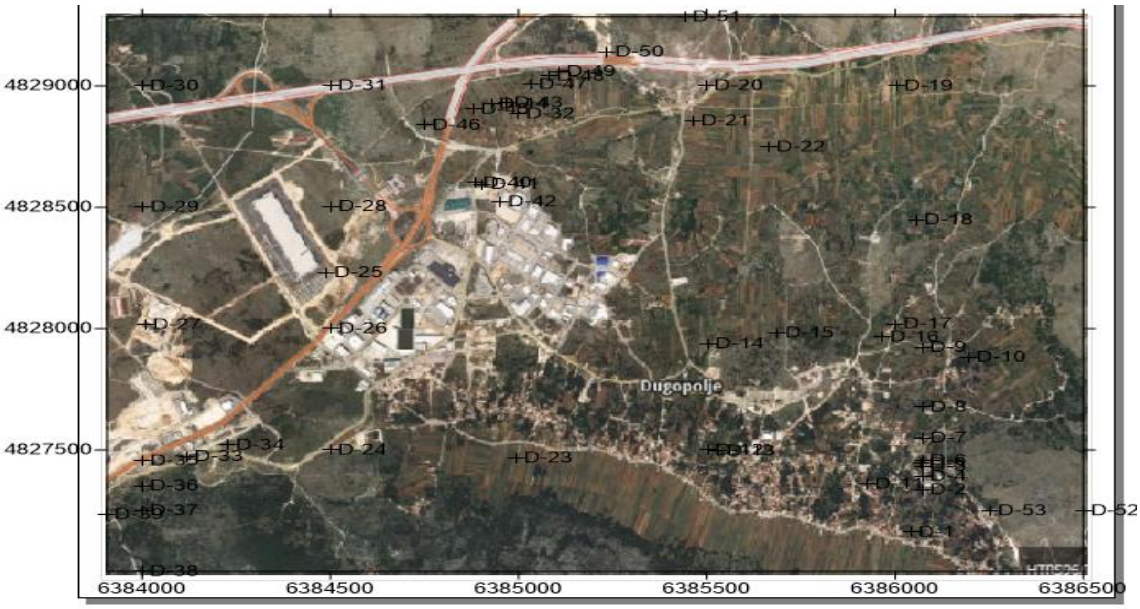
unekome skupu s ‘n’ podataka postupak se ponovi točno ‘n’ puta [14]. U svakome koraku odabire se jedna (uvijek druga) mjerena vrijednost, stavlja izvan skupa podataka, uspoređuje se razlika izvorne i procijenjene vrijednosti na istoj lokaciji te računa njezin kvadrat. Na kraju se zbroje takvi kvadrati po svim postojećim točkama. Konačan zbroj jest rezultat krosvalidacije, još nazvan numerička pogreška procjene ili srednja kvadratna pogreška procjene (engl. meansquareerror– MSE) [15].Potrebno je pronaći teorijski variogram koji će biti najsličniji eksperimentalnom – to se radi tako da poznate funkcije, funkcije različitih teorijskih tipova variograma uklapamo u eksperimentalnu krivulju.

Kriging je prvi put upotrijebljen za procjenu koncentracije zlata u rudnicima Južne Afrike. To je napravio Krige 1951. godine, komu je u čast metoda imenovana krigingom. Mathéron je prvi teoriju kriginga izrazio kao ekvivalent metodi najmanjih srednjih kvadrata primijenjenoj na linearnome Gaussovu modelu. Nakon Mathérona, teorija (semi)variograma, kriginga i kokriginga objavljena je u nizu knjiga. Veliku popularnost i upotrebu geostatistika je doživjela u naftnoj geologiji, gdje se upotrebljava se karakterizaciju ležišta ugljikovodika, te povezivanje seizmičkih i bušotinskih podataka. Interpolacijska metoda bazirana na ponovljenome izračunu težinskih koeficijenata i srednjih vrijednosti podataka (engl. weighted-moving-average), gdje težinski koeficijenti dodijeljeni kontrolnim točkama (podacima) minimiziraju varijancu procjene. Ta varijanca izračunata je kao funkcija variogramskog modela, relativnoga razmještaja podataka i položaja točke ili bloka za koji se procjenjuje vrijednost [15].

5.1.3. Bazapodataka

Bazu podataka korištenu u ovom radu čine koncentracije olova u uzorcima tla uzorkovanim na području Općine Dugopolje[16]. Karta promatranoga područja s ucrtanim lokacijama uzorkovanja prikazana je na Slici 9.

Koncentracije olova u tlu,prethodno izluženezlatotopkom,određene su primjenom tehnikom masene spektrometrije.



Slika 10. Karta promatranoga područja s ucrtanim lokacijama uzorkovanja

6. REZULTATI

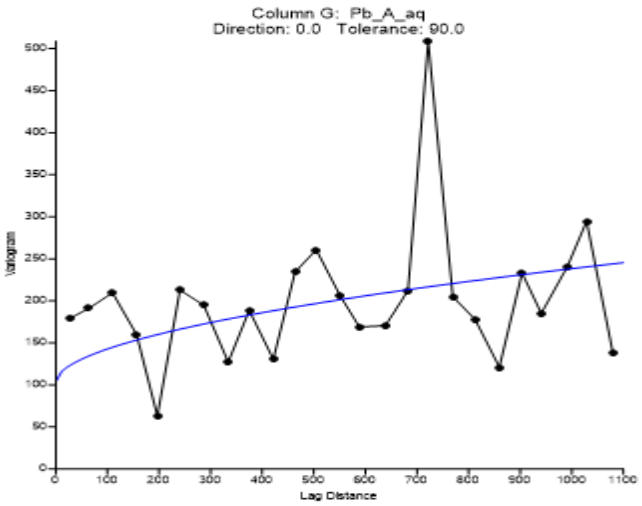
U tablici 1. prikazane su vrijednosti olova u uzorcima tala uzetih na 53lokacije na području Dugopolja te geodetske koordinate lokacija uzorkovanja[16].

Tablica 1. Vrijednosti koncentracije olova u uzorcima tla uzetih na području Dugopolja te geodetske koordinate područja[16]

Uzorak	Pb (mg/kg)	Koordinate		Uzorak	Pb (mg/kg)	Koordinate	
		X	Y			X	Y
D-1	22.25	6386042	4827162	**D-28**	64.00	6384501	4828504
D-2	40.38	6386073	4827336	**D-29**	68.13	6384002	4828502
D-3	45.88	6386073	4827434	**D-30**	59.50	6384000	4829000
D-4	16.00	6386073	4827392	**D-31**	55.88	6384500	4829001
D-5	55.25	6386071	4827445	**D-32**	80.38	6385000	4828886
D-6	33.25	6386073	4827458	**D-33**	59.38	6384119	4827474
D-7	48.88	6386074	4827550	**D-34**	60.00	6384229	4827521
D-8	41.38	6386074	4827677	**D-35**	78.38	6384001	4827456
D-9	58.13	6386073	4827924	**D-36**	55.63	6384000	4827353
D-10	72.88	6386197	4827883	**D-37**	76.38	6384000	4827251
D-11	37.38	6385927	4827360	**D-38**	56.50	6384000	4827001
D-12	26.00	6385502	4827500	**D-39**	71.00	6383907	4827235
D-13	33.88	6385532	4827497	**D-40**	61.75	6384886	4828601
D-14	43.13	6385502	4827939	**D-41**	75.75	6384905	4828595
D-15	32.38	6385688	4827983	**D-42**	79.50	6384952	4828523
D-16	39.50	6385967	4827966	**D-43**	80.75	6384968	4828931
D-17	43.00	6386002	4828020	**D-44**	51.13	6384927	4828926
D-18	41.50	6386057	4828449	**D-45**	41.25	6384879	4828904
D-19	34.75	6386004	4829000	**D-46**	54.13	6384750	4828839
D-20	23.50	6385500	4829001	**D-47**	46.13	6385034	4829006
D-21	42.00	6385465	4828856	**D-48**	51.38	6385080	4829041
D-22	41.88	6385665	4828749	**D-49**	61.63	6385108	4829060
D-23	39.50	6384994	4827467	**D-50**	56.25	6385236	4829141
D-24	38.88	6384500	4827501	**D-51**	57.88	6385442	4829284
D-25	76.25	6384490	4828231	**D-52**	54.75	6386500	4827250
D-26	33.38	6384502	4828001	**D-53**	52.75	6386253	4827251
D-27	79.75	6384008	4828017				

Koncentracije olova u tlu na području Dugopolja kreću se od 16,0 mg/kg do 80,8 mg/kg, s prosječnom vrijednosti 51,8 mg/kg. Najmanja koncentracija olova je utvrđena na lokaciji D-4 (X=6386073, Y=4827390) s koncentracijom 16 mg/kg. Najveća koncentracija olova je utvrđena na lokaciji D-43 (X=6384968 Y=4828931) s koncentracijom 80,8 mg/kg.

Eksperimentalni variogramiza prethodno navedenu bazu podataka koncentracija olova u tlu na području Dugopoljaizrađeni su u programu Surfer 8. Na temelju prikupljenih podataka izrađen je eksperimentalni variogram (Slika 11).



Slika 11. Eksperimentalni variogram istraživanog područja („Power metoda“)

Za ovaj variogram korišteno je 25 koraka. Model koji je odabran je nugget + power metoda. Tolerancija broja koraka je 90.

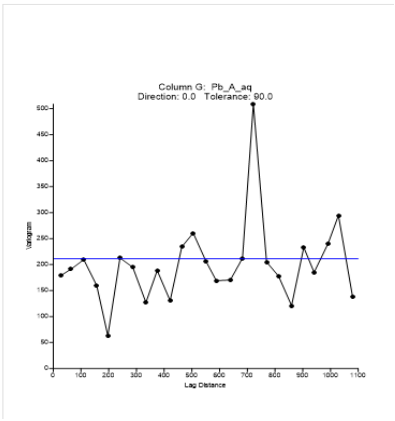
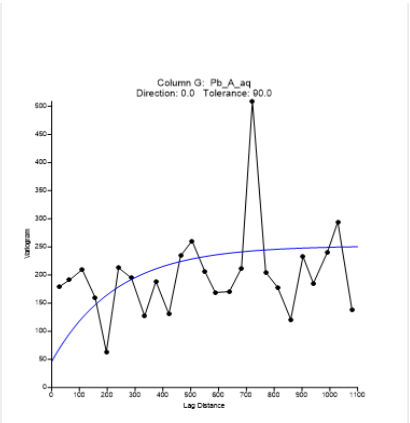
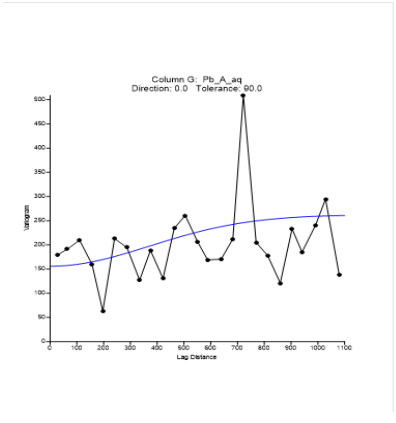
Na temelju tablice 1 izrađena je krosvalidacija svih matematičkih metoda kako bi se eksperimentalni variogram mogao najbolje uklopiti u teorijski varigoram (Tablica 2). Na temelju tablice 2 izračunate su greške procjene za svaku metodu. U našem slučaju Kriging metoda je pokazala najmanju grešku procjene (178,373304003).

Tablica 2. Krosvalidacija podataka za različite matematičke metode

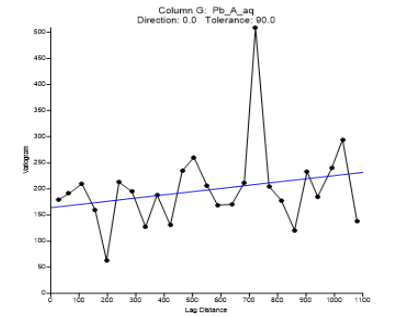
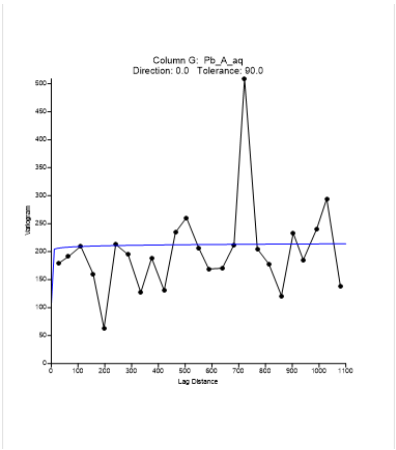
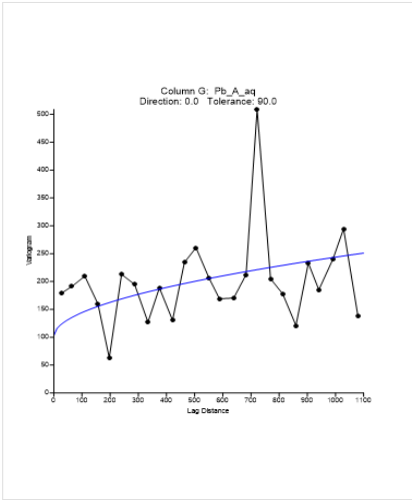
Matematička metoda	Greška procjene
Inverse distance to a power	182.937490284
Kriging	178.373304003
Minimum Curvature	219.949692297
ModifiedShepardsmethod	288.044686614
Natural neighbour	179.955522512
Nearestneighbour	258.493764151
Polynomialregression	189.725384123
Radialbasisfunction	2926.66982777
Triangulationwithlinearinterpolation	178.54109178
Movingaverage	221.570263272
Localpolynomial	187.341121053

Nakon što je određena metoda koja daje najmanju grešku procjene izrađen je graf i izračunata je varijanca greške procjene za svaki teorijski variogram (Tablica 3).
Najnižu varijancu greške procjene dala je „Power“ metoda (118).

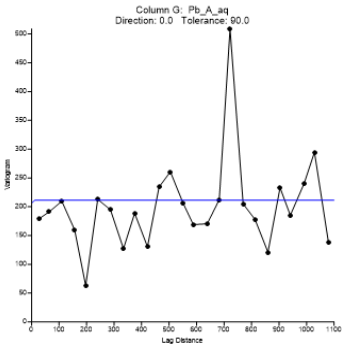
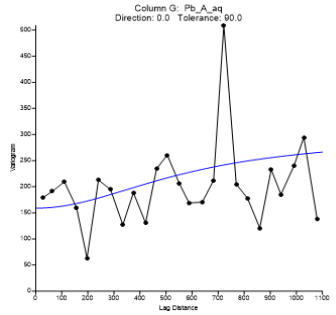
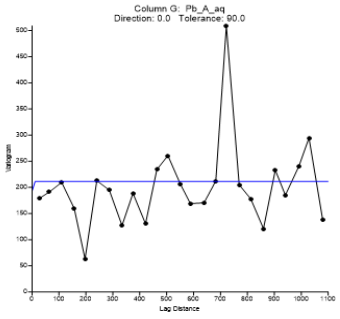
Tablica 3. Krosvalidacija podataka za različite geostatističke metode

Teorijski variogram	Varijanca greške procjene	Graf
Nugget	211,1	
Exponential	146,1	
Gaussian	155,8	

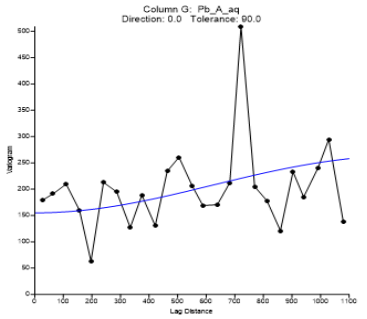
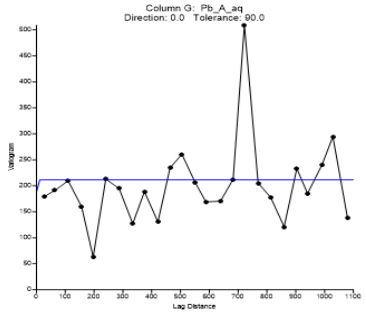
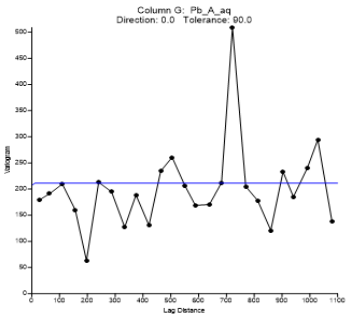
Tablica 3. Krosvalidacija podataka za različite geostatističke metode

Teorijski variogram	Varijanca greške procjene	Graf
Linear	164	
Logarithmic	211,4	
Power	118	

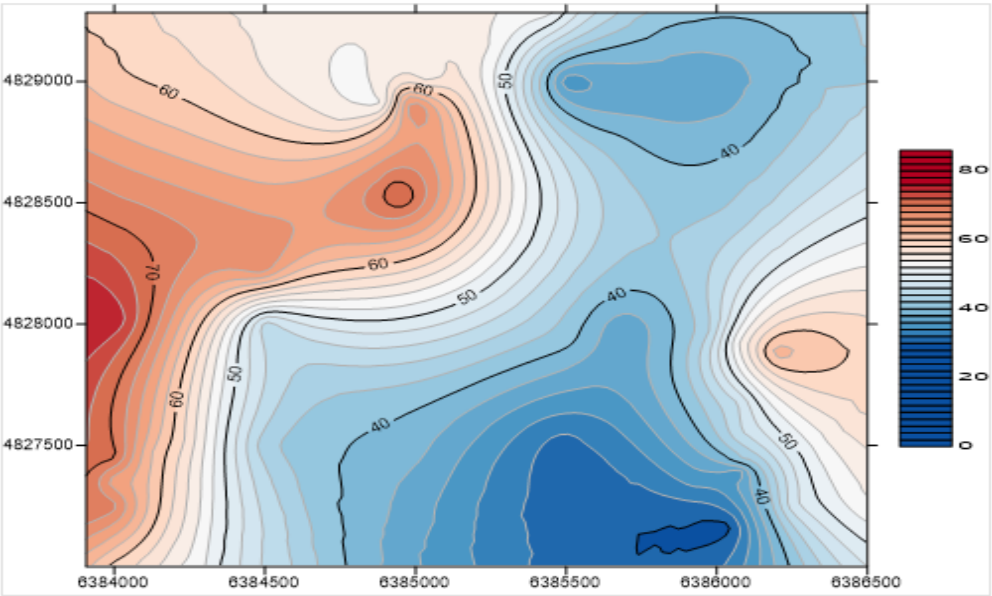
Tablica 3. Krosvalidacija podataka za različite geostatističke metode

Teorijski variogram	Varijanca greške procjene	Graf
Quadratic	211,1	
RationalQuadratic	159,7	
Spherical	194	

Tablica 3. Krosvalidacija podataka za različite geostatističke metode

Teorijski variogram	Varijanca greške procjene	Graf
Wave	156	
Cubic	189,1	
Pentraspherical	208,1	

Na temelju geodetskih koordinata lokacija uzorkovanja i rezultata analiza (vrijednost koncentracije olova) formirana je baza podataka u radnome listu (Surfer 8). Na osnovu podataka o koncentracijama olova u tlu(Tablica 1) i „Power“ metode izrađena je kartaizolinija za istraživano područje Dugopolja (Slika 12).



Slika 12. Karta izolinija za istraživano područje (koncentracija olova)

7. RASPRAVA

Pravilnikom o zaštiti poljoprivrednog zemljišta od onečišćenja (NN 9/2014) maksimalna dopuštena koncentracija (MDK) za praškasto ilovasto tlo iznosi 100 mg/kg, a za glinasto tlo 150 mg/kg.Koncentracije olova u tlu na području Dugopolja (Tablica 1) niže su od navedenih MDK. Utvrđeni rezultati ukazuju da su koncentracije olova u tlu na području Dugopoljarelativno niske, u rasponu od 10-50 % maksimalno dopuštenih koncentracija za glinasta tla.

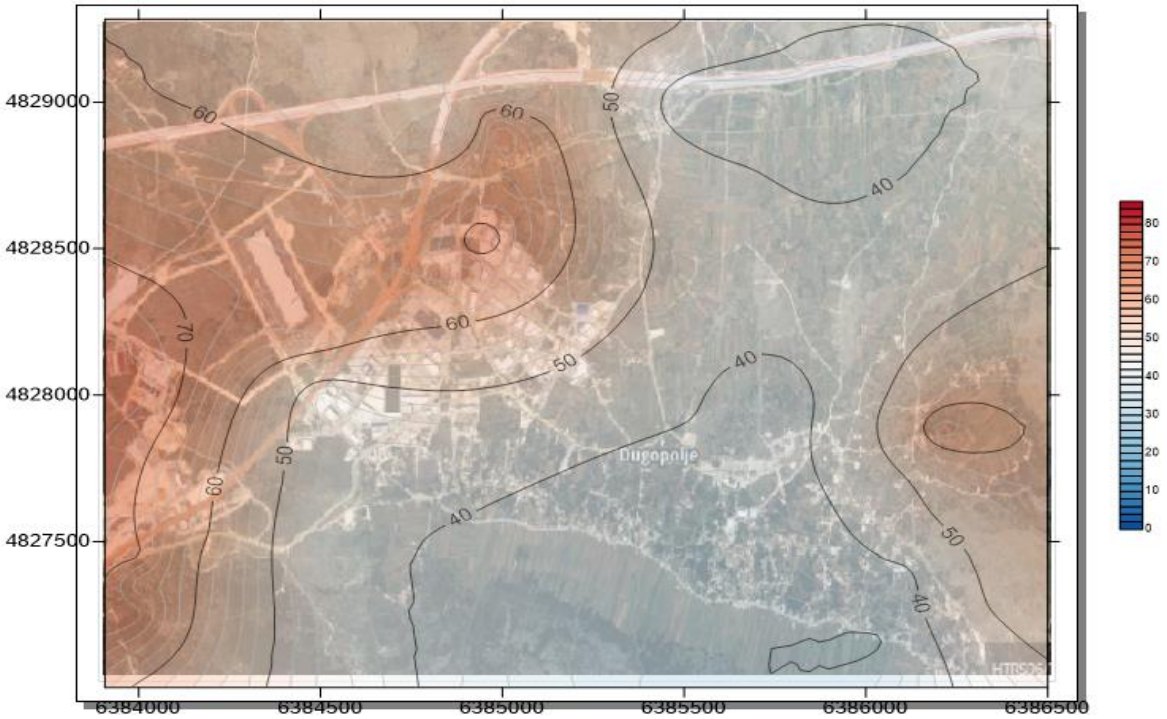
Krosvalidacijomgeostatističkih metoda dobivena je najmanja greška procjene kod metode Kriging (Tablica 2). Zbog toga u daljnjim geostatističkim analizama korištena jeta metoda kao najbolja u našem slučaju. Ostale metode (Inverse distance to a power, Kriging, Minimum Curvature, ModifiedShepardsmethod, Natural neighbour, Nearestneighbour, Polynomialregresion, Radialbasisfunction, Triangulationwithlinearinterpolation, Movingaverage, Loicalpolynomial) su pokazale slične rezultate,što se tiče greške procjene, kaoKriging metoda. Međutim, ima i metoda kao što je „Radialbasisfunction“ koja ima vrlo veliku grešku procjene što ukazuje da nema prostorne povezanosti između podataka ili je ona vrlo slaba.Kad bi koristili ovu metodu rezultati bi uvelike odskakali od rezultata dobivenih Kriging metodom.

Od korištenih metoda, najbolja se pokazala metoda „Power“ jer je imala najmanjuvarijancu greške procijene (Slika 11). Svi provedeni postupci su bili važni zbog provedbe krosvalidacije. Naime, prema metodi koja daje najmanju grešku procjene izrađuje se karta izolinija.Na slici 12 prikazana jeprostornaraspodjela olova u tlu na području Dugopolja pri čemu se jasno mogu izdvojiti područja s povišenim koncentracijama olova.

Preklapanjem navedene karte izolinija i topografske karte na slici 13. vidljivo je da su povećane koncentracije olova vezane uzvažnije prometne pravce odnosno čvorišta više prometnica kao što je izlaz autoceste te državna cesta D1 koja prolazi industrijskom zonom koja je najrazvijenija u tom području. Iako veće vrijednosti olova nalazimo u

blizini prometnica regionalnog značenja, na svim lokacijama koncentracije olova u tlu su ispod MDK.

Područje Dugopolja je u II. zoni sanitarne zaštite izvorišta Jadra. Zbog zakonski odredbi koje onemogućuju bilo kakve opasne radnje koje bi mogle povećati koncentracije olova trenutno stanje se ne bi trebalo niti smjelo pogoršavati.



Slika 13. Preklopljena karta koncentracija olova s topografskom kartom (Dugopolje)

Glavni spoj olova u ispušnim plinovima je PbBrCl koji se dosta brzo raspada te prelazi u druge spojeve. Antropogeno olovo ne predstavlja opasnost za podzemne vode zato što se većina veže za karbonate, okside ili organsku tvar pa se na taj način imobilizira u gornjim, obično najplićim slojevima tla. U zadnje vrijeme se dosta pažnje posvećuje mogućnosti mobilizacije olova pod utjecajem klorida iz soli koja se koristi za posipavanje prometnica u zimskom razdoblju. To je jedan od tri glavna načina za pokretanje olova uz kompleksiranje s organskim kelatnim kompleksima i kompleksiranje s karbonatnim ionom(CO_3^{2-})koji nastaje otapanjem karbonata [17].

8. ZAKLJUČAK

U ovom radu je opisana i prikazana variografska analiza koncentracije olova u tlu na području Dugopolja. U obzir su uzete vrijednosti koncentracija olova s ukupno 53 lokacije. Na temelju rezultata analize određena je prostorna raspodjela koncentracije olova u tlu na istraživanom području. U ovom radu opisane su metode koje nam koriste u analizi ranjivosti krških vodonosnika, a to su: SINTACS, EPIK, PI i COP. Metode su nam vrlo korisne kod analiza stanja podzemnih voda te kao alati za zaštitu podzemnih voda. Na temelju tih metoda kartografski se odredi područje koje je ranjivije na antropogene utjecaje.

Olovo (Pb)je teški metal kojem posvećujemo posebnu pozornost zbog svoje toksičnosti. Kao jedan od alata koji je korišten u ovom radu bila je i geostatistika, odnosno varigorafske analize koje nam omogućuju prostorni prikaz rezultata mjerenja. Iz rezultata vidljivo je da su koncentracije olova prema Pravilniku o zaštiti poljoprivrednog zemljišta od onečišćenja (NN 9/2014) ispod maksimalne dopuštene vrijednosti (MDK) nasvim lokacijama.

Područje Dugopolja je bitno zbog geografskog i prometnogpoložaja, a nalazi se u II. zoni sanitarne zaštite. Rezultati analize pokazali su kakonajveći utjecaj na razinu olova u tlo na istraživanom području imaju regionalne prometnice uz koje su uočene i povećane koncentracije olova. Ostale štetne industrije koje bi ispuštale olovo u većim količinama nisu prisutne zbog ograničenja i propisa. Iako koncentracije olova ne prelaze maksimalne dopuštene granice, variografskom analizom vidljivo je koja su mjesta opterećenija olovom. Bitno je održavati dobro stanje kakvoće tla na području Dugopoljačime će se ikoncentracije olova u tluodržati na današnjoj razini ili smanjiti.Osim toga, važno je održavati niske koncentracije olova u tlu na navedenom području zbog blizine vrlo velikog krškog izvora Jadro, koji opskrbljuje pitkom veliko područje i praktički nema alternative za njega ukoliko se on onečisti. Ulaskom olova u bilo kojem obliku u podzemne vode čini se značajna šteta za vodoopskrbni sustav, a pogotovo na ljudsko zdravlje.

9. LITERATURA

[1] Pedologija. Skripta. Dostupno na:https://www.scribd.com/doc/25065459/PEDOLOGIJA-skripta [15.05.2017]

[2] Goldschmidt, W.M. 1970.: Geochemistry. Clarendon Press, Oxford.

[3] Sofilić T. Skripta. Ekotoksikologija. Sveučilište u Zagrebu, Metalurški fakultet, Sisak 2014.

[4] Howard J. L., Sova J. E. Sequentionalextractionanalysisofleadin Michigan roadsidesoils: Mobilisationinthevadose zone bydeicingsalts? Journal ofsoilcontamination 2(4), 1-18, 1993.

[5] Županijska razvojna strategija (ŽRS). Splitsko-dalmatinska. Dostupno na: https://www.dalmacija.hr/Portals/0/docs/Tajnistvo/%C5%BErs%20sd%C5%BE.pdf . 2011. [10.06.2017]

[6] Zahtjev za ocjenu o potrebi procjene utjecaja zahvata na okoliš „Zamjena dijela opreme u postojećem pogonu za preradu ribe tvrtke AncoraCommerce d.o.o.“ Zeleni servis d.o.o. Ožujak, 2016

[7] Kapelj, Sanja, Loborec, Jelena, Kapelj, Janislav, Assessment of aquifer intrinsic vulnerability by the SINTACS method. // *Geologia Croatica*, 66 (2) (2013)

[8] Kapelj, S. 2005., Studija upravljanja vodama sliva Jadra i Žrnovnice – Prva faza studijsko istraživačkih radova EVV:1/2005. Hrvatske Vode, Split.

[9] Husnjak S., Bogunović M., Opasnost od erozije tla na poljprivrednom zemljištu u agroregijama Hrvatske. Agronomski fakultet, Zagreb

[10] Loborec, Jelena; Kapelj, Sanja; Dogančić, Dragana; PtičekSiročić, Anita; Assessment of groundwater vulnerability in Croatian karstic aquifer in Jadro and Žrnovnica springs catchment area // Hydrogeological and Environmental Investigation in Karst System / Andrei, Bartolome; Carrasco, Francisco; Duran, Juan Jose; Jimenez, Pablo; LaMoreaux, James W. (ur.). Madrid: Springer Verlag, 2014, str. 397-407

[11] Andričević R., Gotovac H., Ljubekov I. 2006., Geostatistika, Sveučilište u Splitu, Građevinsko-arhitektonski fakultet

[12] Žerjavić, V., 2011., Geostatističko modeliranje razine podzemne vode, diplomski rad, Geotehnički fakultet, Sveučilište u Zagrebu

[13] Malvić, T., 2008., Primjena geostatistike u analizi geoloških podataka, udžbenici Sveučilišta u Zagrebu

[14] Malvić, T., Gaćeša, S., 2006., Geostatistika u opisivanju ležišta ugljikovodika, INA – industrija nafte

[15]Interna skripta „Geostatistika“, iz kolegija „Analiza prostornih podataka“ prof. dr. sc. Damir Medak (Geodetski fakultet, Sveučilište u Zagrebu)

[16] Dogančić, D. (2017): Modeliranje specifične ranjivosti podzemnih vodau uvjetima krša na području Dugopolja. Doktorska disertacija, Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, 21. srpnja 2017, 230 str

[17] Lačen T. Uloga tla i sedimenata u zaštiti krških podzemnih voda. Diplomski rad. Varaždin: Sveučilište u Zagrebu, Geotehnički fakultet. 2012

POPIS SLIKA

Slika 1.Geografski položaj Splitsko dalmatinske županije i općine Dugopolje [5] 3
Slika 2. Tlocrt svih poduzetničkih zona u Dugopolju [5] 6
Slika 3. Reljefna karta Splitsko – dalmatinske županije [5] 7
Slika 4. Geološka karta istraživanog područja s ucrtanom lokacijom zahvata od strane izrađivača studije [8] 8
Slika 5. Hidrogeološka karta istraživanog područja s ucrtanom lokacijom zahvata [8] ... 9
Slika 6. Rasprostranjenost pojedinih tipova tala u Splitsko – dalmatinskoj županiji [9] 11
Slika 7. Trodimenzionalni grafički prikaz vertikalnog profila krškog vodonosmika 12
Slika 8. Karta ranjivosti dobivena s jednom od metoda (SINTACS, EPIK, PI i COP)[10] 15
Slika 9. Variogram i njegove komponente [12] 18
Slika 10. Karta promatranoga područja s ucrtanim lokacijama uzorkovanja 20
Slika 11. Eksperimentalni variogram istraživanog područja („Power metoda“) 22
Slika 12. Karta izolinija za istraživano područje (koncentracija olova) 28
Slika 13. Preklopljena karta koncentracija olova s topografskom kartom (Dugopolje) . 30

POPIS TABLICA

Tablica 1. Vrijednosti koncentracije olova u uzorcima tla uzetih na području Dugopolja te geodetske koordinate područja [17] 21
Tablica 2. Krosvalidacija podataka za različite geostatističke metode 23
Tablica 2. Krosvalidacija podataka za različite geostatističke metode 23