

Prepoznavanje paleookoliša metodama združivanja i indikatorskog kriginga na primjeru gornjomiocenskih pješčenjaka u Savskoj depresiji

J. Horváth, K. N. Zelenika

IZVORNI ZNANSTVENI ČLANAK

Metoda združivanja (engl. clustering) i indikatorski kriging standardni su istraživački alati u rješavanju geoloških problema, a u ovom je radu prikazan primjer identifikacije taložnih okoliša koristeći dva postupka združivanja i indikatorski kriging. Združivanje se temelji na principu Kohonenove neuronske mreže (engl. Kohonen's neural network) i hierarhijskom aglomerativnom združivanju. Rezultatom se može vizualizirati geometrija taložnih podokoliša te interpretirati pomoću vjerojatnosti dobivene za svaki klaster indikatorskim krigingom. U tom se slučaju združivanje može definirati kao metoda za prostorno prepoznavanje uzorka. Istraživano područje prikazano u radu nalazi se u Savskoj depresiji. Sedimenti u polju neogenske su i kvartarne starosti, a analizirane stijene pripadaju gornjem panonu, kada je na sedimentaciju utjecao paleoreljef pred-neogenske podine te mehanizmi turbiditnih sustava.

Gljučne riječi: združivanje, paleookoliš, Kohonenova neuronska mreža, hierarhijsko aglomerativno združivanje, indikatorski kriging, Savska depresija, Hrvatska

1. UVOD

Proučavano područje nalazi se u Savskoj depresiji, oko 35 km istočno od Zagreba (slika 1). Sedimenti polja neogenske su i kvartarne starosti. Na sedimentaciju je utjecao oblik paleoreljefa heterogenog litološkog sastava i starosti.

Taložni model analiziranog područja dobro je poznat. Analizirani dijelovi litološki su predstavljeni gornjomiocenskim laporima, siltitima i pješčenjacima, prenašanim mehanizmima turbiditnih struja. Sedimentacija predstavlja kombinaciju taloženja pelitskih sedimenata (nalik hemipelagičkim) i cikličkih turbiditnih tokova u jezerskom okolišu (slika 2), koji se konstantno smanjivao.¹⁹ Oblik pješčenjačkih tijela prati smjer taložnih struja¹⁴, a općenito se u središnjem dijelu depresije pojavljuju debela, uslojena sitnozrnata pješčenjačka ležišta s relativno visokom poroznosti između 15 i 25%. Ona su u rubnim dijelovima ograničena laporima istaloženim na bazenskoj ravnici. Dominantni smjer taloženja bio je sjeverozapad-jugoistok (lokalno sjeverjug), a glavni izvor materijala bile su Istočne Alpe. Detritus, prije nego što je konačno istaložen, nekoliko je puta pretaložavan.^{9,15}

Cilj istraživanja bio je prikaz metodologije u smislu prepoznavanja taložnih paleookoliša i podokoliša (u sustavu pješčenjak-lapor), koristeći klasterne temeljene na odabranim petrofizikalnim parametrima, tj. varijablama (poroznost, zasićenje vodom, volumen lapora). Prikazane su dvije metode združivanja, a obje mogu obrađivati točkaste podatke kojima je pridruženo više atributa ili svojstava. U istraživanju su primijenjene metoda Kohonenove neuronske mreže (skr. KNN) i vrsta

metode višedimenzionalnog hierarhijskog aglomerativnog združivanja (engl. skr. HAC). Kod oba postupka ulazni podatci bili su osnovni petrofizikalni parametri za binarni opis litologije kategoričkom varijablom i to u jedanaest ležišta. Kategorije su određene prema sadržaju lapora u pješčenjačkim ležištima. Unutar analiziranog područja ukupno je dostupno bilo 88 bušotina. Međutim karotažni dijagrami i analize bili su raspoloživi u njih 79, koje su pripremljene kao ulazi za primjenu modela združivanja.

U cijeloj sedimentacijskoj sekvenciji ("seriji") otkriveno je 11 ležišta ugljikovodika gornjomiocenske starosti. Takva se "serija" ležišta sastoji od sitnozrnatih, kvarcnih pješčenjaka u izmjeni s laporima. Ukupne osrednjene vrijednosti po okomici zbirno svih 11 ležišta (čija se ukupna debljina mijenja od 120 do 150 m) ne bi bili dovoljno precizne za odredbu paleookoliša. Zbog toga je modelirano samo jedno ležište koje je najrepresenzativnije, budući da ima najveće debljine, što za posljedicu daje najbolje razvijene karotažne krivulje te posljedično najpouzdanije izračunate petrofizikalne vrijednosti. Izabrano ležište nazvano je *analizirano ležište* (engl. *study reservoir*), čiji je položaj s obzirom na kronostratigrafiju i taložni okoliš prikazan slikom 2.

2. PRIMIJENJENE METODE

U radu su primijenjene dvije metode združivanja za opis ležišnih stijena i prepoznavanje taložnog okoliša, a to su Kohonenove neuronske mreže te jedna vrsta metode klasične višedimenzionalne analize nazvana hierarhijsko aglomerativno združivanje. Pitanje koje bi se moglo postaviti je zbog čega se proces združivanja koristi za prepoznavanje uzorka, tj. okoliša. Metode združivanja

(npr. Kohonenove mreže) daju rješenja različitih geoloških problema te mogu ukazati na mogućnost združivanja uporabom prepoznavanja uzorka.¹⁸ Postupak združivanja ima mogućnost prepoznavanja prostornih uzoraka, koji su određeni kao prostorna skupina točaka ograničena poligonom. Njihov oblik definira klaster, a prepoznavanje uzoraka definira se kao problem združivanja.³

Termin združivanja prvi puta je koristio Tryon¹⁷, koji je definirao tu metodu podjelom podataka u skupine (klaster). Klaster označava objekt sličnih karakteristika, dakle analiza združivanja pronalazi karakteristične strukture u podatcima. Ona se ne temelji samo na objektima, tj. skupinama podataka ili njihovim kvalitativnim opisima, nego i na matematičkim odnosima.

Takvim pristupom postavlja se dodatno pitanje određivanja uzorka kao statističkih skupina. Unutar uzorka kao što je klaster nalaze se točke s istim ili sličnim karakteristikama više ili manje homogenog skupa. To znači da sve točke u podskupu predstavljaju određeni klaster ograničen poligonima. Poligon predstavlja oblik i daje granice okoliša. U ovom radu to su podokoliši (kao zasebni litofacijesi) pješčenjaka, lapora, pjeskovitog lapora i laporovitog pješčenjaka (unutar paleookoliša turbidita taloženih u jezeru), gdje se svojstva mijenjaju između odijeljenih klastera.³ Nakon procesa združivanja rezultati su kartirani uporabom izvornih koordinata. Uzorci klastera su prikazani kartama, a dodatno je uporabljena mogućnost indikatorskog kriginga (skr. IK) prikazivanja vjerojatnosti pojave određenog klastera u svakoj točki mreže.

2.1. KOHONENOVE NEURONSKE MREŽE (KNN)

Ta metoda pripada skupini nenadziranih neuronskih mreža (engl. *unsupervised neural networks*), tj. uvježbavanje se koristi za učenje bez nadzora (uporabom poznatih izlaza), a u cilju traženja pravilnosti u ulaznim podatcima. Uobičajeno je da se Kohonenova neuronska mreža naziva samoorganizirajućom kartom (engl. *Self Organized Map*, skr. SOM) jer treba "urediti" (posebno pripremiti) izvorni skup podataka prikazanih kartom.⁵ No, takva karta nema svojstva prostorne projekcije, jer ne pripisuje prostorne koordinate uzorcima. Dakle, neuroni su organizirani u mreži prikazanoj "kartom". Drugo važno svojstvo SOM-a je uređivanje ulaznih podataka bez gubitka dimenzija u višedimenzionalnom prostoru, a može se opisati metodom klasteriranja koja se temelji na smanjenju dimenzija. Međutim to ne znači pravu redukciju dimenzija, budući da svaki neuron predstavlja n-dimenzijski težinski vektor, gdje "n" odgovara dimenzijama ulaznog vektora. Metoda SOM-a razlikuje se od nadziranih neuronskih mreža svojstvom prividnog skraćivanja organizacijskog procesa. Tako ne postoje pravi izlazni slojevi, nego neuroni koji se nalaze u točkama mreže imaju kao izlazni, tzv. Kohonenov sloj.

Metoda SOM-a s gore spomenutim karakteristikama ima mogućnost prepoznavanja strukture osnovnog višedimenzionalnog skupa podataka te, koristeći funkciju susjedstva, također može sačuvati topologiju ulaznih podataka.

Kohonenove mreže uče strukturu podataka tako da koriste prilagođeno Hebbovo pravilo (1) kao konačni neuronski algoritam.⁶ Ono glasi:

$$w_{t+1} = w_t \eta_t \cdot (x - w_t) \quad (1)$$

gdje su:

x	uvježbavanje,
w	težinski faktor,
η	iznos učenja,
t	vrijeme ponavljanja.

Ulazni podatci obrađeni su unutar svih neurona (slika 3) prikazuje slučaj s tri neurona unutar Kohonenovog sloja). Za svaki neuron izračunat je pripadajući težinski koeficijent, no "pobjeđuje" samo onaj neuron s najvećom vrijednošću aktivacijske funkcije. Ulazne vrijednosti su dodijeljene klasteru koristeći vrijednosti aktiviranog neurona. U Kohonenovom sloju utjecaj ostali neurona iskazan je kroz njihove lateralne veze (tj. funkcija "susjedstva") tijekom uvježbavanja (slika 3).

2.2. HIJERARHIJSKO AGLOMERATIVNO ZDRUŽIVANJE (HAC)

Metoda hijerarhijskog združivanja odnosi se na segmentiranje skupa objekata (točke podataka) u klaster (tj. podskupove). Veza unutar klastera je jača nego između njih. Cilj analize je proračun stupnja sličnosti (ili različitosti) između individualnih objekata unutar klastera. Ovdje je korištena metoda hijerarhijskog aglomerativnog združivanja, koja se temelji na kosinusu udaljenosti i položaju centroida klastera. Oblikovane skupine su predstavljene centroidom za svaku varijablu, iskazanom kao srednji vektor. Udaljenost unutar skupine je udaljenost između dva takva vektora. Za vrijeme osrednjavanja metodom HAC-a dva su klastera ograničena minimalnom udaljenošću između dva centroida. Ako se funkcija temelji na udaljenosti parova točaka, a vrijednost joj iznosi između 0 i 1, mogu se računati funkcije za određivanje sličnih udaljenosti, poput kosinusa. To se često rabi prilikom mjerenja kohezije unutar klastera. Kosinus sličnosti je mjera sličnosti dvaju vektora određena kao kosinus kuta između njih. Izračun kosinusa kuta između dva vektora određuje pružaju li se oni približno istim smjerom. Ako je sličnost prikazana vrijednošću -1 to ukazuje na potpuno suprotan smjer pružanja, dok vrijednost 1 znači potpuno jednako pružanje. Vrijednost 0 indicira neovisnost o smjerovima, dok se ostale vrijednosti interpretiraju stupnjem sličnosti ili različitosti (jednadžba 2).

$$\text{similarity} = \cos(\phi) = \frac{A \cdot B}{\|A\| \cdot \|B\|} = \frac{\sum_{i=1}^n a_i b_i}{\sqrt{\sum_{i=1}^n (a_i)^2} \cdot \sqrt{\sum_{i=1}^n (b_i)^2}} \quad (2)$$

gdje su:

A i B	n -dimenzionalni vektori,
a_i i b_i	i -ta varijabla vektora A i B ,
$\ \cdot \ $	norma vektora.

Opaska (i):

Korelacijski koeficijent predstavljen je kosinusom kuta između dva vektora. Dakle, u slučaju rezultata

korelacijske analize najveći korelacijski koeficijent imat će najbliži vektor.

U slučaju centroidnog združivanja, za vrijeme povezivanja skupina, gore spomenuti kosinus sličnosti (2) dva klastera definiran je sličnošću njihovih centroida.¹⁰

$$\text{similarity - centroid}(C_i, C_j) = \bar{k}(C_i) \cdot \bar{k}(C_j) = \left(\frac{1}{N_i} \sum_{d_m \in C_i} \bar{d}_m \right) \left(\frac{1}{N_j} \sum_{d_n \in C_j} \bar{d}_n \right) \quad (3)$$

$$= \frac{1}{N_i \cdot N_j} \sum_{d_m \in C_i} \sum_{d_n \in C_j} \bar{d}_m \cdot \bar{d}_n \quad (4)$$

gdje su:

- C_i i -ti klaster,
 k_i centroid i -tog klastera,
 d_n n -ti element u jednom klasteru,
 N_i broj elemenata u i -tom klasteru.

Jednadžbom (3) određen je centroid sličnosti, a (4) prikazuje uporabu centroida sličnosti kao ekvivalenta srednje sličnosti svih parova podataka iz različitih klastera. Važno je spomenuti kako algoritam srednjeg aglomerativnog združivanja grupe za razliku od algoritma HAC nije monoton i sličnosti se ne smanjuju za vrijeme procesa. Nasuprot tomu, kod monotonog algoritma HAC-a sličnost se smanjuje u sljedećim ponavljanjima, no mali klasteri mogu ipak zadržati veću koherentnost od velikih.¹⁰

Opaska (ii):

Razlika između metoda SOM-a i HAC-a:

- Hijerarhijski višedimenzionalni algoritam je brza metodologija. Nedostatak je što su klasteri posebno ovisni o vrijednostima početnih vektora podataka, pa počinju računati centroide s većim otežanjima. Nakon toga proces ograničavanja (delineacije) klastera temelji se na reduciranju udaljenosti, a ne na promjeni vrijednosti otežanja (težinskih koeficijenata).
- Hijerarhijski višedimenzionalni algoritam ne može prepoznati nelinearni odnos.
- Postoji i pitanje provjerljivosti postupka ako se ne koristi reduciranje udaljenost između centroida. Suprotno vrijedi kod metoda koje računaju vjerojatnosti pripadanja klasterima, tj. metodama SOM-a.
- Postupak združivanja u metodi SOM-a je spor i odvija se kroz više koraka, no također je i robustan te može detektirati nelinearne odnose.

2.3. KARTIRANJE

Slika 4 prikazuje kartiranje klastera uporabom izvornih koordinata. Metodama HAC-a ili SOM-a određuje se ' m ' klastera nazvanih ' C ' (m je broj klastera). Svaki od njih temelji se na vrijednostima svojstava skupa podataka bez uvođenja originalnih prostornih koordinata. Nakon uporabe združivanja, proces kartiranja grupira najbliže uzorke prostornim organiziranjem točaka, no sada koristeći originalne koordinate (x_i, y_i) . Na taj su način kartirani različiti klasteri, svaki sa svojim uzorcima (točkama). Tako rasprostiranje klastera oko mjerenih

točaka te definiranje granica najbližih (zavisnih) uzoraka ovisi o procesu kartiranja.

"Klasična" interpolacija ne može se koristiti prilikom kartiranja klastera jer ne postoji mogućnost procjene vrijednosti između točaka, tj. područja klastera su u izravnom kontaktu (a ne postupnom obzirom na ekvidistanciju). Brojevi (oznake) klastera nisu vrijednosti, nego samo oznake. Ipak, moguće je odrediti koji će se klaster pojaviti između mjerenih točaka. Također je moguće koristiti interpolacijski algoritam u procesu kartiranja, ako se slijedi pretpostavljena anizotropija i Toblerov zakon¹⁶, prema kojem se prostorna interpolacija temelji na pretpostavci da sličnosti u vrijednostima bliskih točaka pokazuju veće vjerojatnosti od međusobno udaljenijih točaka. To bi značilo da točke koje su međusobno blizu imaju veliku vjerojatnost pripadanja istom ili sličnom klasteru. Također je važno uočiti da klasteri reflektiraju određenu geometriju koja slijedi orijentaciju (strukturnu, sedimentološku itd.), a anizotropija može tijekom kartiranja takvu orijentaciju naglasiti. Zbog toga je u Surferu 8 bila primijenjena mreža s funkcijom radialne baze (engl. *Radial Basis Function*, skr. RBF), a unutar nje multikvadratne metode.² Smjer i odnos orijentacija su dobiveni iz fizikalnih svojstava varijabli, korištenih u procesu združivanja.

Prikazani pristup kartiranja klastera nije egzaktna kartografska metoda. Zbog toga je još primijenjena i tehnika indikatorskog kriginja (IK) za kartiranje vjerojatnosti klastera. IK koristi kategoričke varijable kao diskretni broj oznake klastera (nazvanom kategorija), gdje su oznake definirane kao $Z(u) \in \{0, \dots, k-1\}$, gdje je k broj klastera i indikatorska varijabla, a definirane su jednadžbom (5):

$$I(u, k) = \begin{cases} 1, & \text{if } Z(u) = k \\ 0, & \text{inače} \end{cases} \quad (5)$$

U svakoj točki mreže konačni klaster je određen najvećim vjerojatnostima. Zbog toga su vjerojatnosti filtrirane logičkom funkcijom (6).

$$IF(p_k) = \begin{cases} C_i, & p_k = \text{MAX}(p_1, p_2, \dots, p_n) \\ 0, & p_k \neq \text{MAX}(p_1, p_2, \dots, p_n) \end{cases} \quad (6)$$

gdje su:

- IF matematička logičkom funkcija (gdje su vrijednosti funkcije fiksne ili 0)
 C_i i -ti klaster
 p_k vjerojatnost k -tog klastera u čvoru mreže
 n broj klastera

3. INTERPRETACIJA REZULTATA

Interpretacija klastera temelji se na analitičkim i statističkim aplikacijama kao što su diskriminantna analiza ili indikatorski kriginj. Identifikacija klastera bila je moguća pomoću njihovih oblika i srednjih vrijednosti za svaki petrofizikalni parametar.

3.1. IDENTIFIKACIJA KLASTERA

Ulazni podatci u oba modela združivanja bili su osnovni petrofizikalni parametri (poroznost, zasićenje vodom, volumen lapora) i kategoričke varijabla, koja opisuje

litologiju koristeći broj između 0-10, određen obzirom na sadržaj lapora u pješčenjačkim ležištima. Metodama SOM-a i HAC-a izdvojena su 4 klastera (C_1 - C_4). Za interpretaciju rezultata različitih modela potrebno je uzeti srednju vrijednost fizikalnih parametara klastera (tablice 1-2). Srednja vrijednost definira klaster, npr. C_1 ima najnižu, a C_4 najvišu vrijednost poroznosti. S druge strane klasifikacijske matrice diskriminantne analize (tablice 3-4) korisne su prilikom odredbe na koji način trenutne klasifikacijske funkcije predviđaju grupiranje. U prvoj koloni klasifikacijske matrice mogu se vidjeti postotci slučajeva koji su točno klasificirani u svakom klasteru. Ostali stupci pokazuju odnose između klastera te postotke njihove vjerojatnosti.

Opaska (iii):

Na temelju samih klasifikacijskih matrica ne može se zaključiti o valjanosti metode, budući da HAC organizira grupiranje u hijerarhijskom sustavu, za razliku od SOM-a. No, metoda SOM-a također ima prednost rada s kategoričkim i kontinuiranim varijablama.

Usporedba rezultata (slike 5-6) pokazuje da HAC metoda daje veće rasprostiranje klastera C_3 i C_4 od SOM-a, posebno u sjevernom dijelu polja. Zbog toga karta na slici 6 pokazuje povezaniju geometriju kanala. Ipak, treba pogledati i klasifikacijsku matricu diskriminantne analize (tablice 3-4). Prema klasifikacijskoj matrici klaster C_3 (tanki pješčenjak) i C_4

Tablica 1. Opis SOM-klastera srednjom vrijednosti petrofizikalnih parametara				
Klaster	Facijes	Zasićenje vodom	Volumen škriljaca	Porozitet
C_1	(F_4) Masivni lapor	100	95,0206	0,738341
C_2	(F_3) Laminirani pješčenjaci, siltovi i lapori	84,37476	70,48016	9,333921
C_3	(F_2) Tanki pješčenjaci	72,20415	59,63765	18,33316
C_4	(F_1) Masivni pješčenjaci	39,65112	24,06714	22,17427

Tablica 2. Opis HAC-klastera srednjom vrijednosti petrofizikalnih parametara				
Klaster	Facijes	Zasićenje vodom	Volumen škriljaca	Porozitet
C_1	(F_4) Masivni lapor	100	99,2144	0,37625
C_2	(F_3) Laminirani pješčenjaci, siltovi i lapori	99,52591	90,92864	2,84875
C_3	(F_2) Tanki pješčenjaci	70,38612	58,78594	15,92913
C_4	(F_1) Masivni pješčenjaci	45,50047	22,78151	21,182

Tablica 3. Klasifikacijska matrica SOM-klastera					
Korelativnost (%)	Maksimum	C_1	C_2	C_3	C_4
C_1	96	96	4	0	0
C_2	53	29	53	14	4
C_3	100	0	0	100	0
C_4	100	0	0	0	100
Total	85				

Tablica 4. Klasifikacijska matrica HAC-klastera					
Korelativnost (%)	Maksimum	C_1	C_2	C_3	C_4
C_1	100	100	0	0	0
C_2	75	25	75	0	0
C_3	87	4	0	87	9
C_4	95	0	0	5	95
Ukupno	89				

(masivni pješčenjak) imaju veće vrijednosti (100%) u slučaju SOM modela, no vjerojatnost klastera C_1 je nešto veća tek u modelu HAC-a. U obje metode, prema klasifikacijskoj matrici, može se uočiti da je procjena klastera C_2 relativno manja u odnosu na ostale. Razlike u fizikalnim parametrima (tablice 1-2) su vrlo male između klastera C_1 (masivni lapor) i C_2 (laminirani pješčenjak, silt i lapor), posebno u slučaju rezultata modela HAC-a, a zbog udaljenosti tih klastera u hijerarhijskoj strukturi. Dendrogram (slika 7) također pokazuje oštar kontakt između ta dva klastera. Tako C_2 i C_1 pripadaju zajedničkoj skupini više razine (skupina I na slici 7), što ukazuje na zajedničku genezu, jer se naravno ne mogu isključiti efekti sličnosti taložnih okoliša na rezultate združivanja. Klaster C_2 određen je kao prijelazna zona između C_3 i C_4 .

Rezultati su karte (slike 5 i 6) koje prikazuju glavni smjer transporta sedimenata (sjeverozapad-jugoistok), ocrtavajući oblik glavnog kanala te geometriju četiri litofacijesa. Mogu se odrediti četiri uzorka koja predstavljaju podokoliše. Tako klaster C_3 predstavlja geometriju ruba turbiditnog kanala (zbog povećanih poroznosti), a C_4 označava središnji dio kanala (s najvećim vrijednostima poroznosti). Prijelazna zona uključuje klaster C_2 , koji definira poplavni sediment na bazenskoj ravnici. Na kraju klaster C_1 , određen vrlo malim vrijednostima poroznosti, predstavlja lapor kao normalni bazenski, jezerski pelitni sediment.

Zapravo, klasteri jako dobro odgovaraju litofacijesima, tipičnim za gornjomiocensku sedimentaciju u Savskoj depresiji.²⁰ Ranije definiran facijes masivnih pješčenjaka (F_1) odgovara klasteru C_4 . Facijes tankih slojevitih pješčenjaka (F_2) odgovara C_3 , facijes laminiranih pješčenjaka, siltova i lapora (F_3) klasteru C_2 . Konačno, facijes masivnih lapora (F_4) je klaster C_1 . Rezultati su u skladu s objavljenim taložnim modelima za Savsku depresiju.^{15,19}

Karte (slike 5 i 6) prikazuju sličnu geometriju klastera, no postoje i određene razlike, posebno u sjevernom dijelu. Na slikama 8-11 prikazana su četiri reprezentativna karotažna dijagrama (poroznosti, otpornosti i litologije). U pojedinim slučajevima (npr. slike 8 i 9) može se uočiti da dijagrami vrlo dobro ocrtavaju klaster (slike 5 i 6). Tako oni izračunati modelom SOM-a na lokacijama bušotina br. -62 i -64 (u sjevernom dijelu proučavanog područja, gdje je uočena razlika) točno prikazuju izvorne srednje vrijednosti izračunate iz bušotinskih podataka.

3.2. KARTIRANJE INDIKATORSKIM KRIGINGOM KLASTERA IZRAČUNATIH METODAMA HAC I SOM

Indikatorska transformacija klastera temelji se na jednadžbi (5). Ukupno je bilo 76 ulaznih podataka podijeljenih u četiri razreda (slike 12 i 13).

Za svaki je razred izračunat variogram programom Variowin 2.21.¹² Pri tomu se trebaju ispuniti određeni kriteriji^{2,11} prilikom izrade variogramskih modela koji se kasnije primjenjuju u indikatorskom krigingu (IK):

- Teorijski model treba biti jednak (u oba je slučaja primijenjen sferni);
- Prag mora biti identičan (standardizirani variogram);
- Odstupanje mora biti jednako (0,6 za HAC i 0 za SOM metodu);
- Jedino se doseg može mijenjati za različite granične vrijednosti.

Teorijski variogrami korišteni u kartiranju indikatorskim krigingom prikazani su slikama 14 i 15. Glavna os je smjera 135°. Doseg sporedne osi izračunat je na temelju strukturnih karata po krovini ležišta, čiji je odnos tada primijenjen u variogramima (tj. prema strukturnoj karti glavna os je 1,5 puta dulja od sporedne, prema tome variogramski doseg glavne osi također bi trebao biti 1,5 puta veći od sporedne).

IK kartiranje napravljeno je programom WinGslib™. Prilikom kartiranja korišten je "Full IK" u procjeni jednostavnim krigingom. Mreža je definirana s ukupno 129 454 ćelija. Broj ćelija u X smjeru iznosi 338, a u Y 383. Dobiveni rezultati su karte vjerojatnosti za svaki klaster (slike 16 i 17).

Slike 16 i 17 prikazuju distribuciju vjerojatnosti za svaki klaster (klaster 1-4), gdje je najveća vrijednost vjerojatnosti označena crvenom bojom i iznosi 1, a najmanja plavom te iznosi 0. Usporedimo li slike 16 i 17, karte kriginga za klastere dobiveni HAC metodom ne pokazuju visoke vjerojatnosti, osim za klaster 3. Karta vrijednosti klastera izračunatih po HAC metodi mogu se opisati nižim vjerojatnostima u odnosu na klaster dobivene SOM metodom. Inače, vjerojatnost pojavljivanja klastera 4 (izračunatih po objema metodama) je mala, najvjerojatnije zbog malog broja mjerenja u bazenskim laporima.

Prema jednadžbi (6) određene su najveće vjerojatnosti za svaki pojedinačni klaster u svakoj točki mreže. Takvo ograničavanje rezultiralo je kartama na slikama 18 i 19, gdje je geometrija točaka sličnih karakteristika (npr. geometrija kanala) s najvećim vjerojatnostima ograni-

čena poligonima. Karte pokazuju diskontinuiranu geometriju prostiranja klastera, u kojima su njihove granice određene i vjerojatnostima izračunatim indikatorskim krigingom (klaster 4, tj. litofacijes lapora, nije prikazan na tim kartama).

4. ZAKLJUČAK

Prema kartiranim klasterima moguće je prepoznati turbiditni sustav i smjer taloženja materijala od sjeverozapada prema jugoistoku. Obje metode združivanja u turbiditnom sustavu pokazuju pružanje kanalnih sedimenata, sedimenata prijelaznih facijesa i bazenskih lapora. Sadržaj pijeska obično može opisati taložnu geometriju, a ovim radom je prikazano također moguću primjenu metode združivanja temeljene na tri petrofizikalne varijable (poroznost, zasićenje vodom i volumen lapora).

Oba modela sadrže nesigurnost, što se može vidjeti u rezultatima diskriminantnih analiza. Ipak, obje metode mogu prepoznati spomenute klasterne vezane uz pojedine taložne podokoliše, gdje je stupanj homogenosti karakteriziran svojstvima klastera. Metoda SOM-a može prikazati varijabilnosti na manjim udaljenostima, koje su npr. rezultat pojave tankih slojeva lapora unutar ležišne "serije". To je važno budući da takvi slojevi mogu utjecati na srednje petrofizikalne vrijednosti cijele "serije".

Združivanje metodom HAC-a ne može prikazati takve varijabilnosti. Vjerojatno je tomu razlog taj što metodom HAC-a nije bilo moguće koristiti kategoričku varijablu litologije, za razliku od metode SOM-a, koja koristi takve varijable te može prepoznati nelinearni kontakt unutar podataka. To je objašnjeno srednjim parametrima i krivuljama bušotina označenih na kartama ("Study"-62 i -64 na sjevernom dijelu polja). Takve srednje statističke vrijednosti su bliže srednjim vrijednostima klastera u metodi SOM-a, negoli HAC-a. Međutim HAC metoda ima mogućnost određivanja "bliže" veze između dva klastera na dendogramu, kao što je odnos klastera C_1 i C_2 .

5. ZAHVALE

Prikazano istraživanje načinjeno je aktivnošću Sektora za geologiju i upravljanje ležištima, INA d.d., Hrvatska, te Zavoda za geologiju i paleontologiju Sveučilišta u Segedu, Mađarska. Također puno hvala kolegama na sugestijama i komentarima te recenzentu na korisnim savjetima.



Autori:

Janina Horváth, Sveučilište u Segedu, Zavod za geologiju i paleontologiju, Sveučilište u Segedu, Seged, Mađarska, e-pošta: th.janina@geo.u-szeged.hu

Kristina Novak Zelenika, INA-Industrija nafte d.d., Sektor za geologiju i upravljanje ležištima, Zagreb, Hrvatska, e-pošta: kristina.novakzelenika@ina.hr

UDK : 550.8 : 553.28 : 551.4 (497.5)

550.8	geološka istraživanja
553.28	vrste ležišta, pješčenjaci, osobine ležišta
551.4	kartografija, kriging
(497.5)	R Hrvatska, savska depresija