

Geostatističko kartiranje kokrigingom te važnost kvalitetnog seizmičkog atributa

T. Malvić, M. Barišić i I. Futivić

ORIGINALNI ZNANSTVENI ČLANAK

Višekomponentna seizmika pruža nam novi uvid u karakteristike ležišta. Primjena seizmike koja objedinjuje P i S valove (PS signal), temelji se na razlici refleksije tih valova u ležištu. Jedno od najvažnijih svojstava S valova je njihova relativna neosjetljivost na zasićenje, što nije slučaj kod P valova.

U polju Molve je snimljena i interpretirana 3D seizmika. Pouzdanost svakoga seizmičkog pojedinačnog atributa nije bila dovoljna da bi se mogli interpretirati zone s plinom, poroznost te zasićenje vodom. Razlog tomu je kompleksna litologija ležišta, predstavljena s čak 4 litofacijesa: litofacijesom IV (uglavnom retrogradno metamorfozirani gnajsevi; paleozojski i stariji), litofacijesom III (metakvarciti perma i trijasa), litofacijesom II (uglavnom dolomiti jurske i trijaskе starosti) te litofacijesom I (miocenski vapnenci). To je razlog da seizmički atributi i parametri ležišta nisu mogli biti korelirani. Zato je kreirani novi složeni atribut (engl. „multi-atribut“) za svaki od četiri litofacijesa u ležištu. Takav atribut mogao se znatno lakše korelirati s petrofizikalnim varijablama. Na temelju Kalkomey-eva pristupa vjerojatnost da je takva korelacija lažna iznosi 0,15.

Nadalje, potvrđena je korelacija između atributa i poroznosti, posebno u litofacijesu III (sastavljenom od kvarcita, škriljavaca i grauake). Zato je tu poroznost interpolirana upotrebom geostatističke metode kokriginga, tj. upotrebom sekundarne seizmičke varijable. Također, analiza složenoga atributa vodi do bolje vizualizacije dominantno vapnenačke litologije u litofacijesu II. Može se očekivati da će višekomponentna seizmika biti snimljena, kroz nekoliko godina, u većini važnih hrvatskih polja. Polje Molve jedno je od najvažnijih. Novi seizmički podatci svakako će poboljšati kvalitetu interpretiranih atributa te omogućiti uspostavljanje jasne korelacije između seizmičkih i petrofizikalnih podataka u svim litostratigrafskim jedinicama takvoga heterogenoga ležišta.

Ključne riječi: atributi, interpolacija, kokriging, Molve, trokomponentna seizmika

1. Uvod

Polje Molve otkriveno je 1974. godine. Danas je to najvažnije plinsko polje u hrvatskom dijelu Panonskoga bazena, smješteno u sjeverozapadnom dijelu Dravske depresije (slika 1). Načinjena je seizmička interpretacija i ležišni model, a glavni cilj bio je oblikovanje pouzdanog modela za karakterizaciju ležišta. Ležište je inicijalno bilo nadpritisnuto (početni tlak bio je 40 - 50% veći od hidrostatičkoga), s visokim temperaturama te unutar snažno rasjednute zone sa značajnom sekundarnom poroznošću.¹

Kronostratigrafska analiza omogućila je razlikovanje četiri glavna litofacijesa:^{1,2}

- Litofacijes I – vapnenci tipa biomikrita i biokalkrudita miocenske starosti;
- Litofacijes II – frakturirani dolomiti, šejlovi i filiti jurske i trijaskе starosti;
- Litofacijes III – metakvarciti (s uklopcima tinjaca na južnom dijelu polja) permske i trijaskе starosti te
- Litofacijes IV – retrogradno metamorfozirani gnajsevi kambrijske i pret-kambrijske starosti.

Polje Molve obuhvaća najveće plinsko-kondenzatno ležište u Hrvatskoj. Interpretacija zona zasićenih plinom, vodom te poroznosti u kompleksnoj litološkoj građi (poput one u polju Molve) uključuje poznavanje geologije, karakteristika ležišta te fizike stijena. To može biti načinjeno upotrebom višekomponentnog seizmičkog snimanja i obrade. Višekomponentne metode imaju

primjenu posebno u heterogenim ležištima poput onoga u polju Molve. Analiza anizotropije uočene preko S valova može biti vrlo važan interpretacijski alat.

Seizmička interpretacija rađena je kontinuirano od otkrića strukture Molve, a zadnji podatci se temelje na rezultatima 3D seizmike. Dobiven je vrlo detaljan uvid u strukturu polja (slika 2), ali također i u litološke prijelaze, zasićenje fluidima te njihove kontakte. Ukupna seizmička informacija raščlanjena je na nekoliko atributa. Međutim, pouzdanost svakog pojedinačnog atributa nije bila dovoljna da bi se uspješno prepoznale zone zasićene plinom, vodom ili izračunala poroznost. Razlog leži u složenoj litologiji zbog koje se ne može uspostaviti korelacija između seizmičkog atributa i ležišnih varijabli. Nova vrsta složenog atributa stvorena je za svaki litofacijes, te je takav atribut bilo znatno lakše korelirati s petrofizikalnim varijablama. Određeni izračuni koji se temelje na Kalkomey-ovom pristupu⁹ ukazali su da uspostavljena korelacija može biti ocjenjena kao lažna tek u 15% slučajeva, što je vrlo dobar rezultat. Najpouzdanija korelacija između seizmičkog atributa i poroznosti izračunata je u litofacijesu III, u kojem je stoga za interpolaciju upotrijebljena metoda kokriginga.

Općenito, polja Molve bilo je detaljno kartirano s obzirom na dubinu slojeva, debljinu ležišta te raspodjelu poroznosti. Najnaprednija interpolacija načinjena je za karte poroznosti te su konačno dobivene vrlo pouzdane karte za sva četiri litofacijesa. One su dobivene

upotrebom kriginga i stohastičkih Gaussovih simulacija¹¹, a u litofacijesu III bilo je moguće primijeniti metodu kokriginga.

2. Matematičke osnove kokriginga

Kokriging, poput osnovne metode kriginga, uključuje nekoliko interpolacijskih tehnika.^{6,7,8} Ta metoda uključuje dvije varijable, primarnu te sekundarnu koja opisuje ponašanje primarne (a ujedno su u jakoj korelaciji). Uz to, sekundarna varijabla je interpretirana na znatno većem broju lokacija.

$$z_c = \sum_{i=1}^n \lambda_i \cdot z_i + \sum_{j=1}^m \chi_j \cdot s_j \quad (1)$$

Gdje su:

$\sum_{i=1}^n \lambda_i \cdot z_i$ bilo koja jednadžba kriginga (npr. vidjeti jedn. 2)

$\sum_{j=1}^m \chi_j \cdot s_j$ sekundarna jednadžba kriginga, primijenjena na sekundarnu varijablu

Jednadžba jednostavnoga kriginga, kao primjer najjednostavnije tehnike kriginga, glasi:

$$\begin{bmatrix} \gamma(Z_1 - Z_1) & \gamma(Z_1 - Z_2) & \dots & \gamma(Z_1 - Z_n) \\ \gamma(Z_2 - Z_1) & \gamma(Z_2 - Z_2) & \dots & \gamma(Z_2 - Z_n) \\ & & \dots & \\ \gamma(Z_n - Z_1) & \gamma(Z_n - Z_2) & \dots & \gamma(Z_n - Z_n) \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \lambda_n \end{bmatrix} = \begin{bmatrix} \gamma(Z_1 - Z) \\ \gamma(Z_2 - Z) \\ \dots \\ \gamma(Z_n - Z) \end{bmatrix} \quad (2)$$

Gdje su:

- γ variogramske vrijednosti;
 Z_1, \dots, Z_n poznate, izmjerene vrijednosti u točkama (čvrsti podatci);
 Z točka u kojoj je procjenjena nova vrijednost (iz čvrstih podataka).

Nadalje, kada je procjena načinjena na kontrolnim točkama (tzv. čvrsti podatci), pogriješka se također može izračunati u točki kao:

$$\varepsilon = (Z_{real} - Z_{estimated}) \quad (3)$$

Ako u mjerenim podacima nije moguće uočiti neki vanjski utjecaj (engl. „drift“) na njih (npr. izrazitu sličnost vrijednosti obzirom na zemljopisni položaj), a suma svih težinskih koeficijenata je 1, postignuta je nepristranost procjene. Razlika između svih izmjerenih i procijenjenih vrijednosti naziva se **pogrješka procjene** ili **varijanca kriginga** te je izražena kao:

$$\sigma^2 = \frac{\sum_{i=1}^n (Z_{real} - Z_{estimated})_i^2}{n} \quad (4)$$

U idealnom slučaju, kriging pokušava izračunati optimalne težinske koeficijente koji će dovesti do minimalne pogriješke procjene. Takvi koeficijenti, koji vode do nepristrane procjene i minimalne varijance, izračunati su rješavanjem sustava matričnih jednadžbi.

Druga numerička metoda provjere naziva se **kros-validacijom** (engl. „cross-validation“). Radi se o numerički relativno jednostavnoj i široko korištenoj

tehnicu za provjeru kvalitete procjene. Temelji se na privremenom odstranjivanju jedne od mjerenih vrijednosti te procjene nove vrijednosti iz preostalih podataka na odabranoj lokaciji.⁵ Postupak se ponavlja za sve bušotine te je na kraju za procjenu izračunata vrijednost srednje kvadratne pogriješke (engl. „Mean Square Error – MSE“). Nedostatak metode je djelomična neosjetljivost na broj analiziranih bušotina. Također, takav postupak se ponekad opisuje imenom jack-knifing, no ipak se radi o dva različita pristupa (vidjeti npr. lit.^{3,12}).

$$MSE_{method} = \frac{1}{n} \sum_{i=1}^n (meas.val - est.val)_i^2 \quad (5)$$

Gdje su:

- MSE_{method} srednja kvadratna pogriješka kod odabrane metode procjene
 $meas.val.$ izmjerena vrijednost odabrane varijable na bušotini „i“
 $est.val.$ procjenjena vrijednost odabrane varijable na bušotini „i“

3. Kartiranje kokrigingom u polju Molve

U polju Molve litofacijesu III kartiran je kokrigingom. Interpretirani su seizmički atributi amplitude, frekvencije i faze. Takvu interpretaciju bilo je moguće načiniti u svim litofacijesima osim u najstarijem litofacijesu IV zbog nedovoljnoga broja podataka. Amplituda je odabrana kao najopisniji atribut kod promatranja vrijednosti poroznosti. Zato su različite izvedenice amplitude bile korelirane s poroznostima osrednjenim na lokacijama bušotina u dijelu ležišta nazvanom litofacijesu III (tablica 1).

Tablica 1. Korelacija između poroznosti i amplitudnih atributa (16 parova podataka)

	Amplituda	Snaga refleksije	Nagib snage refleksije
Poroznost	0,47	0,51	-0,14

Maksimalna korelacija izračunata je između poroznosti i snage refleksije. Značajnost korelacije provjerena je t-testom. Izračunata je vrijednost $t=2,22$ dok je $t_{kritični}=1,76$ (za $\alpha=5\%$). To znači da je izračunata korelacija statistički značajna. U geološkom smislu snaga refleksije može opisivati varijacije u vrijednostima poroznosti. Zbog toga je snaga refleksije odabrana kao sekundarna prostorna varijabla. Nadalje, sekundarna varijabla je uzorkovana na znatno većem broju točaka nego li primarna (2 500 nasuprot 16 točaka). Zbog toga je anizotropni eksperimentalni variogram modeliran na podacima sekundarne varijable (slika 3). Model je određen sljedećim vrijednostima:

- Azimut primarne osi 120°;
- Širina razreda oko 350 m;
- Doseg na primarnoj osi 4 000 m (sferni teoretski model bez odstupanja);

- Doseg na sekundarnoj osi 2 900 m (sferni teoretski model bez odstupanja).

Broj variogramskih parova podataka bio je iznimno visok i predstavlja pogodnost stečenu uvođenjem sekundarne varijable. Dosezi su mogli biti određeni iznimno točno (u bilo kojoj interpretaciji mogu varirati tek nekoliko postotaka).

Odgovarajuća karta poroznosti, dobivena tehnikom običnoga kokriginga, prikazana je na slici 4.

Numerička kvaliteta interpolacije provjerena je kros-validacijom, a izračunata vrijednost je $MSE = \frac{1}{n} \sum_{i=1}^n (x_{measured} - x_{estimated})^2 = 1,28$. To je najmanja

moгуća vrijednost koja se može dobiti iz dostupnih podataka za promatrani litofacijes.

Dodatne informacije o ležištu dobivene su upotrebom stohastičkih Gaussovih simulacija. Načinjeno je 100 realizacija, no taj pristup temeljio se na rješenju dobivenim krigingom kao nultim rješenjem. Razlog tomu bila je što je stohastička analiza načinjena samo na primarnoj varijabli (poroznost). Analizirani novi skup podataka poroznosti odabran je iz skupa od 100 realizacija. Izračunati histogram simuliranih podataka (izvorni skup bio je premali za izradbu pouzdanog histograma) prikazan je na slici 5.

Iz histograma su određene sljedeće statističke vrijednosti: srednja poroznost od 0,031 9 dij. jed. standardna devijacija 1,99 te maksimalna vrijednost od 0,122 7. Iz stotinu stohastičkih rješenja bilo je moguće prikazati nekoliko vrijednih karata za interpretaciju. Ovdje je priložena karta (slika 6) gdje su vrijednosti poroznosti prikazane samo u ćelijama gdje vrijednost iznosi samo 0,003 dij. jed. Primijetimo kako su područja veće poroznosti uglavnom smještene duž glavnih rasjednih zona.

4. Analiza seizmičkih atributa u polju Molve

Atributna analiza može pružiti mnoge informacije o ležištu, na primjer u prepoznavanju različitih litotipova, poroznosti i zasićenja plinom.

Složeni atribut je kvocijent normalizirane amplitude i frekvencije te njihov umnožak s fazom. Takav izračun napravljen je za svaki litofacijes.¹⁴ U svrhu korelacije između seizmičkih atributa i ležišnih parametara u poljima kompleksne sedimentacije i tektonike potrebno je u obzir uzeti upravo litološku raznolikost. Nakon stvaranja složenog atributa bilo je moguće postići dobru korelaciju između atributa i ležišnih varijabli u litofacijesu III. Takva korelacija pokazala se uspješnom u svim litotipovima. Vjerojatnost lažne korelacije⁹ između poroznosti i seizmičkog atributa procjenjena je na samo 0,15.

Litofacijes I određen je preko dviju genetskih i proizvodnih jedinica – biomikrita sa slabijim te biokalkrudita s vrlo dobrim ležišnim svojstvima. Postoji dobra korelacija između složenoga atributa te efektivnog pornog volumena (engl. „net pore volume“) u oba spomenuta litotipa (slika 7).

Litofacijes II sastavljen je od čistih dolomita na sjevernom dijelu te glinovitih dolomita na južnom dijelu

polja (slika 8). Koeficijent determinacije (R²) između složenoga atributa i efektivnog pornog volumena iznosi 0,65.

Litofacijes III uglavnom uključuje metakvarcite kao dominantni litotip (područja koja sadrže značajan udjel tinjaca, kao nepropusne zone, isključena su iz analize; slika 9). Koeficijent determinacije (R²) između složenoga atributa i efektivnog pornog volumena je 0,72.

Litofacijes IV uključuje premali broj podataka za pouzdanu analizu.

Nema sumnje kako je kvaliteta seizmičkog atributa te bilo kojega sintetskoga atributa (stvorenoga iz dva ili više pojedinačnih atributa) je „ključni alat“ za izračunavanje značajne korelacije između poroznosti (ili bilo koje druge ležišne varijable) te seizmike.

Vrijedno je spomenuti da transverzalni valovi su, sve više i više, vrijedan izvor seizmičkog signala koji je na kraju pretvoren u attribute. Nadalje, od kraja osamdesetih godina počeo je rasti interes za P valove kao izvor energije S valova. Tome su jedim dijelom pridonijela i mjerenja vertikalnih seizmičkih profila (VSP). Slika 10 prikazuje primjer VSP-a kod kojeg se P valovi izravno pretvaraju u S valove (PS valovi). Takvi valovi imaju približno jednaku amplitudu kao P valovi.

Većina projekata gdje je primijenjena višekomponentna seizmika,^{4,5} uz korištenje S-valova kao izvora seizmičkih signala, rađena je u ležištima smještenim u klasičnim stijenama gdje je promjena kompresibilnosti glavna značajka seizmičkog vremenskog praćenja. No, slična analiza može bi načinjena u karbonatnim stijenama, gdje anizotropija S-valova može poslužiti kao koristan alat za mjerenje promjena u čvrstoći. Takva metoda može se primijeniti u bilo kojemu heterogenom ležištu, poput onoga opisanoga u polju Molve, nadajući se da će se postići bolja analiza atributa.

5. Zaključak

Potpuna slika seizmičkoga vala, visoke kvalitete, upotrebom transverzalnih (S) valova, može poboljšati razlučivost te znatno efikasnije reducirati šum. Takva visokokvalitetna seizmika i posljedično pouzdanija atributna analiza povećala bi naše znanje o ležištu u svakom obliku te omogućila upotrebu kokriginga u cijelome ležištu. Također, S-valovi, koji nisu osjetljivi na utjecaj fluida, mogu vrlo uspješno pomoći u razlikovanju litologije.

Kvaliteta dostupnih seizmičkih podataka te njihova dobra obradba omogućile su primjenu običnoga kriginga u litofacijesu III polja Molve. Definiranje sekundarne varijable, uzorkovane na znatno većem broju lokacija nego li primarna, omogućilo je određivanje vrlo pouzdanog anizotropnog variogramskog modela. Tako su tehnikom običnoga kriginga interpolirane su vrlo precizne karte poroznosti litofacijesa III unutar područja ležišta određenog glavnim rasjedima.

Dopunske statističke vrijednosti za varijablu poroznosti dobivene su upotrebom sekvencijskog Gaussovog pristupa u litofacijesu III. Prosječna poroznost je procjenjena na 0,031 9 dij. jed.

Naravno, definiranje složenoga atributa (što ovisi o kvalitetnijem seizmičkom signalu) vjerojatno bi rezultirala u uspostavljanju korelacije između poroznosti i atributa i u drugim litofacijesima u polju Molve. To bi značajno unaprijedilo kartiranje poroznosti i općenito ležišnih varijabli, jer vizualizacija takvoga atributa omogućuje prepoznavanje zona s boljim ležišnim svojstvima ili područja koja sadrže rezidualne akumulacije plina.

Zahvala

Prikazani rezultati djelomice se temelje na podacima koji su ranije objavljeni, a predstavljaju rezultate aktivnosti u Sektoru za razradu, SD Istraživanje i proizvodnja nafte i plina, INA-Industrija nafte d.d. Zahvaljujemo za mogućnost prenošenja djela rezultata iz nekih radova nabrojanih u popisu literature.



Autori:

Tomislav Malvić Dr. sc. Tomislav Malvić, dipl. ing. geol., INA-Naftaplin, Sektor za razradu, savjetnik, tomlav.malvic@ina.hr, Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, Zavod za geologiju i geološko inženjerstvo, gostujući predavač

Miroslav Barišić, dipl. ing. geol., u mirovini (ranije INA-Naftaplin, Sektor za istraživanje), miroslav.barisic2@zg.t-com.hr

Igor Futivić, dipl. ing. geol., INA-Naftaplin, Sektor za razradu, Rukovoditelj jedinice za kapitalni remont sloja, igor.futivic@ina.hr

UDK :550.8 : 553.98 : 551.4 : 550.34 (497.5)

550.8	geološka istraživanja
553.98	ležišta nafte i plina
551.4	kartiranje
550.34	seizmika
(497.5)	RH, Molve