

# METODA I POSTUPAK ZA ODREĐIVANJE IZNOSA POROZNOSTI NALAZIŠTA UGLJKOVODIKA S POMOĆU ODBACIVANJA KONTEKSTA MODELSKOG SADRŽAJA DOMINANTNIH KOMPONENTI SEIZMIČKOG SIGNALA, P20040828

Franjo Jović, emeritus HATZ, FERIT Osijek, Sveučilište J.J. Strossmayera, fjovic90@gmail.com

**Sažetak:** Prikazani izum je algoritam za izradu analitičkog modela procesa koji služi za otkrivanje jedne ili više skrivenih procesnih veličina. Iz ulaznih mjernih veličina procesa izdvajaju oni procesni modeli koji ukazuju na vodeće procesne veličine tako da se ispituje njihova kompatibilnost sa skrivenom procesnom varijablom. Izbacivanjem te vodeće procesne veličine postupkom renormalizacije ulaznih i referentnih ili ciljnih podataka dobivaju se rekombinacijom složeni modeli koji imaju to bolju kvalitativnu korelaciju sa skrivenom varijablom, što je poremećajna funkcija izrazitija.

## 1. Uvod

Standardna tehnika koja se rabi za analizu seizmičkih profila i njihovo obilježavanje je ručni proces kojim seizmički interpretator obilježava ucrtavanjem svoje vizualiziranje seizmičkih podataka dobivenih refleksijom akustičkih valova u nekom vremenskom intervalu od interesa. Dobiveni seizmički profili koriste se za različite svrhe no primarno služe za interpretaciju razdiobe litologije i svojstava stijena. Vješt interpretator slijedi svoju sposobnost opažaja, intuiciju i iskustvo te tako doprinosi značajno uspješnosti takvih analiza. Istodobno to utječe na subjektivnost dobivenih rezultata, potrošak vremena i teškoće pri odlučivanju.

## 2. Opis patenta, patentne prijave ili inovacije

1. Izvodi se prikupljanje i pretvorba procesnih mjernih, dakle u pravilu kvantitativnih varijabli u kvalitativni oblik po načelu rangiranja za sve odnosno za određeni broj uzastopnih mjernih uzoraka. Uzorci ne moraju nužno biti vremenski vezani, ali njihov poredak mora biti prema nekom kvalitativnom kriteriju, odnosno varijable ne moraju biti u principu kvantitativne, već mogu biti kvalitativne i rangirane po nekom kriteriju koji omogućava njihovo neposredno uključivanje u proces modeliranja. Moguće je upisivati i ocjene geologa, odnosno rudarskih inženjera za pojedinu točku polja odnosno za pojedina područja polja. Takvi upisi i ocjene moraju biti u izravnoj vezi s konačnim ciljem metode. Slučaj malog broja uzastopnih procesnih podataka se također razmatra pod kriterijima ove patentne prijave.

2. Filtriraju se izbacivanjem oni podaci koji su očigledno neispravni. Filtriraju se podaci nadopunjavanjem, ukoliko je to nužno. U ovoj se fazi izvodi operacija smještanja referentnih mjernih podataka, u ovom slučaju s iznosima poroznosti dobivenih iz laboratorija, na stvarnu mrežu točaka seizmike. Određuju se mjerne točke najbliže mjernim referentnim točkama. Dakle, svaka ispravno filtrirana točka 2D polja sadrži mjerne podatke seizmike iz kojih su izbačene sve neprimjerene veličine, te podatke njezina položaja. Uz to znaju se najbliži susjedi mjernih referentnih točaka.

3. Područja sličnosti mjernih točaka određuju se na način razvrstavanja. Pri razvrstavanju generiraju se i inverzni podaci za sve mjerne veličine. Također svi se podaci skaliraju na istu srednju vrijednost i slično područje raspona. Istražuje se područje sličnosti za različite oblike geometrije oko svih mjernih točaka polja. Konkretno, polja 2x2, 2x3, 3x3, 2x4, 3x4, 4x4 itd.. Istraživanjem sličnosti izvodi se ograničenje duljine promatranih vektora, odnosno veličine lokalnog polja npr izborom veličine 3x3. S veličinim polja zbog pada sličnosti mjernih podataka drastično pada funkcija sličnosti dobivena postupkom razvrstavanja.

4. Procesne modelske varijable oblikuju se po dužini iz dobivenih ograničenja na sličnost, te po broju ovisno o mjernim obilježjima. Tako vektor polja 4x4 ima 16 članova za svaku mjernu veličinu, te 16 za njen inverz, koji se obavezno uvodi zbog potrebe optimalnosti opisa domene problema (Jović – Informatica). Isto tako se mogu oblikovati procesne varijabli različitim redanjem mjernih točaka u 2D području, slika 1.

5. Ciljna se funkcija generira u najbližem okruženju referentnih mjernih podataka određenim postupkom datim u točki 3. npr lokalnim poljem datim veličinom 3x3 dobivenoj na bazi dostatne sličnosti 2D područja referentne mjerne točke metodom razvrstavanja. Generiranje ciljne funkcije izvodi se iz mjernih podataka okoline referentnih mjernih bušotina, tj takvih funkcija ima više, slika 2.

6. Model se izrađuje tako da se ispituju kvalitativne sličnosti ciljnih funkcija i procesnih modelskih varijabli za svako lokalno polje. Tako za 2D polje sa 100x3 mjerne točke, lokalnim poljem 3x3, s dvije referentne mjerne veličine te tri mjerne veličine po točki imamo ukupno 97 lokalnih polja x 6 procesnih varijabli s inverzima x 6 ciljnih funkcija s inverzima x 2 ciljne funkcije ili 6984 mogućih kandidata za model. Kao ispravni model se može uzeti ona procesna veličina nekog lokalnog polja koja 100% kvalitativno korelira s ciljnom funkcijom. Takvih

modela može biti više ili ih uopće ne mora biti. Ukoliko ih nema dovoljno potrebo je uzeti kvantitativnu kombinaciju varijabli npr  $V1 + k1 V2$ , odnosno  $V1 - k2 V2$ , odnosno neku od algebarskih operacija nad varijablama. Da bi takvi modeli bili praktički dohvatljivi uzimaju se podaci za varijable  $V1$  i  $V2$  prethodno normalizirani pozitivno definitni mjerni podaci npr normalizirani na njihovu istu srednju veličinu ili/i isti raspon kretanja. Tako se veličina faznog kuta iz područja  $(-\pi, \pi)$  mora prebaciti u područje npr  $(1000, 2000)$  te se u isto područje prebacuju i amplituda i frekvencija mjernih seizmičkih signala. Algebarskim operacijama dobivene nove varijable se opet uspoređuju na kvalitativan način s ciljnim funkcijama za svako lokalno polje. Svaka dobivena potpuna kvalitativna sličnost se sprema u bazu podataka.

Tako dobiveni modeli npr  $M1 = V1 + k1V2$  odnosno  $M2 = V3$  nazivaju se dominantnim modelima.

7. Dominantni modeli daju za svaku mjernu točku više mogućih rješenja, jedno rješenje ili nijedno rješenje, slika

3. Nastupaju sljedeći slučajevi sa slike 3:

- mjerna točka ne korelira kvalitativno ni s jednom referentnom mjernom točkom ni po jednom modelu
- mjerna točka korelira kvalitativno s jednom referentnom mjernom točkom po jednom modelu
- mjerna točka korelira kvalitativno s referentnom mjernom točkom po više modela
- mjerna točka korelira kvalitativno s više od jedne referentne mjerne točke s jednim ili više modela, a referentna mjerenja su dovoljno blizu
- mjerna točka korelira kvalitativno s više od jedne referentne mjerne točke s jednim ili više modela, a referentna mjerenja nisu dovoljno blizu.

Za zadnji slučaj može se smatrati da je došlo do smetnje koja je jača od signala te je potrebno izlučiti tu dominantnu komponentu smetnje izraženu dominantnim modelom sličnosti.

Ostali slučajevi mogu se podijeliti u tri skupine: ili ima dovoljno pogodaka pa se može izraditi model ciljne funkcije interpolacijom za nepostojeće rezultate, ili ima pretičak podataka pa se oni mogu izraziti težinskim udjelom s referentnim mjernim iznosima, ili se može izvesti kombinacija obaju postupaka.

Dominacija nekog modela za veći broj mjernih točaka iz zadnjeg slučaja smatra se znakom potrebe sustavnog potiskivanja smetnje iz procesa identifikacije.

8. Renormalizacija podataka koja se izvodi u cilju potiskivanja smetnje izvodi se u pravilu

za one veličine koje su dominantne u modelskom očitovanju, tako npr ako je većina modela izražena izrazom  $V2$  onda se veličina  $V2$  smatra dominantnom i treba je potisnuti.

Potiskivanje se izvodi renormalizacijom podataka s veličinom  $V2$ , primjer na slici 4.

9. Nakon renormalizacije podataka i njihovog svođenja na isto područje veličina izvodi se

povratak u točku 6. postupka. No tada se u skupu podataka nalazi jedna varijabla manje budući da renormalizacija varijable  $V2$  varijablom  $V2$  daje konstantan iznos. Rekurzija se dakle može izvesti za  $(2 \times \text{broj varijabli} - 1)$  puta. Renormalizacijom inverza  $V2$  dobiva se npr varijabla  $1/V2$ , itd.

10. Analogno točki 7. Postupka sada se ponovno provodi kontrola nelogičnosti rezultata

modeliranja. Ukoliko se i opet pojavljuju prekrivanja više rješenja različitih referentnih mjernih veličina za pojedinu točku, potrebno je ponovno ići u rekurziju postupka povratku u točku 8. postupka.

11. Ukoliko to nije više slučaj potrebno je iz dobivenih podataka izraditi izračun za svaku

pojedinu mjernu točku iz težinskih iznosa doprinosa ako su blizu, odnosno interpolacijom ako su nepostojeći. Jednostruki podaci mogu se uzeti onakvi kako su dobiveni.

### 3. Zaključak

Prikazani izum je algoritam za izradu analitičkog modela procesa koji služi za otkrivanje jedne ili više skrivenih procesnih veličina. To je iterativan postupak kojim se iz ulaznih mjernih veličina procesa (1), a na temelju poznavanja vrlo ograničenog broja referentnih ili podataka ciljnih funkcija, izdvajaju oni procesni modeli koji ukazuju na vodeće procesne veličine tako da se ispituje njihova kompatibilnost sa skrivenom procesnom varijablom (10). Izbacivanjem te vodeće procesne veličine postupkom renormalizacije ulaznih i referentnih ili ciljnih podataka dobivaju se rekombinacijom (11) složeni modeli koji imaju to bolju kvalitativnu korelaciju sa skrivenom varijablom (12), što je poremećajna funkcija izrazitija. U slučaju da su poremećajne veličine poznate moguće je izravno pristupiti renormalizaciji podataka (9A), izradi modela rekombinacijom normaliziranih podataka (11) i dobivanju skrivene procesne veličine (12), slika 1.

