

# Primjena umjetnih neuronskih mreža u kartiranju ležišta ugljikovodika, primjer EK markera Rs5 u Bjelovarskoj subdepresiji



Marijan Šapina<sup>1</sup>

<sup>1</sup> Pavićeva 93, 31400 Đakovo, mag.ing.naft.rud.

## Sažetak

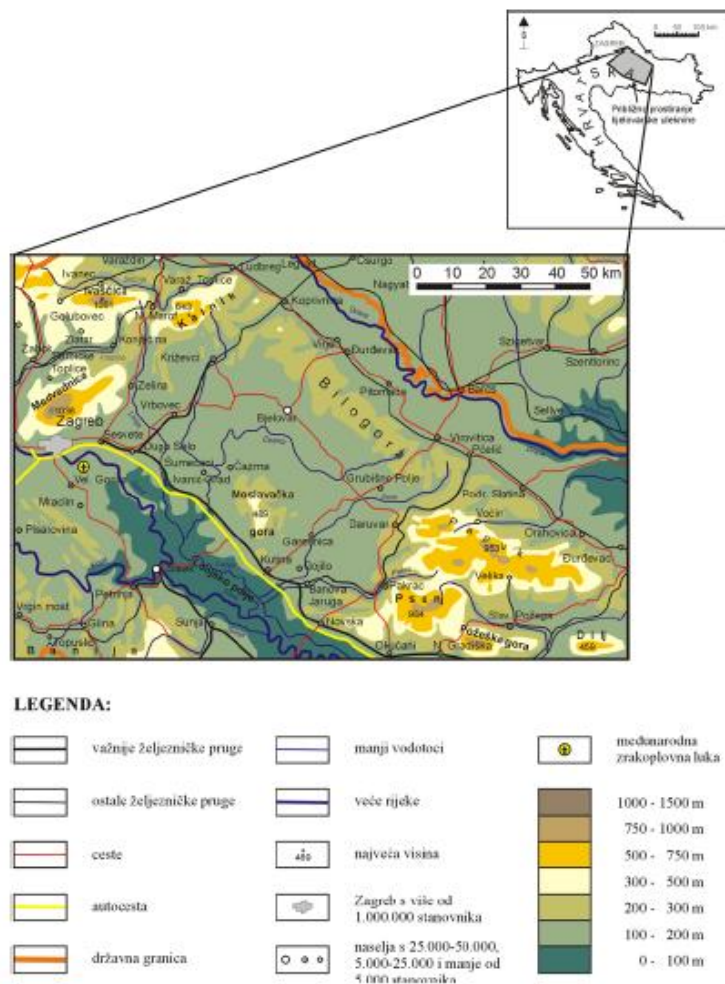
U ovomu radu su prikazani rezultati uspješno primijenjene metode umjetnih neuronskih mreža u kartiranju ležišta ugljikovodika. Kartirana, odnosno, izlazna varijabla je bila dubina, a kartirana je s obzirom na dvije ulazne varijable, koordinate  $x$  i  $y$ . Promatrano područje je EK marker Rs5 u Bjelovarskoj subdepresiji unutar Dravske depresije koja je dio hrvatskog dijela Panonskog bazenskog sustava. Algoritmom umjetne neuronske mreže izrađenim u programu za statističku obradu „R“ dobivena je arhitektura mreže koja daje „najbolje“ izlaze, tj. izlaze s najmanjom pogreškom u odnosu na ulazni skup podataka. Ta mreža se sastojala od četiri sloja, od čega dva skrivena koji su imali 10 i 6 neurona. Kao najbolji algoritam pokazao se algoritam s povratnim postupkom. Ukupna kvaliteta rezultata i načinjene karte je obrađena statističkom analizom i usporedbom s drugim često korištenim metodama kartiranja kao što je metoda običnog krigiranja. Usporedba je načinjena metodom kros-validacije.

## Ključne riječi

Bjelovarska subdepresija, geomatematika, kartiranje, kros-validacija, umjetne neuronske mreže.


## 1. Uvod

U ovomu radu je postavljena hipoteza uspješnog kartiranja metodom umjetnih neuronskih mreža. Karakteristika metode umjetnih neuronskih mreža je da simulira postupak ljudskog učenja uvježbavanjem i optimiziranjem parametara nizom ponavljanja. Uspoređeni su rezultati kartiranja umjetnom neuronskom mrežom i geostatističkom interpolacijom, tj. metodom običnog kriginga. Metoda je primijenjena na kartiranju dubine EK markera (elektrokarotaznog markera) „Rs5“. EK marker „Rs5“ predstavlja granicu formacija Moslavačka gora (taložne stijene donjeg i srednjeg miocena) te formacije Ivanić-grad (taložne stijene gornjeg panona), a nalazi se u Bjelovarskoj subdepresiji koja je na jugozapadu Dravske depresije (slika 1). Ovaj marker je prethodno kartiran u više navrata različitim metodama (npr. Malvić, 2003; Malvić, 2011; Špelić et al., 2014).



Slika 1: Zemljopisni položaj Bjelovarske subdepresije (iz Malvić, 2003)


Dravsku depresiju je općenito sačinjena od neogenskih i kvartarnih stijena i naslaga (Malvić and Cvetković, 2013). Debljine naslaga premašuju 7000 m u središnjem dijelu depresije. Uz pojavu sedimentnih stijena, mjestimice se mogu naći pojave efuzivnih stijena srednjomiocenske starosti kao i fluvijalnih i jezerskih sedimenata donjeg miocena. U većini slučajeva neogensko-kvartarna slijed sastoji se od srednjomiocenskih i gornjomiocenskih, pliocenskih te pleistocenskih i holocenskih klastičnih i biogenih sedimenata. Stijene u podini neogensko-kvartarnoga slijeda su bitno drukčijeg litološkog sastava i stratigrafske pripadnosti. Radi se većinom o karbonatima (vapnencima i dolomitima), metamorfitima (amfibolitima, škriljalcima i gnajsevima) i magmatitima (granitima i gabrima) mezozojske i paleozojske starosti. Stijene u podini neogensko-kvartarnoga slijeda nisu litostratigrafski raščlanjene u Hrvatskom dijelu. Litostratigrafska raščlamba Dravske depresije prikazana je na slici 2.



Slika 2: Litostratigrafske jedinice unutar Dravske depresije (Malvić and Cvetković, 2013)

## 2. Metode

Cilj rada je kartiranje dubine EK-markera „Rs5“ metodom umjetnih neuronskih mreža. Kako postupak izradbe algoritma umjetne neuronske mreže i njegovo korištenje zahtijeva „uvježbavanje“ mreže postojećim podacima, korišteni su podaci sadržavali vrijednosti varijabli koordinata  $x$  i  $y$  te vrijednost varijable dubine. Uvježbavanje ili postupak učenja je iterativni postupak predočavanja ulaznih primjera (uzoraka, iskustva) i eventualno očekivana izlaza (Dalbelo-Bašić et al., 2008). Podatci su u pravilnoj mreži, a na slici 3 prikazana je karta s prikazom položaja svih točaka kojima su pridružene vrijednosti dubina na temelju kojih je načinjena karta.



Slika 3: Karta s položajem ulaznih vrijednosti

Prvi korak uspješnog kartiranja algoritmom umjetne neuronske mreže je prikupljanje i priprema ulaznih podataka. U ovom radu su korišteni podatci o koordinatama smjesta te pripadajuća dubina. Budući da je bila nužna obradba podataka za što bolji izlaz, odnosno smanjenje pogreške, početne Gauss-Krügerove koordinate su pretvorene u *relativne* koordinate, čime se nije promijenio prostorni odnos, ali jest numerička vrijednost, dok su vrijednosti dubina logaritmiranjem po bazi 10 numerički umanjene, ali su odnosi ostali isti. Bez dodatnog uređivanja podataka, izlaz kojeg je algoritam dao je bio konstantan za sve vrijednosti ulaznih varijabli te je pogreška bila izuzetno velika.


Nakon uređivanja ulaznog skupa, podijeljen je na skup za uvježbavanje i skupa za provjeru. Skup za uvježbavanje se sastoji od 75 % slučajno odabranih podataka iz ulaznog skupa. Sljedeći korak uključuje optimiziranje parametara neuronske mreže, a parametri podložni optimiranju su broj skrivenih slojeva i broja neurona u njima, vrijednost praga (zadana vrijednost 0,01), maksimalan broj koraka kod uvježbavanja nakon kojeg se zaustavlja postupak uvježbavanja (zadana vrijednost  $1 \times 10^5$ ), broj ponavljanja uvježbavanja mreže, početne vrijednosti težinskih koeficijenata (zadana je slučajna vrijednost), stopa učenja, vrsta algoritma (zadan je algoritam s povratnim postupkom učenja), funkcija pogreške (zadana je suma kvadrata pogreške), aktivacijska funkcija (**Malvić and Cvetković, 2013a**) (zadana je sigmoidalna) i još određen broj dodatnih parametara.

Zatim program ispisuje izlaz neuronske mreže i crta shemu pripadajuće mreže uz prikaz pripadajućih težinskih koeficijenata i pogreške. Ukoliko je optimiranjem parametara pogreška smanjena na minimalnu vrijednost, slijedi korištenje uvježbane mreže na novim podatcima koji će biti ukomponirani u ulazni skup. To je umjetni skup koji se sastoji od  $x$  i  $y$  koordinata iz ulaznog skupa uvećanih za 1 ( $x_i+1$ ,  $y_i+1$ ) da bi se dobio veći broj podataka na karti i bolja razlučivost. Kad su predviđene dubine za koordinate dodatnog skupa, izlaz prvog i drugog skupa se ujedinjuje i slijedi postupak kartiranja, odnosno grafičkog prikaza prostornog razmještaja.

## 2.1. Rezultati i odabir najbolje mreže

Izlaz algoritma daje ukupnu pogrešku predviđanja u iznosu od 0,238 u oko 35000 ponavljanja (iteracija). Takva pogreška je rezultat računanja s *relativnim* iznosima vrijednosti podataka, odnosno s logaritmiranim podatcima. Izlaz algoritma u postupku predviđanja dubina drugog (umjetnog) skupa daje pogrešku u iznosu 0,03178 u oko 40000 ponavljanja. Primjenjujući isti algoritam na skup podataka koji nije prethodno logaritmiran dobije se pogreška u iznosu 84854148,760 u 1616 ponavljanja, te je izlaz konstantna vrijednost za svaki par ulaznih varijabli, što onemogućava interpretaciju. Funkcija pogreške koja se koristi u algoritmu je suma kvadrata pogreške (engl. sum of squared errors). Funkcija pogreške mjeri razliku između predviđene i promatrane vrijednosti izlaza, a proces se zaustavlja kad je vrijednost svih parcijalnih derivacija funkcija pogreške po težinskim koeficijentima ( $\partial E/\partial w$ ) manja od zadanog praga (**Günther & Fritsch, 2010**). Najbolja mreža je odabrana s obzirom na najmanju pogrešku koju daje, a to je dobiveno u slučaju mreže s dva skrivena sloja gdje se u prvom sloju nalazi 10, a u drugom 6 neurona. Na **slici 4** se nalazi karta dobivena pomoću izlaznih vrijednosti algoritma neuronske mreže.

Vrijednost najpreciznijeg podatka dobivenog algoritmom neuronske mreže iznosi 2089,336 m, umjesto 900 m na lokaciji X=6431993, Y=5059986. Najpodcjenjeniji podatak je na lokaciji X=6429993, Y=5081986 sa vrijednosti 2086,28 m umjesto 3060 m.




Slika 4: Karta dubina EK markera „Rs5“ dobivena algoritmom neuronskih mreža

## 2.2. Interpolacija običnim krigiranjem

Geostatistička interpolacija je izvršena običnim krigiranjem te variogramskom analizom koja je prethodila interpolaciji. Brojne interpolacije krigiranjem su obavljene u zadnjem desetljeću u Hrvatskom dijelu Panonskom bazenskom sustavu, a neke od relevantnih za Dravsku depresiju su karte šupljikavosti u polju Beničanci, u istočnom dijelu Depresije, a napravljene su kartiranjem inverznom udaljenošću te krigiranjem (Malvić, 2008; Malvić and Đureković, 2003), a u Savskoj depresiji su karte šupljikavosti izrađene u polju Ivanić (Malvić, 2008a) te polju Kloštar (Balić et al., 2008). U izradi karte su kao ulazne vrijednosti uzete koordinate EK markera Rs5 ( $x$  i  $y$ ) te podatci o dubini. Vrijednost variograma je također jedan od bitnih podataka za izradbu karte metodom krigiranja. Kao relevantna metoda izabrana je metoda običnog krigiranja. Načinjena karta je prikazana na slici 5, a metodom kros-validacije (npr. Davis, 1987) dobivene su vrijednosti kvadratne pogreške procjene te najprecijenjeniji i najpodcjenjeniji podatci. Vrijednost kvadratne pogreške procjene iznosi 14638,35. Najprecijenjeniji podatak je dubina s vrijednošću 900 m, koja je procijenjena na 2161,50 m, a nalazi se na koordinatama  $X=6431993$  te  $Y=5059986$ . Najpodcjenjeniji podatak je podatak na  $X=6429993$  i  $Y=5081986$ . Umjesto 3060 m predviđeno je 2271,39 m.

Za usporedbu, kvadratna pogreška procjene kod kartiranja metodom umjetnih neuronskih mreža iznosi 16742,5. Ova usporedba pokazuje ipak nešto točniju procjenu i točniji prikaz karte dobivene običnim krigiranjem.



Slika 5: Karta EK markera „Rs5“ dobivena metodom običnog krigiranja

#### 4. Diskusija i zaključci

U ovom radu su dani prikazi rezultata uspješnog kartiranja geoloških varijabli, u ovom slučaju dubine EK markera, metodom umjetnih neuronskih mreža. Najbolji rezultati su dobiveni mrežom takve arhitekture da sadrži četiri sloja, po jedan ulazni i izlazni te dva skrivena sloja između njih. Prvi skriveni sloj je imao 10 neurona, a drugi 6 neurona. Korišten je višeslojni perceptron sa svim neuronima međusobno povezanim, a algoritam kojim su dobiveni najbolji rezultati je bio algoritam s povratnim postupkom. Značajan rezultat ovog istraživanja je i dobivena jednačba kojom se može urediti ulazni skup podataka koji se sastoji od varijabli koje imaju preveliku vrijednost te kompliciraju rad mreže koja naposljetku daje izlaz koji značajno odstupa od željenog. To je dobiveno logaritmiranjem vrijednosti dubina, koje su imale raspon od 260 do 3140, ali i pretvaranjem vrijednosti koordinata  $x$  i  $y$  u *relativne* koordinate čime se smanjila pogreška te je dobiven bolji izlaz. Prepoznat je problem veće pogreške u odnosu na krigiranje, a to je nemogućnost prilagodbe mreže na velike razlike u vrijednostima dubina na relativno maloj horizontalnoj udaljenosti (nekoliko metara). U slučaju uporabe kod podataka obilježenih linearnom međuzavisnošću neuronske mreže mogu se i trebaju usporediti s drugim često uspješnim linearnim metodama kartiranja. Najpoznatija među njima je krigiranje. Tada u odnosu na klasične geostatističke interpolacijske metode, primjerice tehniku običnog krigiranja, metoda umjetnih neuronskih mreža daje iznimno dobre i kvalitetne rezultate.

#### 6. Popis literature

- Balić, D., Velić, J. and Malvić, T. (2008): Selection of the most appropriate interpolation method for sandstone reservoirs in the Kloštar oil and gas field. *Geologia Croatica*. 61, 1, 27-35.
- Dalbelo-Bašić, B., Čupić, M. and Šnajder, J. (2008): Umjetne neuronske mreže. Nastavni materijali za kolegij Umjetna inteligencija, Fakultet elektrotehnike i računalstva Zagreb, 2008.
- Davis, B (1987): Uses and Abuses of Cross Validation in Geostatistic. *Mathematical Geology*, 19, 3, 241-248.
- Günther, F., Fritsch, S. (2010): Neuralnet: Training of neural networks. *The R Journal*. 2, 1, 30-38.
- Malvić, T. (2003): Naftnogeološki odnosi i vjerojatnost pronalaska ugljikovodika u Bjelovarskoj uleknini (Doktorska disertacija), Zagreb, 156 str.

- Malvić, T., Đureković, M. (2003). Application of methods: Inverse distance weighting, ordinary kriging and collocated cokriging in porosity evaluation, and comparison of results on the Beničanci and Stari Gradac fields in Croatia. *Nafta*. 54, 9, 331-340.
- Malvić, T. (2008). Kriging, cokriging or stohastical simulations, and the choice between deterministic or sequential approaches. *Geologia Croatica*. 61, 1, 37-47.
- Malvić, T. (2008a): Izrada karte poroznosti krigranjem u pješčenjačkim ležištima, primjer iz Savske depresije (Production of a Porosity Map by Kriging in Sandstone Reservoirs, Case study from the Sava Depression). *Kartografija i geoinformacije*, 7, 9, 12-19.
- Malvić, T. (2011): Geological maps of Neogene sediments in the Bjelovar Subdepression (northern Croatia). *Journal of Maps*, 2011, str. 304-317.
- Malvić, T., Cvetković, M. (2013): Lithostratigraphic units in the Drava Depression (Croatian and Hungarian parts) - a correlation / Korelacija litostratigrafskih jedinica u Dravskoj depresiji (hrvatski i mađarski dio). *Nafta*. 64 (1), 27-33.
- Malvić, T., Cvetković, M. (2013a): Neuronski alati u geologiji ležišta ugljikovodika, II. Izdanje (Neural tool in geology of hydrocarbon reservoirs, 2nd issue). Hrvatsko geološko društvo (Geomat. odsjek), Sveučilište u Zagrebu (RGN fakultet), sveučilišni priručnik, Zagreb.
- Špelić, M., Malvić, T., Saraf, V. and Zalović, M. (2014): Remapping of depth of e-log markers between Neogene basement and Lower/Upper Pannonian border in the Bjelovar Subdepression, *Journal of Maps*, DOI: 10.1080/17445647.2014.978909

## Abstract in English

### Application of artificial neural networks in mapping of hydrocarbon reservoirs, an example on e-log border Rs5 in Bjelovar subdepression

The results of successful application of artificial neural networks in mapping of hydrocarbon reservoirs are presented in this paper. The mapped variable was depth, and it was mapped in regard of two input variables, coordinates  $x$  and  $y$ . The mapped area was the e-log border in the Bjelovar Subdepression which is part of the Drava Depression in the Croatian part of the Pannonian Basin System. The algorithm of the network is made in the statistical computing software „R“, and the network architecture which gave the best results, i.e. with the lowest error, was the one with four layers, one input layer, one output layer and two hidden layers inbetween with 10 and 6 neurons, respectively. Backpropagation algorithm was used. The final quality of the results and of the map were statistically analyzed and compared with other commonly used mapping method, such as Ordinary Kriging. The comparison was made using cross-validation.

### Key words

Artificial neural networks, Bjelovar Subdepression, cross-validation, geomathematics, mapping.