

Barbara Darlak, Małgorzata Kowalska-Włodarczyk

Instytut Nafty i Gazu, Kraków

Zastosowanie logiki rozmytej w budowie modeli geologicznych

Przedstawiona praca jest kontynuacją próby wprowadzenia metody logiki rozmytej do rutynowych modelowań geologicznych. Wykorzystując dane laboratoryjne i otworowe uzupełniano z jej pomocą brakujące fragmenty profilowań petrofizycznych i geofizycznych. Metoda ta pozwoliła także prognozować całe brakujące profile na podstawie zestawu innych danych, ponieważ nie wymaga ona nauczyciela, czyli zbioru uczącego, opiera się natomiast na poprawnie sformułowanych regułach wnioskowania, co w modelowaniach geologicznych daje jej przewagę nad sieciami neuronowymi.

An application of fuzzy logic in evaluation of geological models

This paper presents a possibilities of fuzzy logic application in geological model evaluation. Two potential fields of activity was showed. The first is to complete petrophysical and well log database. The second, more ambitious is estimation of petrophysical parameters in no data wells. It is possible because of depending of fuzzy logic on inference rules not on teaching files. It is the main advantage of fuzzy logic over ANN extrapolation method.

Wstęp

Przedstawiona praca jest kontynuacją prac nad zastosowaniem logiki rozmytej przy tworzeniu modeli geologicznych. Logika rozmyta (*fuzzy logic*) [12] stosowana jest w wielu dziedzinach nauki, a ostatnio coraz częściej w zagadnieniach geologicznych. W poprzedniej pracy [2] została omówiona teoria logiki rozmytej i próba wykorzystania jej do interpretacji parametrów petrofizycznych. Kolejny krok został wykonany w kierunku zastosowania tej metody w szerszym kontekście. Obok danych labora-

toryjnych wykorzystano dane geofizyczne i zastosowano analizę skupień rozmytych [3, 4, 5]. W efekcie kolejnych etapów rozmytego procesu uzyskano kompletne zbiory podstawowych parametrów zbiornikowych skał (porowatości i przepuszczalności). Należy zaznaczyć, że metoda logiki rozmytej nie wymaga nauczyciela, czyli zbioru uczącego. Opiera się natomiast na poprawnie sformułowanych regułach wnioskowania, co w pewnym zakresie może dać jej przewagę nad sieciami neuronowymi.

Przygotowanie materiału doświadczalnego do badań

W badaniach wykorzystano wyniki analiz wykonanych na jurajskich skałach węglanowych i piaskowcach ciężkowickich. Istotnym było przetestowanie poprawności metody na tak różnym materiale skalnym. Wykorzystano wyniki analizy porozymetrycznej oraz parametrów geofizycznych. Sporządzono podstawową bazę danych, którą zweryfikowano i uzupełniono za pomocą sieci

neuronowej, co w efekcie pozwoliło ustalić podstawowy zbiór obliczeniowy, do którego ostatecznie weszły takie parametry petrofizyczne jak: średnica progowa, powierzchnia właściwa, gęstość objętościowa i szkieleto-towa, średnia kapilara, porowatość oraz impedancja. Na tak przygotowanej bazie danych wykonano obliczenia metodą logiki rozmytej.

Zastosowanie logiki rozmytej do obliczeń

Teoria skupień rozmytych

W metodzie *fuzzy logic* istotną rolę odgrywa analiza skupień rozmytych, która znacznie różni się od klasycznej

analizy skupień. W teorii klasycznej ze zbioru głównego zostają wydzielone podzbiory, na zasadzie bliskiego pokrewieństwa takich cech, że każdy element danego podzbioru nie występuje w innych podzbiórach, innymi słowy

granice podzbiorów są ostro zdefiniowane – co oznacza, że przynależność do podzbioru wynosi 0 lub 1.

W logice rozmytej przynależność do zbioru określają reguły rozmyte; w analizie skupień rozmytych podzbiory częściowo się przenikają, granice między nimi są niewyraźne, a dana składowa podzbioru może występować także w innych podzbiorach. Teoria, którą w skrócie przedstawiono poniżej, została opracowana przez Bezdeka [1].

Gdy mamy zbiór $Y = (y_1, y_2, \dots, y_n)$ fuzji-skupienia przypisują każdą daną y_1 do podzbioru k ze stopniem przynależności $\mu_k(y_i)$ dla wszystkich k i l . Gdy $\mu_k(y_i) = 1$, dana y_1 całkowicie należy do podzbioru k . Kiedy zachodzi zależność $0 < \mu_k(y_i) < 1$ to y_1 częściowo należy do podzbioru k , ale równie dobrze należy do innych podzbiorów, a gdy $\mu_k(y_i) = 0$ to y_1 definitywnie nie należy do podzbioru k . Powyższe można przedstawić w zapisie:

$$\sum_{k=1}^c \mu_k(y_i) = 1 \text{ dla } 1 \leq i \leq n$$

$$0 < \sum_{k=1}^c \mu_k(y_i) \leq n \text{ dla } 1 \leq i \leq n$$
(1)

Zagadnienie tego typu rozwiązuje się na drodze procedur iteracyjnych, w celu otrzymania przybliżonych rozwiązań.

Algorytm dla skupień rozmytych ma za zadanie znaleźć wszystkie stopnie przynależności $\mu_k(y_i)$, które minimalizują sumę odchyżeń danej y_1 od centrum skupienia V_k , będącego średnią ze wszystkich danych w podzbiorze k . Funkcja minimalizacji wygląda następująco:

$$Z = \sum_{k=1}^c \sum_{i=1}^n [\mu_k(y_i)]^m = d_k$$
(2)

gdzie $d_{ik} = |y_i - V_k|$ – jest odpowiednio dobraną fuzji-normą [11]. Wykładnik m ma wpływ na przypisanie danych poszczególnym skupieniom i przeważnie $m = 2$.

Optymalna ilość podzbiorów, oznaczona $T(c)$, definiowana jest wzorem:

$$T(c) = \sum_{k=1}^c \sum_{i=1}^n [\mu_k(y_i)]^m \times (d_k - d_{k+1})$$
(3)


gdzie d_k – jest wybraną fuzji-normą obrazującą odległość centrum k -tego podzbioru do centrum zbioru głównego

$$d_k = \left[V_k - \frac{1}{n} \sum_{i=1}^n y_i \right]^m$$
(4)


Jak wynika z powyższego, liczba podzbiorów jest optymalna kiedy różnice wewnątrz podzbioru są małe, a różnice między podzbiorem są duże. Innymi słowy optymalne wyniki otrzymuje się, gdy można dobrać takie funkcje, które maksymalizują podobieństwo wewnątrz skupień, a minimalizują podobieństwo pomiędzy skupieniami.

Wykonanie obliczeń

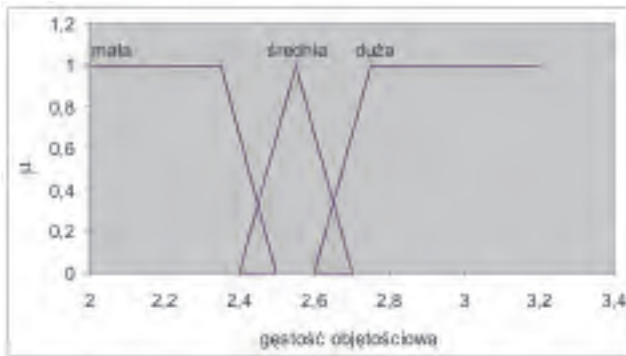
W zadaniu do symulacji użyto zbiorów zawierające parametry przestrzeni porowej: średnicę progową, powierzchnię właściwą i gęstość objętościową oraz impedancję, czyli wielkości, od których współzależny porowatość i przepuszczalność, i na tej podstawie próbowano odtworzyć podstawowe parametry złożowe. Obliczenia wykonano dla dwóch typów skał: węglanowej i piaskowca. Na zbiorach wykonano operację grupowania rozmytego, czego wynikiem są podzbiory rozmyte. Zgodnie z założeniami metody logiki rozmytej, kolejnym przedziałom przypisano atrybuty lingwistyczne, co przedstawiono graficznie w układzie współrzędnych, gdzie na osi rzędnych znajduje się stopień przynależności μ (rysunki 1-7). Znajdujemy tam przyporządkowanie do poszczególnych podzbiorów, opisanych określeniami lingwistycznymi.




Rys. 1. Zgrupowanie lingwistyczne dla średnicy progowej



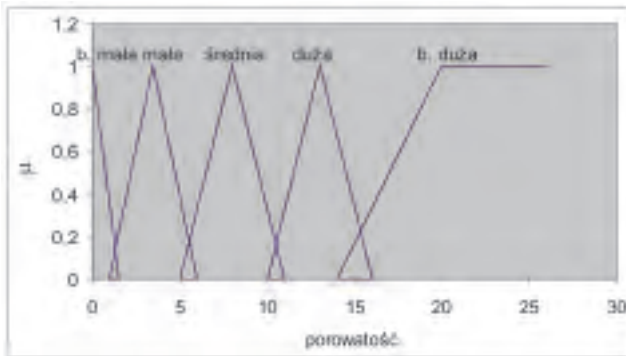
Rys. 2. Zgrupowanie lingwistyczne dla powierzchni właściwej



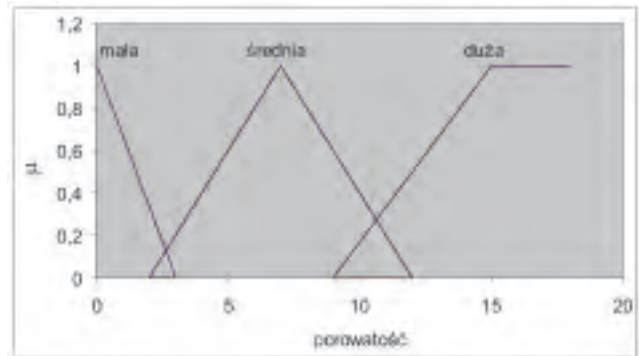
Rys. 3. Zgrupowanie lingwistyczne dla gęstości objętościowej



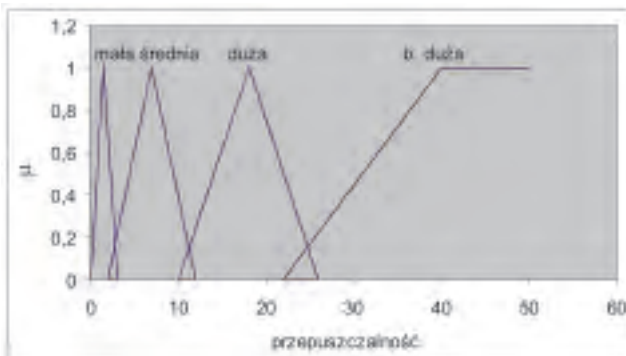
Rys. 4. Zgrupowanie lingwistyczne dla impedancji



Rys. 5. Zgrupowanie lingwistyczne dla porowatości (5 podzbiorów)



Rys. 6. Zgrupowanie lingwistyczne dla porowatości (3 podzbiory)



Rys. 7. Zgrupowanie lingwistyczne dla przepuszczalności

Dla porowatości zastosowano dwa wydzielenia:

- 5 podzbiorów rozmytych: bardzo mała, mała, średnia, duża i bardzo duża,
- 3 podzbiory rozmyte: mała, średnia, duża.

Poniżej przedstawiono granice podzbiorów rozmytych, wytypowanych metodą fuzji-skupień do dalszych obliczeń:

- porowatość (5): 0-1,5; 1-6; 5-11; 10-16; powyżej 14,
- porowatość (3): 0-3; 2-12; powyżej 9,
- przepuszczalność: 1-3; 2-12; 10-26; powyżej 22,
- impedancja: 0-13 x 10³; 12-16 x 10³; > od 15 x 10³,
- średnica progowa: 0-2; 1-9; > od 7,
- powierzchnia właściwa: 0-0,25; 0,1-0,7; > od 0,5,
- gęstość objętościowa: 0-2,5; 2,4-2,7; > od 2,6.

Rozmyty system wnioskujący

Rozmyty system wnioskujący przebiega według określonego porządku: BLOK ROZMYWANIA – BLOK WNISKOWANIA (Z BAZĄ REGUŁ) – BLOK WYOSTRZANIA.

Blok rozmywania to działanie, które za pomocą stosownych norm rozmytych powoduje przekształcanie zbiorów tradycyjnych w zbiory rozmyte, w postaci zbioru stopni przynależności.

W bloku wnioskowania pod działaniem wybranych norm rozmytych, posługując się regułą „JEŻELI ... TO”, uzyskuje się logiczne powiązania pomiędzy elementami zbiorów.

Ostatni blok defuzyfikacji (czyli wyostrzania) to taki, w którym zbiory rozmyte przechodzą określone procesy odwzorowania, pozwalające na wyjściu uzyskać ostre wartości.

Rozmywanie

Na zbiorze danych wykonano stosowne przekształcenia w celu uzyskania podzbiorów rozmytych i wyznaczono ich granice. Dla każdego parametru obliczono wielkość zwaną stopniem (funkcją) przynależności [7, 10]. Należy przypomnieć, że zbiorem rozmytym A w pewnej przestrzeni X ($A \subseteq X$) nazywamy zbiór par

$$A = x, \mu_A(x); \quad x \in X$$

w którym $\mu_A: X \rightarrow [0,1]$

jest funkcją przynależności zbioru rozmytego A . Funkcja ta każdemu elementowi $x \in X$ przypisuje jego stopień przynależności do zbioru rozmytego A , przy czym należy wyróżnić trzy przypadki:

- 1) $\mu_A(x) = 1$ oznacza pełną przynależność elementu x do zbioru rozmytego A ,
- 2) $\mu_A(x) = 0$ oznacza brak przynależności elementu x do zbioru rozmytego A ,
- 3) $0 < \mu_A(x) < 1$ oznacza częściową przynależność do zbioru rozmytego A .

Jeżeli X jest przestrzenią o skończonej liczbie elementów, $X = \{x_1, \dots, x_n\}$, to zbiór rozmyty zapisuje się w postaci

$$A = \sum_{i=1}^n \frac{\mu_A(x_i)}{x_i} \quad (5)$$

Gdy zbiór jest o nieskończonej liczbie elementów, znak sumy zastępuje całka

$$A = \int \frac{\mu_A(x)}{x} \quad (6)$$

Jak wspomniano wyżej, w warunkach zbiorów rozmytych elementy mogą zostać przypisane różnym podzbiорom równocześnie. Każda konkretna wartość sygnału wejściowego $x' = [x'_1, x'_2, \dots, x'_n]^T$ należąca do X zostaje w bloku rozmywania poddana operacji rozmywania, skutkiem czego zostaje odwzorowana w zbiór rozmyty. W praktyce wykonuje się rozmywanie zbiorów poprzez znalezienie stopnia przynależności $\mu_{A'}(x)$, gdzie:

$$\mu_{A'}(x) = \delta(x - x') \text{ jest } 1 \\ \text{jeżeli } x = x', \text{ jest } 0 \text{ jeżeli } x \neq x'$$

Wnioskowanie

W literaturze można znaleźć wiele reguł wnioskowania dla modelu logicznego z wykorzystaniem implikacji rozmytej. Poniżej zasygnalizowano najczęściej stosowane. Są nimi reguły wnioskowania *modus ponens* i *modus tollens*; równie często stosowana jest reguła typu *minimum* i reguła typu *iloczynu* dla modelu Mandaniego [8, 9].

Lingwistyczne reguły wnioskowania logiki rozmytej dla omawianych przypadków dobierane są stosownie do zagadnienia.

W wykonywanej pracy zbiory wejściowe zawierają w sobie podzbiory, których parametry są wzajemnie

zależne. Podzbiory wejściowe to: średnica progowa X_1 , powierzchnia właściwa X_2 , gęstość objętościowa X_3 , i impedancja X_4 . Na wyjściu uzyskujemy porowatość Y_1 i przepuszczalność Y_2 .

Z dotychczasowych badań i stosownej teorii wiadomo, w jakim stopniu parametry tych podzbiорów wzajemnie od siebie zależą [6]. Zastosowanie odpowiednich norm rozmytych dało zależności w postaci reguł: „JEŻELI ... TO”. Ogólnie można to zapisać:

$$\text{JEŻELI: } x_1 \text{ jest } A_1^k \text{ I } x_2 \text{ jest } A_2^k \text{ I } x_n \text{ jest } A_n^k$$

$$\text{TO: } x_1 \text{ jest } B_1^k \text{ I } x_2 \text{ jest } B_2^k \text{ I } x_n \text{ jest } B_n^k$$

dla $k = 1, 2, \dots, N$, gdzie N – jest liczbą reguł, A_i^k – to zbiory rozmyte.

W szczególnej sytuacji zilustruje to następujący przykład:

Rzeczywisty zbiór parametrów petrofizycznych (średnica progowa, powierzchnia właściwa, gęstość objętościowa) wprowadzono do bloku rozmywania. W efekcie uzyskano zbiory rozmyte odpowiednich wielkości fizycznych, zgodnie z regułami przyporządkowania według kwalifikacji lingwistycznej: wielkość mała, średnia i duża. Zbiory te w bloku wnioskowania zostały przyporządkowane odpowiednim zbiorom rozmytym oczekiwany na wyjściu, a mianowicie porowatości, poprzez funkcję przynależności.

1. JEŻELI x_1 jest duże, x_2 jest małe, x_3 jest małe
TO y_1 jest duża.
2. JEŻELI x_1 jest duże, x_2 jest średnie, x_3 jest średnie
TO y_1 jest duża.
3. JEŻELI x_1 jest średnie, x_2 jest małe, x_3 jest średnie
TO y_1 jest średnia.
4. JEŻELI x_1 jest średnie, x_2 jest średnie, x_3 jest średnie
TO y_1 jest średnia.
5. JEŻELI x_1 jest średnie, x_2 jest duże, x_3 jest małe
TO y_1 jest średnia.
6. JEŻELI x_1 jest średnie, jest duże x_2 , x_3 jest duże
TO y_1 jest mała.
7. JEŻELI x_1 jest małe x_2 jest średnie, x_3 jest średnie
TO y_1 jest mała.

gdzie:

x_1 – średnica progowa,

x_2 – gęstość,

x_3 – powierzchnia właściwa,

y_1 – porowatość jest elementem zbiorów rozmytych X_1 , X_2 , X_3 i Y_1 .

Na wyjściu uzyskujemy zbiór rozmyty, w którym każdej wartości rozmytej przypisany jest stopień przynależności.

Wyostrzanie

W ten sposób zostały określone podzbiory i przypisane im funkcje przynależności.

Kolejnym etapem jest wyostrzanie (*defuzzification*). Zbiór rozmyty, jeden lub wiele, podany z bloku wnioskowania przechodzi pewien proces odwzorowania, polegający na wyostrzaniu, aby na wyjściu otrzymać jedną wartość. Jeżeli mamy N zbiorów rozmytych \bar{B} (pojedynczy zbiór oznaczymy B^*), wychodzących z bloku wnioskowania z funkcjami przynależności $\mu_{B^k}(y)$ $k = 1, 2, \dots, N$ i wprowadzamy je do bloku wyostrzania, to na wyjściu otrzymujemy wartość ostrą $\bar{y} \in T$, którą możemy obliczyć za pomocą odpowiedniego wzoru.

Najczęściej stosowane metody wyostrzania to:

1. Metoda środka ciężkości (COA – *Center of Area*) [7]. Definiuje ona wyostrzoną wartość \bar{y} rozmytego zbioru B w przestrzeni $Y \subset R$

$$\bar{y} = \frac{\int_{Y} y \cdot \mu_B(y) dy}{\int_{Y} \mu_B(y) dy}$$

Powyżej przedstawiono metodę postępowania przy stosowaniu logiki rozmytej. Obecnie zostaną zaprezentowane konkretne przykłady wykonane w tym opracowaniu.

Jak już wspomniano wcześniej, celem pracy było zastosowanie logiki rozmytej, która obok sieci neuronowej mogłaby być skuteczną metodą w weryfikacji i odtwarzaniu brakujących danych. Główny nacisk położono na parametry zbiornikowe: porowatość i przepuszczalność. Pierwszym zadaniem było ustalenie optymalnych warunków obliczeń. Za pomocą sieci neuronowej i podstawowych metod statystycznych wygenerowano zbiór rzeczywisty, w skład którego wchodziły: średnica progowa, powierzchnia właściwa i gęstość objętościowa oraz porowatość (jako zbiór testowy).

Zbiór ten poddano analizie skupień rozmytych i na tej podstawie zdefiniowano rozmyte granice zgrupowań lingwistycznych wielkości małej, średniej i dużej:

- impedancja: 0-13 x 10³; 12-16 x 10³; większe od 15 x 10³,
- średnica progowa: 0-2; 1-9; większe od 7,

W przypadku, gdy przestrzeń Y jest skończona; $Y = (y_1, y_2, \dots, y_n)$, równanie powyższe przyjmuje postać sum:

$$\bar{y} = \frac{\sum_{i=1}^n y_i \cdot \mu_B(y_i)}{\sum_{i=1}^n \mu_B(y_i)}$$

2. Metoda maksimum funkcji przynależności (MOM – *Mean of Maxima*) [7].

Ta metoda wyznacza wyostrzoną wartość \bar{y} jako podstawową z całej dyskutowanej przestrzeni Y , posiadającą maksymalny stopień przynależności, i wyraża się równaniem:

$$\bar{y} = \frac{1}{T} \sum_{y_i \in T} y_i$$

gdzie T – reprezentuje podzbiór z przestrzeni Y , która osiąga maksimum wartości, gdy $\mu_B(y_i) = 1$ oraz gdy t należy do T .

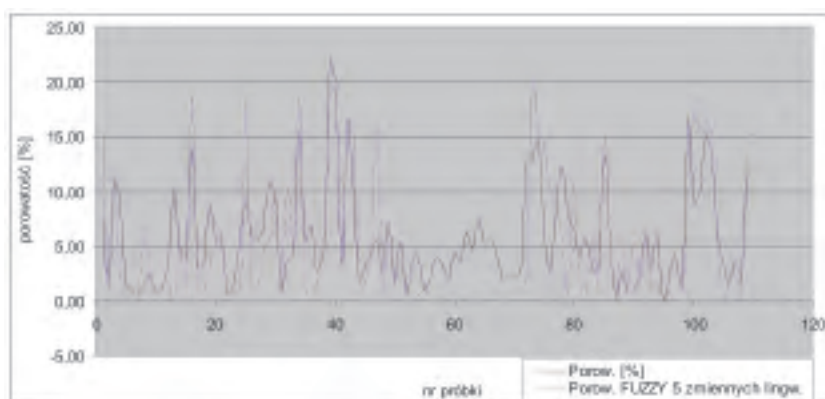
W przedstawionej pracy rozwiązaniem było uzyskanie zbiorów rzeczywistych porowatości i przepuszczalności. Wyniki i ich omówienie przedstawiono w dalszej części pracy.

Wyniki


- powierzchnia właściwa: 0-0,25; 0,1-0,7; większe od 0,5,
 - gęstość objętościowa: 0-2,5; 2,4-2,7; większe od 2,6.
- Ustalono także lingwistyczny model dla porowatości, jako zbioru wyjściowego, w dwóch wariantach:
- 5 podzbiorów rozmytych: bardzo mała, mała, średnia, duża i bardzo duża, porowatość (5): 0-1,5; 1-6; 5-11; 10-16; powyżej 14,
 - 3 podzbiory rozmyte: mała, średnia, duża, porowatość (3): 0-3; 2-12; powyżej 9.

Na rysunkach 1-7 przedstawiono wykonane wydzielenia.


Ten etap obliczeń jest istotny, gdyż jego następstwem jest poprawne przypisanie stopni przynależności poszczególnym rozmytym elementom. Następnie wykonano obliczenia, w wyniku których otrzymano na wyjściu dwa zbiory porowatości, opisane: porowatość FUZZY 5 i 3. Wyniki przedstawiono na rysunkach 8 i 9, w zestawieniu z porowatością doświadczalną. Współczynnik korelacji wyniósł odpowiednio 0,75 i 0,76. Wynik jest wystarczająco dobry, a zachowanie trendów na tyle poprawne, by uznać metodę za wiarygodną, choć ma niższą wydajność



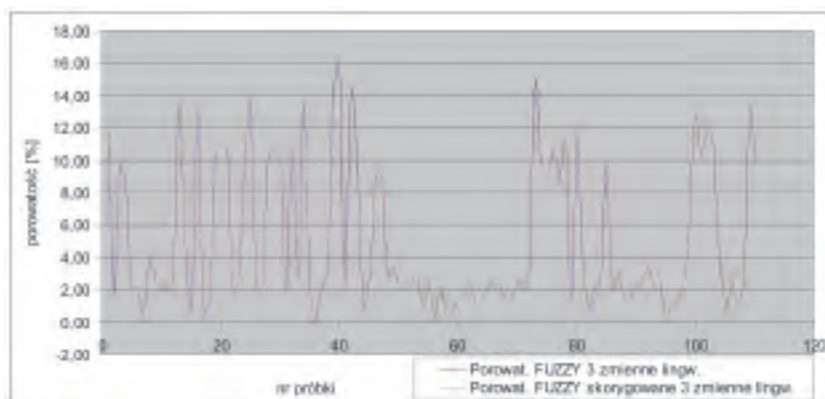
Rys. 8. Zestawienie porowatości doświadczalnej z obliczoną metodą FUZZY dla 5-ciu zmiennych lingwistycznych dla skał węglanowych



Rys. 9. Zestawienie porowatości doświadczalnej z obliczoną metodą FUZZY dla 3-ch zmiennych lingwistycznych dla skał węglanowych




Rys. 10. Zestawienie porowatości obliczonej metodą FUZZY dla 3-ch i 5-ciu zmiennych lingwistycznych z porowatością ANN dla skał węglanowych



Rys. 11. Porównanie porowatości obliczonej metodą FUZZY dla 3-ch zmiennych lingwistycznych z uwzględnieniem impedancji dla skał węglanowych

niż sieć neuronowa (rysunek 10). Zaletą metody FUZZY jest to, że nie wymaga ona nauczyciela. Ponieważ skuteczność obu przetestowanych wydzieleń była prawie jednakowa, do dalszych symulacji stosowano model lingwistyczny z trzema podzbiorami.

Kolejnym krokiem było wprowadzenie dodatkowego parametru, tj. impedancji, gdyż jest to wielkość silnie związana z porowatością. Spodziewano się zwiększenia korelacji danych obliczonych z doświadczalnymi. Wynik przedstawiono na rysunku 11, gdzie można zauważyć,



Rys. 12. Zestawienie przepuszczalności doświadczalnej z obliczoną metodą FUZZY oraz ANN dla skał węglanowych

że wpływ tego parametru na poprawienie wyników był niewielki – co można skomentować, że w ujęciu logiki rozmytej parametr ten wywiera równie cenny wpływ na porowatość, jak i na pozostałe parametry. Drugim istotnym parametrem zbiornikowym jest przepuszczalność efektywna. Jej oznaczenie jest często niewykonalne ze względu na trudności w obróbce rdzeni do pomiarów. Dlatego właśnie znalezienie metody jej oznaczenia jest tak ważnym zagadnieniem. W dotychczasowych pracach stosowano do tego sieci neuronowe. W tej pracy po raz pierwszy wykorzystano metodę logiki rozmytej. Obliczenia wykonano dla dwóch typów skał: dla skał wapiennych i dla piaskowca.

Wyniki obliczeń przedstawiono na rysunkach 12 i 13. Zestawiono tam wyniki uzyskane metodą FUZZY i me-

todą ANN, z przepuszczalnością efektywną uzyskaną doświadczalnie.

W obu przypadkach dane wyliczone odwzorowują trendy rzeczywiste. Można natomiast zauważyć, że dla piaskowców odwzorowanie to jest znacznie lepsze: współczynnik korelacji dla wapieni $k = 0,62$, a dla piaskowców $0,69$. Odwrotnie jest w przypadku sieci neuronowych (dla wapieni aż $0,95$ a dla piaskowców już tylko $0,74$). Porównanie metod przedstawiono w tabelicy 1.

Tabela 1. Zestawienie współczynników korelacji

Przepuszczalność piaskowców		Przepuszczalność skał węglanowych	
ANN	FUZZY	ANN	FUZZY
0,74	0,69	0,95	0,62

Podsumowanie

1. Do wyznaczenia parametrów zbiornikowych porowatości i przepuszczalności zastosowano nową metodę symulacji, opartą na logice rozmytej. Otrzymane wyniki pokazują, że metoda ta jest skuteczna. Reaguje na zmiany właściwości materii skalnej i choć obraz tych zmian jest spłaszczony, na jej podstawie można wyznaczyć poziomy całkowicie nieprzepuszczalne oraz te o podwyższonej przepuszczalności. Odwzorowuje ona również poprawnie trendy rozwoju przestrzeni porowych skał (współczynniki korelacji są istotne).
2. Analiza wyników otrzymanych dla piaskowców i wapieni potwierdza zasadność i wrażliwość metody dla tego typu problemów. Jakość dopasowania zależy

w sposób jednoznaczny od przyjętych definicji granic (przyjęto takie same dla piaskowców i wapieni). ANN reaguje na jakość zbiorów wejściowych, stąd lepsze dopasowanie tą metodą dla wapieni, natomiast jednakowy podział zbiorów rozmytych nie uwzględnia jedynie specyfiki skał węglanowych.

3. Jakość dopasowania dla logiki rozmytej zależy jednoznacznie od poprawnego przyjęcia podziału poszczególnych zbiorów (choćby na podstawie analizy właściwości skał tego samego typu w badanym rejonie).
4. Wydaje się, że przy wejściu na nowy teren metoda ta będzie niezastąpiona, nie wymaga ona bowiem zbioru uczącego.

Recenzent: prof. dr hab. inż. Andrzej Kostecki

Literatura

- [1] Bezdek J.C.: *Pattern recognition with fuzzy objective function algorithms*. Plenum, New York 1981.
- [2] Darlak B., Włodarczyk M.: *Próba zastosowania logiki rozmytej do interpretacji parametrów petrofizycznych skal zbiornikowych*. Nafta-Gaz Nr 5, s. 305-413, 2007.
- [3] Finol J., et al.: *A rule based fuzzy model for the prediction of petrophysical rock parameters*. Journal of Petroleum Science and Engineering, vol. 29, Issue 2, p. 97-113, 2001.
- [4] Finol J., Xu-Dong Jing: *Permeability prediction in shaly formations: the fuzzy modeling approach*. Geophysics 67, Issue 3, p. 817-829, 2002.
- [5] Finol J., Xu-Dong Jing: *Predicting Petrophysical parameters in a fuzzy environment*. Soft computing for reservoir characterization and modeling. Physica-Verlag, 80, p. 183-218, 2002.
- [6] Jong-Se Lim: *Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea*. Journal of Petroleum Science and Engineering, vol. 49, Issue 3-4, p. 182-192, 2005.
- [7] Łęski J.: *Systemy neuronowo rozmyte*. Wydawnictwo Naukowo-Techniczne, 2008.
- [8] Piegat A.: *Modelowanie i sterowanie rozmyte*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999.
- [9] Piegat A.: *Fuzzy modeling and control*. ISBN 3-7908, p. 1385-1390, 2001.
- [10] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, 1997.
- [11] Rutkowski L.: *Filtry adaptacyjne i adaptacyjne przetwarzanie sygnałów*. Wydawnictwo Naukowo-Techniczne, Warszawa 1994.
- [12] Zadeh L.A.: *Fuzzy sets*. Information and Control, p. 338-353, 1965.



Mgr Barbara DARLAK – absolwentka Wydziału Chemii na Uniwersytecie Jagiellońskim w Krakowie. Od 1979 roku jest pracownikiem Instytutu Nafty i Gazu w Krakowie, w Zakładzie Geologii i Geochemii, Laboratorium Petrofizyki, na stanowisku starszy specjalista badawczo-techniczny. Zajmuje się wykorzystaniem sieci neuronowych w zagadnieniach geologicznych.



Mgr inż. Małgorzata KOWALSKA-WŁODARCZYK – absolwentka Wydziału Energochemiczne Przetwórstwo Węgla i Fizykochemii Sorbentów AGH w Krakowie. Pracownik INiG w Krakowie, w Zakładzie Geologii i Geochemii, Laboratorium Petrofizyki, na stanowisku starszy specjalista badawczo-techniczny. Zajmuje się wykorzystaniem sieci neuronowych w zagadnieniach geologicznych.

INiG
INSTYTUT NAFTY I GAZU

ZAKŁAD GEOLOGII I GEOCHEMII

Kierownik: dr inż. Grzegorz Leśniak
31-503 Kraków, ul. Łubicz 25 A, tel.: +48 012 421 00 33 www: 262

Oferta

OFERUJEMY:

- Badania mediów złożowych (skala macierzysta, ropa naftowa, solenki, analiza gazów), ocenę systemów naftowych, określenie dróg migracji węglowodorów, akumulacji i napełniania pułapek
- Wykonanie genetycznej korelacji płynów złożowych i skal macierzystych (analiza biomarkerów GC/MS i GC/MS/MS)
- Modelowanie generacji i ekspansji węglowodorów (Genex, PetroMod)
- Analizę przestrzeni porowej (skaly zbiorcze, skaly uszczelniające, model sieciowy, przepuszczalność szczelinowa). Analizy regionalne i zbiornikowe.
- Badania petrograficzne (klasyczne, katodoluminescencja, komputerowa analiza obrazu), procesy diagenetyczne i ich wpływ na właściwości zbiornikowe
- Badania przepływów mediów złożowych w skałach zbiornikowych (przepuszczalność fazowa, zwilżalność)
- Budowę trójwymiarowych modeli geologicznych złóż (PETREL)

INSTYTUT NAFTY I GAZU
ul. Łubicz 25 A, 31-503 Kraków
tel.: +48 12 421 00 33 fax: +48 12 430 38 85
www.inig.pl office@inig.pl