

Małgorzata Kowalska-Włodarczyk, Barbara Darlak  
Instytut Nafty i Gazu, Kraków

## Modele stochastyczne wybranych parametrów jako wsparcie konstruowania modeli geologicznych przy użyciu ANN i *Fuzzy Logic*

### Wstęp

W dotychczas wykonywanych pracach, obok symulacji neuronowych ANN, wprowadzona została nowa technika obliczeniowa – logika rozmyta (*Fuzzy Logic*). Metodę tę stosuje się z powodzeniem w tych przypadkach, gdy niewystarczająca jest baza danych do stworzenia zbiorów uczących, koniecznych w większości sieci neuronowych. Metoda wymaga opracowania funkcji,

algorytmów i wielkości rozmytych oraz funkcji decyzyjnych na poziomie lingwistycznym. W niniejszej pracy sformułowano nowe algorytmy i funkcje rozmyte, a także system funkcji decyzyjnych, dla umożliwienia graficznej wizualizacji danych. Celem pracy było opracowanie modeli obliczeniowych do wykorzystania ich w programach wizualizacyjnych.

### Metodyka

Metoda logiki rozmytej była już omawiana w poprzednich pracach dotyczących tego zagadnienia [2, 5]. W obecnej pracy, tytułem przypomnienia, przedstawiamy główne zasady rządzące logiką rozmytą.

Metoda logiki rozmytej jest jedną z najnowocześniejszych metod obliczeniowych, wykorzystującą pojęcie zbioru rozmytego – w przeciwieństwie do teorii klasycznej, w której ze zbioru głównego zostają wydzielone podzbiory na zasadzie bliskiego pokrewieństwa, takiego, 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 podzbiórach. Powyższa metoda różni się też od większości symulacji stosujących sieci neuronowe tym, że nie wymaga zbiorów uczących [1, 10] – co jest wygodne zwłaszcza w przypadkach, gdzie występuje dokuczliwy brak ciągłości danych. Może być ona także przydatna przy reinterpretacji danych archiwalnych.

Sieci neuronowe, którymi posłużono się do weryfikacji i obliczeń, są dobrze znanym narzędziem, opisywanym i stosowanym w wielu dotychczasowych pracach [3, 4], a w niniejszej pracy wykorzystano je jako czynnik weryfikacyjny w kolejnych etapach doboru algorytmów i funkcji rozmytych.

### Baza danych

Bazę do obliczeń sporządzono na podstawie wyników uzyskanych z wykonanych badań laboratoryjnych, takich jak: badania mikroskopowe, porozymetryczne, z ana-

lizą przestrzeni porowej, pomiarem przepuszczalności absolutnej i gęstości materiałowej, a także oparto się na uzyskanych danych sejsmicznych (impedancja). Ponieważ

pomiary były niekompletne – co wynika z nieciągłości pozyskanego materiału rdzeniowego – obie techniki obliczeniowe zastosowano do ich uzupełnienia i weryfikacji. Przetestowana i zweryfikowana baza została wprowadzona

do dalszych obliczeń. Na ich podstawie odtworzono arkusz danych, który posłużył do prześledzenia rozkładu regionalnego wybranych parametrów i umożliwił wizualizację tego rozkładu.

### Wprowadzenie do metodyki logiki rozmytej

Obliczenia wstępne prowadziły do przygotowania podstawowej bazy danych. Posłużyła do tego celu zarówno symulacja neuronowa (dotychczas z sukcesem stosowana w podobnych zagadnieniach) oraz najnowsza technika obliczeniowa, jaką jest logika rozmyta.

W pierwszej kolejności wykonano symulacje neuronowe na arkuszu danych. Po kolejnych wstępnych próbach dobrano sieć neuronową, wykorzystującą algorytm propagacji wstecznej, wspierany algorytmem genetycznym. Ten typ sieci dał najlepsze rezultaty i na nim oparto dalsze obliczenia, zmierzające do uzupełnienia danych.

Na tej samej bazie danych wykonano równoległe obliczenia posługując się metodą logiki rozmytej. Metodzie tej poświęcono wcześniej kilka publikacji [2, 5]. W tym miejscu należy przypomnieć pryncypia metody.

Rozmyty system wnioskujący przebiega według określonego porządku:

#### BLOK ROZMYWANIA – BLOK WNISKOWANIA (Z BAZĄ REGULI) – BLOK WYOSTRZANIA

**Blok rozmywania** to działania, które za pomocą stosownych norm rozmytych powodują przekształcanie zbiorów tradycyjnych w zbiory rozmyte, w postaci zbioru stopni przynależności. Podstawą jest lingwistyczne przypisanie własności rozmytych danej ostrej wielkości (czyniąc ją tym samym wielkością rozmytą) za pomocą dobranych reguł wnioskowania rozmytego. Lingwistyczne reguły wnioskowania logiki rozmytej dla omawianych przypadków dobierane są stosownie do zagadnienia.

W **bloku wnioskowania**, pod działaniem wybranych norm rozmytych, posługując się regułą „Jeżeli ... To”, uzyskuje się logiczne powiązania pomiędzy elementami zbiorów. Istnieje wiele reguł wnioskowania dla modelu logicznego z wykorzystaniem implikacji rozmytej – można

je znaleźć w literaturze [7, 8]. Najczęściej stosowane są reguły wnioskowania *modus ponens* i *modus tollens*, choć równie często stosowana jest reguła *typu minimum* i reguła *typu iloczynu* dla modelu Mandaniego [6, 9].

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

1. Metoda środka ciężkości (ang. *center of area* – COA) [7, 8]. Definiuje ona wyostrzoną wartość  $\bar{y}$  rozmytego zbioru  $B$  w przestrzeni  $Y \subset R$

$$\bar{y} = \frac{\int_Y y \cdot \mu_B(y)}{\int_Y \mu_B(y)}$$

gdzie:

$\mu$  – funkcja przynależności.

Gdy przestrzeń  $Y$  jest skończona ( $Y = \{y_1, y_2, \dots, y_n\}$ ), wówczas 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 (ang. *mean of maxima* – MOM). Ta metoda wyznacza wyostrzoną wartość  $\bar{y}$  jako podstawową z całej dyskutowanej przestrzeni  $Y$  posiadającą maksymalny stopień przynależności i wyraża się równaniem:

$$\bar{y} = \frac{1}{2} \sum_{y_i \in G} y_i$$

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

### Wykonanie obliczeń

Zgodnie z przedstawioną teorią, do czynności rozmywania zastosowano funkcję przynależności  $\mu_A(x)$ , która każdej wartości ostrej pozwala przypisać wartość rozmytą.

Funkcja ta ma postać:

$$\mu_A(x) = \exp[-(x - x)^T \times (x - x)/\delta] \text{ dla } \delta > 0$$

gdzie:

$x$  – wartość konkretna,

$x$  – wartość rozmyta,

$\mu_A(x)$  – funkcja przynależności zbioru rozmytego  $A$ ,

$T$  – jest dowolną  $t$ -normą, dobieraną do zagadnienia.

W omawianym przypadku, na zbiorze  $X$  (o skończonej liczbie elementów) została zastosowana  $t$ -norma w postaci:

$$\mu(y) = \max \{ \min [\mu(x) \times \mu(x, y)] \}$$

dla  $x$  należącego do  $X$ .

Na tym etapie nastąpiła kwalifikacja lingwistyczna badanych parametrów. Przyjęto zasadę kwalifikacji: wielkość mała-średnia-duża, wraz z uwzględnieniem wzajemnych zależności pomiędzy parametrami.

Stosownie do opracowanych algorytmów wykonano obliczenia funkcji rozmytych  $\mu$  i znaleziono wartości rozmyte odpowiadające poszczególnym parametrom. Następnie taki rozmyty zbiór został przeniesiony do bloku wnioskowania. 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, oczekiwanym na wyjściu:

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

gdzie:  $x_1, x_2, x_3, y_1$  – elementy zbiorów rozmytych  $X_1, X_2, X_3$  i  $Y_1$ , stanowiące parametry ze zbioru bazowego.

## Wyniki

Na tym etapie wykonano obliczenia za pomocą sieci neuronowych i logiki rozmytej, w celu uzupełnienia arkusza danych i porównania skuteczności metod. Na rysunkach 1–5 przedstawiono korelacje rzeczywistych i obliczonych danych.



Rys. 1. Zestawienie impedancji

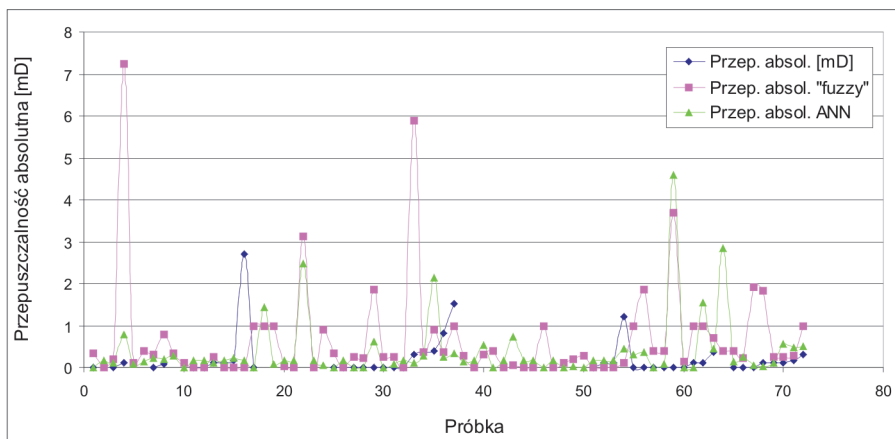
Na rysunku 1 zestawiono wyniki obliczeń **impedancji** za pomocą sieci neuronowej (ANN) i logiki rozmytej (*fuzzy*) z danymi doświadczalnymi. Jest to istotny krok, ponieważ w dalszej kolejności właśnie na impedancji oparto obliczenia pozostałych parametrów. Obliczenia – choć przeprowadzone tak odmiennymi metodami – wykazują wysoką zgodność w zachowaniu trendów i po odrzuceniu kilku skrajnych punktów można uznać, że ich wyniki są

wiarygodne, dobrze korelują z danymi doświadczalnymi i mogą stanowić podstawę do dalszych obliczeń.

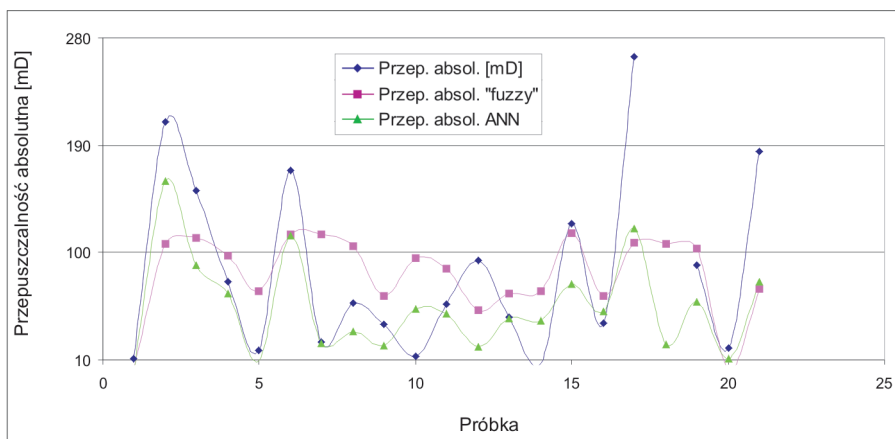
Na rysunkach 2 i 3 przedstawiono wyniki obliczeń **przepuszczalności absolutnej**, przy czym rozdzielono próbki na te o przepuszczalności mniejszej od 10 mD (rysunek 2) i większej od 10 mD (rysunek 3), co było podyktowane potrzebą czytelnej prezentacji wyników.

Podobnie jak poprzednio, na rysunkach 4 i 5 zestawiono porównywane metody: neuronową i logiki rozmytej. Danymi do obliczeń były parametry przestrzeni porowej otrzymane laboratoryjnie, gdyż mają one związek z przepuszczalnością absolutną oraz impedancją. Tu także obserwuje się zachowanie trendów przebiegu krzywych, jednak rozrzut danych jest większy.

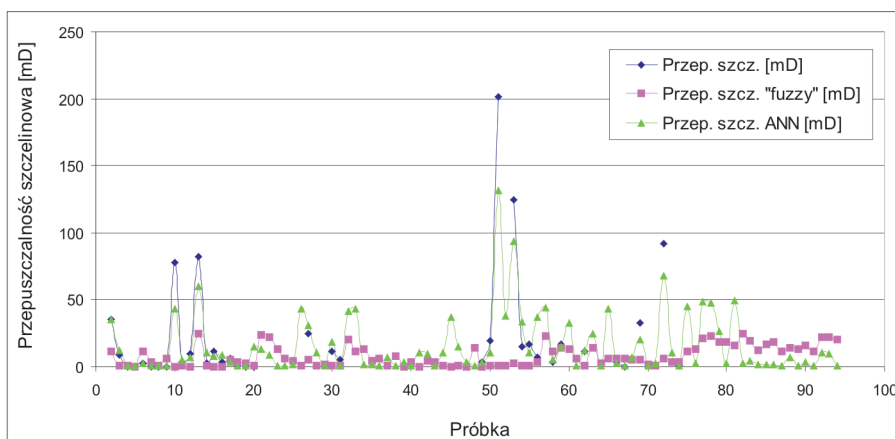
Logika rozmyta ma skłonność do spłaszczania w zakresie dużych przepuszczalności, natomiast dla małych przepuszczalności pojedyncze wyniki odbiegają od doświadczalnych. Znacznie poprawniej w takim przypadku zachowuje się sieć neuronowa. Różnice pochodzą stąd, że w obliczeniach *fuzzy* każdy zbiór parametrów opisujący jednostkowe zdarzenie jest przeliczany indywidualnie, gdy tymczasem sieci neuronowe uogólniają otoczenie jednostkowego zdarzenia.



Rys. 2. Zestawienie przepuszczalności absolutnej dla próbek o przepuszczalności < 10 mD



Rys. 3. Zestawienie przepuszczalności absolutnej dla próbek o przepuszczalności > 10 mD



Rys. 4. Zestawienie przepuszczalności szczelinowej

Na rysunku 4 przedstawiono wyniki obliczeń **przepuszczalności szczelinowej**. Obliczenia przeprowadzono w wielu turach, aby ostatecznie ustalić najkorzystniejszy skład zbioru bazowego. Finalnie obliczenia oparto na impedancji oraz gęstościach szkieletowej i objętościowej, bowiem te dawały najlepsze efekty z możliwych. Podobnie jak poprzednio, sieć neuronowa daje lepsze podobieństwo,

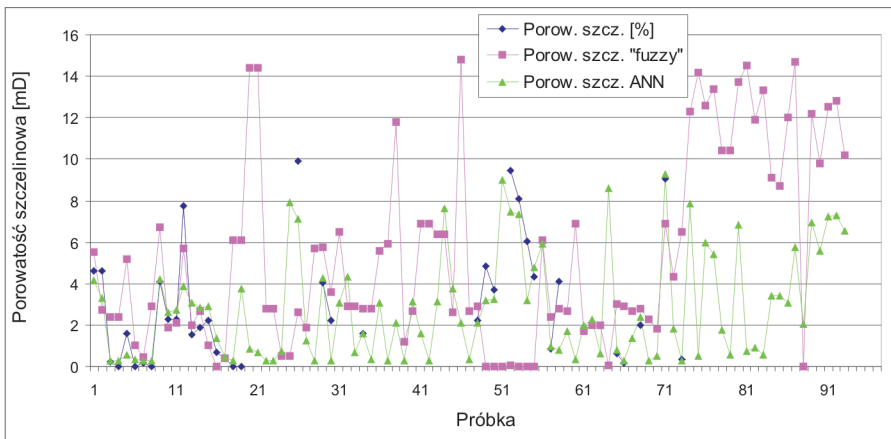
nie mniej jednak także w przypadku logiki rozmytej zauważalne są poprawne trendy zmian przepuszczalności – obliczonej i rzeczywistej.

Podobnie jak w przypadku przepuszczalności szczelinowej, także dla **porowatości szczelinowej** poszukiwano najkorzystniejszego składu zbioru bazowego i tak jak poprzednio, oparto się na impedancji oraz gęstościach: szkieletowej i objętościowej. W tym przypadku również można powiedzieć, że otrzymane wyniki zachowują poprawne trendy, przy czym sieci neuronowe lepiej korelują z danymi doświadczalnymi.

Zachodzi więc pytanie, po co wprowadzać logikę rozmytą, skoro dotychczasowe narzędzie obliczeniowe – jakim są sieci neuronowe – lepiej odzwierciedla rzeczywistość? Otóż logika rozmyta może być zastosowana zarówno tam, gdzie nie ma warunków do stworzenia zbioru uczącego, jak i dla sieci neuronowych. Dobrym przykładem są obliczone parametry w końcowej części zbioru (dla prób poniżej numeru 64), gdzie impedancja została całkowicie odtworzona – obiema metodami, dla dwóch otworów. Podobny przebieg krzywych impedancji, obliczonych obiema metodami, weryfikuje i uwiarygodnia nowo wprowadzoną metodę logiki rozmytej, dając tym samym możliwość skompletowania bazy danych, która może posłużyć do dalszych obliczeń i wizualizacji w znanych programach.



W oparciu o tak skompletowaną bazę danych wykonano wizualizacje rozkładu uśrednionych (w dziesięciometrowej warstwie przystropowej) parametrów petrofizycznych na obszarze występowania badanych otworów: porowatości, przepuszczalności szczelinowej oraz przepuszczalności absolutnej. Wyniki te przedstawiono na rysunkach 6–11.

Przedstawione rysunki ukazują możliwości praktycznego zastosowania wyżej omówionych metod do prze-





Rys. 5. Zestawienie porowatości szczelinowej


śledzenia rozwoju przestrzennego badanych parametrów petrofizycznych (po uprzednim uzupełnieniu baz danych obydwoma metodami), dowodząc tym samym skuteczności tych metod w konkretnych zagadnieniach. Zbliżony przebieg trendów rozwoju poszczególnych parametrów dowodzi, że obie metody są skuteczne i mają swoje priorytety. Metoda sztucznych sieci neuronowych jest metodą dokładniejszą, lecz wymaga zbioru uczącego.

Rys. 6. Porowatość szczelinowa obliczona metodą *fuzzy*

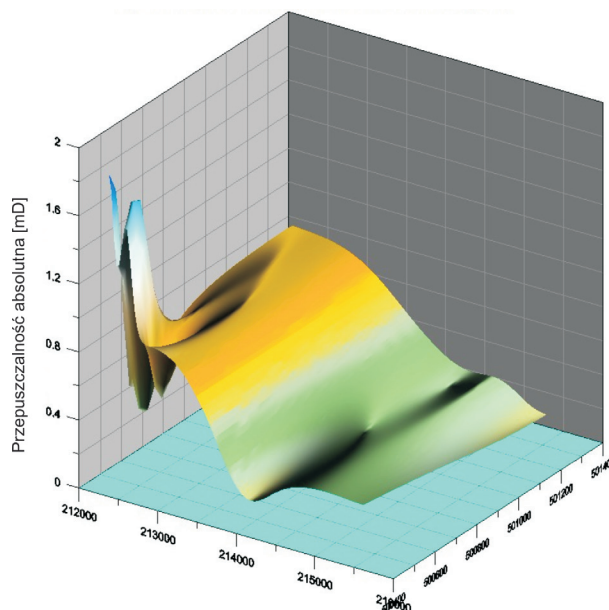
Rys. 7. Porowatość szczelinowa obliczona metodą ANN

Rys. 8. Przepuszczalność szczelinowa obliczona metodą *fuzzy*

Rys. 9. Przepuszczalność szczelinowa obliczona metodą ANN



Rys. 10. Przepuszczalność absolutna obliczona metodą *fuzzy*



Rys. 11. Przepuszczalność absolutna obliczona metodą ANN

W przypadku logiki rozmytej traci się na dokładności, ale ponieważ metoda ta nie wymaga zbioru uczącego, a jedynie

lingwistycznych definicji zależności, zatem należy uznać, że jej wynik jest zadziwiająco poprawny.

### Wnioski

1. Przetestowano sposób odtwarzania informacji metodami sieci neuronowych ANN oraz logiki rozmytej (*fuzzy logic*) i stwierdzono, że obie metody prawidłowo odtwarzają trendy poszczególnych wielkości.
2. Sztuczne sieci neuronowe poprawnie odtwarzają wyniki badań laboratoryjnych i są bardziej odporne od metody logiki rozmytej na duże wahania odtwarzanych parametrów, jednak wymagają one zbioru uczącego.
3. Wyniki otrzymywane metodą *fuzzy* w sposób naturalny są spłaszczone i uśrednione; trudno więc oczekiwać, by poprawnie odtwarzały punktowe wyniki analiz (np. przepuszczalności szczelinowej). Natomiast, co istotne, metoda *fuzzy* w poprawny sposób odtwarza interwały zeszczelinowane, zaś uzyskiwana obydwoma metodami średnia ważona – wielkość najistotniejsza dla symulacji złożowych – jest bardzo podobna. Można tu mówić o analogii pomiędzy pomiarami karotażowymi a punktowymi badaniami laboratoryjnymi.
4. Podsumowując, można stwierdzić, że stosowanie logiki rozmytej dla oszacowania parametrów zbiornikowych i filtracyjnych daje poprawne wyniki i że narzędzie to może być z powodzeniem stosowane w praktyce złożowej jako metoda pozyskiwania danych – zwłaszcza tam, gdzie nie ma wystarczającej bazy danych do stworzenia zbioru uczącego.

Artykuł nadesłano do Redakcji 22.11.2010 r. Przyjęto do druku 13.01.2011 r.

Recenzent: prof. dr hab. Piotr Such

### Literatura

- [1] Bezdek J.C. et al.: *Pattern recognition with fuzzy objective function algorithms*. Plenum, New York 1981.
- [2] Darlak B., Kowalska-Włodarczyk M.: *Zastosowanie logiki rozmytej w budowie modeli geologicznych*. Nafta-Gaz nr 6, s. 454–461, 2009.
- [3] Darlak B., Kowalska-Włodarczyk M.: *Niektóre problemy oceny właściwości skal zbiornikowych z wykorzystaniem sieci neuronowych*. Prace IGNiG nr 120, 2003.
- [4] Darlak B., Kowalska-Włodarczyk M.: *Zastosowanie sztucznej sieci neuronowej do uzupełnienia danych zbiornikowych*. Przegląd Geologiczny nr 9, t. 49, s. 797–806, 2001.
- [5] Darlak B., Włodarczyk M.: *Próba zastosowania logiki rozmytej do interpretacji parametrów petrofizycznych skal zbiornikowych*. Nafta-Gaz nr 5, s. 305–413, 2007.
- [6] Łęski J.: *Systemy neuronowo rozmyte*. Wydawnictwo Naukowo-Techniczne, 2008.

- [7] Piegat A. *Modelowanie i sterowanie rozmyte*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 1999.
- [8] Piegat A.: *Fuzzy modeling and control*. ISBN 3-7908, p. 1385–1390, 2001.
- [9] Rutkowski L. i in.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, 1997.
- [10] Zadeh L.A.: *Fuzzy sets*. Information and Control, p. 338–353, 1965.



Mgr inż. Małgorzata KOWALSKA-WŁODARCZYK – absolwentka Wydziału Energochemiczne Przetwórstwo Węgla i Fizykochemii Sorbentów w AGH w Krakowie. Od roku 1980 jest pracownikiem INiG w Krakowie w Zakładzie Geologii i Geochemii, Laboratorium Petrofizyki, na stanowisku starszy specjalista badawczo-techniczny. Zajmuje się wykorzystaniem sieci neuronowych w zagadnieniach geologicznych.



Mgr Barbara DARŁAK – 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.

Zapraszamy  
do Kielce

**TargiKielce**  
EXHIBITION & CONGRESS CENTRE



**EXPO-GAS 2011**  
VI Targi Techniki Gazowniczej  
**13-14.04.2011, Kielce**

- atrakcyjny program
- konferencje i seminaria
- liczni przedstawiciele branży

**www.expo-gas.pl**

ORGANIZATORZY:



www.igg.pl



Targi Kielce S.A., 25-672 Kielce, ul. Zakładowa 1  
Dyrektor Produktu - Anna Prędoła  
tel. 41 365 12 31, fax 41 345 62 61, tel. kom. 606 447 412, e-mail: predota.a@targikielce.pl

Patronat Medialny:

