

Małgorzata Włodarczyk, Barbara Darłak  
Instytut Nafty i Gazu, Kraków

## Analiza porównawcza wyników interpretacji parametrów zbiornikowych i uszczelniających bioherm przedgórza Karpat metodami ANN i *fuzzy logic*

### Wstęp

W węglanowych utworach jury górnej, zalegających pod utworami zapadliska przedkarpackiego i Karpat, od szeregu już lat zainteresowanie badaczy, ze względu na swą perspektywiczność, budzą budowle organogeniczne. Rozwój nowoczesnych metod badawczych potwierdził istnienie takich struktur w profilach otworów wiertniczych [6, 7]. Budowle organogeniczne w kształcie grubej i często rozległej soczewki, utworzone w trakcie depozycji utworów oksfordu, nazywane są biohermami. Powstały one przy współdziałaniu gąbek krzemionkowych (tworzących miejscami duże nagromadzenia) oraz sinic – mikroorganizmów, które stymulowały procesami życiowymi wytrącanie węglanu wapnia oraz w bierny sposób wychwytywały i wiązały drobiny węglanowego osadu. Wzrost bioherm zapoczątkowały gąbki, które miały zdolność zasiedlania miękkiej powierzchni dna. Rozpuszczoną w trakcie wczesnej diagenety krzemionkę, budującą igły gąbek, zastępował kalcyt, wytrącający się wokół gnijących szczątków.

Nagromadzenia powstających w ten sposób skalcytowanych i dzięki temu nierozpadających się tzw. mumii gąbkowych stawały się twardym podłożem, dogodnym dla rozwoju sinic. Bioherma jest więc ciałem o złożonej budowie, z różnym ilościowo udziałem profilu gąbek i struktur pochodzenia sinicowego.

Taka struktura stwarzająca warunki do gromadzenia płynów złożowych, wraz z nadkładem warstwy uszczelniającej stanowi doskonały materiał zbiornikowy.

Przedmiotem wykonanego opracowania była interpretacja geologiczna skał pod kątem dobrych parametrów



Rys. 1. Przykładowa forma biohermy

zbiornikowych (duża porowatość i przepuszczalność), jak również ocena efektywności skał uszczelniających przy użyciu najnowszych metod obliczeniowych, tj. sztucznych sieci neuronowych (ANN) i logiki rozmytej (*fuzzy logic*), a także ocena skuteczności tych metod.

## Metodyka

Zarówno metoda ANN, jak i *fuzzy logic* są najnowszymi metodami przydatnymi w obróbce danych geologicznych – zwłaszcza tam, gdzie punktowo pobierane próbki nie dają pełnego obrazu zmienności parametrów petrofizycznych. Obie metody zostały już opracowane i zastosowane

w wybranych problemach [2–5]. W przedstawionym zagadnieniu dzięki tym metodom możliwa jest rekonstrukcja całkowitych profili, których korelacja z innymi parametrami, np. impedancją, daje możliwość regionalnej analizy występowania utworów organogenicznych.

### Metoda sieci neuronowych ANN

Metoda sieci neuronowych jest wieloparametrową metodą obliczeniową. Opiera się ona na biologicznych podstawach pracy neuronów [9, 13]. W stosowanych sztucznych sieciach neuronowych wymagane jest stworzenie zbiorów uczących, testujących i wynikowych, które odpowiednio uczą, weryfikują i ostatecznie dostarczają oczekiwanych danych.

Sztuczna sieć neuronowa ANN w pewnym uproszczeniu odzwierciedla układy biologiczne. Składa się z dużej liczby elementów przetwarzających informacje, które na podobieństwo komórek nerwowych nazywane są neuronami. Każdy neuron przenosi, przetwarza, zapamiętuje i odwzorowuje informacje. Zadaniem sztucznego neuronu jest obliczenie sumy ważonej sygnałów wejściowych. Wprowadzane do neuronu iloczyny sygnałów wejściowych  $x_i$  ( $i = 1, 2, \dots, m$ ) i wag, zwanych wagami synaptycznymi  $w_i$  ( $i = 1, 2, \dots, k$ ), są sumowane dla wszystkich neuronów, a na koniec generowany jest sygnał wyjściowy –  $g$ .

$$g = \sum_{i=1}^m w_i x_i \quad (1)$$

Sygnał  $g$  zostaje przetworzony w bloku aktywacji przez dobrą funkcję aktywacji  $F$ , dając w wyniku oczekiwany sygnał wyjściowy

$$y = F(g) \quad (2)$$

Funkcje aktywacji mają charakter dwudecyzyjny w pracy neuronu i pozwalają otrzymaną informację przeanalizować oraz przesłać do następnego neuronu.

Sztuczna sieć neuronowa jest zbudowana z wielu połączonych neuronów zorganizowanych w warstwy. Parametry tych połączeń, zwane wagami, są modyfikowane w trakcie tzw. procesu uczenia. Topologia połączeń oraz ich parametry stanowią program działania sieci.

Architektura sieci jest ściśle powiązana z odpowiednią metodą doboru wag, czyli metodą uczenia. Najpopularniejsza w użyciu jest sieć jednokierunkowa nieliniowa z co najmniej jedną warstwą ukrytą, której uczenie odbywa się przy zastosowaniu odpowiednio dobranego algorytmu

uczenia. Uczenie takiej sieci odbywa się z nauczycielem, tzn. zbiorem o znanym rozwiązaniu. Testowanie przeprowadza się na podobnym zbiorze bez danych wynikowych. Algorytm propagacji wstecznej jest oparty na minimalizacji sumy kwadratów błędów uczenia, z wykorzystaniem gradientowych metod optymalizacji. Podstawę algorytmu stanowi funkcja energetyczna  $E(W)$ , będąca sumą kwadratów różnic pomiędzy wartościami sygnałów wyjściowych sieci  $y$ , a wartościami zadanymi  $d$ , która jest miarą błędu sieci. W przypadku wielu próbek uczących  $j$  ( $j = 1, \dots, p$ ), przy  $k$  ( $k = 1, 2, \dots, m$ ) elementach przetwarzających w warstwie wyjściowej, przybiera ona postać:

$$E(W) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^m (y_k^j - d_k^j)^2 \quad (3)$$

Problem uczenia sieci to zagadnienie minimalizacji funkcji energetycznej.

Przyrost wag  $W$  określa się według kierunku ujemnego gradientu pomiędzy jednostkami z warstw ukrytych i warstwy wyjściowej:

$$\Delta W = -\eta \frac{\partial E}{\partial W} \quad (4)$$

$\mu$  – współczynnik uczenia.

Uczenie sieci prowadzi się aż do uzyskania najmniejszego błędu średniokwadratowego dla wartości spodziewanej i otrzymanej. Tak przygotowaną sieć można testować na innych zbiorach o tych samych parametrach.

Celem zasadniczym sieci jest wygenerowanie danych z przesłanek dostarczonych w postaci zbiorów specjalnie dobranych parametrów petrofizycznych, sejsmicznych czy geofizycznych. Ogólna metodyka została opracowana w dotychczasowych pracach badawczych [2, 4], jednak każde nowe zagadnienie wymaga indywidualnego toku postępowania w dobieraniu parametrów sieciowych. W kolejnych etapach weryfikacji danych zostaje wyselekcjonowana baza danych petrofizycznych, stanowiąca podstawę do dalszych obliczeń zarówno dla ANN, jak i *fuzzy logic*.

## Metoda logiki rozmytej *fuzzy logic*

Istota logiki rozmytej zasadza się na zbiorach rozmytych i posługuje się regułami rozmytymi [8, 12]. Podstawowa wiedza wprowadzana jest w postaci lingwistycznych zmiennych [14]. W praktyce sprowadza się to do tego, że przynależność do zbioru określana jest na przykład przymiotnikami: duży, średni, mały. Musimy jednak pamiętać, że mamy do czynienia ze zbiorami rozmytymi, co pozwala zakwalifikować daną zmienną do więcej niż jednego zbioru w procesie tak zwanego rozmywania za pomocą funkcji przynależności. Następnie stosuje się rozmyte reguły wnioskowania, pozwalające wartości i funkcje rozmyte przyporządkować jednemu zbiorowi rozmytemu. Po wykonaniu stosownych operacji na zbiorach następuje proces wyostrzania, w wyniku którego otrzymujemy rzeczywiste dane.

Rozmyty system wnioskujący skonstruowany jest według określonego porządku [1, 10, 11]:

### 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. Zbiorem rozmytym  $A$  w pewnej przestrzeni  $X$  ( $A \subseteq X$ ) nazywamy zbiór par

$$A = \{x, \mu_A(x); x \in X\} \quad (5)$$

w którym

$$\mu_A : X \rightarrow [0, 1] \quad (6)$$

jest **funkcją przynależności** zbioru rozmytego  $A$ .

Wtedy reguła rozmywania typu minimum zastosowana w obliczeniach przyjmuje postać:

$x_1, x_2, \dots, x_n$  – zmienne wejściowe modelu lingwistycznego, przy czym

$$x = [x_1, x_2, \dots, x_n]^T \quad x \in X_1 \cdot X_2 \cdot \dots \cdot X_n$$

$y_1, y_2, \dots, y_m$  – zmienne wyjściowe modelu lingwistycznego, przy czym

$$y = [y_1, y_2, \dots, y_m]^T \quad y \in Y_1 \cdot Y_2 \cdot \dots \cdot Y_m$$

Symbolami  $X_i, i = 1, \dots, n$  oraz  $Y_j, j = 1, \dots, m$ , ozna-

czamy odpowiednio: przestrzenie zmiennych wejściowych i wyjściowych.

W bloku wnioskowania pod działaniem wybranych norm rozmytych uzyskuje się logiczne powiązania pomiędzy elementami zbiorów. Stosuje się w tym celu regułę „Jeżeli ... To”

**JEŻELI:**  $x_1$  jest  $A_1^k$  **I**  $x_2$  jest  $A_2^k$  **I**  $x_n$  jest  $A_n^k$   
**TO:**  $x_1$  jest  $B_1^k$  **I**  $x_2$  jest  $B_2^k$  **I**  $x_n$  jest  $B_n^k$

dla  $k = 1, 2, \dots, N$ , gdzie  $N$  jest liczbą reguł, natomiast  $A_i^k$  to zbiory rozmyte. Istotne na tym etapie jest dobranie odpowiednich reguł wnioskowania.

Ostatni element, blok defuzyfikacji, czyli wyostrzania, służy jako faza, w której zbiory rozmyte przechodzą określone procesy odwzorowania, pozwalające na wyjściu uzyskać ostre wartości.

Zastosowana została tutaj jedna spośród wielu metod, tzw. metoda maksimum funkcji przynależności (ang. *mean of maxima* – MOM). Metoda ta wyznacza wyostrzoną wartość  $\bar{y}$  jako podstawową z całej dyskutowanej przestrzeni  $Y$ , posiadającą maksymalny stopień przynależności, i wyraża się równaniem:

$$\bar{y} = \frac{1}{t} \sum_{y_i \in T} y_i \quad (7)$$

gdzie  $T$  reprezentuje podzbiór z przestrzeni  $Y$ , która osiąga maksimum wartości, gdy

$$\mu(y) = 1$$

oraz gdy  $t$  należy do  $T$ ,

$T$  – jest dowolną  $t$ -normą dobieraną do zagadnienia,  $\mu(y)$  – jest funkcją przynależności danego zbioru rozmytego.

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

$$\mu(y) = \max \{ \min [m(x) \cdot m(x, y)] \}, \text{ dla } x \text{ należącego do } X,$$

co popularyzując, można opisać jako poszukiwanie za pomocą odpowiednich algorytmów minimalnych funkcji przynależności oznaczonych dla poszczególnych zbiorów rozmytych, a następnie wśród tych ostatnich wytypowanie maksymalnej i ostatecznie znalezienie dla niej ostrej wartości.

## Wykonanie obliczeń

Powyżej przedstawiono naturę bioherm, których immanentną cechą jest wysoka porowatość i przepuszczalność,

wynikająca z ich sposobu powstawania, a nadkłady uszczelniające stwarzają warunki do magazynowania płynów

złożowych. Przedmiotem niniejszego opracowania było zdefiniowanie takich tworów za pomocą najnowszych metod obliczeniowych, tj. sieci neuronowych i logiki rozmytej.

Pierwszym krokiem było sporządzenie podstawowej bazy danych. Do obliczeń wykorzystano wyniki analizy porozymetrycznej i przepuszczalności jako parametrów punktowych oraz impedancji akustycznej jako parametru ciągłego. W toku kolejnych obliczeń weryfikacyjnych sporządzono zbiór podstawowy. Na jego podstawie wykonano dalsze obliczenia. Wyniki przedstawiono na rysunkach 2–8.

Na rysunku 2 przedstawiono profile rzeczywistych danych, tj. parametrów otrzymanych laboratoryjnie: porowatości oraz gęstości szkieletowej i objętościowej, które najlepiej korelują z parametrami odtwarzanymi za pomocą

ANN i *fuzzy logic*, tzn. przepuszczalnością i impedancją. Na osi odciętych oznaczono numer kolejny próbki. Na profilach tych wyraźnie zarysowują się warstwy o podwyższonej porowatości i zarazem pomniejszonej gęstości.

W oparciu o podstawową bazę danych i za pomocą obu metod symulacyjnych obliczono całe profile impedancji i przepuszczalności oraz zestawiono je z niekompletnymi wynikami rzeczywistymi. Wyniki przedstawiono na rysunkach 3–6.


Niepewność związana z wyznaczeniem porowatości oraz gęstości została oszacowana na podstawie zdolności przyrządu pomiarowego i nie przekracza 0,0005%. Dla przepuszczalności błąd pomiarowy liczony jest różniczką zupełną i nie przekracza 2%.

### Omówienie wyników

W obliczeniach oparto się na zbiorach parametrów przestrzeni porowej, przepuszczalności i impedancji akustycznej. Dane uzyskano z ośmiu otworów. Na rysunku 2 przedstawiono trendy parametrów porozymetrycznych ściśle związanych z przestrzenią porową i przez to odzwierciedlających jej charakter. Nie wyszczególniono tu wszystkich pojedynczych otworów, a jedynie nakreślono ich granice, które wyraźnie wskazują na istnienie bioherm. Rozdzielenie pozostałych otworów nie ma bowiem dla obliczeń istotnego znaczenia, stanowi natomiast materiał

obliczeniowy i porównawczy. Badania porozymetryczne dostarczyły pełnych profili danych dla każdego odwiertu. Inaczej wyglądają profile impedancji i przepuszczalności; dla niektórych otworów w ogóle nie były one wyznaczone (impedancja), bądź, jak w przypadku przepuszczalności, niekiedy nie udało się wykonać pomiaru (próbka była zbyt krucha by uzyskać rdzeń, lub uległ on zniszczeniu w czasie pomiaru) i uzyskane profile nie były kompletne.

Aby uzyskać kompletne dane zastosowano obie opisane wyżej techniki symulacyjne – ANN i *fuzzy logic*.




Rys. 2. Zestawienie porowatości, gęstości szkieletowej oraz gęstości objętościowej dla badanych próbek




Na wyselekcjonowanej wcześniej bazie danych wykonano obliczenia. Uzyskano kompletne profile impe-

dancji i przepuszczalności. Wyniki przedstawiono na rysunkach 3–6.




Rys. 3. Zestawienie porowatości, gęstości objętościowej oraz gęstości szkieletowej z impedancją doświadczalną i obliczoną metodą ANN




Rys. 4. Zestawienie porowatości, gęstości objętościowej oraz gęstości szkieletowej z impedancją doświadczalną i obliczoną metodą *fuzzy logic*

Rysunki 3 i 4 mają w zestawie cztery diagramy: porowatość, gęstości objętościową i szkieletową oraz wyliczoną impedancję zestawioną z rzeczywistą. Występowanie wyraźnych odchyłek parametrów przestrzeni porowej bardzo

dobrze koreluje z impedancją. W przypadku metody ANN wyniki wyliczone różnią się od rzeczywistych jedynie amplitudą, przy czym symulacja za pomocą *fuzzy logic* znacznie dokładniej odtwarza trendy przebiegu krzywych.



Rys. 5. Zestawienie porowatości i impedancji z przepuszczalnością doświadczalną i obliczoną metodą ANN



Rys. 6. Zestawienie porowatości i impedancji z przepuszczalnością doświadczalną i obliczoną metodą *fuzzy logic*

Wyniki obu symulacji poprawnie wskazują lokalizację bioherm – tworów odmiennych od otaczających ich utworów skalnych.

Na rysunkach 5 i 6 zestawiono profile porowatości oraz wyliczonej impedancji z przepuszczalnością obliczoną obiema metodami, w zestawieniu z danymi doświadczalnymi. Należy tu zaznaczyć, jak skąpyimi danymi rzeczywi-

stymi dysponowano (linia zielona na wykresie przepuszczalności), a mimo to wyliczona krzywa zachowuje trendy rozwoju przestrzeni skalnej i z dużym podobieństwem odwzorowuje przepuszczalność. W przypadku obu metod dane wyliczone mają mniejszą amplitudę niż rzeczywiste, ale – jak poprzednio – położenie wzmożonej przepuszczalności zostaje odwzorowane z dużą dokładnością.

### Zestawienie metod

Porównując obie metody, można zaobserwować między nimi podstawowe różnice. Jak już wcześniej zaznaczono, sieć neuronowa wymaga zbioru uczącego i weryfikacyjnego. Może to stanowić pewną trudność, zwłaszcza gdy dysponujemy skąpą bazą danych. Metoda wymaga reprezentatywnego zbioru uczącego, obejmującego wszystkie przypadki zaproponowane sieci do liczenia, wraz z rozwiązaniami. Innymi słowy, wartości otrzymane w wyniku obliczeń powinny znajdować się w wynikowym zbiorze uczącym. Zbiór weryfikacyjny nie wymaga takich obostrzeń, natomiast posiada gotowe rozwiązania, które służą do określenia zdolności obliczeniowej wybranej sieci. Tak więc ta metoda obliczeniowa wymaga zbioru z gotowymi rozwiązaniami, które posłużą do nauki i weryfikacji, oraz zbioru badanego, którego rozwiązań właśnie w tej metodzie poszukujemy.

Przewagą drugiej metody – logiki rozmytej – jest to, że nie wymaga ona zbioru uczącego i może być zastoso-


wana tam, gdzie posiadamy mniej danych bądź nie mamy możliwości stworzenia zbiorów porównawczych. Wyniki możemy wtedy korelować z otrzymanymi z innych metod.

Ta metoda obliczeniowa pozwala przewidywać nieznane parametry jedynie w oparciu o logiczne przesłanki lingwistyczne.


W przedstawionej pracy wykonano analizę porównawczą obu metod, bazując na zbiorach parametrów zbiornikowych i uszczelniających bioherm w rejonie przedgórze Karpat.

Na rysunku 7 zestawiono impedancję obliczoną obiema metodami, tj. ANN i *fuzzy logic*, z porowatością. Takie zestawienie stanowi potwierdzenie skuteczności obu metod w charakteryzowaniu właściwości fizycznych materii skalnej, zwłaszcza pod względem najistotniejszych parametrów zbiornikowych: przepuszczalności i porowatości.

Otrzymane wyniki pozwalają na wyraźne wyszczególnienie w profilach dwóch otworów (Z-7 i Z-1) poziomów



Rys. 7. Porównanie impedancji obliczonej metodami ANN i *fuzzy logic*



Rys. 8. Porównanie przepuszczalności obliczonej metodami ANN i *fuzzy logic*

poświadczających istnienie bioherm. Są to zakreślone dwa poziomy o dużej porowatości i przepuszczalności oraz małej impedancji. Wydzielone są z otoczenia o bardzo niskiej

porowatości i przepuszczalności, a więc skał uszczelniających. Profile innych otworów nie mają tak zdecydowanego charakteru – występuje w nich duża zmienność parametrów.

### Podsumowanie

Obie techniki obliczeniowe są skuteczne. Pozwalają z dużą dokładnością odtworzyć trendy zmian poszukiwanych wielkości, a nawet zrekonstruować całkowite profile. Reagują na zmiany właściwości skalnych. Można za ich pomocą wyznaczyć poziomy uszczelniające i poziomy o dobrych własnościach zbiornikowych. Różnica pojawia się w amplitudzie wykresów. Metoda sieci neuronowych ma tendencje do spłaszczania, co wynika z zasady generalizacji zależności pomiędzy wprowadzonymi danymi; zarówno w zbiorze uczącym, jak i testującym. W logice

rozmytej jakość dopasowania zależy od definicji granic zbiorów rozmytych za pomocą tzw. pojęć lingwistycznych, a następnie od stosownie dobranych zależności rozmytych. Im lepiej są one określone, tym lepsze otrzymuje się dopasowanie. Na rysunku 5 daje się zaobserwować ograniczenie metody, polegające na tym, że przy dużych rzeczywistych przepuszczalnościach wartości obliczone są tylko do pewnej granicy, niemniej jednak na tyle wysokiej, że nadal można zakwalifikować tę przepuszczalność jako bardzo dobrą.

### Wnioski

1. Obie metody obliczeniowe omówione w opracowaniu, tj. sieci neuronowe ANN i logika rozmyta *fuzzy logic*, okazały się bardzo skutecznymi narzędziami do rozróżniania skał zbiornikowych i uszczelniających. Można też zdefiniować za ich pomocą wszystkie inne stany pośrednie.
2. W niniejszym opracowaniu z dużą trafnością potwierdzono istnienie formacji organogenicznych, w tym

- przypadku poszukiwanych bioherm, które różnią się od otoczenia właściwościami fizycznymi.
3. Dzięki wyskalowaniu tych metod na tak różnorodnym materiale skalnym opracowana metoda może być zastosowana na wszystkich typach skał i być nie tylko metodą diagnostyczną, ale także rekonstrukcyjną w niekompletnych profilach geologicznych, a nawet tam, gdzie z różnych powodów danego parametru nie pomierzono.



## Literatura

- [1] Bezdek J. C. et al.: *Pattern recognition with fuzzy objective function algorithms*. New York, Plenum, 1981.
- [2] Darlak B., Kowalska-Włodarczyk M.: *Niektóre problemy oceny właściwości skał zbiornikowych z wykorzystaniem sieci neuronowych*. Prace IGNiG 2003, nr 120.
- [3] Darlak B., Kowalska-Włodarczyk M.: *Zastosowanie logiki rozmytej w budowie modeli geologicznych*. „Nafta-Gaz” 2009, nr 6, s. 454–461.
- [4] Darlak B., Kowalska-Włodarczyk M.: *Zastosowanie sztucznej sieci neuronowej do uzupełnienia danych zbiornikowych*. „Przegląd Geologiczny” 2001, t. 49, nr 9, s. 797–806.
- [5] Darlak B., Włodarczyk M.: *Próba zastosowania logiki rozmytej do interpretacji parametrów petrofizycznych skał zbiornikowych*. „Nafta-Gaz” 2007, nr 5, s. 305–413.
- [6] Gliniak P., Laskowicz R., Urbaniec A.: *Górnojurajskie budowie organiczne w rejonie Kraków–Dębica. Możliwości identyfikacji z zapisu sejsmicznego oraz perspektywy poszukiwawcze dla złóż węglowodorów*. Prace IGNiG 2000, nr 110, s. 161–165.
- [7] Gliniak P., Urbaniec A.: *Charakterystyka geofizyczna bioherm oksfordu na obszarze przedgórze Karpat w aspekcie nowych technik poszukiwania złóż węglowodorów*. „Nafta-Gaz” 2005, R. 61, nr 7/8, s. 343–348.
- [8] Łęski J.: *Systemy neuronowo-rozmyte*. Wydawnictwo Naukowo-Techniczne, 2008.
- [9] Osowski S.: *Sieci neuronowe*. Warszawa, Oficyna Wydawnicza Politechniki Warszawskiej, 1996.
- [10] Piegat A.: *Fuzzy modeling and control*. 2001. ISBN 3-7908-1385-0.
- [11] Piegat A.: *Modelowanie i sterowanie rozmyte*. Warszawa, Akademicka Oficyna Wydawnicza EXIT, 1999.
- [12] Rutkowski L. i in.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, 1997.
- [13] Tadeusiewicz R.: *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Warszawa, Akademicka Oficyna PLJ, 1998.
- [14] Zadeh L. A.: *Fuzzy sets*. „Information and Control” 1965, s. 338–353.



Mgr inż. Małgorzata KOWALSKA-WŁODARCZYK – absolwentka Wydziału Energochemiczne Przetwórstwo Węgla i Fizykochemii Sorbentów 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 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 i logiką rozmytą.

## ZAKŁAD GEOLOGII I GEOCHEMII

Zakres działania:

- analiza systemów naftowych (badania skał macierzystych, modelowanie generacji, ekspulsji i migracji węglowodorów, analiza dróg migracji, analiza parametrów zbiornikowych pułapek złożowych);
- badania prospekcyjne (trendy przestrzennego rozwoju parametrów zbiornikowych i filtracyjnych, analiza macierzystości, ranking stref zbiornikowych);
- konstrukcja statycznych modeli geologiczno-złożowych 3D;
- analiza procesów diagenetycznych i ich wpływu na parametry zbiornikowe skał;
- genetyczna korelacja płynów złożowych ze skałami macierzystymi;
- obliczanie zasobów złóż węglowodorów z analizą niepewności;
- modele przepływu płynów złożowych w skałach zbiornikowych;
- badania ekshalacji gazu;
- badania złóż typu *tight/shale gas*;
- specjalistyczne analizy: przestrzeni porowej, petrograficzne, geochemiczne RSO, płynów złożowych, analizy biomarkerów, analizy chromatograficzne, analiza GC/MS, GC/MS/MS;
- interpretacja danych geofizyki wiertniczej.

**Kierownik:** dr inż. Grzegorz Leśniak

**Telefon:** 12 421-00-33 w. 262

**Adres:** ul. Lubicz 25A, 31-503 Kraków

**Faks:** 12 430-38-85

**E-mail:** grzegorz.lesniak@inig.pl