

# Zastosowanie sztucznej sieci neuronowej do uzupełnienia danych zbiornikowych

Barbara Darlak\*, Małgorzata Włodarczyk\*\*

**The use of the Artificial Neural Network to complete the reservoir properties data.** Prz. Geol., 49: 797–803.

*Summary.* This paper deals with a new method of using Artificial Neural Network (ANN) in solving various geological problems, including reservoir properties assessment of carbonate rocks derived from results of microscopic analysis of images, as well as from reconstruction of relative permeability curves for several sandstone types. Based on ANN, the relative permeability data and results of numerical parameterisations of microscopic analyses of images were performed. Porosity permeability, and other parameters, i.e. threshold pressures, specific surfaces and density, obtained during capillary pressure analyses were applied as a database. These studies indicate that the reliable database and properly prepared series of measurements result in good quality of extrapolation of relative permeability and microscopic analysis parameters. In both cases the use of ANN produces good results. The correlation coefficient of experimental and simulated data is high amounting to 0.98 (computer microscopic analysis) and 0.89 (relative permeability), which enable using this method for further investigations.

**Key words:** artificial neural network (ANN), microscopic analyses of images, relative permeability, porosity

Przedstawiona praca jest kontynuacją problemu zastosowania sieci neuronowych w zagadnieniach geologicznych. Dotychczasowe poszukiwania, wykorzystując wzajemne związki między parametrami fizycznymi skał, wyznaczanymi metodami laboratoryjnymi na próbkach rdzeni, a także w połączeniu z danymi otworowymi profilowań geofizycznych koncentrowały się na symulacjach neuronowych, w wyniku których wyznaczano przepuszczalność, jako jeden z podstawowych parametrów charakteryzujących właściwości zbiornikowe skał (Tiab & Donaldson, 1996).

Nowym elementem wykonanej pracy było przeniesienie znaczenia współczynnika przepuszczalności z wielkości poszukiwanej (jak postępowano w dotychczas prezentowanych pracach własnych (Darła i in., 1998) oraz w krajowej i zagranicznej literaturze (Mohaghegh i in., 1996; Rogers i in., 1995) do roli statystycznego czynnika weryfikującego działanie sieci, przy obliczaniu innych parametrów petrofizycznych.

Kolejnym krokiem w zastosowaniu sieci neuronowych do charakterystyki właściwości zbiornikowych było odtworzenie innych parametrów zbiornikowych, takich jak przebieg krzywych przepuszczalności fazowej (Such i in., 2000) oraz parametrów przestrzeni porowej na podstawie danych z badań szczelinowatości wykonanych na szlifach, wraz z komputerową analizą obrazu (Leśniak, 1999).

Zarówno badania przepuszczalności fazowej, jak i badania szczelinowatości na szlifach, ze względu na ich czasochłonne przygotowanie i kosztowną obróbkę, są prowadzone na mniejszej liczbie próbek niż rutynowe badania porozymetryczne. Zaistniała więc potrzeba odtworzenia brakujących danych i uzupełnienia profili geologicznych. Do poszukiwania relacji łączących poszczególne parametry wykorzystywano do tej pory proste statystyki korelacyjne, jednak sieć neuronowa okazała się najlepszym narzędziem, pozwalającym poprawnie przewidywać związki pomiędzy parametrami i wyciągać prawidłowe

wnioski. Poprawność przebiegu symulacji neuronowej była kontrolowana za pomocą analiz statystycznych.

## Sztuczna sieć neuronowa

Sieć neuronowa bazuje na analogii do centralnego układu nerwowego istot myślących (Tadeusiewicz, 1993; Master, 1996). W pewnym uproszczeniu odtwarza neuronowe układy biologiczne: składa się z dużej liczby elementów przetwarzających informację, które na podobieństwo komórek nerwowych nazywane są neuronami.

Każdy neuron przenosi, przetwarza, zapamiętuje i odwzorowuje informacje dzięki czemu cała sieć potrafi sama podejmować decyzje i generować poprawny wynik pod warunkiem, że operator dokonał prawidłowego doboru architektury sieci i parametrów sieciowych oraz stosownych algorytmów uczenia.

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 sygnałów wejściowych, a na koniec generowany jest sygnał wyjściowy oznaczony  $g$ .

$$g = \sum_{i=1}^m w_i x_i \quad [1]$$

Sygnał  $g$  zostaje przetworzony w bloku aktywacji przez dobraną 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 i przesłać do następnego neuronu lub wytłumić.

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

Architektura sieci jest ściśle powiązana z odpowiednią metodą doboru wag czyli metodą uczenia. Uczenie takiej sieci odbywa się z nauczycielem tzn. zbiorem o znanym

\*Instytut Górnictwa Naftowego i Gazownictwa,  
31-503 Kraków, ul. Lubicz 25A; darlak@igng.krakow.pl  
\*\*j.w. wlodarczyk@igng.krakow.pl

rozwiązaniu. Testowanie przeprowadza się na podobnym zbiorze bez danych wynikowych. Metoda uczenia oparta jest na zasadzie minimalizacji błędu wyjściowego pomiędzy wartością wyliczoną a oczekiwaną, tj. doświadczalną, poprzez dobór odpowiedniego algorytmu. Wybrany do obliczeń algorytm propagacji wstecznej jest oparty na zasadzie 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  $d$  będącą miarą błędu sieci [3]. 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:

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

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

$$\Delta W = -\eta \frac{\partial E}{\partial W} \quad [4]$$

$\eta$  — 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. Na podobnych założeniach oparte są też inne algorytmy stosowane do sieci z nadzorem, to znaczy z procesem uczenia w celu minimalizacji błędu na wyjściu.

W przedstawionym zagadnieniu do obliczeń zastosowano nowy program komputerowy NeuralSIM, działający w środowisku Windows 95, wyposażony w narzędzia podstawowej statystyki korelacyjnej. W drodze kolejnych prób do każdego zagadnienia dobierano stosowną sieć w zależności od liczby parametrów wprowadzanych i oczekiwanych. Ogólnie zastosowano sieć typu perceptron wielowarstwowy z algorytmem propagacji wstecznej oraz tangensem hiperbolicznym jako funkcją progową. Liczbę warstw ukrytych i neuronów w nich zawartych dobierano w żmudnym procesie uczenia, aby uniknąć przeuczenia (gdy sieć jest zbyt duża) lub niedouczenia (gdy sieć jest za mała), gdyż w obu przypadkach sieć źle generalizuje. Podstawowym czynnikiem przedstawiającym poprawność symulacji jest zwykle wielkość błędu średniokwadratowego (Osowski, 1996). W prowadzonych badaniach, gdy wartość jego spadała poniżej 0,05 uznawano, że sieć pracuje poprawnie i można otrzymane wyniki zastosować do dalszych obliczeń. Weryfikację statystyczną otrzymanych wyników uzyskano poprzez zastosowanie równań korelacyjnych dla porównania wielkości pomierzonych z obliczonymi za pomocą sieci neuronowej. Wysoki współczynnik korelacji pozwala uwiarygodnić otrzymany wynik.

## Materiał badawczy

Zarówno badania mikroskopowe jak i przepuszczalności fazowej, ze względu na wysoki koszt pojedynczej analizy i jej czasochłonność, są wykonywane na starannie dobranych, reprezentatywnych dla danej facji próbkach. Nie udało się znaleźć takiego materiału, na którym wykonano równocześnie oba rodzaje analiz w odpowiednich ilościach. Dlatego też, zdecydowano się oba przypadki omawiać oddzielnie dobierając materiał skalny możliwie najlepiej opróbowany.

Mikroskopowe badania szczelinowości wykonywane w krótkich, starannie dobranych seriach, tak aby mogły reprezentować zmienność w badanym profilu geologicznym, zostały przeprowadzone na wydzielonych facjach zeszcelinowanych skał węglanowych dolomitu głównego o szerokim spektrum wykształcenia przestrzeni porowej (wykorzystano badania mikroskopowe wykonane w Pracowni Petrofizyki IGNiG).

Podobnie badania przepuszczalności fazowej prowadzono na wyselekcjonowanych próbkach reprezentatywnych dla określonych warstw w profilu, mających istotne znaczenie dla określenia zdolności transportowych badanej skały. Najwięcej badań przepuszczalności fazowej przeprowadzono na piaskowcach różnego pochodzenia obejmujących piaskowce mioceneskie, karbońskie, cenomańskie oraz czerwonego spągowca. Chodziło o szeroką reprezentację różnych typów skał piaskowcowych. Materiał ten posłużył jako baza do obliczeń neuronowych (badania przepuszczalności fazowej przeprowadzono w Pracowni Petrofizyki IGNiG).


W obydwu zagadnieniach podstawową rolę w bazie danych odgrywał zbiór parametrów porozymetrycznych wraz z wynikami analizy krzywych kumulacyjnych ciśnień kapilarnych, uzyskany z badań nad skałami węglanowymi dolomitu głównego oraz piaskowcami miocenu, karbonu, cenomanu i czerwonego spągowca (pomiaru porowatości i analizę porozymetryczną oraz przepuszczalność liniową wykonano w Pracowni Petrofizyki IGNiG).

Wszystkie badania laboratoryjne wykonano zgodnie z obowiązującą w PGNiG instrukcją *Wykonywanie analiz petrofizycznych*.

### Zastosowanie sieci neuronowej do odtworzenia parametrów przestrzeni porowej na podstawie badań porozymetrycznych i mikroskopowych dla wydzielonych facji skał węglanowych

Nowym podejściem do badań przestrzeni porowej w przedstawionym zagadnieniu było zastosowanie sieci neuronowej do obliczeń, na podstawie poszerzonej bazy danych, obejmującej mikroskopowe badania szczelinowości, wykonane na szlifach wraz z komputerową analizą obrazu (Anselmetti i in., 1998; Leśniak, 1999)

Jak wspomniano wyżej, badania mikroskopowe są wykonywane w ograniczonych ilościach ze względu na ich czasochłonne przygotowanie. Zaistniała potrzeba znalezienia metody, która pozwoliłaby na odtworzenie bra-



**Ryc. 1.** Ideowy schemat blokowy. Rekonstrukcja parametrów komputerowej analizy obrazu

**Fig. 1.** Block diagram showing reconstruction of computer image analysis parameters.

kujących danych dla całych profili geologicznych na podstawie kompletu danych uzyskanych z innych pomiarów wykonanych na tym samym kawałku rdzenia. Możliwość taką dało zastosowanie sieci neuronowej, która dzięki poprawnej generalizacji na przedstawionych wynikach pozwoliła na uzupełnienie brakujących parametrów, a tym samym na stworzenie spójnego obrazu przestrzeni porowej dla badanego typu skał. Materiał badany stanowiły porowate skały węglanowe dolomitu głównego o szerokim spektrum wykształcenia przestrzeni porowej.

### Metodyka

Obliczenia wykonano w dwóch etapach. W pierwszym etapie bazę danych stanowiły połączone wyniki z porozymetrii otrzymane dla sześćdziesięciu próbek (ryc. 1):

- gęstość objętościowa
- porowatość
- powierzchnia właściwa
- pory > 1 μm
- średnica progowa
- przepuszczalność

i komputerowej analizy obrazu przestrzeni porowej oznaczonej dla dziesięciu próbek:

- objętość ekwiwalentnej kuli
- średnia cięciwa
- kulistość
- wydłużenie

oraz badań mikroskopowych na szlifach cienkich dla sześćdziesięciu próbek:

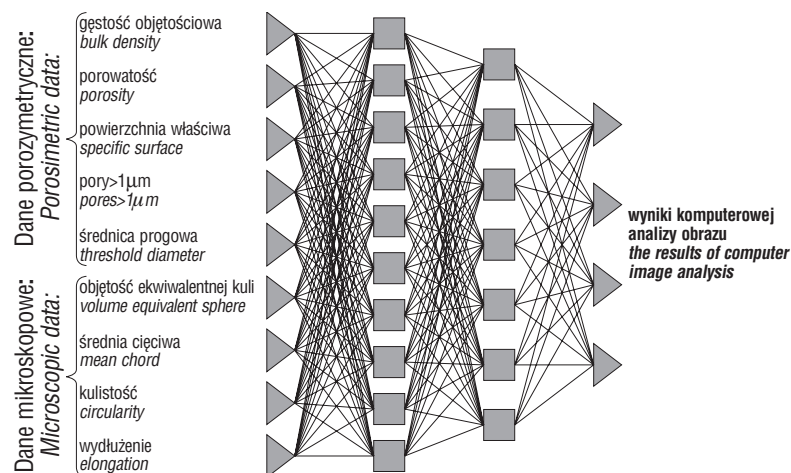
- wskaźnik objętości szczelinowej
- porowatość szczelinową
- przepuszczalność szczelinową

Ponieważ analizę obrazów wykonano jedynie na dziesięciu próbkach, podstawowym zadaniem sieci było uzupełnienie tych danych dla pozostałych pięćdziesięciu próbek. Stworzono więc bazę obliczeniową zawierającą

dziesięć pełnych kompletów danych, tj. dane porozymetryczne i dane z komputerowej analizy obrazu na której wyuczono sieć. Schemat architektury sieci ustalonej w kolejnych etapach uczenia przedstawiono na ryc. 2, gdzie zaznaczono także parametry wejściowe. W sieci zaprojektowano cztery wyjścia odpowiadające czterem parametrom komputerowej analizy obrazu: objętości ekwiwalentnej kuli, średniej cięciwie, kulistości, wydłużeniu, które wymagały uzupełnienia. Następnie w wyniku symulacji na zbiorze testującym uzupełniono poszukiwane parametry. W ten sposób uzyskano pełen zestaw danych dla wszystkich 60 próbek.


Ze względu na małą liczbę kompletnych danych, niemożliwe było wydzielenie zbioru walidacyjnego, na którym sprawdzono poprawność metody w procesie symulacji neuronowej. Należało więc przeprowadzić weryfikację otrzymanych wyników, uciekając się do metod statystycznych na podstawie nowej bazy danych, na której wyuczono nowo skonstruowaną sieć. Ideą takiego postępowania było dołączenie obliczonych parametrów jako parametrów wejściowych wraz z kompletem innych oznaczonych doświadczalnie jako nową bazą danych do nowo skonstruowanej sieci i sprawdzenie wiarygodności tak sporządzonej bazy danych przez porównanie przepuszczalności obliczonej z doświadczalną. Nowa baza danych obejmowała wyniki badań porozymetrycznych, wyliczone w poprzedniej symulacji parametry analizy obrazu i dołączone dodatkowo parametry przestrzeni porowej wyznaczone na szlifach cienkich (wskaźnik objętości szczelinowej, porowatość szczelinową i przepuszczalność szczelinową). W bazie danych wydzielono zbiory uczący i testujący. Wynik stanowiła przepuszczalność liniowa. Architektura sieci przedstawiono na ryc. 3.

Dobra korelacja wyników pozwoliłaby uznać, że otrzymane parametry komputerowej analizy obrazu zostały poprawnie obliczone. Tak więc przygotowaną sieć ponownie wyuczono i przetestowano. Porównano obliczone za

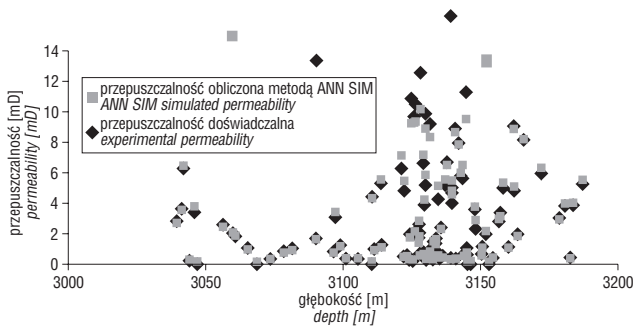


**Ryc. 2.** Schemat perceptronu wielowarstwowego zastosowanego do symulacji mikroparametrów przestrzeni porowej na podstawie badań porozymetrycznych oraz mikroskopowych (komputerowa analiza obrazu).

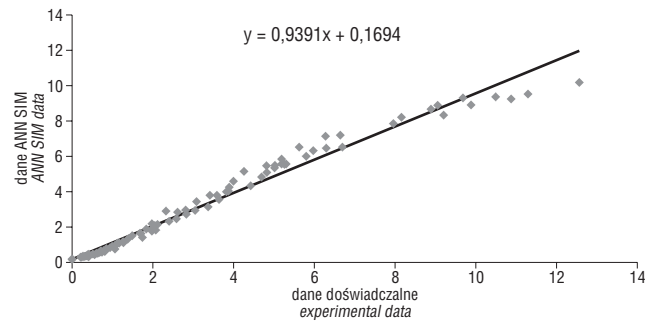
**Fig. 2.** Scheme of multilayer perceptron used for ANN SIM simulations of pore space microparameters based on porosimetric and microscopic investigations (computer analysis of images)



**Ryc. 3.** Schemat perceptronu wielowarstwowego zastosowanego do symulacji przepuszczalności na podstawie badań porozymetrycznych, mikroskopowych oraz na szlifach cienkich  
**Fig. 3.** Scheme of multilayer perceptron used for ANN SIM permeability simulations based on porosimetry, microscopic and thin section data



**Ryc. 4.** Zestawienie przepuszczalności doświadczalnej (czarne romby) oraz obliczonej metodą ANN SIM (popielate kwadraty)  $k = 0,98$   
**Fig. 4.** Comparison of experimental (black rhombs) and ANN SIM simulated (gray squares) permeability ( $k = 0,98$ )




**Ryc. 5.** Korelacja przepuszczalności doświadczalnej z przepuszczalnością obliczoną metodą ANN SIM  
**Fig. 5.** Correlation between experimental and ANN SIM simulated permeability

pomocą sieci neuronowej wyniki przepuszczalności liniowej z otrzymanymi doświadczalnie, wykorzystując metodę równań korelacyjnych. W wyniku przeprowadzonych obliczeń uzyskano wysoki współczynnik korelacji pomiędzy danymi doświadczalnymi a obliczonymi za pomocą sieci neuronowych, który wyniósł 0,98. Współczynnik ten potwierdza poprawność metody.


Na ryc. 4 zostały zestawione wartości przepuszczalności doświadczalnej (romby) i obliczonej za pomocą ANN (kwadraty) w profilu geologicznym. Na rysunku zaznacza się duża zgodność wyników i zachowanie trendów obu przepuszczalności. Wyniki korelacji przedstawiono gra-

ficznie na ryc.5. Ilustrują one poprawność obliczeń, z małymi odchyleniami przy wyższych wartościach przepuszczalności. Sieć neuronową zastosowano do wyznaczenia parametrów petrofizycznych szczelinowo porowatych skał węglanowych.

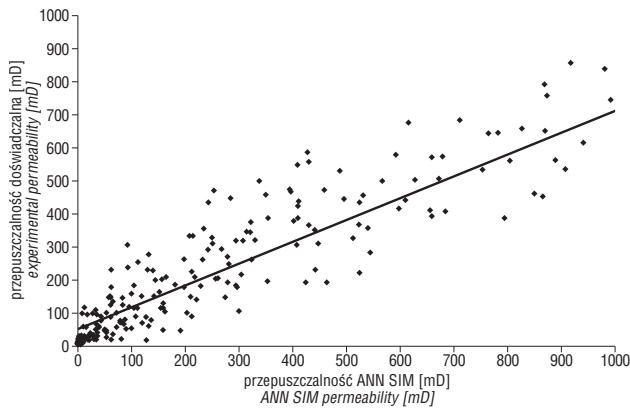
Zastosowana dwuetapowa symulacja, w której w pierwszym etapie za pomocą sieci neuronowej uzupełniono brakujące parametry, a w kolejnej symulacji neuronowej w następnym etapie zweryfikowano otrzymane wyniki, wykazała dobrą jakość dopasowania. Zgodność wyników potwierdził wysoki współczynnik korelacji liniowej wynoszący 0,98.



**Ryc. 6.** Ideowy schemat blokowy. Rekonstrukcja parametrów przepuszczalności względnej  
**Fig. 6.** Block diagram showing reconstruction of relative permeability parameters



**Ryc. 7.** Schemat perceptronu wielowarstwowego zastosowanego do symulacji przepuszczalności liniowej na podstawie badań porozymetrycznych  
**Fig. 7.** Scheme of multilayer perceptron used for ANN SIM simulation of linear permeability based on porosimetric data



**Ryc. 8.** Korelacja przepuszczalności wyliczonej za pomocą ANN SIM z doświadczalną (k = 0,89)  
**Fig. 8.** Correlation between experimental and ANN SIM simulated permeability (k = 0.89)

**Próba korelacji przepuszczalności liniowej z danymi przepuszczalności względnych dla podstawowych typów piaskowców zbiornikowych przy użyciu sztucznej sieci neuronowej**

Kolejne zagadnienie jest poświęcone nowemu zastosowaniu sieci neuronowych jakim jest odtworzenie przebiegu wykresów przepuszczalności fazowych (Oldenzieli in., 2000). Zagadnienie jest istotne ponieważ, ze względu na długotrwałość pomiaru przepuszczalności fazowych, liczba przebadanych próbek jest bardzo mała w stosunku do innych badań. Interpretacja krzywych przepuszczalności fazowych jest o tyle skomplikowana, że wymaga odtworzenia całego szeregu wielkości, a mianowicie przepuszczalności względnych dla poszczególnych faz oraz odpowiadającego im nasycenia rezydualnego (Kruczek i in., 1995). Podobnie jak w poprzednim zagadnieniu podjęto próbę rekonstrukcji brakujących parametrów stosując technikę obliczeniową sieci neuronowych. Aby generalizacja wyników przebiegała prawidłowo jest wymagane posiadanie reprezentatywnego zbioru uczącego. Zbiór taki sporządzono gromadząc wyniki przepuszczalności fazowej w układzie woda-gaz, wykony-

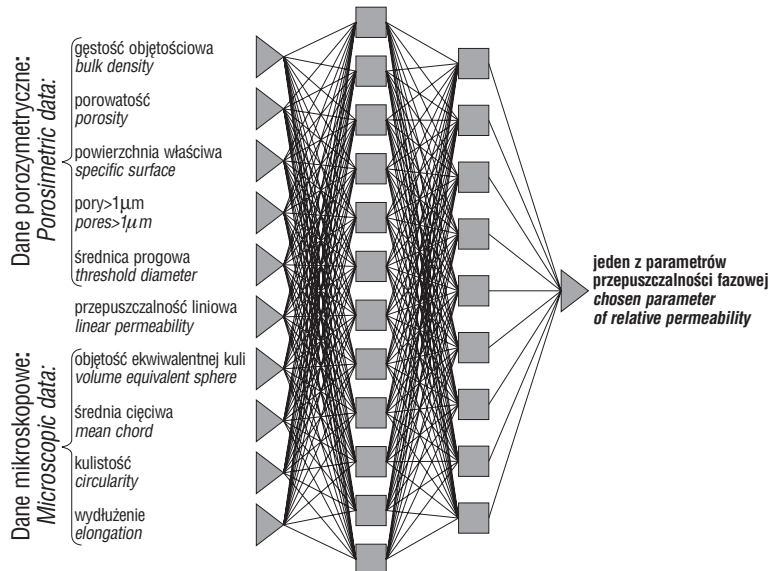
wanych dla podstawowych typów piaskowców zbiornikowych (ryc. 6)

- woda rezydualna
  - woda nieredukowalna
  - przepuszczalność względna dla gazu
  - przepuszczalność względna dla wody
- zaś bazą do interpolacji stały się badania ciśnień kapilarnych:
- gęstość objętościowa
  - porowatość
  - powierzchnia właściwa
  - udział porów większych od 1μm
  - średnica progowa
- oraz
- przepuszczalność efektywna dla gazu.

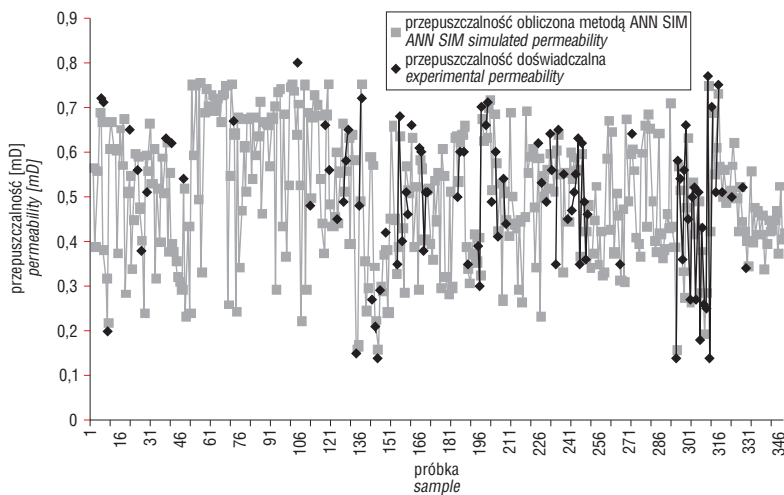
Odwołując się do tak sporządzonej bazy danych uzupełniono parametry przepuszczalności fazowej a następnie sporządzono wykresy fazowe dla każdej próbki.

**Metodyka**

Badania przepuszczalności fazowej, ze względu na ich długotrwałość, prowadzi się na wyselekcjonowanych próbkach reprezentatywnych dla określonych warstw w profilu mających istotne znaczenie dla określenia zdolności transportowych badanej skały. Dlatego też, najczęściej badań przepuszczalności fazowej przeprowadzano na piaskowcach. Materiał ten posłużył jako podstawa do obliczeń neuronowych. Baza danych obejmowała podstawowe typy piaskowców zbiornikowych a mianowicie mioceńskie, karbońskie, cenomańskie oraz czerwonego spągowca. Chodziło o szeroką reprezentację różnych typów skał piaskowcowych. Pierwszy etap obliczeń miał dać odpowiedź na to czy takie zunifikowanie danych jest poprawne. Zastosowano program obliczeniowy NeuralSIM wykorzystujący jako podstawę sieci neuronowe z różnymi algorytmami uczenia.

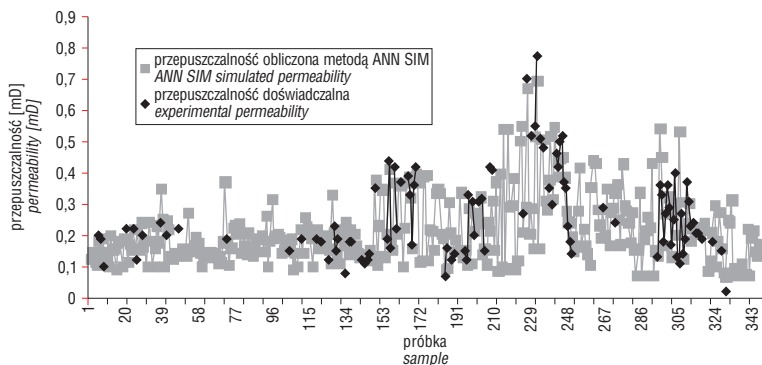


**Ryc. 9.** Schemat perceptronu wielowarstwowego zastosowanego do symulacji przepuszczalności na podstawie badań porozymetrycznych oraz przepuszczalności fazowych  
**Fig. 9.** Scheme of multilayer perceptron used for ANN SIM simulated permeability based on porosimetric and relative permeability data



**Ryc. 10.** Zestawienie maksymalnej przepuszczalności dla gazu obliczonej metodą ANN SIM (szare kwadraty) z doświadczalną (czarne romby)  $k = 0,83$

**Fig. 10.** Comparison of experimental (black rhombs) and ANN SIM simulated (gray squares) maximum permeability for gas ( $k = 0.83$ )



**Ryc. 11.** Zestawienie max. przepuszczalności dla wody obliczonej ANN SIM (popielaty kwadrat) z doświadczalną (czarny romb)  $k = 0,83$

**Fig. 11.** Comparison of experimental (black rhombs) and ANN SIM simulated (gray squares) maximum permeability for water ( $k = 0.83$ )

Ponieważ, jak już wspomniano, liczba pomiarów przepuszczalności fazowej w porównaniu z porozymetryczną analizą rdzeni była znacznie mniejsza, aby poszerzyć bazę danych dołączono do nich wyniki porozymetrii i analizy krzywych kumulacyjnych ciśnień kapilarnych oraz przepuszczalność liniową. Dane te charakteryzują przestrzeń porową wraz z jej zdolnościami transportowymi (Tiab & Donaldson, 1996).

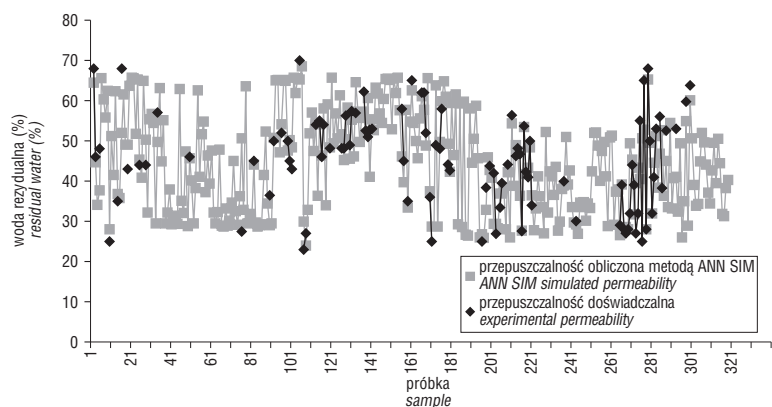
W pierwszej kolejności, aby stwierdzić że piaskowce różne genetycznie nie zakłóca poprawności wyniku należało na bazie danych porozymetrycznych przeprowadzić symulację neuronową i przeanalizować korelację pomiędzy danymi wyjściowymi przepuszczalności liniowej z doświadczalną. Oznaczenie przepuszczalności liniowej nie było możliwe dla wszystkich próbek ze względów technicznych (brak rdzenia), w pierwszym więc etapie zostały wykonane obliczenia mające na celu — za pomocą symulacji neuronowej — uzupełnienie profilu przepuszczalności liniowej. Na bazie danych sporządzonej z parametrów petrofizycznych uzyskanych z badań porozyme-

trycznych wraz z analizą krzywej kumulacyjnej ciśnień kapilarnych oraz przepuszczalnością liniową jako parametrem wyjściowym (ryc. 7) wyliczono za pomocą symulacji neuronowej brakujące przepuszczalności liniowe. Normalną procedurą sporządzono zbiory uczący z wszystkimi znanymi przepuszczalnościami na wyjściu i testujący, w którym parametr wyjściowy był niekompletny. Dobre dopasowanie trendów przepuszczalności (ryc. 8) oraz dobra korelacja obliczona dla znanych wyjściowych (współczynnik korelacji wyniósł 0,89) pozwoliła uznać że sieć wyliczyła poprawne wielkości, a ostateczny wynik można uważać za wiarygodny i zastosować do dalszych obliczeń. Ten etap odpowiedział na postawione pytanie twierdząco: sieć generalizuje poprawnie nawet w przypadku, gdy badany materiał jest różnorodny genetycznie.

Kolejnym etapem było obliczenie za pomocą symulacji neuronowej pozostałych brakujących parametrów przepuszczalności fazowej. Posługując się bazą danych porozymetrycznych, uzupełnioną o wyliczoną przepuszczalność liniową oraz poszerzoną o parametry przepuszczalności fazowej, takie jak: wody nieredukowalnej, wody rezydualnej, przepuszczalności względnej dla gazu oraz przepuszczalności względnej dla wody — wykonano obliczenia za pomocą sieci neuronowej, której architektura została przedstawiona na ryc. 9. Podobnie jak poprzednio skonstruowano zbiory uczący i testujący.

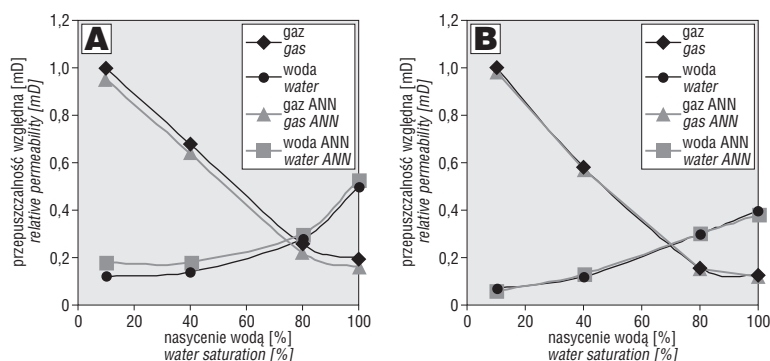
Sieć posiada jeden neuron wyjściowy. W każdej kolejnej symulacji wielkością oczekiwaną na wyjściu był jeden z uzupełnianych parametrów przepuszczalności fazowej. W ten sposób zrekonstruowano parametry fazowe dla wszystkich próbek a otrzymane korelacje zamieszczono na ryc. 10, 11, 12.

Przedstawione wykresy dowodzą, że symulacja neuronowa poprawnie odtwarza trendy w badanym materiale



**Ryc. 12.** Zestawienie wody rezydualnej obliczonej ANN SIM (popielate romby) z doświadczalną (czarne kwadraty)  $k = 0,81$

**Fig. 12.** Comparison of experimental (black rhombs) and ANN SIM simulated (gray squares) values for residual water ( $k = 0.81$ )



**Ryc. 13.** Porównanie krzywych przepuszczalności fazowych doświadczalnej i obliczonej metodą ANN SIM (A — najgorsze dopasowanie, B — najlepsze dopasowanie)

**Fig. 13.** Comparison of experimental and ANN SIM simulated relative permeability curves (A — poor fit, B — the best fit)

rdzeniowym i poprawnie odtwarza zakresy wielkości dla poszczególnych parametrów. Wyliczone parametry przepuszczalności fazowej są wiarygodne i mogą posłużyć do dalszych obliczeń.

Weryfikację otrzymanych wyników przeprowadzono zestawiając krzywe przepuszczalności fazowej dla każdej badanej próbki na podstawie danych doświadczalnych i obliczonych za pomocą sieci neuronowej. Wykreślenie krzywych przepuszczalności fazowych dla próbek o obliczonych parametrach oraz porównanie ich z krzywymi przepuszczalności fazowej wykreślonymi na podstawie danych doświadczalnych potwierdziło poprawność metody symulacji tych parametrów. Przykładowe wyniki przedstawiono na ryc. 13. Na ryc. 13A przedstawiono najgorsze z otrzymanych dopasowań a na ryc. 13B pokazano dobre dopasowanie krzywych przepuszczalności fazowych.

### Podsumowanie

Otrzymane wyniki pokazały, że wieloparametrowa metoda korelacji z zastosowaniem sztucznej sieci neuronowej daje zdecydowanie lepsze wyniki od dotychczas stosowanych klasycznych metod korelacyjnych. Szczególnie dla pomiarów przepuszczalności fazowej ANN stanowi jedyną wiarygodną metodę scharakteryzowania parametrów tej przepuszczalności dla pełnych profili na bazie wyników laboratoryjnych.

W obydwu przeprowadzonych eksperymentach obliczeniowych posłużono się siecią neuronową wielowarstwową, jednokierunkową, z algorytmem propagacji wstecznej, która dzięki swojej architekturze, wykorzystującej wszystkie połączenia pomiędzy neuronami, posiada zdolność dobrej generalizacji w oparciu o tak różnorodną (pochodzącą z niezależnych i dość specyficznych typów analiz) bazę danych jak w przedstawionym zagadnieniu.

Nowym elementem było wprowadzenie dwuetapowej symulacji której pośrednim etapem było uzupełnienie parametrów w badanych profilach, posiłkując się odpowiednio do zagadnienia dobrać bazą danych, a końcowym etapem — weryfikacja danych za pomocą sieci

neuronowej i ostateczne potwierdzenie wiarygodności otrzymanych wyników przez zastosowanie współczynnika korelacji liniowej. Poprawność wyników potwierdza wysoki współczynnik korelacji wynoszący dla badań mikroskopowych na szczelinowo-porowatych skałach węglanowych 0,98, a dla badań przepuszczalności fazowej na różnych typach piaskowców zbiornikowych 0,89. Dla przepuszczalności względnych doskonałą jakość dopasowania ilustrują przykładowo wybrane rysunki o najgorszym i najlepszym dopasowaniu krzywych (ryc. 13).

### Wnioski

Zaprojektowane metody symulacji i architektury sieci stanowią doskonale narzędzie obliczeniowe bazujące na różnorodnym materiale skalnym jakim były zarówno szczelinowo-porowate skały węglanowe jak i różnego typu piaskowce (miocenijskie, karbońskie, cenomańskie oraz czerwonego spągowca), a także na różnych niezależnych analizach laboratoryjnych jak porozymetria wraz z analizą ciśnień kapilarnych, przepuszczalnością liniową i fazową i wreszcie badaniami mikroszczelinowości z komputerową analizą obrazu. Otrzymane wyniki pokazały, że wieloparametrowa metoda korelacji z zastosowaniem sztucznej sieci neuronowej daje zdecydowanie lepsze wyniki od dotychczas stosowanych klasycznych metod korelacyjnych i stanowi wiarygodną metodę scharakteryzowania parametrów dla pełnych profili na bazie wyników laboratoryjnych.

### Literatura

- ANSELMETTI F.S., LUTHI S. & EBERLI G.P. 1998 — Quantitative Characterization of Carbonate Pore Systems by Digital Image Analysis. AAPG Bull., 82: 678–701.
- DARŁAK B., WŁODARCZYK M. & P. SUCH P. 1998 — Metodyka oceny właściwości zbiornikowych skał z zastosowaniem sieci neuronowych. Pr. IGNiG 97.
- KRUCZEK J., SUCH P., DARŁAK B. & LEŚNIAK G. 1995 — Metodyka pomiaru i interpretacja krzywych przepływów fazowych skał zbiornikowych dla ropy naftowej i gazu ziemnego. Pr. IGNiG 86.
- LEŚNIAK G. 1999 — Zastosowanie komputerowej analizy obrazu w badaniach petrofizycznych. Prz. Geol., 47: 644–651.
- MASTERS T. 1996 — Sieci neuronowe w praktyce. WNT, Warszawa.
- MOHAGHEGH S., AREFI R., AMERI S. & ROSE D. 1996 — Petroleum Reservoir Characterization with the Aid of Artificial Neural Networks. SPE 16: 263–274.
- OLDENZIEL T., PAUL DE GROOT. & KVAMME L.B. 2000 — Statford study demonstrates use of NN to predict porosity and water saturation. Industry Feature, 18 February, 2000: 65–69.
- OSOWSKI S. 1996 — Sieci neuronowe. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- ROGERS S.J., CHEN H.C., KOPASKA-MERKEL D.C. & FANG J.H. 1995 — Predicting Permeability from Porosity Using Artificial Neural Network. AAPG Bull., 79: 1786–1797.
- SUCH P., MALISZEWSKA A. & LEŚNIAK G. 2000 — Właściwości filtracyjne utworów górnego czerwonego spągowca a jego wykształcenie facjalne. Pr. IGNiG, 103.
- TADEUSIEWICZ R. 1993 — Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa.
- TIAB D. & DONALDSON E.C. 1996 — Petrophysics. Gulf Publishing Company, Houston.