

Jadwiga Jarzyna, Monika Ujma

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie

Wyznaczanie przepuszczalności skał klastycznych czerwonego spągowca z wykorzystaniem sztucznych sieci neuronowych

Dlaczego przepuszczalność należy do grupy danych rozmytych (*Fuzzy Data*)?

W literaturze petrofizycznej w kraju i na świecie opisano wiele eksperymentalnych metod wyznaczania przepuszczalności [23]. Wiele sposobów określania tego parametru funkcjonuje także w komercyjnych systemach interpretacyjnych stosowanych w geofizyce otworowej. Jednak badacze cały czas poszukują uniwersalnego sposobu wyznaczenia przepuszczalności. Podejście wykorzystujące sztuczne sieci neuronowe, przedstawione w niniejszym artykule, jest jedną z metod wyznaczania przepuszczalności.

Przepuszczalność jest własnością skał, umożliwiającą migrację mediów złożowych przez system porów ośrodka skalnego [13]. Parametr ten zależy od rozmiaru porów, ich kształtu i średnicy oraz łączności hydraulicznej – decydujących o ruchu cieczy lub gazu w skale. Opisuje on nie tylko własności skały, ale również charakter przepływu mediów

w skałach. Przepuszczalność jest parametrem bardzo trudnym do określenia w sposób deterministyczny, ponieważ jest zależna od wielu cech skał, które trudno jest wyznaczyć zarówno w badaniach laboratoryjnych, jak i w ramach interpretacji profilowań geofizyki otworowej [18]. Przepuszczalność silnie zależy od struktury oraz powierzchni właściwej przestrzeni porowej [21]. Kozeny [17] i Carman [4] próbowali określić wzór łączący przepuszczalność i porowatość, ale do chwili obecnej nie udało się sparametryzować wszystkich wielkości występujących we wzorze Kozeny'ego-Carmana [1]. Obserwuje się także związki między przepuszczalnością a porowatością efektywną, nasyceniem wodą związaną (S_{vir}) czy zaileniem. Ze względu na trudne do parametryzacji wielkości, od których zależy ten parametr fizyczny skał, jest on zaliczany do grupy danych rozmytych (*fuzzy data*).

Wskaźnik przepływu, *Flow Zone Index* – przepuszczalność i porowatość

Wskaźnik przepływu (FZI) jest parametrem charakteryzującym zdolność skały do ruchu mediów w jej przestrzeni porowej [1]. Wykorzystanie tego parametru ułatwia obliczanie przepuszczalności na podstawie porowatości efektywnej. Użycie FZI powoduje, że przepuszczalność – obliczona dla jednostek o jednakowych zdolnościach hydraulicznych – jest bardziej wiarygodna. FZI łączy porowatość i przepuszczalność [3, 14, 20] oraz nie wymaga żadnych dodatkowych informacji, które charakteryzują kształt i wielkość przestrzeni porowej skały. Przepuszczalność w zbiorze danych o jednakowym FZI jest dokładniej wyznaczona niż w prostej relacji prze-

puszczalność vs. porowatość dla całego zbioru danych. Jednostki o jednakowych FZI charakteryzują się większym uporządkowaniem relacji K vs. Φ . Do obliczenia FZI wykorzystano wzór łączący przepuszczalność (K) i porowatość efektywną (ϕ_e):

$$FZI = 0,0314 \frac{\sqrt{\frac{K}{\phi_e}}}{1 - \phi_e} \quad (1)$$

We wzorze (1) FZI oznacza wskaźnik przepływu, który jest wielkością bezwymiarową, K – przepuszczalność

fizyczną wyrażoną w mD, ϕ_e jest porowatością efektywną, wyrażoną w ułamku; współczynnik we wzorze (1) wynika z przeliczenia jednostek oraz określenia wielkości występujących we wzorze Kozeny’ego-Carmana i wzorze (1) [1, 5]. Obliczony wskaźnik przepływu wykorzystano jako parametr wejściowy w tworzonych sztucznych

sieciach neuronowych, których celem było wyznaczenie przepuszczalności. Parametr FZI pozwala na podzielenie zbioru danych na jednostki o jednakowych parametrach hydraulicznych (*Hydraulic Units* – HU). Pozwala to na obliczanie przepuszczalności w spójnych pod względem własności zbiornikowych częściach ośrodka skalnego.

Opis materiału badawczego na tle elementów budowy geologicznej rejonu badań

W niniejszej pracy analizowano utwory czerwonego spągowca pochodzące z otworów zlokalizowanych na niżu polskim [9, 14, 19]. Pod względem litologicznym z zestawów danych wyodrębniono piaskowce. Do analiz w głównej mierze wykorzystywano dane z osadów facji eolicznej, natomiast w niektórych przypadkach wykorzystano również dane z osadów facji fluwialnej i plaża.

Podstawą do tworzenia sieci neuronowych były wyniki laboratoryjnych pomiarów porowatości i prze-

puszczalności wykonywane na próbkach pochodzących z rdzeni wiertniczych. W analizowanym obszarze dysponowano zestawami pomiarów geofizyki otworowej, które zawierały wyniki wszystkich profilowań oraz wyniki kompleksowej interpretacji w poszczególnych otworach wiertniczych w funkcji głębokości. W tablicach 1 i 2 przedstawiono wykazy wykorzystanych profilowań geofizyki otworowej i wyniki interpretacji w analizowanych otworach.

Tablica 1. Wykaz profilowań geofizyki otworowej w poszczególnych otworach

Nazwa otworu/ profilowanie	Średnicy [m]	Jądrowe [c/mn]	Akustyczne [μs/m]	PS [mV]	Elektryczne [omm]
Ba-1	+	(PG, PNG)	+	-	(LL3, EL03, EL14, EL28)
Bo-1	+	(PG, PNG)	-	+	(LL3, EL03, EL14, EL28)
Ka-4	+	(PG, PNG)	+	+	(LL3, EL03, EL14, EL28)

PG – profilowanie gamma, PNG – profilowanie neutron gamma, LL3 – profilowanie oporności laterologiem trójelektrodowym, EL03, EL14 i EL28 – profilowania oporności sondami gradientowymi o długości równej odpowiednio: 1,05 m; 4,25 m; 8,5 m

Tablica 2. Wykaz wyników interpretacji w poszczególnych otworach

Nazwa otworu/ profilowanie	PHI	VSH	SW	VANH	VLIM	VDOL	VSAN	PHSW
Bi-1	+	+	+	+	+	-	+	-
Br-2	+	+	+	+	-	+	+	+
Łu-1	+	+	-	+	+	-	+	+
Si-3	+	+	+	+	+	-	+	+
W IG-1	+	+	+	+	+		+	+
Wy Wi-1	+	+	+	+	+	+	+	+


PHI – porowatość ogólna, VSH – zailenie, SW – współczynnik nasycenia wodą w strefie poza obszarem filtracji, VANH, VLIM, VDOL i VSAN – odpowiednio: objętość anhydrytu, wapienia, dolomitu i piaskowca w badanych skalach, PHSW – objętość skały zajęta przez wodę.

Sztuczne sieci neuronowe jako narzędzie badawcze

Sztuczne sieci neuronowe (SSN) stanowią narzędzie matematyczne do przetwarzania danych, zdolne do odwzorowywania złożonych funkcji. SSN stają się coraz bardziej popularne i znajdują zastosowanie w różnych dziedzinach nauki, między innymi w przetwarzaniu i interpretacji danych geofizycznych [2, 6, 15]. Narzędzie to

jest imitacją biologicznych struktur mózgowych i składa się z dużej liczby elementów wzajemnie połączonych, zwanych neuronami [10, 22]. Sieci stosuje się do klasyfikacji, redukcji zakłóceń i do predykcji, co jest tematem niniejszej pracy. Sieci neuronowe mają zdolność do uczenia się, zapamiętywania i generalizowania na podstawie

zbiorów treningowych. Dodatkowo, bardzo dobrze radzą sobie z niespójnymi lub zaszumionymi danymi oraz w nowych, nieprzewidywanych sytuacjach. Wtedy sieci, jako elastyczne narzędzie, wykorzystują wcześniej zdobyte doświadczenia i potrafią dostosować się do nowych sytuacji. Dodatkowo, podczas pracy z sieciami można korzystać z dużych zbiorów danych, ponieważ wszystkie neurony prowadzą obliczenia równoległe, zatem omawiane narzędzie jest wyjątkowo wydajne. Ewentualne uszkodzenie pojedynczego neuronu nie niszczy całej sieci, co czyni jej pracę stabilną. SSN umożliwiają swobodne i łatwe tworzenie modeli nieliniowych, pozwalających na rozwiązywanie trudnych zagadnień, w których nie zawsze intuicyjnie wyczuwalne są związki pomiędzy badanymi parametrami.



Rys. 1. Struktura perceptronu o 3 warstwach [15]

Wśród SSN wyróżniają się sieci jednokierunkowe (*feedforward*), wielowarstwowe, stosunkowo proste w konstrukcji, których działanie jest intuicyjnie łatwe do analizy. Perceptrony wielowarstwowe MLP (*Multi Layer Perceptrons*) posiadają co najmniej jedną ukrytą warstwę

Testowanie sieci dla wyznaczania przepuszczalności

Analiza i selekcja danych

Istotnym czynnikiem podczas korzystania z sieci neuronowych jest dobór danych wejściowych. Zakłada się, że dane wejściowe mają związek z danymi wyjściowymi. W związku z tym, posiadanie odpowiedniej ilości reprezentatywnych danych jest istotnym warunkiem przy tworzeniu sieci. Wprowadzanie do analizy dodatkowych danych, które nie mają związku ze zmiennymi wyjściowymi, ale zwiększają zbiór wejściowy, może obniżać jakość pracy sieci [8].

W niniejszej pracy danymi wejściowymi do tworzenia sieci neuronowych były wielkości rejestrowane podczas pomiarów geofizyki otworowej i wyniki ich interpretacji oraz wyniki pomiarów laboratoryjnych. Natomiast wyniki oznaczeń laboratoryjnych przepuszczalności posłużyły za

neuronów, pomiędzy warstwą wejściową a wyjściową (rysunek 1). Perceptron wielowarstwowy został wykorzystany w niniejszej pracy.

W niniejszej pracy wykorzystano naukę sieci pod nadzorem, czyli na przykładowych danych wprowadzonych przez użytkownika. Warunkiem sukcesu sieci jest praca na danych reprezentatywnych, jak najlepiej opisujących oczekiwane zależności.

Architekturę sieci typu MLP opisać można poprzez podanie liczby warstw i liczby neuronów w każdej warstwie. Dodatkowo organizacja i kontrola obliczeń dla sieci warstwowych jest wyjątkowo efektywna i łatwa, co czyni je sprawnymi obliczeniowo. Za tym idzie szybkość obliczeń i wygoda dla użytkownika [8]. Jednak dobór odpowiedniej ilości warstw ukrytych i neuronów w nich zawartych jest bardzo ważnym czynnikiem w procesie uczenia sieci. W przypadku przyjęcia zbyt małej ilości neuronów ukrytych sieć może mieć istotne problemy z rozwiązaniem zadania, a zbyt duża ich ilość może powodować tzw. „przeuczenie sieci”, czyli znakomite dopasowanie wyników do zbioru uczącego, ale tylko w rozpatrywanym przypadku, bez możliwości powtórzenia doskonałego dopasowania na innym zbiorze danych. Przy przeuczeniu sieci występuje także wydłużenie czasu uczenia. Jednak sieć tego typu z odpowiednio dobraną liczbą warstw i neuronów w warstwach może modelować zależności o niemal dowolnej złożoności. Zatem sieci neuronowe można stosować do wyznaczania wielkości zależnych od wielu czynników, w przypadkach, gdy trudno jest opracować dobrze działający algorytm łączący dane wejściowe i wynik na wyjściu. Przykładem takiego parametru jest przepuszczalność.

zbiór wyjściowy. Pracę rozpoczęto od wybrania reprezentatywnych danych, które posłużyły za parametry wejściowe i wyjściowe w procesie tworzenia sieci. Spośród danych laboratoryjnych dla zgromadzonych otworów wybrano próbki piaskowca. Wykorzystano zestawy danych przedstawione w tablicy 3.

Podstawowe statystyki, wykresy, histogramy i FZI

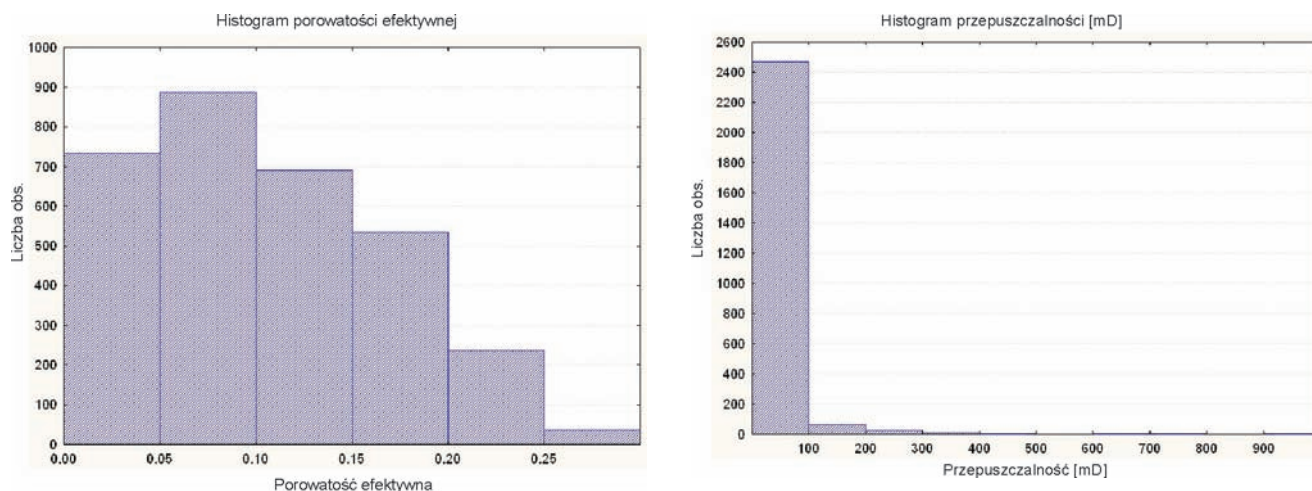
W celu rozpoznania wartości w zbiorach danych laboratoryjnych dla porowatości efektywnej i przepuszczalności obliczono podstawowe statystyki (tablica 4), wykonano histogramy (rysunek 2) oraz wykres rozrzutu (rysunek 3). Dodatkowo, zbadano statystyki regresyjne, w szczególności współczynnik korelacji – R . Na podstawie powyższych wyników odrzucono wartości odstające, sprawdzono normal-

Tablica 3. Wykaz danych wejściowych i wyjściowych w procesie uczenia sieci


Dane wejściowe		Dane wyjściowe
Pomiary laboratoryjne	porowatość efektywna (Φ_e), obliczony parametr przepływu (FZI),	przepuszczalność – K
Profilowania geofizyki otworowej	elektryczne (LL3, EL03, EL14, EL28), jądrowe (PG, PNG), akustyczne (PA), potencjałów polaryzacji naturalnej (PS), średnicy otworu (PŚr)	przepuszczalność z pomiarów laboratoryjnych – K
Wyniki kompleksowej interpretacji profilowań geofizycznych	porowatość ogólna (PHI), zailenie (VSH), współczynnik nasycenia wodą (SW), objętość piaskowca (VSAN), objętość anhydrytu (VANH)	przepuszczalność z pomiarów laboratoryjnych – K

Tablica 4. Podstawowe statystyki danych laboratoryjnych

Zmienne	Statystyki opisowe						
	N ważnych	Średnia arytmetyczna	Średnia geometryczna	Mediana	Minimum	Maksimum	Odchylenie standardowe
Porowatość efektywna	2307	0,10	0,08	0,10	0,01	0,29	0,06
Przepuszczalność [mD]	2307	23,53	1,51	1,10	0,02	1193,20	81,10



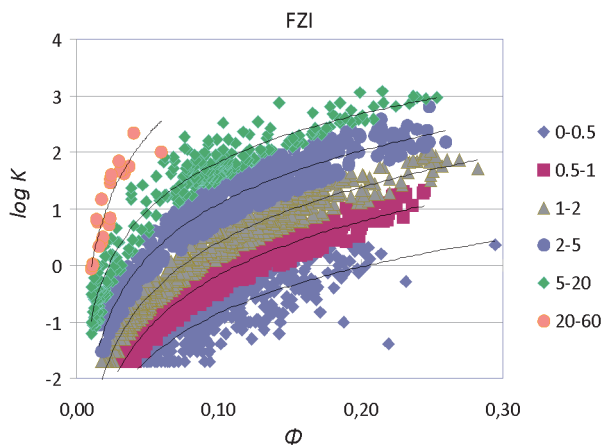
Rys. 2. Histogramy porowatości (po lewej) oraz przepuszczalności (po prawej)



Rys. 3. Wykres rozrzutu logarytmu przepuszczalności i porowatości

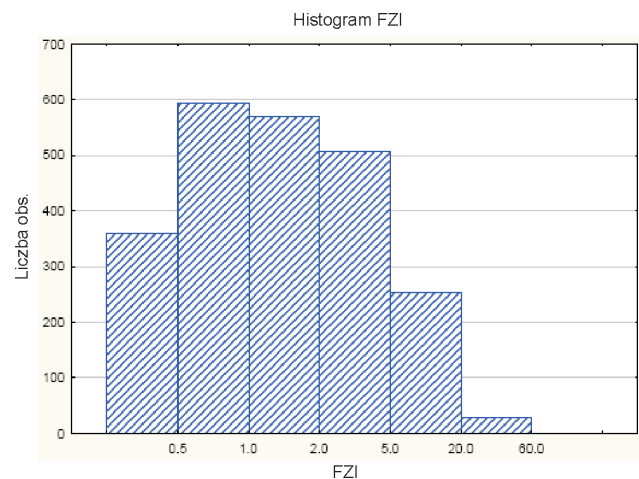
ności rozkładów i wzajemne dopasowanie poszczególnych wielkości (Deutsch, 2002). Podstawowe analizy podjęto celem sprawdzenia, czy zbiór danych petrofizycznych, wykorzystywany w dalszych obliczeniach, spełnia wymogi w zakresie statystycznych parametrów oceny pracy sieci neuronowych.

W ramach wstępnych analiz obliczono także współczynnik *Flow Zone Index* (FZI) na podstawie wzoru 1. W oblicze-



Rys. 4. Wykres rozrzutu $\log K$ vs. Φ dla wyznaczonych współczynników FZI (*Flow Zone Index*)

niach wykorzystano wyniki laboratoryjnych pomiarów przepuszczalności (K) i porowatości efektywnej (Φ). Następnie wartości FZI podzielono na 6 klas. Najlepsze dopasowanie do danych uzyskano dla zależności logarytmicznych typu: $\log K$ vs. Φ (rysunek 4). Następnie dla obliczonych wartości FZI wykonano histogram. Na podstawie histogramu stwierdzono, że najwięcej próbek znajduje się w klasach FZI z przedziałów $0,5 \div 1$, $1 \div 2$ oraz $2 \div 5$.



Rys. 5. Histogram wyznaczonych współczynników FZI (*Flow Zone Index*)

A. Praca z SSN w programie Statistica®

Ocena poprawności sieci, wskaźniki

Istotnym elementem tworzenia sieci neuronowych jest proces walidacji. Proces ten służy do oszacowania jakości rozwiązania uzyskanego przez sieć. W tym celu wykorzystuje się pewną liczbę przypadków uczących, które są przyporządkowywane do oddzielnej grupy. Dane pochodzące z utworzonej grupy nie są bezpośrednio stosowane w trakcie uczenia sieci, natomiast są one wykorzystywane do przeprowadzenia niezależnej kontroli postępów algorytmu uczenia. Podczas uczenia błąd popełniany przez sieć zmniejsza się i, o ile proces uczenia minimalizuje prawidłowo zdefiniowaną funkcję błędu, zmniejsza się także błąd walidacyjny. Po początkowym spadku błędów uczenia i walidacji obserwuje się relatywnie szybszy spadek błędu dla zbioru uczącego i wolniejszy dla zbioru walidacyjnego. Natomiast wzrost błędu walidacyjnego jest dowodem na przeuczenie sieci w zbiorze danych uczących. Tym samym sieć traci zdolność do generalizacji wyników uczenia. W tym wypadku należy zmniejszyć liczbę neuronów ukrytych, ponieważ wykorzystana sieć jest zbyt rozbudowana dla rozpatrywanego zagadnienia, lub ograniczyć ilość epok w procesie uczenia.

Aby ocenić jakość sieci, w procesie jej uczenia używana jest funkcja błędu. Funkcja ta jest miarą zgodności wyniku predykcji sieci z zadaną wartością. Wykorzystywana jest ona do wyznaczenia wielkości niezbędnych zmian wag neuronów w każdej iteracji (epoce uczenia). Jako funkcję błędu można wykorzystywać sumę kwadratów różnic między wynikiem predykcji sieci a zadaną wartością (*Sum of Squares*) o rozkładzie normalnym [8]:

$$E_{SOS} = \sum_{i=1}^N (y_i - t_i)^2 \quad (2)$$

gdzie:

N – liczba przypadków (par wejście-wyjście) używanych do uczenia,

y_i – wynik predykcji sieci (wyjście sieci),

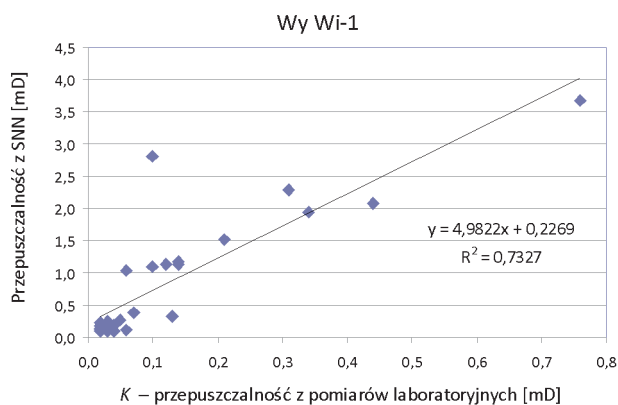
t_i – rzeczywista wartość dla i -tego przypadku.

Do budowy sieci wykorzystano moduł *Automatyczny projektant sieci* (tablica 5), zdając się na w pełni automatyczny dobór danych wejściowych. Samodzielnie konstruowano SSN z użyciem modułu *Projekt sieci użytkownika* (tablica 6), starając się wprowadzać dane wejściowe do

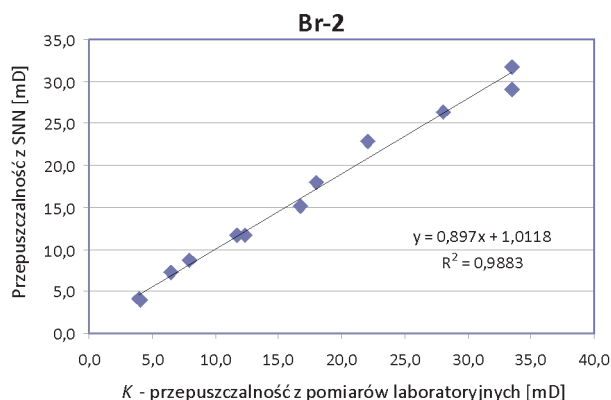
sieci zgodnie z wiedzą petrofizyczną oraz geologiczną dotyczącą parametrów wejściowych. W przeważającej większości przypadków zastosowano losowy wybór danych do zbiorów uczących, testujących i walidacyjnych. Tylko w jednym przypadku zastosowano technikę *bootstrap* [7, 8]. Uczenie sieci przeprowadzono na danych uzyskanych dla piaskowców facji eolicznej. Predykcję wykonano dla utworów facji eolicznej, fluwialnej oraz plai, wykorzystując jedynie sieci o wysokich parametrach.

W przypadku SSN skonstruowanych w programie Statistica® w module *Automatyczny projektant sieci* najlepsze wyniki uzyskano dla sieci PHI_FZI_K, która na wejściu miała porowatość, PHI, FZI oraz przepuszczalność (K), uczonej na danych z facji eolicznej oraz zastosowanej do obliczenia przepuszczalności na zbiorze danych z tej samej

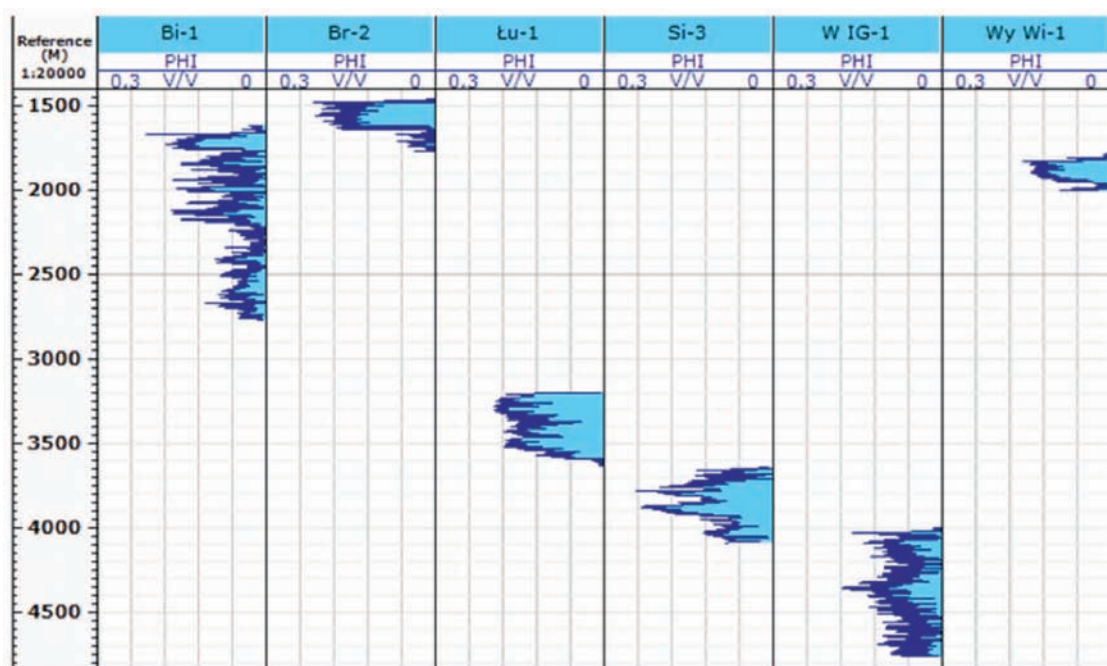
facji. Do utworzenia sieci wykorzystano porowatość z pomiarów laboratoryjnych (Φ) i parametr przepływu (FZI) oraz przepuszczalność (K). W procesie uczenia współczynnik korelacji między przepuszczalnością obliczoną przez sieć i przepuszczalnością z badań laboratoryjnych był równy maksymalnie 0,99, wystąpiły także stosunkowo niewielkie błędy. Z użyciem najlepszej sieci wykonano przewidywanie przepuszczalności w otworach Wy Wi-1 i Br-2, a uzyskane wyniki porównano z laboratoryjnymi pomiarami przepuszczalności dla tych otworów. Uzyskano znaczące współczynniki determinacji, odpowiednio równe $R^2 = 0,73$ dla Wy Wi-1 i $R^2 = 0,99$ dla Br-2 (rysunki 6 i 7). Stwierdzono jednak, że użyteczne może być dostarczenie sieci danych z szerszego zakresu głębokościowego (rysunek 8).



Rys. 6. Wykres rozrzutu K z SNN i z pomiarów laboratoryjnych dla otworu Wy Wi-1



Rys. 7. Wykres rozrzutu K z SNN i z pomiarów laboratoryjnych dla Br-2

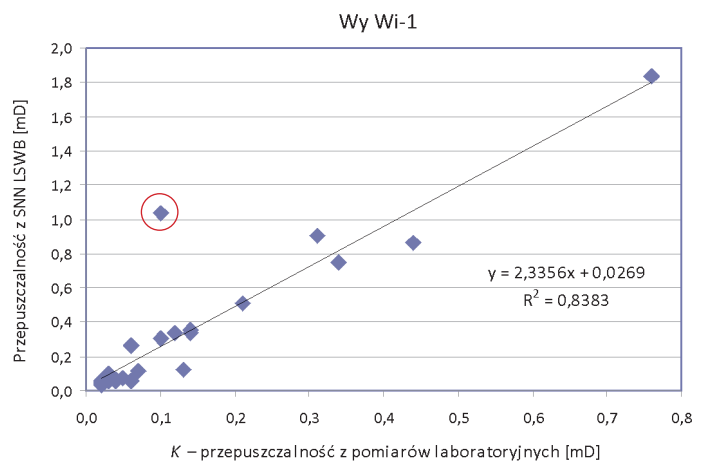


Rys. 8. Zestawienie głębokościowe porowatości PHI z otworów wykorzystanych do tworzenia sieci neuronowych

Wykonano kolejną sieć (LSWB), w której do zestawu uczącego (Łu-1, Si-3 i Wr IG-1) dołączono dane z otworu Bi-1. Kolejnym krokiem było wykonanie przewidywania przepuszczalności w otworze Wy Wi-1. Otrzymano znaczną poprawę wyników, uzyskując $R^2 = 0,83$. Przewidywania przepuszczalności wykonano także w otworze Br-2 i również otrzymano bardzo wysoki współczynnik determinacji, $R^2 = 0,99$. W przewidywaniach dla otworu Wy Wi-1 zauważono też znaczną poprawę korelacji po usunięciu punktu odstającego, zaznaczonego kolorem czerwonym na rysunku 9. Współczynnik determinacji wzrósł z $R^2 = 0,84$ do $R^2 = 0,97$. Stwierdzono, iż odpowiednio dobrany, reprezentatywny zestaw danych wejściowych pozwolił utworzyć prawidłowo działającą sieć.

Sieć LSBW wykorzystano również do predykcji przepuszczalności dla otworów przewierczających utwory facji plaża (otwór Ok-1) i fluwialnej (Sł-1). Uzyskane współczynniki determinacji były znacznie gorsze niż w poprzednich predykcjach (Ok-1 – 0,41, Sł-1 – 0,76). Stwierdzono zatem, iż sieci pracują najlepiej w obrębie facji eolicznej (dla której wykonano uczenie), a wyniki predykcji jedynie dla tej facji są poprawne.

W przypadku SSN opracowanych w module *Projekt sieci użytkownika* dobre wyniki uzyskano dla dwóch sieci, przy uczeniu na danych z facji eolicznej i predykcji przepuszczalności na zbiorze danych z facji eolicznej (tablica 6).




Rys. 9. Wykres rozrzutu przepuszczalności z SNN i z pomiarów laboratoryjnych dla otworu Wy Wi-1 z zaznaczonym punktem określonym jako wartość odstająca

Przetestowano szereg ustawień danych wejściowych (tablica 7). Sieci 1 i 2 dały dobre wyniki, uzyskując wysokie współczynniki korelacji i małe wartości błędów. Dodatkowo wykonano przewidywanie przepuszczalności w otworach Wy Wi-1 i Br-2, uzyskując zadowalające wyniki.

Praca z SSN w programie Techlog®

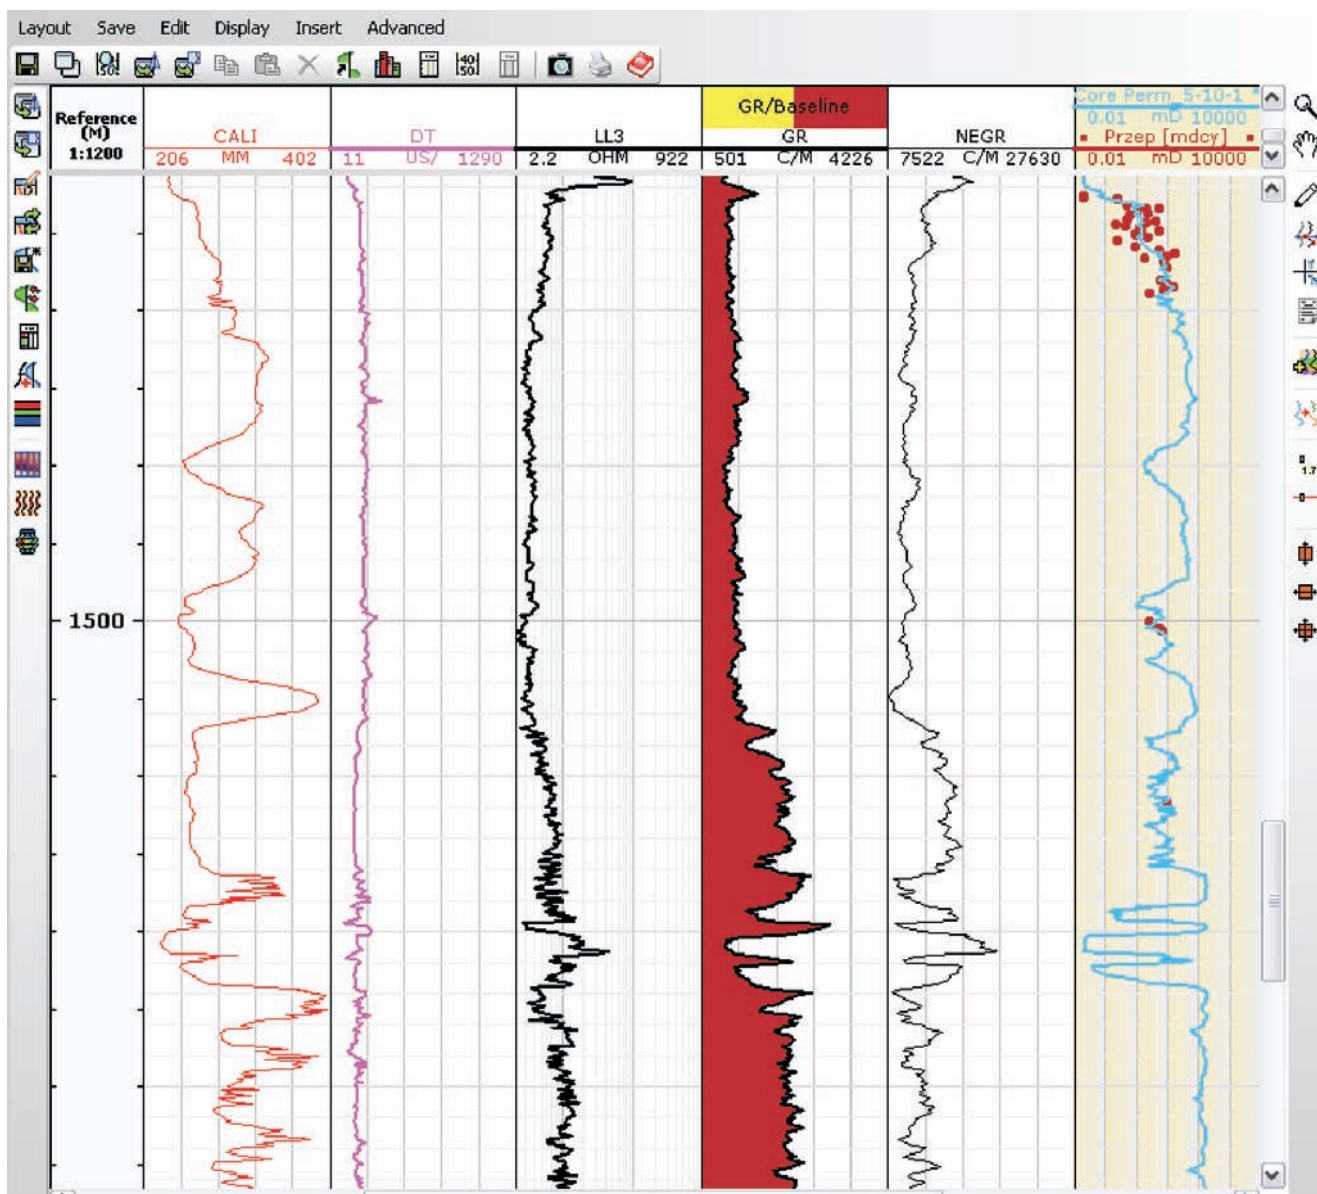
W programie Techlog® utworzono sieci z wykorzystaniem wyników profilowań i interpretacji geofizyki otworowej. Skorzystano z głębokościowego zestawienia



Rys. 10. Wykresy rozrzutu przepuszczalności z pomiarów laboratoryjnych oraz wyznaczonej z użyciem SNN (sieć prof2) dla otworu Ba-1

otworów (rysunek 8) i na jego podstawie dobrano optymalne wykorzystanie otworów. W najkorzystniejszym wariantcie do uczenia wykorzystano dane z otworów Bi-1, Łu-1, Si-3 i Wr IG-1, gdyż pomiary w tych otworach miały duże rozpiętości głębokościowe i pozwalały na utworzenie sieci do wykonania optymalnej predykcji; zarówno dla otworów płytkich, jak i głębokich. Natomiast do walidacji i zaaplikowania zastosowano dane z otworów Wy Wi-1 i Br-2. Najlepszy wynik uzyskano dla sieci 1 i 3 (tablica 8), wykorzystujących następujące zestawy parametrów: Φ_e , FZI, K oraz Φ_e , VSH, FZI, K. Dodanie do parametrów wejściowych innych wyników kompleksowej

interpretacji nie wpłynęło na ich poprawę (tablica 8). Sieci skonstruowane z wykorzystaniem jedynie wyników profilowań dały efekty średniej jakości (rysunek 10). Przyczyną stosunkowo słabych wyników mógł być nierównomierny rozkład danych (rysunek 11) oraz fakt, że dane uczące obejmowały podobne zestawy porowatości i przepuszczalności. Zaletą modułu do tworzenia SSN w programie Techlog®, obok łatwości operowania danymi w postaci wyników profilowań geofizyki otworowej zapisanych jako zależności parametrów w funkcji głębokości, jest grafika dobrze ilustrująca wyniki uzyskane z wykorzystaniem SSN na tle wyników profilowań geofizyki otworowej.



Rys. 11. Wykres profilowań wejściowych, laboratoryjnych pomiarów przepuszczalności oraz przepuszczalności obliczonej z SSN (sieć prof2) dla otworu Ba-1

B. Prezentacja wybranych wyników dla SSN z programu Statistica i programu Techlog

W pracy przedstawiono wybrane wyniki testów wykonanych z użyciem różnorodnych danych oraz sposobów konstrukcji sieci. Przedstawiono wyniki uzyskane z użyciem powszechnie występujących danych, nawet w starszych otworach, tj. profilowań oporności gamma,

neutronowego i wyników kompleksowej interpretacji. Nie wykonano porównania współczynników przepuszczalności wyznaczonych z użyciem SSN z wynikami uzyskanymi wzorem Zawisy [25], ze względu na brak takich wyników we wszystkich otworach wykorzystywanych w badaniach.

Tablica 5. Podsumowanie obliczeń w programie Statistica®, dla modułu *Automatyczny projektant sieci*

Nazwa sieci	Metoda próbkowania	Dane	Otwory		Facja	Uwagi
			uczenie	predykcja		
Automatyczny projektant sieci						
PHI_FZI_K	losowa	Φ_e, K, FZI	Łu-1, Si-3, Wr IG-1	Wy Wi-1, Br-2, Bi-1	eoliczna	wysoka jakość
LSWB	losowa	Φ_e, K, FZI	Łu-1, Si-3, Wr IG-1, Bi-1	Wy Wi-1, Br-2, Si-1, Ok-1	eoliczna, fluwialna, plaja	lepsze wyniki niż dla sieci PHI_FZI_K, przewidywanie dla facji fluwialnej i facji plaja dało słabe wyniki
PHI_FZI_K bootstrap	<i>bootstrap</i>	Φ_e, K, FZI	Łu-1, Si-3, Wr IG-1	Wy Wi-1, Br-2	eoliczna	większe błędy niż dla sieci PHI_FZI_K

Tablica 6. Podsumowanie obliczeń w programie Statistica®, dla modułu *Projekt sieci użytkownika*

Nazwa sieci	Metoda próbkowania	Dane i algorytm uczenia	Otwory		Facja	Uwagi
			uczenie	predykcja		
Projekt sieci użytkownika						
1	losowa	Φ_e, K, FZI , algorytm BFGS	Łu-1, Si-3, Wr IG-1, Bi-1	Wy Wi-1, Br-2	eoliczna	wysokie współczynniki korelacji i małe wartości błędów uczenia i walidacji
2	losowa	Φ_e, K, FZI , algorytm BFGS	Łu-1, Si-3, Wr IG-1, Bi-1	Wy Wi-1, Br-2	eoliczna	wysokie współczynniki korelacji i małe wartości błędów uczenia i walidacji
3	losowa	Φ_e, K, FZI , algorytm najszybszego spadku	Łu-1, Si-3, Wr IG-1, Bi-1	-	eoliczna	bardzo duże błędy uczenia
4	losowa	Φ_e, K, FZI , algorytm gradientów sprzężonych	Łu-1, Si-3, Wr IG-1, Bi-1	-	eoliczna	zadowalające wyniki uczenia

Tablica 7. Ustawienia wejściowe sieci użytkownika w programie Statistica®, dla modułu *Projekt sieci użytkownika*

Lp.	Typ sieci	Funkcja aktywacji		Liczba neuronów	Algorytm uczenia	Uwagi
		Neurony ukryte	Neurony wyjściowe			
1	MLP	logistyczna	wykładnicza	3	BFGS	
2	MLP	logistyczna	wykładnicza	5	BFGS	
3	MLP	logistyczna	wykładnicza	3	Najszybszego spadku	b. duże błędy
4	MLP	logistyczna	wykładnicza	3	Gradyenty sprzężone	

Tablica 8. Podsumowanie obliczeń w programie Techlog®, dla wyników pomiarów laboratoryjnych i kompleksowej interpretacji profilowań geofizyki otworowej

Nazwa sieci	Dane	Otwory			Facja	Uwagi
		uczenie	walidacja	predykcja		
Wyniki pomiarów laboratoryjnych i kompleksowej interpretacji profilowań geofizyki otworowej						
1	Φ_e, K	Bi-1, Łu-1, Si-3, Wr IG-1	Br-2, Wy Wi-1	Br-2, Wy Wi-1	eoliczna	wysokie współczynniki korelacji
2a, 2b, 2c	PHI, VSH, K ,	Łu-1, Si-3	Wr IG-1	-	eoliczna	słaba jakość
3	PHI, VSH, FZI, K	Bi-1, Łu-1, Si-3, Wr IG-1	Br-2, Wy Wi-1	Br-2, Wy Wi-1	eoliczna	słaba jakość
3a, 3b	Φ_e , VSH, FZI, K	Bi-1, Łu-1, Si-3, Wr IG-1	Br-2, Wy Wi-1	Br-2, Wy Wi-1	eoliczna	bardzo dobra jakość
4	Φ_e , VSH, FZI, K , VSAN, VANH, SW	Bi-1, Łu-1, Si-3, Wr IG-1	Br-2, Wy Wi-1	Br-2, Wy Wi-1	eoliczna	bardzo dobra jakość, jednak nie ma znacznej poprawy w stosunku do wcześniejszych wyników

Tablica 9. Podsumowanie obliczeń w programie Techlog®, dla wyników profilowań geofizyki otworowej

Nazwa sieci	Dane wejściowe	Otwory	Facja	Uwagi
		uczenie		
Wyniki profilowań geofizyki otworowej				
prof1	PG, PNG, PA, PS, LL3, EL03, EL14, EL28, PŚr	Ka-4	eoliczna	słaba jakość ze względu na małą ilość laboratoryjnych pomiarów przepuszczalności w interwale głębokościowym, w którym wykonane zostały profilowania geofizyki otworowej
prof2	PG, PNG, PA, PS, LL3, EL03, EL14, EL28, PŚr	Ba-1, Ka-4	eoliczna	średnia jakość
prof3	PG, PNG, PA, PS, LL3, PŚr	Ka-4, Bo-1	eoliczna	średnia jakość
prof4	PG, PNG, PA, PS, LL3, EL03, EL14, EL28, PŚr	Ba-1, Ka-4	eoliczna	średnia jakość
prof5	PG, PNG, PA, PS, LL3, EL03, EL14, EL28, PŚr	Ka-4, Bo-1	eoliczna	średnia jakość

Podsumowanie wyników

Niniejsza praca miała na celu przygotowanie efektywnej metody wyznaczania przepuszczalności skał z wykorzystaniem sztucznych sieci neuronowych na podstawie dostępnych wyników badań laboratoryjnych i wyników pomiarów oraz interpretacji geofizyki otworowej. Prace badawcze nad wyznaczaniem przepuszczalności cały czas zmierzają do opracowania metodyki pozwalającej ograniczyć konieczność wykonywania kosztownych badań laboratoryjnych do niezbędnego minimum. Przedstawione opracowanie dostarczyło metodykę, która może być wykorzystana na istniejących zbiorach danych do weryfikacji już znanych wyników oraz może być stosowana do wyników nowych pomiarów.

Dane pochodziły z utworów czerwonego spągowca facji eolicznej, fluwialnej i plaża z niżu polskiego. Były to

wyniki badań laboratoryjnych oraz starszego typu wyniki profilowań geofizyki otworowej, wykonane w latach 70. i 80. XX w. Istotnym aspektem w uzyskaniu dobrych wyników było wykorzystanie wskaźnika przepływu FZI (*Flow Zone Index*), którego obliczenie pozwoliło na wydzielenie jednostek o jednakowych zdolnościach przepływu mediów.

Równie istotne okazało się wykonanie wstępnej statystycznej analizy danych przed wyborem wielkości wejściowych do sieci neuronowych, dzięki której odrzucono wartości odstające i wybrano reprezentatywne wielkości, dobrze opisujące zależności zachodzące między parametrami zbiornikowymi.

Skorzystano z sieci MLP (*Multi Layer Perceptron*) z algorytmem uczenia z nauczycielem, z wykorzystaniem wstecznej propagacji błędu, który zapewnił minimaliza-

cję błędu działania sieci. Uczenie sieci przeprowadzono w obrębie utworów facji eolicznej, natomiast predykcję wykonano w głównej mierze dla facji eolicznej oraz w mniejszym stopniu dla facji fluwialnej i plaża. Liczba wykorzystanych cykli uczenia powinna być dobrana tak, aby sieć była jak najwyższej jakości, a jednocześnie nie doszło do jej przeuczenia. Dodawanie warstw ukrytych w większości wypadków nie poprawiało jakości wyników.

W przypadku programu Statistica® stwierdzono, że wykorzystanie modułu *Automatyczny projektant sieci* pozwoliło na uzyskanie dobrej jakości sieci, natomiast w przypadku modułu *Projekt sieci użytkownika* jakość wyników nie była lepsza, a praca z tym modułem była bardziej czasochłonna. Lepsze wyniki uzyskano dla losowej metody próbkowania, a dodawanie warstw ukrytych nie wносиło znaczących zmian w uzyskiwanych wynikach.

Stwierdzono, iż najlepsze wyniki predykcji uzyskiwano w obrębie facji eolicznej, natomiast dla facji fluwialnej i plaża sieć nie zawsze dawała zadowalające efekty. Przy-

czyną takiego zachowania sieci było wykorzystanie do uczenia danych pochodzących wyłącznie z facji eolicznej.

W programie Techlog®, podobnie jak w programie Statistica®, stwierdzono, że najlepsze wyniki uzyskano w przypadku wykorzystania wyników bezpośrednich pomiarów laboratoryjnych i wyników interpretacji geofizyki otworowej, wraz ze wskaźnikiem FZI.

Przedstawione w niniejszej pracy podejście do obliczania przepuszczalności może być wykorzystywane do określania zdolności hydraulicznych skał. Wiedza na ten temat jest bardzo istotna w aspekcie zwiększenia możliwości efektywnego poszukiwania i eksploatacji węglowodorów w coraz bardziej skomplikowanych warunkach złożowych. Dodatkowo, uzyskane wyniki mogą mieć znaczenie przy poszukiwaniu i eksploatacji wód pitnych, mineralnych i geotermalnych. Także badanie skał, które potencjalnie mogą tworzyć podziemne magazyny CO₂ jest dodatkowym, bardzo istotnym zastosowaniem opracowanej metodyki.

Spis symboli

K	– przepuszczalność [mD]
Φ_e	– porowatość efektywna [%, v/v], v/v – ułamek
FZI	– wskaźnik przepływu (<i>Flow Zone Index</i>) [v/v]
PHI	– porowatość ogólna [%, v/v]
VSH	– zailenie [%, v/v]
SW	– współczynnik nasycenia wodą w strefie poza obszarem filtracji [%, v/v]
VANH	– objętość anhydrytu [%, v/v]
VLIM	– objętość wapienia [%, v/v]
VDOL	– objętość dolomitu [%, v/v]
VSAN	– objętość piaskowca w badanych skałach [%, v/v]
PHSW	– objętość skały zajęta przez wodę [%, v/v]
PG	– profilowanie gamma [API]

PNG	– profilowanie neutron gamma [%]
LL3	– profilowanie oporności laterologiem trójelektrodowym [omm]
EL03	– profilowanie oporności sondą gradientową o długości 1,05 m [omm]
EL14	– profilowanie oporności sondą gradientową o długości 4,25 m [omm]
EL28	– profilowanie oporności sondą gradientową o długości 8,5 m [omm]
PA	– profilowanie akustyczne [μ s/m]
PS	– profilowanie potencjałów polaryzacji naturalnej [mV]
PŚr	– profilowanie średnicy otworu [mm]

Literatura

- [1] Amaefule J.O., Altunbay M., Tiab D., Kersey D.G., Kelan D.K.: *Enhanced reservoir description: Using core and log data to identify hydraulic (flow) units and predict permeability in uncored intervals/wells*: SPE Paper 26436, 1993, s. 1–16.
- [2] Aminzadeh F., De Groot P.: *Neural networks and other soft computing techniques with applications in the oil industry*. EAGE Publications. 2006.
- [3] Bała M., Jarzyna J.: *Określanie współczynnika przepuszczalności skał na podstawie czasów interwałowych fali Stoneleya*. „Nafta-Gaz” 2004, nr 2, s. 97–103.
- [4] Carman P.C.: *Fluid Flow through Granular Beds*. Trans. Inst. Chem. Eng., 1937, vol. 15, s. 150–167.
- [5] Corbett P.W.M., Ellabard Y., Mohammed K.: *Global Hydraulic Elements-Elementary Petrophysics for Reduced Reservoir Modeling*. EAGE 65th Conference and Exhibition. Stavanger. F-26. 2003.
- [6] Darlak B.: *Ocena możliwości wprowadzenia sieci neuronowych w badaniach petrofizycznych*. „Nafta-Gaz” 1997, nr 7–8.
- [7] Deutsch C.V.: *Geostatistical reservoir modeling*. University Press. Oxford 2002.
- [8] *Elektroniczny Podręcznik Statistica* (2011), EPS (2011) StatSoft Polska, EPS, 2011.
- [9] Górecki W., Papiernik B., Bała M., Jarzyna J., Krawiec J., Puskarczyk E. i in.: *Zasoby prognostyczne, nieodkryte*

potencjal gazu ziemnego w utworach czerwonego spągowca i wapienia cechsztyńskiego w Polsce. Sprawozdanie z projektu finansowanego z NFOŚiGW, umowa nr 562/2005/wN-06/FG-sm-tx/D, 2009.

- [10] Horzyk A.: *Nowe metody uczenia sieci neuronowych bez sprzężeń zwrotnych*. Praca doktorska napisana pod kierunkiem prof. zw. dr. hab. inż. Ryszarda Tadeusiewicza, AGH. Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki. 2001.
- [11] Jarzyna J., Bała M.: *Zależności między parametrami petrofizycznymi klastycznych skał karbońskich w basenie lubelskim na przykładzie obszaru Stężycy*. „Kwartalnik AGH Geologia” 2005, t. 31, zes. 3–4, s. 337–355.
- [12] Jarzyna J., Prętka J.: *Zastosowanie sztucznych sieci neuronowych do wyznaczania przepuszczalności skał na podstawie danych otworowych z rejonu Dzików–Wola Obszańska w północno-wschodniej części zapadliska przedkarpackiego*. „Biuletyn PIG” 2010, 439: 399–402.
- [13] Jarzyna J., Bała M., Zorski T.: *Metody geofizyki otworowej – Pomiar i interpretacja*. Wydawnictwo AGH. Kraków 1999.
- [14] Jarzyna J., Ha Quang M.: *Podział skały zbiornikowej na jednostki o jednakowych własnościach hydraulicznych dla udokładnienia wyznaczania przepuszczalności przy modelowaniu przepływów w złożu gazu*. „Przegląd Geologiczny” 2009, vol. 57, nr 11, s. 996–1003.
- [15] Jarzyna J., Opyrchał A., Mozgowej D.: *Sztuczne sieci neuronowe dla uzupełnienia danych w geofizyce otworowej – wybrane przykłady*. „Kwartalnik AGH Geologia” 2007, t. 33, zes. 4/1, s. 81–102.
- [16] Jarzyna J., Puskarczyk E., Bała M., Papiernik B.: *Variability of the Rotliegend sandstones in the Polish part of the Southern Permian Basin – permeability and porosity relationships*. „Annales Societatis Geologorum Poloniae” 2009, 79:13–26.
- [17] Kozeny J.: *Über Kapillare Leitung des Wassers im Boden*, *Sitzungsberichte: Royal Academy of Science, Vienna, Proc. Class I* (1927) vol. 136, s. 271–306.
- [18] Plewa S., Plewa M.: *Petrofizyka*. Wydawnictwa Geologiczne. Warszawa 1992.
- [19] Poszytek A.: *Sedimentary Processes Diversifying of Reservoir Properties of The Upper Rotliegend Deposits in the Fore-Sudetic Monocline*. EAGE 69th Conference & Exhibition – London, UK, 11–14 June 2007.
- [20] Prasad M.: *Velocity-permeability relations within hydraulic units*. „Geophysics” 2003, vol. 68, No. 1, s. 108–117.
- [21] Such P., Leśniak G.: *Warunki konieczne i wystarczające do up-scalingu danych petrofizycznych*. „Nafta-Gaz” 2006, nr 11.
- [22] Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza. Warszawa 1993.
- [23] Tiab D., Donaldson E.C.: *Petrophysics, Theory and Practice of Measuring Reservoir Rock and Fluid Transport Properties*. Elsevier, N.Y., 899 s. (sec. ed.), 2000.
- [24] Ujma M.: *Wyznaczanie przepuszczalności skał w jednostkach o jednakowych zdolnościach przepływu mediów z wykorzystaniem sztucznych sieci neuronowych*. Praca magisterska. Biblioteka Wydziału Geologii, Geofizyki i Ochrony Środowiska AGH, 2011.
- [25] Zawisza L.: *Simplified method of absolute permeability estimation of porous beds*. „Archives of Mining Sciences” 1993, vol. 38, No. 4, s. 343–352.



Jadwiga JARZYNA – ukończyła studia w specjalności geofizyka stosowana na Wydziale Geologiczno-Poszukiwawczym AGH. Zajmuje się wyznaczeniem własności fizycznych skał – przede wszystkim zbiornikowych i sprężystych, na podstawie pomiarów geofizyki otworowej i badań laboratoryjnych oraz doskonalą metody kompleksowej interpretacji profilowań geofizyki otworowej.



Monika UJMA – w 2011 roku ukończyła studia o specjalności geofizyka poszukiwawcza na Wydziale Geologii, Geofizyki i Ochrony Środowiska na Akademii Górniczo-Hutniczej. We wrześniu 2011 roku rozpoczęła pracę w firmie BG Group jako petrofizyk.