

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO WYZNACZANIA PRZEPUSZCZALNOŚCI SKAŁ NA PODSTAWIE DANYCH OTWOROWYCH Z REJONU DZIKÓW-WOLA OBSZAŃSKA W PÓŁNOCNO-WSCHODNIEJ CZĘŚCI ZAPADLIKA PRZEDKARPACKIEGO

ARTIFICIAL NEURAL NETWORKS APPLYING FOR DETERMINING THE ABSOLUTE ROCK PERMEABILITY ON THE BASIS OF DATA FROM BOREHOLES SITUATED ON THE DZIKÓW-WOLA OBSZAŃSKA AREA (NORTHEASTERN PART OF THE CARPATHIAN FOREDEEP BASIN)

JADWIGA JARZYNA¹, JOANNA PRĘTKA²

Abstrakt. Zbadano zdolność sztucznych sieci neuronowych SNN do oceny przepuszczalności absolutnej skał. Do tego celu wykorzystano dane z pięciu otworów wiertniczych, zlokalizowanych w północno-wschodniej części zapadliska przedkarpackiego: Dzików 16, 17, 20 oraz Wola Obszańska 10 i 15. Modele neuronowe stworzono na podstawie wyników badań laboratoryjnych próbek skał pobranych w wymienionych otworach, profilowań geofizyki otworowej oraz wyników kompleksowej interpretacji tych profilowań. Otrzymano SSN, służącą do odtwarzania wartości przepuszczalności całkowitej, określonej w laboratorium. Następnie model neuronowy wdrożono do estymowania przepuszczalności w otworze wiertniczym DZ17, przenosząc tym samym rozpoznane wcześniej zależności na nowy zbiór danych. Sieci neuronowe mogą stanowić alternatywę dla klasycznych metod wyznaczenia przepuszczalności skał.

Słowa kluczowe: przepuszczalność skał, sztuczne sieci neuronowe SSN, selekcja danych wejściowych, profilowania geofizyki otworowej.

Abstract. The absolute rock permeability was determined with the use of artificial neural networks (ANN). Authors checked up ANN ability to determine permeability on the data from five borehole located in northeastern part of the Carpathian Foredeep: Dzików 16, 17, 20 and Wola Obszańska 10 and 15. Neural models were built on the basis of results from laboratory tests, well logs data and the results of the comprehensive interpretation. ANN provided good results in estimating laboratory permeability. The best neural network was applied on similar data set from DZ17 borehole to show that complicated links between input variable and absolute permeability can be used for prediction of permeability from another data. It is hard to find definite deterministic model for permeability estimation so neural model gained in training process is an alternative method.

Key words: rock permeability, Artificial Neural Networks ANN, input data selection, well logging.

WSTĘP

Przepuszczalność skał (K) jest jednym z parametrów zbiornikowych określających zdolność skał do ruchu mediów złożowych w systemie porów przy gradiencie ciśnienia. Najdokładniejszą bezpośrednią metodą określania przepuszczalności są badania laboratoryjne próbek pobranych z rdzeni, jednak ich wysokie koszty powodują, że uzyskana

informacja jest fragmentaryczna/punktowa (Plewa, Plewa, 1992). Pośrednie sposoby oceny przepuszczalności absolutnej oraz przepuszczalności względnych są oparte na związkach korelacyjnych z innymi właściwościami skał, najczęściej porowatością efektywną oraz z wielkościami charakteryzującymi MRJ. Zjawisko przepuszczalności jest

¹ Akademia Górniczo-Hutnicza, Wydział Geologii, Geofizyki i Ochrony Środowiska, Katedra Geofizyki, al. Mickiewicza 30, 30-059 Kraków; e-mail: jarzyna@uci.agh.edu.pl

² Geofizyka Kraków Sp. z oo., ul. Łukasiewicza 3, 31-429 Kraków; e-mail: joanna.pretka@geofizyka.krakow.pl

uwarunkowane wieloma parametrami petrofizycznymi, których wpływ jest trudny do opisanego metodami deterministycznymi. Ponadto większość empirycznych wzorów ustalono dla określonych formacji geologicznych i dlatego ich zastosowanie nie daje dobrych wyników w przypadku innych skał lub rejonów. Sztuczne sieci neuronowe SSN stanowią alternatywę dla metod pośrednich. Krzywe profilowań geofizycznych niosą informacje o właściwościach fizycznych skał i wraz z wynikami interpretacji pomiarów

mogą służyć jako informacje wejściowe do sieci neuronowych. Przy tworzeniu modeli neuronowych wykorzystuje się również wyniki badań laboratoryjnych na próbkach skał. W artykule pokazano wybraną SSN oraz jej zdolność do szacowania przepuszczalności, na podstawie danych pochodzących z pięciu otworów wiertniczych, zlokalizowanych w północno-wschodniej części zapadliska przedkarpackiego: Dzików 16, 17, 20 oraz Wola Obszańska 10 i 15 (Prętka, 2009).

DANE WEJŚCIOWE DO SSN

W pierwszym etapie badań obliczono w profilach otworów przepuszczalność absolutną na podstawie wzoru Zawiszy:

$$K = C \cdot \phi^{m+1} (1 - S_{wir})^2$$

Łączy on przepuszczalność (K) z porowatością całkowitą (ϕ) i zawartością wody nieredukowalnej (S_{wir}). Uwzględnia również współczynnik zależny od stopnia cementacji spoiwa (m) i stałą C , które ustalono w procesie kalibracji dla omawianego rejonu zapadliska przedkarpackiego (Zawisza, 1994). Wartości przepuszczalności K_{Zaw} stanowiły podstawę dowiązania głębokościowych wyników laboratoryjnych K_{lab} do wyników profilowań i ich interpretacji. Powstała w ten sposób baza danych posłużyła do uczenia SSN, poszczególne próbki stanowiły poprawne przykłady rozwiązania postawionego zadania (łącznie 55 przypadków ze wszystkich analizowanych otworów). W obrębie tego zbioru wydzielono losowo przypadki uczące (trenowanie sieci), przypadki walidacyjne (kontrola uczenia sieci), przypadki testowe (ostateczny test jakości sieci).

Danymi wejściowymi były profilowania: gamma (PG), neutronowe (NPHI, PNNt), akustyczne (PA), średnicy (PŚr), potencjałów naturalnych (PS), oporności (LL3, ILa, EN16,

EN64, EL14, EL28), a także ilorazy oporności zmierzonych sondami potencjałowymi i gradientowymi o różnym zasięgu radialnym (EN64/EN16) i (EL28/EL14). Ponadto na wejściu umieszczono wyniki interpretacji: porowatość całkowitą (PHI) oraz objętość składników mineralnych (zawartość piaskowca – V_{psc} , iłu – $Vił$, wapienia i/lub anhydrytu – V_{wa}). Duża liczba wejść powodowała, że wygenerowane sieci neuronowe były bardzo rozbudowane, o skomplikowanej sieci połączeń między neuronami. Aby taka sieć dobrze funkcjonowała, potrzebny jest odpowiednio obszerny zbiór uczący. Ze względu na niewielką liczbę próbek, na których laboratoryjnie określono przepuszczalność, sieć należało uprościć. Wykonano analizę przydatności poszczególnych zmiennych wejściowych do estymowania przepuszczalności przez sieć, opierając się na:

- analizie podstawowych statystyk danych wejściowych;
- statystykach regresyjnych (mierniki jakości działania sieci);
- macierzy korelacji (zestawienie liniowych korelacji pomiędzy zmiennymi wejściowymi);
- analizie wrażliwości wejścia sieci neuronowej (podstawową miarą wrażliwości sieci jest iloraz błędów uzyskanego przy uruchomieniu sieci dla zbioru danych bez jednej zmiennej i błędów uzyskanego z kompletem zmiennych) (Internetowy podręcznik statystyki).

Wyeliminowano zmienne, które wносиły podobną informację lub były mało informatywne i w efekcie miały nikły wpływ na końcowy wynik uzyskany z sieci K_{SSN} . Liczba wejść sieci była jednak na tyle duża, by odwzorować zasadnicze cechy i złożoność zjawiska. Zgodnie z regułami tworzenia SSN liczba wejść powinna być mniejsza od \sqrt{N} , gdzie N jest liczbą przypadków uczących. Ostatecznie sieć była uczona przypadkami o znanej wartości K_{lab} , na podstawie następujących zmiennych wejściowych: PG, NPHI, ILa, PS, PŚr, PA, EN64/EN16, EL28/EL14, PHI, $Vił$, V_{wap} . W wyniku licznych testów wybrano też optymalne cechy SSN: architekturę sieci (perceptron trójwarstwowy), algorytm uczenia (najszybszego spadku), ilość neuronów ukrytych (osiem), funkcje aktywacji neuronów ukrytych i wyjściowego (logistyczna). Zastosowana sieć to MLP: 11-8-1 (*Multi Layer Perceptron*: 11 sygnałów wejściowych, 8 neuronów ukrytych, 1 neuron wyjściowy). Schemat zastosowanego perceptronu przedstawia figura 1.

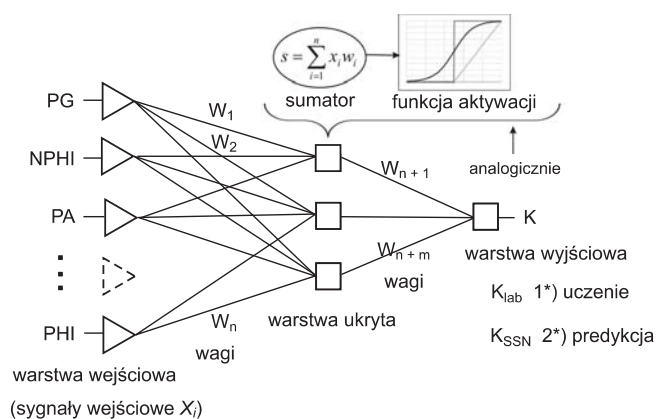


Fig. 1. Schemat zastosowanej sieci – perceptronu

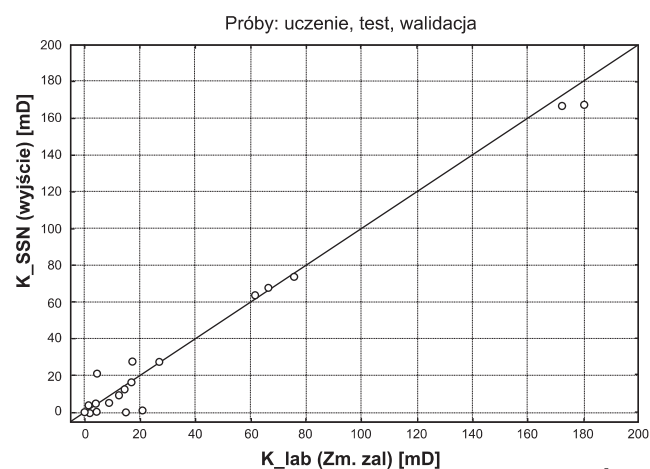
Schematic diagram of perceptron applied to permeability estimation

WYNIKI

Jakość odwzorowania przepuszczalności za pomocą otrzymanego modelu neuronowego jest dobra, co widać na wykresie korelacji K_{lab} i K_{SSN} (fig. 2). Współczynnik korelacji R dla przypadków uczących wynosi 0,995, dla walidacyjnych 0,975 i testowych 0,980.

Uzyskany model neuronowy wdrożono do estymowania przepuszczalności w otworze wiertniczym DZ17. Otrzymało predykcję przepuszczalności ze SSN w sposób ciągły w funkcji głębokości i zestawiono ją z K_{Zaw} oraz oznaczeniami laboratoryjnymi w tym otworze (fig. 3). Wyniki K_{Zaw} i K_{SSN} mają podobny trend, jednak miejscami rozbieżności między nimi są duże. Okazało się, że sieć neuronowa nie radzi sobie z odwzorowaniem wysokich wartości przepuszczalności skał, ponieważ brak było takich przypadków w zbiorze uczącym, gdzie K_{lab} nie przekraczało 180,5 mD. W profilu całego otworu (2701 punktów głębokościowych) średnia arytmetyczna wyników K_{Zaw} wynosi 54 mD, natomiast w przypadku K_{SSN} – 25,7 mD. Wyniki prezentowane w artykule uzyskano wykorzystując 55 przypadków uczących, w których korelacja przepuszczalności wyinterpretowanej K_{Zaw} z wynikami badań laboratoryjnych K_{lab} była na akceptowalnym poziomie (odrzuco-

no łącznie 10 próbek, dla których $K_{lab} > K_{Zaw}$). Jedną z przyczyn słabej korelacji wspomnianych wyników jest rozdzielczość pionowa profilowań, która nie pozwoliła na poprawne odwzorowanie właściwości skał w skali mikro. Gdy w procesie uczenia uwzględniono wszystkie próbki okazało się, że jakość uzyskiwanych modeli neuronowych była znacznie niższa niż poprzednio. Współczynnik korelacji między K_{lab} i K_{SSN} w poszczególnych przypadkach (uczenie, test i walidacja) nie przekraczał zwykle 0,8. Potwierdza to słuszność zastosowanego wcześniej podejścia (eliminacji wspomnianych próbek).



Nr	Próba	K-lab	K-SSN wyjście	Nr	Próba	K_lab	K-SSN wyjście
1	test	0,11	0,03	29	walid.	0,04	0,16
2	ucz.	0,01	0,02	30	ucz.	16,99	16,02
3	walid.	0,01	0,02	31	walid.	14,71	0,02
4	ucz.	0,01	0,02	32	ucz.	0,01	0,01
5	ucz.	1,36	1,91	33	ucz.	0,01	0,01
6	ucz.	26,80	27,56	34	test	0,01	0,01
7	walid.	66,33	67,36	35	test	0,01	0,01
8	test	4,60	20,77	36	ucz.	0,09	0,01
9	ucz.	0,01	0,12	37	ucz.	172,16	166,63
10	ucz.	180,49	167,41	38	ucz.	8,83	5,11
11	ucz.	75,61	73,71	39	ucz.	0,01	0,20
12	ucz.	12,72	9,06	40	ucz.	1,99	0,10
13	ucz.	17,39	27,27	41	ucz.	0,01	0,19
14	test	0,05	0,31	42	ucz.	0,01	0,19
15	ucz.	0,12	0,12	43	ucz.	0,23	0,05
16	ucz.	0,01	0,24	44	ucz.	0,01	0,07
17	walid.	4,10	4,65	45	walid.	0,03	0,04
18	ucz.	0,01	0,40	46	ucz.	4,49	0,18
19	ucz.	21,29	0,67	47	ucz.	0,53	0,04
20	ucz.	0,01	0,29	48	ucz.	0,57	0,18
21	test	1,51	3,88	49	ucz.	0,09	0,01
22	test	0,01	0,16	50	ucz.	0,13	0,02
23	walid.	0,06	0,13	51	ucz.	0,10	0,01
24	ucz.	0,04	0,69	52	ucz.	0,10	0,01
25	test	1,46	3,24	53	walid.	1,84	0,04
26	ucz.	61,44	63,42	54	ucz.	2,11	0,03
27	ucz.	14,33	12,83	55	ucz.	0,35	0,02
28	ucz.	1,49	0,70				

Fig. 2. Wykres korelacji między K_{SSN} i K_{lab} dla omawianej sieci neuronowej z tabelą zawierającą szczegółowe dane do wykresu

Correlation graph between K_{SSN} i K_{lab} with detailed data in a table

WNIOSKI

Największym problemem w uzyskaniu dobrego modelu neuronowego może być mała liczba lub słaba reprezentatywność przebadanych w laboratorium próbek rdzeni. W analizowanych otworach wiertniczych sieć uczono na niewielkiej liczbie próbek, pochodzących z różnych jednostek litostratigraficznych, o mocno zróżnicowanej charakterystyce. Otrzymało dobrą jakość od wzorowania przepuszczalności przez sieć, co nie przełożyło się jednak na dobre

wyniki po wdrożeniu tej sieci na inny zbiór danych. Większa liczba reprezentatywnych próbek uczących pozwoliłaby uzyskać lepszy model neuronowy zjawiska, tzn. lepiej opisać skomplikowane zależności w zbiorze, wiążące zmienne wejściowe ze sobą i z przepuszczalnością, a następnie z lepszym skutkiem przenieść je na podobny zbiór danych. Warto pamiętać, że zmienne wejściowe, przydatne dla konkretnego zbioru danych, nie muszą równie dobrze sprawdzać się w in-




Fig. 3. Zestawienie K_{SSN} , $K_{Zawisza}$ i K_{lab} w otworze DZ17 (interwał 850–1035 m)

K_{SSN} in comparison with K_{Zaw} i K_{lab} in DZ17 borehole (interval 850–1035 m)

nym rejonie, otworze wiertniczym, czy po prostu zbiorze danych. Wiele zależy od jakości pomiarów i interpretacji, od tego, jaki ośrodek skalny badamy i na ile poszczególne pomiary są w stanie pokazać jego właściwości. Metoda esty-

macji przepuszczalności przez SSN ma sens w otworach wiertniczych lub w najbliższym sąsiedztwie otworów o obszernej dokumentacji laboratoryjnej.

LITERATURA

INTERNETOWY podręcznik statystyki — <http://www.statsoft.pl>, StatSoft Polska.

PRĘTKA J., 2009 — Doskonalenie metod wyznaczania przepuszczalności skał z wykorzystaniem sieci neuronowych. [Pr. magister.] Bibl. WGGiOŚ AGH, Kraków.

PLEWA S., PLEWA M., 1992 — Petrofizyka. Wyd. Geol., Warszawa.

ZAWISZA L., 1994 — Uproszczona metoda oceny absolutnej przepuszczalności warstw porowatych. *Arch. Min. Sc.*, **38**, 4: 343–352.