

SZTUCZNE SIECI NEURONOWE DLA UZUPEŁNIENIA DANYCH W GEOFIZYCE OTWOROWEJ – WYBRANE PRZYKŁADY

Artificial Neural Networks for completing data in well logging – selected examples

Jadwiga JARZYNA¹, Anna OPYRCHAŁ² & Dariusz MOZGOWOJ²

*¹Akademia Górniczo-Hutnicza im. Stanisława Staszica,
Wydział Geologii Geofizyki i Ochrony Środowiska;
al. Mickiewicza 30, 30-059 Kraków;*

*²PGS Geophysical AS, DP Department, Strandveien 4 1366 Lysaker, Norway;
e-mail: jarzyna@uci.agh.edu.pl, anna.opyrchal@pgs.com,
dariusz.mozgowoj@pgs.com*

Treść: Wykorzystano sztuczne sieci neuronowe do odtwarzania profilowań geofizyki otworowej. Na podstawie dostępnych profilowań geofizyki wiertniczej odtworzono czas interwałowy rejestrowany przy profilowaniu akustycznym, gęstość objętościową będącą wynikiem profilowania gamma–gamma oraz oporność pozorną. Wybrano perceptrony i wsteczną propagację błędu jako metodę nauczania. Najbardziej skuteczne przy odtwarzaniu parametrów okazały się perceptrony z kilkoma neuronami na wejściu i przynajmniej kilkoma neuronami w warstwie ukrytej. Miarą poprawności wyników dostarczanych przez sieci były podstawowe statystyki obliczane dla odtworzonych parametrów w porównaniu z wynikami pomiarów lub estymacji. Najtrudniejsze do opracowania okazały się interwały, w których skały miały skomplikowaną litologię i zróżnicowaną przynależność stratygraficzną. Wyniki wykorzystano dla potrzeb interpretacji sejsmicznej, grawimetrycznej i magnetotellurycznej.

Słowa kluczowe: profilowania geofizyki otworowej, sztuczne sieci neuronowe, czas interwałowy, gęstość objętościowa, oporność pozorna, Karpaty Zachodnie

Abstract: Artificial Neural Networks were used for reconstruction of well logs. Transit interval time recorded during acoustic log, bulk density as a result of gamma–gamma log and apparent resistivity were reconstructed on the basis of available logs. Perceptrons were chosen and the back propagation method was applied as the most effective training algorithm. Perceptrons with a few input neurons and at least a few neurons in a hidden layer turned out in reconstructing parameters. Basic statistics calculated for the reconstructed parameters compared to the measured or estimated ones acted as measures of correctness of solutions delivered by the networks. Intervals containing rocks of complex lithology and diversified stratigraphy turned out to be the most difficult to interpret. Results were applied in seismics, gravimetric and magnetotelluric interpretations.

Key words: Well logging, Artificial Neural Networks, transit interval time, bulk density, apparent resistivity, Western Carpathians

WSTĘP

Reinterpretacja archiwalnych materiałów geofizycznych, sejsmicznych, gravimetrycznych czy geofizyki otworowej wymaga wykorzystania starych wyników pomiarów. W tej grupie danych często brakuje wyników profilowania akustycznego i gęstościowego lub są bardzo słabej jakości. Stare pomiary mają zwykle duży zestaw klasycznych profilowań oporności, profilowanie potencjałów polaryzacji naturalnej oraz profilowanie gamma i neutron–gamma. Znaczna część starych pomiarów jest już obecnie przygotowana w wersji elektronicznej, a wyniki profilowań radiometrycznych są przeliczone na obecnie obowiązujące jednostki, czyli API w przypadku pomiaru naturalnej promieniotwórczości i umowne jednostki porowatości wapienia dla porowatości neutronowej.

Podczas przygotowania danych dla potrzeb sejsmiki, gravimetrii i magnetotelluryki przy reinterpretacji materiałów geofizycznych w obszarze Karpat Zachodnich powstała potrzeba uzupełnienia informacji o prędkości fal podłużnych, gęstości objętościowej i oporności. W tym celu wykorzystano sztuczne sieci neuronowe.

SZTUCZNE SIECI NEURONOWE

Sztuczne sieci neuronowe, SSN, są narzędziem informatycznym, którego zasada działania jest wzorowana na pracy mózgu (Tadeusiewicz 1993). Mogą być użyte do przetwarzania i interpretacji danych geofizycznych dzięki dużej możliwości adaptacji sieci do rozwiązywanego problemu. W geofizyce otworowej i petrofizyce SSN są wykorzystywane do predykcji brakujących parametrów na podstawie innych wielkości (Jarzyna *et al.* 2006, Mozgowoj 2007). Najważniejszą cechą sieci w tym zastosowaniu jest zdolność rozpoznawania wzajemnych związków między parametrami na podstawie treningu na zadanym zbiorze danych. Rozpoznane zależności sieć następnie przenosi na podobne zbiory danych i dzięki temu możliwe jest wyznaczenie poszukiwanych wielkości.

Jedną z najpopularniejszych jest nieliniowa sieć – perceptron wielowarstwowy (Osowski 1996). Posiada on 3 rodzaje warstw – wejściową, wyjściową oraz co najmniej jedną warstwę ukrytą (Fig. 1).




Fig. 1. Struktura perceptronu o trzech warstwach

Fig. 1. Structure of the three layer perceptron

Wszystkie neurony w sieci mają wzajemne połączenia, a sygnał wyjściowy jest sumą sygnałów przekazywanych przez neurony mnożonych przez wagi (1). Każdy neuron posiada nieliniowy element w postaci funkcji aktywacji, $f(x_j)$.

$$y_k = f \left(\sum_{i=0}^K w_{ki}^{(2)} \cdot v_i \right) = f \left(\sum_{i=0}^K w_{ki}^{(2)} \cdot f \left(\sum_{j=0}^N w_{ij}^{(1)} \cdot x_j \right) \right) \quad (1)$$

gdzie: y_k – sygnał wyjściowy neuronów warstwy wyjściowej, v_i – sygnał wyjściowy neuronów warstwy ukrytej, x_j – wektor wejściowy, $w_{ki}^{(2)}$ – wagi warstwy wyjściowej, $w_{ij}^{(1)}$ – wagi warstwy ukrytej.

Najważniejszym zagadnieniem przy stosowaniu SSN jest ich uczenie, polegające na prawidłowym doborze wag. W pracy wykorzystano algorytm nauczania sieci pod nadzorem (z nauczycielem). Uczenie perceptronu z nauczycielem wymaga znajomości oczekiwanego sygnału wyjściowego. Proces uczenia polega na takiej zmianie wag podczas każdej iteracji, aby aktualny sygnał na wyjściu zbliżał się do oczekiwanego. Proces ten, powtarza się do momentu, gdy różnica pomiędzy sygnałem pożądanym a aktualnym zostanie zminimalizowana.

W przypadku uczenia wielowarstwowego perceptronu często używany jest algorytm wstecznej propagacji błędów (*Back Propagation Method*) (Osowski 1996). Jego podstawą jest minimalizacja funkcji celu, zdefiniowanej dla wielu próbek ($j = 1, 2, \dots, p$) jako:

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

gdzie: y_k – aktualne wyjście,
 d_k – oczekiwane wyjście.

Minimalizacja funkcji celu polega na zmianie wag, która może odbywać się zgodnie ze wzorem (3):

$$w(k+1) = w(k) + \eta p(w) \quad (3)$$

gdzie: k – numer kolejnej iteracji,
 η – współczynnik uczenia,
 $p(w)$ – kierunek gradientu w przestrzeni wielowymiarowej.

Określenie $p(w)$ dla warstwy wyjściowej odbywa się na podstawie znanych wartości wag na wyjściach neuronów. Dla warstw pozostałych stosuje się wsteczną propagację błędów. Proces ten powtarzany jest tyle razy (epok), aby warunek dokładności obliczenia wyjścia był spełniony. Współczynnik uczenia kontroluje proces uczenia sieci. Zbyt mały powoduje niewykorzystanie możliwości zminimalizowania wartości funkcji celu w danym kroku i konieczność powtórzenia iteracji, natomiast zbyt duży może spowodować pominięcie minimum funkcji.

ODTWARZANIE PROFILOWAŃ GEOFIZYKI OTWOROWEJ

Ilość zmiennych wejściowych oraz ich rodzaj zależą od określonego problemu, jaki sieć ma rozwiązać. Wszystkie przypadki zmiennych podzielono na trzy zbiory: uczący, obejmujący przypadki służące do treningu sieci, weryfikacyjny – do kontroli algorytmu podczas uczenia i testowy – do sprawdzenia poprawności funkcjonowania nauczonej sieci. Dane w każdym z tych zbiorów powinny być reprezentatywne. Przydzielenie przypadków do odpowiednich

zbiorów odbyło się w sposób losowy. Pomimo, że sieci neuronowe w pewnym stopniu są odporne na szum, szczegółowo sprawdzono przypadki uczące i wyeliminowano te, które znacznie odbiegały od pozostałych na skutek zakłóceń.

Ilość neuronów wejściowych oraz wyjściowych w sieci była wyznaczona przez ilość zmiennych rozważanych na etapie przygotowywania danych. Od liczby neuronów ukrytych w dużej mierze zależał efekt końcowy. W pracy z sieciami posłużono się automatycznym wspomaganie (*Intelligent Problem Solver*) oferowanym przez program Statistica Neural Network (1999).

Profilowanie akustyczne

SSN wykorzystano do odtwarzania brakujących fragmentów profilowania akustycznego w otworach w obszarze okna tektonicznego Wiśniowej. W tym rejonie obserwuje się złożony obraz stratygraficzny spowodowany skomplikowaną tektoniką (Burtan 1978) (Tab. 1). Niepełne wykształcenie litostratygraficzne w badanych otworach utrudniało efektywne wykorzystanie sieci.

Tabela (Table) 1

Stratygrafia i litologia w otworach W4 i W6 oraz D6
Stratigraphy and lithology in the W4 and W6 and D6 wells

D6			W6			W4	
Hstr/Hsp Ht/Hb [m]	Symbol Code	Litologia Lithology	Hstr/Hsp Ht/Hb [m]	Symbol Code	Litologia Lithology	Hstr/Hsp Ht/Hb [m]	Symbol Code
0/15	Q	gliny, piaski, żwiry <i>clays, sands, gravels</i>	0/10	Q	gliny, piaski, żwiry <i>clays, sands, gravels</i>	0/20	Q
15/1290	wK2s	piaskowce, łupki, mułowce <i>sandstones, shales, mudstones</i>	10/640	wK2s		20/2100	
1290/1407	wK2g	piaskowce, mułowce <i>sandstones, mudstones</i>	640/729	wK2g			
			729/1312	K1			
			1312/1867	JPS			
1407/1949	Mb3	piaskowce, mułowce <i>sandstones, mudstones</i>	1867/2052	M	piaskowce, ilowce, mułowce <i>sandstones, claystones, mudstones</i>	2100/2328	M
			2052/2080	Kt	łupki, wapienie <i>shales, limestones</i>		
			2080/2093	Kc	piaskowce, margle <i>sandstones, marls</i>		
1949/1984	J3	wapienie <i>limestones</i>	2093/2208	J3	wapienie <i>limestones</i>	2328/2490	J3
			2208/2318	Cm	mułowce, piaskowce <i>mudstones, sandstones</i>	2490/2599	P
			2318/2454	Pr	(nieokreślone) <i>undefined</i>		

Do uczenia sieci wykorzystano dane z otworu Wiśniowa 6 z interwału 2438.5÷2066.5 m, obejmujące utwory prekambru, kambru, jury oraz kredy. Pod względem litologicznym są to piaskowe, mułowce, iłowce oraz wapienie. Ze względu na niekompletne dane niemożliwe było uczenie sieci, wykorzystując profilowania z całego interwału głębokościowego. Jako dane wejściowe wykorzystano 8 dostępnych parametrów: głębokość, DEPTH [m], potencjał polaryzacji naturalnej, SP [mV], oporność zarejestrowaną sondą gradientową EL09 [omm], sondą gradientową EL14 [omm], sondą gradientową EL28 [omm], średnicę, CAL [mm], naturalną promieniotwórczość gamma, GR [API], oraz wynik profilowania neutronowego, NEGR [%]. Na wyjściu znajdował się czas interwałowy DT [μ s/m]. Wszystkie zmienne były standaryzowane.

Przyjęto perceptron trójwarstwowy z 8 neuronami na wejściu i 4 neuronami w warstwie ukrytej. Po procesie uczenia, obejmującym 800 epok, wykonano analizę czułości (Tab. 2). Posłużyła ona do klasyfikacji zmiennych wejściowych na podstawie rankingu wejść (*rank*), segregując je od najbardziej (numer 1) do najmniej istotnego. Wyświetlany był również błąd (*error*), jaki popełnia sieć po usunięciu z obliczeń danego wejścia. Im błąd był wyższy, tym wejście miało większe znaczenie. Na podstawie tej analizy zmodyfikowano sieć do 5 neuronów na wejściu i 3 neuronów ukrytych usuwając oporność, jako parametr o najniższych pozycjach rankingowych (Opyrchal 2007).

Tabela (Table) 2

Wyniki analizy czułości dla perceptronu z 8 neuronami na wejściu i 3 w warstwie ukrytej

Results of the sensitivity analysis for the perceptron with 8 input neurons and 3 neurons in a hidden layer

Parametr <i>Parameter</i>	H	SP	EL09	EL14	EL28	CAL	GR	NEGR
Ranking <i>Rank</i>	3	4	6	7	8	5	1	2
Błąd <i>Error</i>	11.52	10.58	9.66	9.08	8.98	10.34	17.77	17.34

Wyniki uzyskane podczas nauczania sieci z 5 neuronami na wejściu oceniono na podstawie statystyk regresyjnych obliczonych dla czasu interwałowego na wyjściu sieci (Tab. 3).

Sieć wykorzystano do obliczenia czasu interwałowego w otworze Wiśniowa 4 w odcinku obejmującym te same utwory, zarówno pod względem stratygraficznym, jak i litologicznym. Na figurze 2 pokazano krzywą czasu interwałowego obliczoną i pomierzoną, razem z uproszczoną prezentacją rozwiązania litologicznego. Widać dobre dopasowanie krzywej obliczonej do pomierzonej, co potwierdza wysoki współczynnik korelacji równy 95%.

Hstr/Hsp – głębokość stropu/spągu, *depth of the top/bottom*; Q – czwartorzęd, *Quaternary*; wK2s – formacja istebniańska, *Istebna Formation*; wK2g – formacja godulska, *Godula Formation*; Mb3 – miocen, baden górny, *Miocene, Upper Badenian*; K1 – kreda dolna, *Lower Cretaceous*; JPS – jednostka podśląska, *Sub-Silesian unit*; M – miocen, *Miocene*; Kt – kreda, turon, *Cretaceous, Turonian*; Kc – kreda, cenoman, *Cretaceous, Cenomanian*; J3 – jura górna, *Upper Jurassic*; P – perm, *Permian*; Cm – kambry, *Cambrian*; Pr – prekambry, *Precambrian*

Jednak, profilowanie obliczone za pomocą SSN ma gorszą pionową rozdzielczość, zwłaszcza w obrębie wapienia, gdzie zostało bardziej uśrednione. Wynik ten jest skutkiem zróżnicowanej pionowej rozdzielczości profilowań wejściowych, na podstawie których, sieć wyliczyła DT SSN.

Tabela (Table) 3

Statystyki regresyjne dla DT SSN

Regression statistics for DT SNN

Średnia DT SSN, <i>Mean DT SNN</i> [$\mu\text{s}/\text{m}$]	200.44
Odchylenie standardowe DT SSN, <i>Standard deviation DT SNN</i> [$\mu\text{s}/\text{m}$]	27.70
Iloraz odchylenia standardowego błędu i zmiennej, <i>Ratio of standard deviations of error and DT SNN</i>	0.32
Współczynnik korelacji, <i>Correlation coefficient</i>	0.95

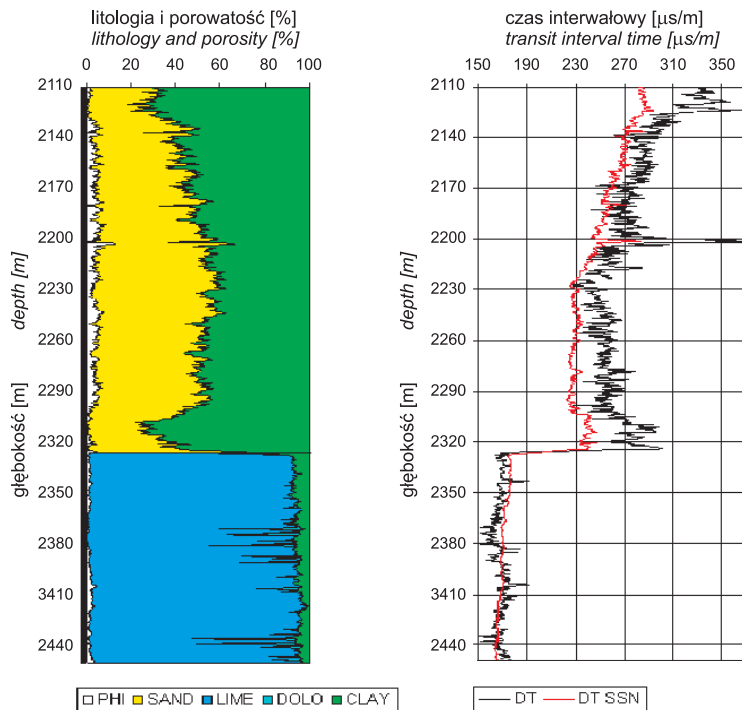


Fig. 2. Czas interwałowy pomierzony, DT, i obliczony z użyciem SSN (5 neuronów na wejściu), DT SSN, oraz uproszczone rozwiązanie litologiczne w otworze W4 dla odcinka 2110÷2440 m

Fig. 2. Transit interval time, DT, from log and calculated with ANN, DT SSN together with simplified lithology solution in W4 well in the depth section 2110÷2440 m

Dla wartości czasów interwałowych pomierzonych, DT i odtworzonych przy użyciu SSN obliczono podstawowe statystyki (Tab. 4). Wartości obliczone są niższe od pomierzonych, jednak średnia różnica pomiędzy nimi nie jest duża. Mniejsze odchylenie standardowe dla DT SSN wskazuje, że odtworzone czasy interwałowe mają mniejszy rozrzut, co zauważono wcześniej w postaci zmniejszonej pionowej rozdzielczości.

Tabela (Table) 4

Podstawowe statystyki dla czasu interwałowego w otworze W4
Basic statistics for transit interval time in W4 well

Parametr, <i>Parameter</i>	DT [$\mu\text{s}/\text{m}$]	DT SSN [$\mu\text{s}/\text{m}$]	Różnica <i>Difference</i> [$\mu\text{s}/\text{m}$]
Średnia, <i>Average</i>	235.89	216.71	21.26
Maksimum, <i>Maximum</i>	368.51	294.25	134.36
Minimum, <i>Minimum</i>	151.12	160.17	0
Odchylenie standardowe, <i>Standard deviation</i>	59.00	44.58	19.30

W otworze W4 wykonano także porównanie wyniku uzyskanego z użyciem perceptronów z 8 i 5 neuronami na wejściu. Współczynnik korelacji zmalał nieznacznie, z 95% do 93%, przy zestawieniu wyników DT SSN(8) i DT SSN(5), ale podniosły się wartości czasów interwałowych w obrębie wapienia. Z tego powodu uznano, że model sieci z pięcioma wejściami oraz trzema neuronami ukrytymi lepiej odtwarza profilowanie DT (Fig. 3).

SSN wykorzystano do odtworzenia krzywej DT na podstawie dostępnych profilowań w otworze Dobczyce 6. Utworzono dwie sieci, jedną uczoną na podstawie danych z otworu W4, a drugą na podstawie danych z otworu W6. Jako ilustrację wybrano interwał wapieni jury górnej (malmu). Obie sieci miały cztery profilowania wejściowe (SP, CALI, GR, NEGR) oraz dwa neurony ukryte. Głębokość występowania jury różni się znacznie w omawianych otworach, dlatego usunięto profilowanie głębokości z danych wejściowych.

Obie sieci uzyskały bardzo wysokie współczynniki korelacji oraz niskie ilorazy odchylenia standardowego błędu i DT SSN, co świadczy o ich dobrej jakości (Tab. 5). Kształt krzywych DT jest podobny (współczynnik korelacji między DT SSN (W6) i DT SNN (W4) równa się 95%), natomiast widoczna jest rozbieżność otrzymanych wartości czasów interwałowych (Tab. 6).

Tabela (Table) 5

Statystyki regresyjne dla DT SNN dla sieci uczonych na podstawie danych z otworów W6 i W4

Regression statistics for DT SNN for the networks trained on the basis of data from W6 and W4 wells

Statystyka regresyjna, <i>Regression statistic</i>	DT SSN (W6)	DT SSN (W4)
Średnia DT SSN, <i>Mean DT SSN</i> [$\mu\text{s}/\text{m}$]	184.51	163.60
Odchylenie standardowe DT SSN <i>Standard deviation DT SSN</i> [$\mu\text{s}/\text{m}$]	37.96	34.62
Iloraz odchylenia standardowego błędu i zmiennej <i>Ratio of standard deviations of error and DT SSN</i>	0.14	0.24
Współczynnik korelacji, <i>Correlation coefficient</i>	0.99	0.97

Średni czas interwałowy obliczony za pomocą sieci (W6) jest wyższy o 21 $[\mu\text{s}/\text{m}]$ od czasu obliczonego siecią W4. Podobne odchylenie standardowe świadczy, że zróżnicowanie wartości jest podobne. W tym przypadku, wyniki należy traktować jako przybliżone. Porównując średnie czasy interwałowe w interwale jury w otworach W4 (183.6 $\mu\text{s}/\text{m}$) oraz W6 (184.51 $\mu\text{s}/\text{m}$) można założyć, że wynik uzyskany z użyciem sieci nauczonej na danych z otworu W6 jest lepszy.

Tabela (Table) 6

Podstawowe statystyki dla czasu interwałowego w otworze D6
Basic statistics for transit interval time in D6 well

Parametr, <i>Parameter</i>	DT SSN (W4) [$\mu\text{s}/\text{m}$]	DT SSN (W6) [$\mu\text{s}/\text{m}$]
Średnia, <i>Average</i>	157.64	178.81
Maksimum, <i>Maximum</i>	176.27	200.76
Minimum, <i>Minimum</i>	153.20	175.61
Odchylenie standardowe, <i>Standard deviation</i>	3.51	4.03

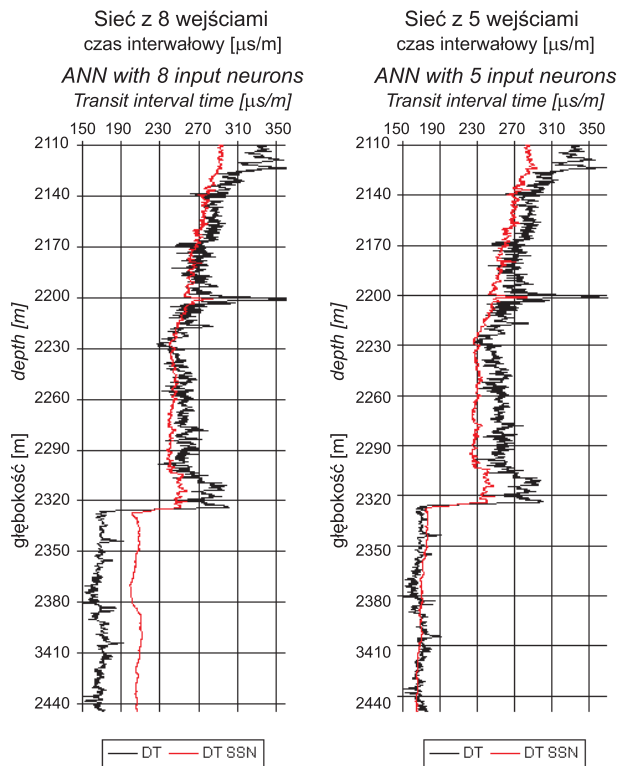


Fig. 3. Porównanie wyników pracy perceptronów z 8 i 5 neuronami na wejściu w otworze W4
Fig. 3. Comparison of the results of the perceptrons with 8 and 5 neurons as input in W4 well

Profilowanie gamma–gamma – wyznaczanie gęstości objętościowej

Gęstość objętościową wyznaczono na podstawie dostępnych profilowań w otworach Lachowice 7 i Roczyny 3. W otworze L7 RHOB była wynikiem pomiaru jedynie w dolnym interwale (od 2194.25 m do spodu otworu). W dolnym interwale były dostępne także następujące profilowania: naturalnej promieniotwórczości – GR, porowatości neutronowej – NPHI, czasu interwałowego – DT, potencjałów polaryzacji naturalnej – SP i średnicy – CAL. Utworzono kilka sieci typu perceptron i wytrenowano je najpierw w interwale występowania utworów fliszu i miocenu (2194.25÷2740 m). Celem pracy było odtworzenie gęstości objętościowej w interwale górnym, pozbawionym pomiaru, gdzie występowały utwory fliszowe, z użyciem opracowanych sieci w interwale dolnym.

Gęstość odtworzoną przez sieć, GEST, zestawiono z wynikiem pomiaru w otworze, RHOB, dla dwóch sieci, które dały dobre wyniki (Fig. 4). Sieć z numerem 10 (Fig. 5) okazała się najlepsza zgodnie ze stosowanymi kryteriami. Jako dane wejściowe w sieci tej wystąpiły wszystkie dostępne profilowania z wyjątkiem SP. Dane wejściowe dla sieci 8 stanowiły profilowania gamma, GR, i akustyczne, DT. Porównano wyniki testu czułości dla sieci nr 10 i 8 (Tab. 7). Ranking danych pokazuje, że czas interwałowy odgrywa bardzo ważną rolę w obu sieciach. Wkład profilowania GR w obu sieciach był podobny.

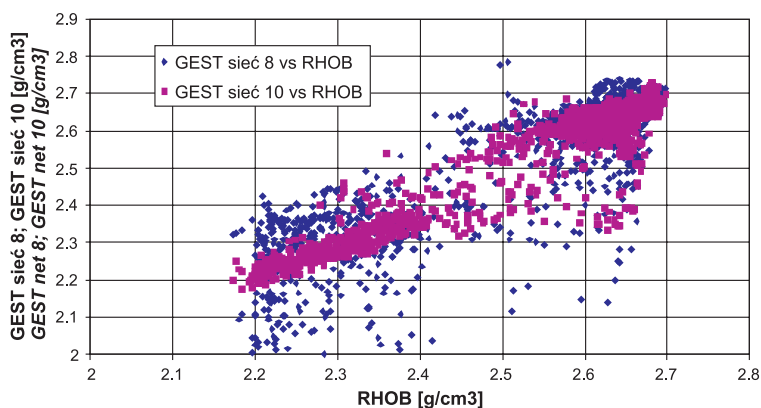


Fig. 4. Zestawienie gęstości, GEST, odtworzonej przez SSN o nr 10 i 8 z wynikiem pomiaru, RHOB

Fig. 4. Dispersion plot of bulk density, GEST, reconstructed by ANN No. 10 and 8 and log, RHOB




Fig. 5. Sieć neuronowa nr 10 użyta do odtworzenia gęstości objętościowej w interwale fliszu i miocenu w otworze L7

Fig. 5. Artificial neural network No. 10 trained in the flysch and Miocene beds in L7 well for reconstructing bulk density

Wyniki analizy regresji dla gęstości objętościowej dla obu rozważanych sieci zestawiono w tabeli 8. Sieć nr 8 ma nieznacznie gorsze wyniki analizy regresji, ale uwzględnia na wejściu jedynie dwa profilowania, jest, zatem, łatwiejsza w użyciu. Rozproszenie punktów dla sieci 8 jest wyraźnie większe (Fig. 4). Jednak odchylenie standardowe dla gęstości w grupie nauczania, weryfikacji i testowania dla obu sieci jest podobne. Wykresy rozrzutu dla obu sieci są podzielone na dwie części, dla mniejszych gęstości i dla większych. W środku występuje strefa o największym rozproszeniu danych. Podział wykresu na części można uzasadnić zróżnicowanym wykształceniem litologicznym utworów fliszowych i miocęńskich. Iloraz odchylenia standardowego błędu i zmiennej jest niski we wszystkich grupach danych dla obu sieci, co świadczy o ich dobrej jakości.

Tabela (Table) 7

Wyniki analizy czułości dla perceptronów nr 10 i 8 w otworze L7 w interwale
2194.25÷2740 m

*Results of the sensitivity analysis for the perceptrons No. 10 and 8 in the L7 well in depth
2194.25÷2740 m*

Parametr, <i>Parameter</i>	H	GR	NPHI	DT	CAL	Sieć, <i>Net</i>
Ranking, <i>Rank</i>	1	5	4	2	3	10
Błąd, <i>Error</i>	0.125	0.069	0.079	0.103	0.093	
Ranking, <i>Rank</i>		2		1		8
Błąd, <i>Error</i>		0.090		0.176		

Tabela (Table) 8

Statystyki regresyjne dla uczenia sieci do odtwarzania gęstości objętościowej w otworze L7
na podstawie danych z fliszu i miocenu

*Regression statistics for training network for bulk density restoration in L7 well on the basis
of data from the flysch and Miocene beds*

Statystyka regresyjna <i>Regression statistic</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>
	Sieć 10, <i>Net 10</i>			Sieć 8, <i>Net 8</i>		
Średnia GEST <i>Mean GEST</i>	2.560	2.547	2.549	2.560	2.547	2.549
Odchylenie standardowe GEST <i>Standard deviation GEST</i>	0.166	0.169	0.169	0.166	0.169	0.169
Iloraz odchylenia standardowego błędu i zmiennej <i>Ratio of standard deviations of error and GEST</i>	0.409	0.384	0.408	0.475	0.478	0.488
Współczynnik korelacji <i>Correlation coefficient</i>	0.910	0.920	0.913	0.880	0.878	0.873

Opracowane sieci wykorzystano do wyznaczenia gęstości objętościowej w górnym odcinku pomiarowym w otworze L7 w interwale 30÷2194 m. W tej części otworu dysponowano takim samym zestawem profilowań. Odtworzone za pomocą sieci 8 wartości gęstości w górnym odcinku zestawiono w funkcji głębokości z wynikami uzyskanymi w programie *Estymacja* (Bała & Witek 2007) (Fig. 6). Krzywa RHEQ wykazuje znacznie mniejszą zmienność w porównaniu z wykresem GEST. Wykres RHEQ uśrednia dość zmienne wartości GEST. Gęstość objętościowa obliczona siecią neuronową 8 i estymowana wartość czasu interwałowego, DPEQ, dobrze korelują ze sobą (Fig. 6), co jest skutkiem użycia na wejściu sieci 8 czasu interwałowego z pomiaru, DT. Wyniki uzyskane z użyciem sieci 10 nie zostały zaakceptowane, mimo najlepszych parametrów statystycznych tej sieci, ponieważ były zbyt obciążone wpływem głębokości. Głębokość znalazła się na wejściu tej sieci na najwyższej pozycji (ranking 1 w tabeli 6).




Fig. 6. Zestawienie gęstości objętościowej obliczonej przy pomocy sieci neuronowej, GEST, oraz estymowanej, RHEQ, w otworze L7, na dodatkowej osi występuje czas interwałowy fali P, DPEQ, estymowany w programie *Estymacja*

Fig. 6. Comparison of bulk density reconstructed with ANN, GEST, and estimated in program *Estymacja*, RHEQ, in L7 well; additionally, transit interval time, DPEQ, is presented

Górny interwał pomiarowy w otworze L7 obejmował jedynie utwory fliszu. Na skutek słabej korelacji między wartościami GEST, obliczonymi z użyciem sieci trenowanej na zbiorze danych obejmujących utwory fliszu i miocenu, oraz wartościami RHEQ, jeszcze raz przystąpiono do tworzenia i trenowania sieci. Tym razem do uczenia sieci wykorzystano jedynie dane w utworach fliszowych w interwale 2194.25÷2442 m. Utworzono kilka perceptronów i wykonano analizy regresji dla wyników uczenia. Najlepsza w procesie uczenia okazała się sieć z trzema neuronami na wejściu (H, NPHI, DT) i czterema neuronami ukrytymi (Fig. 8, sieć 10). Podobny wynik dawał perceptron z 3 neuronami na wejściu i 3 w warstwie ukrytej (Fig. 8, sieć 7). Na wejściu tych sieci także występuje głębokość, ale na pozycji ostatniej, najmniej znaczącej. Współczynniki determinacji dla zależności między wynikiem pomiaru, RHOB a odtworzonymi wartościami gęstości objętościowej – GEST 10 i GEST 7, uzyskanymi w procesie uczenia sieci, są bardzo wysokie (Fig. 7). Sieci te wykorzystano do obliczenia gęstości w górnym interwale pomiarowym. Zgodność wartości gęstości objętościowej estymowanych, RHEQ i odtworzonych przy pomocy sieci jest dobra (Fig. 9). Odtworzone warto-

ści gęstości objętościowej dobrze korelują także z estymowanym czasem interwałowym, DPEQ (Fig. 9). Dodatkowo zilustrowano zależności między gęstością estymowaną i gęstością odtworzoną na podstawie sieci w fragmentach interwału występowania utworów fliszowych. Fragmenty te zostały wydzielone na podstawie zróżnicowania litologicznego. Podkreślono w ten sposób możliwość podniesienia jakości pracy sieci w interwałach o ustalonej litologii.

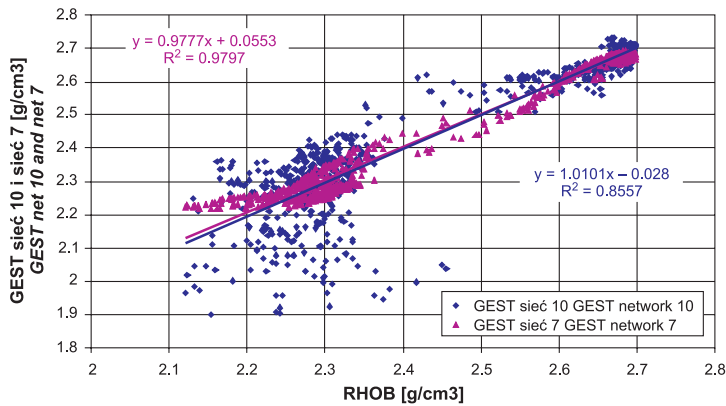


Fig. 7. Wynik uczenia perceptronów nr 10 i 7, GEST, w utworach fliszu w otworze L7 w zestawieniu z wynikiem pomiaru, RHOB

Fig. 7. Result of the training of perceptrons No. 10 and 7, GEST, in the flysch beds in L7 well in comparison to logging, RHOB

Tabela (Table) 9

Wyniki analizy czułości dla perceptronów 10 i 7 w otworze L7 w interwale 2194÷2442 m

Results of the sensitivity analysis for the perceptrons No. 10 i 7 in the L7 well in depth 2194÷2442 m

Parametr, <i>Parameter</i>	H	NPHI	DT	H	NPHI	DT
Sieć, <i>Net</i>	10 (Fig. 7 i 8)			7 (Fig. 7 i 8)		
Ranking, <i>Rank</i>	3	2	1	3	2	1
Błąd, <i>Error</i>	0.085	0.093	0.105	0.090	0.096	0.107




Fig. 8. Schemat sieci neuronowej z najlepszym wynikiem uczenia (3 neurony na wejściu i 4 w warstwie ukrytej) oraz sieci z dobrym wynikiem (3 neurony na wejściu i 3 w warstwie ukrytej) w otworze L7 w utworach fliszu

Fig. 8. Sketch of the best perceptron in the training stage (3 input neurons and 4 ones in the hidden layer) and the net with good result (3 neurons in the input and 3 in the hidden layer) in L7 well in the flysch beds




Fig. 9a. Zależność gęstości objętościowej, GEST, odtworzonej z użyciem sieci 7, oraz estymowanej, RHEQ, w górnym interwale otworu L7

Fig. 9a. Relation between bulk density, GEST, from ANN 7 and estimated bulk density, RHEQ, in the upper interval of L7 well




Fig. 9b. Zależność gęstości objętościowej, GEST, odtworzonej z użyciem sieci 7 i estymowanego czasu interwałowego, DPEQ w górnym interwale otworu L7

Fig. 9b. Relation between bulk density, GEST, from ANN 7 and estimated transit interval time, DPEQ, in the upper interval of L7 well




Fig. 9c. Zależność gęstości objętościowej, GEST, odtworzonej z użyciem sieci 7 oraz estymowanej, RHEQ, w interwale 30÷702 m otworu L7

Fig. 9c. Relation between bulk density, GEST, from ANN 7 and estimated bulk density, RHEQ, in the 30÷702 m interval of L7 well




Fig. 9d. Zależność gęstości objętościowej, GEST, odtworzonej z użyciem sieci 7 oraz estymowanej, RHEQ, w interwale 702÷2188 m otworu L7

Fig. 9d. Relation between bulk density, GEST, from ANN 7 and estimated bulk density, RHEQ, and in the 702÷2188 m of L7 well

Statystyki regresyjne dla sieci nr 10 i nr 7 trenowanych na danych z interwału, w którym występują utwory fliszowe w otworze L7 przedstawiono w tabeli 10.

Podobne badania w zakresie wykorzystania SSN do odtwarzania profilowań wykonano w otworze Roczyny 3. W dolnym interwale w tym otworze (1069.75÷1795 m) był dostępny duży zbiór profilowań: CAL, SP, GR, NPHI, DT, RHOB, LLD (profilowanie oporności sterowane sondą o dalekim zasięgu radialnym), MSFL (mikroprofilowanie oporności sondą sferycznie sterowaną), GRS (spektrometryczne profilowanie gamma – intensywność naturalnej promieniotwórczości pochodząca od minerałów zawierających potas i tor), PEF (indeks absorpcji fotoelektrycznej). Wyniki z tych profilowań wykorzystano jako wejścia do perceptronów.

Tabela (Table) 10

Statystyki regresyjne dla uczenia sieci do odtwarzania gęstości objętościowej w otworze L7 na podstawie danych z fliszu

Regression statistics for training network for bulk density reconstruction in L7 well on the basis of data from the flysch

Statystyka regresyjna <i>Regression statistic</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>
	Sieć, <i>Net</i>					
	10			7		
Średnia GEST <i>Mean GEST</i>	2.488	2.496	2.470	2.489	2.500	2.470
Odchylenie standardowe GEST <i>Standard deviation GEST</i>	0.207	0.202	0.228	0.207	0.202	0.228
Iloraz odchylenia standardowego błędu i zmiennej <i>Ratio of standard deviations of error and GEST</i>	0.375	0.343	0.424	0.403	0.373	0.451
Współczynnik korelacji <i>Correlation coefficient</i>	0.927	0.940	0.907	0.915	0.928	0.894

W dolnym odcinku wytrenowano i wytestowano 2 perceptrony. Analizy czułości i statystyki regresyjne dla wyników uczenia na dużym zbiorze danych przedstawiono w tabelach 11 i 12. Zależność korelacyjną między gęstością objętościową odtworzoną z wykorzystaniem obu sieci oraz RHOB z pomiaru zaprezentowano na figurze 10.

Tabela (Table) 11

Analiza czułości dla perceptronów nr 10 i nr 9 trenowanych na dużym zbiorze danych w dolnej części otworu R3

Sensitivity analysis for the perceptrons No. 10 and 9 trained on the great data file in the lower part of the R3 well

Parametr, <i>Parameter</i>	H	CAL	NPHI	DT	MSFL	PEF	Sieć, <i>Net</i>
Ranking, <i>Rank</i>	6	4	5	1	2	3	10
Błąd, <i>Error</i>	0.073	0.080	0.074	0.117	0.091	0.090	
Ranking, <i>Rank</i>		2		1			9
Błąd, <i>Error</i>		0.089		0.145			

Perceptrony z 6 neuronami na wejściu i 6 neuronami w warstwie ukrytej – SSN nr 10 oraz z 3 neuronami na wejściu i 3 w warstwie ukrytej – SSN nr 9, nauczone na dużym zbiorze danych dobrze odtwarzają gęstość objętościową. Współczynnik determinacji przy korelacji danych GEST i RHOB w przypadku sieci nr 10 wynosi 0.83, a w przypadku sieci nr 9 – 0.81.

Tabela (Table) 12

Statystyki regresyjne dla perceptronów nr 10 i nr 9 trenowanych na dużym zbiorze danych w dolnej części otworu R3

Regression statistics for the perceptrons No. 10 and 9 trained on the great data file in the lower part of the R3 well

Statystyka regresyjna <i>Regression statistic</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>	Uczenie <i>Training</i>	Weryfikacja <i>Verifying</i>	Testowanie <i>Testing</i>
	Sieć, <i>Net</i>					
	10			9		
Średnia GEST <i>Mean GEST</i>	2.678	2.662	2.665	2.678	2.662	2.665
Odchylenie standardowe GEST <i>Standard deviation GEST</i>	0.166	0.173	0.170	0.166	0.173	0.170
Iloraz odchylenia standardowego błędu i zmiennej <i>Ratio of standard deviations of error and GEST</i>	0.421	0.384	0.408	0.448	0.400	0.419
Współczynnik korelacji <i>Correlation coefficient</i>	0.91	0.92	0.91	0.89	0.92	0.91

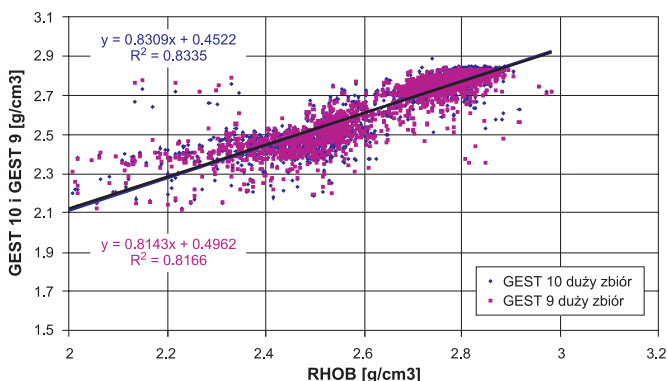


Fig. 10. Wykres rozrzutu dla gęstości z pomiaru, RHOB, oraz gęstości objętościowych, GEST 10 i GEST 9, odtworzonych z wykorzystaniem SSN nr 10 i 9 trenowanych w na dużym zbiorze danych z dolnego interwału w otworze R3

Fig. 10. Dispersion plot of measured bulk density, RHOB, and bulk density, GEST 10 and GEST 9, reconstructed using perceptrons No. 10 and 9 trained on the big data file at the lower section of R3 well

Proste regresji na figurze 10 praktycznie się pokrywają, a współczynniki w równaniach regresji są prawie takie same. Można, zatem, z powodzeniem wykorzystać SSN 9 do odtworzenia gęstości w górnym interwale mając do dyspozycji wynik profilowania średnicy, CAL,

i czas interwałowy, DT. Współczynniki korelacji dla grupy danych weryfikujących (Tab. 12) są wyższe (0.92) dla obu sieci w porównaniu ze współczynnikami korelacji dla grupy danych uczących (0.91 i 0.89, odpowiednio dla sieci 10 i 9). Znaczne wartości odchylenia standardowego razem z wymienionymi zróżnicowanymi współczynnikami korelacji wskazują na rozrzut wyników w przypadku stosowania obu sieci.

W dolnym interwale także skonstruowano i wytrenowano SSN zadając z góry mniejszą ilość neuronów na wejściu: sieć nr 10 – DT, H, CAL, SP, NPFI i GR, sieć nr 8 – DT, CAL, H i SP oraz sieć nr 7 – DT i CAL. We wszystkich tych sieciach czas interwałowy, DT, jest na pierwszym miejscu, a jego rola jest największa w sieci 7. Wykres rozrzutu na figurze 11 ilustruje zależność między wartościami gęstości objętościowej obliczonymi z użyciem SSN oraz gęstością objętościową z pomiaru. Wysokie współczynniki determinacji i praktycznie pokrywające się proste regresji wskazują na dobre odtworzenie poszukiwanego parametru oraz możliwość zastąpienia sieci wymagającej pełnego kompletu danych sieciami o mniejszej liczbie danych na wejściu.




Fig. 11. Wykres rozrzutu dla gęstości objętościowych, GEST 10, GEST 9 i GEST 7, odtworzonych z wykorzystaniem SSN nr 10, 9 i 7 trenowanych w na małym zbiorze danych z dolnego interwału w otworze R3 oraz gęstości z pomiaru, RHOB

Fig. 11. Dispersion plot of the bulk density, GEST 10, GEST 9 and GEST 7, reconstructed using perceptrons No. 10, 9 and 7, trained on the small data file at the lower section of the R3 well, vs. measured bulk density, RHOB

SSN opracowane i wytestowane na małym zbiorze danych w dolnym odcinku interwału pomiarowego w otworze R3 wykorzystano do odtworzenia gęstości objętościowej w całym interwale pomiarowym. Poprawność odtworzenia oceniono porównując wynik pracy sieci z wynikiem pomiaru, RHOB, lub z estymowaną wartością, RHEQ. Zgodność wyników dla sieci nr 10 jest bardzo dobra, zarówno dla RHOB ($R^2 = 0.76$) jak i RHEQ ($R^2 = 0.83$). W interwale 171÷1800 m w otworze R3 występują utwory różnorodnie pod względem litologii i stratygrafii. Na figurze 12 zilustrowano rozrzut gęstości wyznaczonych w całym otworze R3 z użyciem sieci 10 trenowanej na małym zbiorze danych w dolnym odcinku otworu. Współczynniki determinacji dla zależności GEST 10 vs. RHOB (Fig. 12a) i GEST 10 vs. RHEQ (Fig. 12b) są wysokie.

Jakość odtworzenia gęstości objętościowej w poszczególnych odcinkach otworu była zróżnicowana. Najlepsze wyniki uzyskano przy odtwarzaniu gęstości w utworach fliszu i miocenu.




Fig. 12a. Wykres rozrzutu gęstości objętościowej RHOB i GEST, odtworzonej w całym otworze R3 z użyciem SSN trenowanej na małym zbiorze danych w dolnym interwale

Fig. 12a. Dispersion plot of bulk density RHOB and GEST, recovered in the whole R3 profile using ANN trained in the lower section with small data file

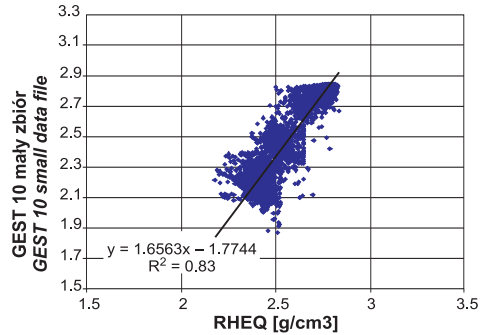


Fig. 12b. Wykres rozrzutu gęstości objętościowej estymowanej, RHEQ, i GEST, odtworzonej w całym otworze R3 z użyciem SSN trenowanej na małym zbiorze danych w dolnym interwale

Fig. 12b. Dispersion plot of estimated bulk density RHEQ and GEST, recovered in the whole R3 profile using ANN trained in the lower section with small data file

W otworze R3 przeprowadzono również dobór perceptronów i ich nauczanie w zbiorze danych dostępnym w całym interwale pomiarowym. Najlepszy okazał się perceptron z 6 neuronami wejściowymi i 10 neuronami ukrytymi. Przy jego wykorzystaniu odtworzono gęstość objętościową w całym interwale pomiarowym i porównano ją z gęstością z pomiaru, RHOB, i gęstością estymowaną, RHEQ (Fig. 13). Obserwuje się zgodność wyników.

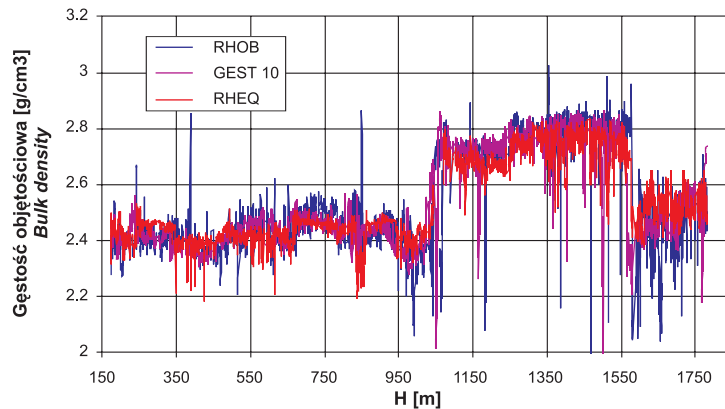


Fig. 13. Gęstości objętościowe w funkcji głębokości w otworze R3: z pomiaru, RHOB, z programu *Estymacja*, RHEQ, oraz wartości odtworzone siecią nauczoną na zbiorze danych z całego otworu

Fig. 13. Bulk density as a function of depth in R3 well: from log, RHOB, from *Estymacja* program, RHEQ, and density reconstructed using ANN trained on the data file from the whole borehole

Zestawiono także gęstość objętościową, GEST 10, odtworzoną w całym zbiorze danych w otworze R3 z gęstością estymowaną, RHEQ (Fig. 14). Gęstość objętościowa utworów fliszowych i prawdopodobnie mioceńskich (?) jest niższa niż utworów starszych. Korelacja obu typów gęstości w utworach fliszowych i mioceńskich jest niższa niż w formacjach starszych.

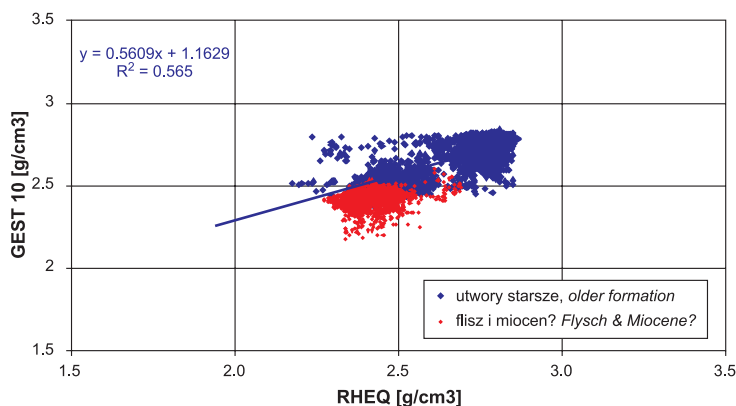


Fig. 14. Korelacja gęstości objętościowej odtworzonej z użyciem SSN nr 10 wytrenowanej na zbiorze danych z całego otworu R3 oraz gęstości estymowanej, RHEQ

Fig. 14. Correlation between bulk density reconstructed on the basis of ANN No. 10 trained on the data file from the whole R3 well vs. estimated density, RHEQ

Odtwarzanie oporności pozornej

SSN wykorzystano do obliczenia oporności pozornej w interwałach, w których nie wykonano potrzebnego profilowania oporności. W otworze Lachowice 7, podobnie, jak w innych otworach w rejonie badań, w górnym odcinku wykonano profilowania oporności klasyczne, gradientowe i potencjałowe, EN16 i EN64 oraz EL14, EL18 i EL28, w dolnym – profilowania sterowane, LLD i LLS oraz LL3, a także mikrosferycznie sterowane profilowanie, MSFL, oraz profilowania indukcyjne, ILD, ILM. W otworze L7 możliwe było wyodrębnienie interwału, w którym wykonano wszystkie rodzaje profilowań oporności (2188÷2328 m). Interwał ten obejmował utwory fliszowe. W tym interwale dokonano wyboru i trenowano perceptrony wykorzystane w następnym etapie do obliczania oporności pozornej odpowiadającej rejestracji poszczególnymi sondami. Odtwarzano oporność pozorną odpowiadającą rejestracji sondą LL3 oraz sondami ILD i LLD. Wyniki przedstawiono w tabeli 13.

Zdolność przygotowanych SSN do wykonania zaplanowanego zadania, czyli odtworzenia oporności pozornej, RES, przypisanej do danej sondy oceniono na podstawie jakości wykresów rozrzutu oraz wartości współczynników determinacji między wynikami pracy sieci i pomiaru w interwale nauczania sieci. Współczynnik determinacji dla pary RES (LL3 10) i oporność pozorną zarejestrowaną sondą potencjałową bliskiego zasięgu, EN16 wyniósł $R^2 = 0.97$, dla pary RES (ILD 10) i oporność pozorną zarejestrowaną sondą ILD – $R^2 = 0.90$. Dla pary oporności pozornej odpowiadających laterologowi dalekiego zasięgu, LLD, R^2 wyniósł 0.93. Wytrenowane perceptrony wykorzystano do odtworzenia oporności pozornej

w interwale występowania utworów fliszowych w otworze L7 (Fig. 15). Obserwuje się podobne przebiegi oporności pozornej odtworzonej dla sondy LL3 i oporności zarejestrowanej krótką sondą potencjałową. Współczynniki determinacji dla zależności między opornościami odtworzonymi dla sond LL3 i ILD oraz wynikami pomiarów oporności sondami o podobnym zasięgu: EN16 i EN64 wynoszą odpowiednio: 0.86 i 0.65.

Tabela (Table) 13

Charakterystyki SSN do odtwarzania oporności pozornej RES
Characteristics of ANN for apparent resistivity, RES, reconstruction

Profilowania oporności <i>Resistivity logs</i>							Liczba neuronów ukrytych <i>Number of hidden neurons</i>	Iloraz odchylenia stand. błędu i zmiennej <i>Ratio of standard deviations of error and RES</i>
Wyjście <i>Output</i>	LL3							
Wejście <i>Input</i>	DT	EN16	SP	NPHI	EN64	EL18	10	0.1414
Wyjście <i>Output</i>	ILD							
Wejście <i>Input</i>	GR	NPHI	DT	EN16	EN64	EL28	10	0.2824
Wyjście <i>Output</i>	LLD							
Wejście <i>Input</i>	DT	NPHI	EN64				1	0.2342




Fig. 15. Zestawienie oporności pozornej odtworzonej dla sondy LL3 10 w interwale warstw fliszu w otworze L7 z wynikiem pomiaru krótką sondą potencjałową, EN16, oraz czasem interwałowym, DT w funkcji głębokości

Fig. 15. Relations between reconstructed resistivity from ANN, LL3 10, logged resistivity, EN16, and transit interval time, DT, vs. depth

PODSUMOWANIE

Przedstawione przykłady wykorzystania sztucznych sieci neuronowych do odtwarzania brakujących profilowań geofizyki otworowej na podstawie dostępnych pomiarów ilustrują możliwości nowoczesnego narzędzia statystycznego. SSN zastosowano do odtworzenia czasu interwałowego, gęstości objętościowej i oporności pozornej w odcinkach otworów, w których brakowało danego pomiaru. Praca w rejonie badań w Karpatach Zachodnich była bardzo trudna ze względu na skomplikowaną tektonikę, powodującą brak pełnych sekwencji utworów zarówno w zakresie wykształcenia litologicznego, jak i wydzielenia stratygraficznego w interwałach trenowania sieci i odtwarzania parametrów.

Wykorzystanie perceptronów i zastosowanie wstecznej propagacji błędu jako efektywnej metody nauczania SSN były możliwe dzięki dostępności wyników pomiarów poszukiwanych parametrów oraz wartości estymowanych parametrów przynajmniej w niektórych fragmentach profili. Wytrenowane i zweryfikowane perceptrony były wykorzystane do odtworzenia szukanego parametru.

Sieci z dużą ilością parametrów na wejściu zwykle okazywały się najbardziej efektywne. Praca z sieciami o małej ilości wejść także dawała wiarogodne wyniki. Zwykle, najlepsze wyniki w zakresie odtwarzania parametrów uzyskiwano dla sieci z kilkoma neuronami ukrytymi. Pomoc oferowana przez moduł *Intelligent Problem Solver* w programie *Statistica Neural Network* firmy StatSoft była bardzo przydatna. Dzięki niej czas pracy przy wyborze i uczeniu sieci był krótszy i stosowano optymalne rozwiązania.

Najtrudniejsze zadanie stało przed interpretatorem i SSN przy odtwarzaniu parametrów w skomplikowanych warunkach litologiczno-stratygraficznych. Wtedy należało podzielić opracowywany interwał na możliwie małe odcinki związane z ustaloną litologią i stratygrafią, zarówno dla procesu uczenia, jak i dla odtwarzania parametrów.

Włączanie głębokości, jako wejściowego parametru prowadziło czasem do zafałszowania wyniku, zwłaszcza w przypadku dużej różnicy między głębokością interwału wykorzystanego do treningu i do odtworzenia.

Praca została wykonana w ramach projektu badawczego nr 4 T12 B 025 28 Ministerstwa Nauki i Informatyzacji pt. „Nowe aspekty interpretacji wyników pomiarów geofizycznych dla weryfikacji możliwości poszukiwania węglowodorów w Karpatach Zachodnich”. Część wyników uzyskanych w ramach projektu została włączona do prac magisterskich Anny Opyrchał i Dariusza Mozgowej, przygotowanych na WGGiOŚ AGH w roku akademickim 2006/07 pod kierunkiem Jadwigi Jarzyny.

LITERATURA

- Bała M., & Witek K., 2007. Model prędkościowy fal P i S oraz gęstości objętościowych dla wybranych otworów w rejonie Karpat Zachodnich. *Kwartalnik AGH Geologia*, 33, 4/1, 59–80.
- Burtan, J., 1978. *Objaśnienia do szczegółowej mapy geologicznej Polski, Arkusz Mszana Dolna (1016)*. Państwowy Instytut Geologiczny, Warszawa.

- Jarzyna J., Mozgowej D. & Opyrchał A., 2006. *Wykorzystanie sieci neuronowych do wyznaczenia profilowań geofizyki otworowej na podstawie znajomości parametrów fizycznych skał*. Prace Instytutu Nafty i Gazu, nr 137, 487–496.
- Mozgowej D., 2007. Ocena możliwości sieci neuronowych do przetwarzania i interpretacji profilowań geofizyki otworowej na przykładach z wybranych otworów. Praca dyplomowa, niepublikowana.
- Statistica Neural Networks, 1999. Licencja NN9 112228001A40.
- Opyrchał A., 2007. Obliczanie gęstości objętościowej oraz prędkości fal sprężystych w profilu otworu na podstawie wybranych profilowań geofizyki otworowej z wykorzystaniem sieci neuronowych. Praca dyplomowa, niepublikowana.
- Osowski S., 1996. *Sieci w ujęciu algorytmicznym*. Wydawnictwo Naukowo-Techniczne, Warszawa, 1–344.
- Tadeusiewicz R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa, 1–195.

Summary

Artificial Neural Networks, ANN, were applied for reconstructing transit interval time, bulk density and apparent resistivity in selected sections of boreholes in the study region. A short description of ANN (Fig. 1) as an effective statistical tool was done together with principles of net constructing. Explanation of the back propagation algorithm for ANN training and basic statistics for evaluating results were also done. Formula (1) presents the idea of perceptron. Formulas (2) and (3) describe how the back propagation algorithm works. Data from the W6 well were used to prepare the network (a perceptron with 5 input neurons and 3 neurons in the hidden layer) and train it for reconstructing transit interval time, DT SNN. Results of sensitivity analysis and regression statistics for that network are presented in Tables 2 and 3. That network was used for calculating DT in the W4 well in the similar geology (Fig. 2). A comparison of the results of two networks with different number of neurons (the 5/3 neuron perceptron described earlier and the other one with 8 input neurons and 4 ones in the hidden layer) was made in the W4 well (Fig. 3). Complicated relations of lithology and stratigraphy in W4, W6 and D6 boreholes are presented in Table 1. ANN trained on the W4 and W6 well data were used for DT reconstruction in the D6 well. Regression statistics for the networks prepared in the W6 and W4 wells and used in the D6 well in the Jurassic section are enclosed in Tables 4 and 5, respectively.

Bulk density was reconstructed in the L7 well and R3 well. In the lower part of the L7 profile 2 perceptrons were constructed on the basis of all available logs: GR, NPHI, SP, DT and CAL. Results of sensitivity analysis for these two networks are enclosed in Table 6. Bulk density, GEST, reconstructed with the use of these ANN vs. measured bulk density, RHOB is presented in figure 4. Regression statistics for two networks discussed are enclosed in Table 7. The best network, 10 is presented in figure 5. Comparison of the reconstructed bulk density, GEST (network 8) and density estimated with the *Estymacja* program, RHEQ, in the L7 well with transit interval time, DPEQ, presented on an additional axis is shown (Fig. 6). The upper interval in the L7 well, where bulk density was reconstructed, comprises only flysch formation. Therefore and because the results of reconstruction were not very good a new session of

constructing and training networks in the lower section of the L7 well was performed. Only the flysch interval (2194.25–2442 m) was taken into account. Results of training of 2 perceptrons are compared (Fig. 7). Sketches of the best perceptron in the training stage (3 input neurons and 4 ones in the hidden layer) and the network with a good result (3 neurons in the input and 3 in the hidden layer) in the L7 well in the flysch beds are shown in figure 8. Results of sensitivity analysis for networks 10 and 7 are presented in Table 8. Regression statistics for training networks for bulk density reconstruction in the L7 well on the basis of data from the flysch beds are in Table 9. Relations between bulk density from ANN 7, GEST 7 and estimated bulk density, RHEQ, in the upper interval of the L7 well are presented in figure 9 in different section due their various lithology.

Two perceptrons were trained in the R3 well in its lower section. Results of sensitivity analysis and regression statistics for these 2 networks are presented in Tables 10 and 11, respectively. All available logs were used as inputs. The reconstructions of bulk density with these networks were very good (Fig. 10). Similar results were obtained putting at the input of ANN in the training stage a small data file in the lower section of R3 well. The small file comprised logs available in the whole well. Dispersion plots for the results of training of 3 sets are presented in figure 11. Determination coefficients for correlation of the measured and reconstructed values of bulk density are quite high. But the reconstruction of bulk density in sections of different lithology was not satisfactory (Fig. 12). In the third attempt a network was trained on the basis of data from the whole well. The reconstructed bulk density, GEST, together with estimated density, RHEQ and the measured one, RHOB were compared (Figs 13 and 14). Experiments with constructing and training ANN for reconstructing apparent resistivity were performed in the L7 well. The depth interval in which a large set of resistivity logs was available was selected. In this interval ANNs were trained on the basis of the available classic resistivity logs for reconstructing apparent resistivity from LL3, ILD and LLD. Characteristics of two ANNs for reconstruction of apparent resistivity, RES, were compared (Tab. 12). Correctness of reconstruction was measured by analysis of similarity of resistivity curves (Fig. 14).

Presented analysis showed the ANN is an effective and fruitful statistical tool, which can be used in many cases for reconstructing logs. Diversity of logs enables to choose at inputs of ANN the ones that are in the best relation with the expected parameter (log at output). There are many difficulties, mainly associated with variability of lithology and stratigraphy. Intelligent Problem Solver offered by Statistica Neural Network is helpful and effective for training the best network and saving time of analysis.