

## Sztuczne sieci neuronowe w zastosowaniu do budowy modelu geologicznego Pradoliny Głogowsko-Barudzkiej w okolicy Nowej Sól

Andrzej Kraiński<sup>1</sup>, Maria Mrówczyńska<sup>1</sup>



A. Kraiński



M. Mrówczyńska

**The use of neural networks in the construction of geological model of the Głogów-Baruth Ice-Marginal Valley in the Nowa Sól area, Poland.** *Prz. Geol.*, 60: 650–656.

*Abstract.* This article attempts to determine the course of geological strata in part of the Głogów-Baruth Ice-Marginal Valley, using the multilayer neural networks of a sigmoidal type, trained by the back propagation method that is based on the known theory of gradient optimization methods. Determination of the trend of individual layers was made based on the coordinates (x, y) and the following data: depth of the top, depth of the base and thickness of the strata, obtained from field studies.

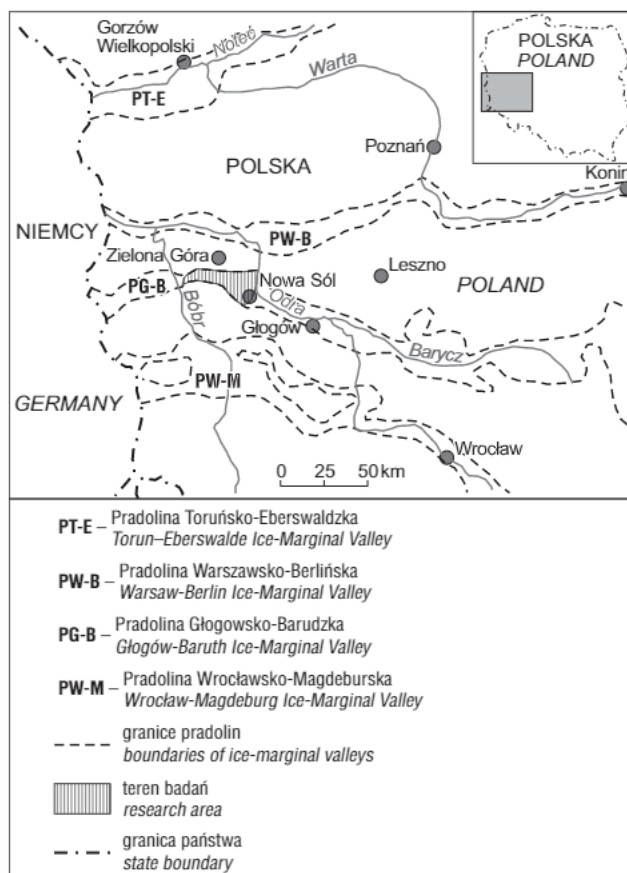
**Keywords:** neural networks, gradient methods of optimization, ice-marginal valley, glaciotectionic depression

Podstawową cechą systemów informacji przestrzennej jest duża liczba danych przestrzennych. Efektywność ich przetwarzania w dużym stopniu zależy od przyjętego modelu. Numeryczne modele przestrzenne dzielą się na modele punktowe, modele liniowe (wektorowe) i modele powierzchniowe, a ponadto każde z nich można podzielić na modele regularne i nieregularne. Podczas tworzenia numerycznych modeli przestrzennych podstawowe znaczenie mają numeryczna reprezentacja powierzchni terenu, utworzona przez zbiór odpowiednio wybranych punktów o współrzędnych przestrzennych (x, y, z), oraz algorytmy interpolacyjne pozwalające na przekształcenie danych punktowych w trójwymiarowy model tej powierzchni z odpowiednią dokładnością. Spośród algorytmów umożliwiających odtworzenie kształtu powierzchni terenu i przebiegu warstw geologicznych szczególnego znaczenia nabierają sztuczne sieci neuronowe jako uniwersalne aproksymatory. Aproksymacja powierzchni terenu i przebiegu warstw geologicznych przeprowadzona za pomocą sieci neuronowej polega na przybliżeniu funkcji wielu zmiennych  $\varphi(\mathbf{x})$ , określonej na dyskretnym zbiorze punktów, funkcją ciągłą  $f(\mathbf{w}, \mathbf{x})$ , gdzie  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$  to wektor sygnałów wejściowych w postaci danych wynikających z pomiaru, a  $\mathbf{w} = [w_1, w_2, \dots, w_n]^T$  ( $w_1, \dots, w_n \in \{0, 1\}$ ) jest wektorem współczynników (wag). Rozwiązanie zadania polega na wyznaczeniu takiego wektora  $\mathbf{w}^*$ , aby był spełniony warunek:

$$d[f(\mathbf{w}^*, \mathbf{x})\varphi(\mathbf{x})] \leq d[f(\mathbf{w}, \mathbf{x}), \varphi(\mathbf{x})], \quad (1)$$

gdzie odległość  $d[f(\mathbf{w}, \mathbf{x}), \varphi(\mathbf{x})]$  jest wskaźnikiem jakości przybliżenia funkcji  $f(\mathbf{w}, \mathbf{x})$  do  $\varphi(\mathbf{x})$  w określonym przedziale ( $a \leq x \leq b$ ).

W niniejszej pracy przedstawiono próbę aproksymacji przebiegu warstw geologicznych na obszarze Pradoliny Głogowsko-Barudzkiej (ryc. 1) metodą propagacji wstecznej błędu, za pomocą sieci neuronowej dwuwarstwowej



**Ryc. 1.** Położenie terenu badań na tle występowania pradolin w Polsce Zachodniej

**Fig. 1.** Location of the study area on the background of the occurrence of ice-marginal valleys in Western Poland

przy zastosowaniu bipolarnej funkcji aktywacji oraz z wykorzystaniem gradientowych metod optymalizacji (Kraiński & Mrówczyńska, 2010).

<sup>1</sup>Zakład Geotechniki i Geodezji, Wydział Inżynierii Lądowej i Środowiska, Uniwersytet Zielonogórski, ul. Prof. Z. Szafrana 1, 65-516 Zielona Góra.



## MODEL SIECI NEURONOWEJ

W celu wykonania odwzorowania wejście–wyjście posłużono się siecią o strukturze dwuwarstwowej. Neurony warstwy ukrytej były pobudzane przez nieliniową oraz ciągłą funkcję aktywacji (Bishop, 1995, 2006):

$$y = f(\mathbf{w}_i^T \mathbf{x}) = f(\text{net}) \quad (i = 1, 2, \dots, n), \quad (2)$$

której dziedziną jest zbiór łącznych pobudzeń neuronu. Do rozwiązania zadania wykorzystano sigmoidalną bipolarną funkcję aktywacji  $f(\text{net}) = \tanh(\lambda \text{net})$ , gdzie  $\lambda$  jest współczynnikiem nachylenia funkcji aktywacji. Zastosowanie ciągłej funkcji aktywacji pozwala przyjąć strategię doboru wag na podstawie gradientowych metod optymalizacji. W procesie realizacji numerycznej zadania korekcja wag polega na minimalizacji funkcji błędu  $E$ :

$$E = \frac{1}{2} \sum_{j=1}^m (d_j - z_j)^2, \quad (3)$$

definiowanej jako suma kwadratów różnic pomiędzy wartościami sygnałów na wyjściu: oczekiwaną  $d_j$  i aktualną  $z_j$  ( $j = 1, 2, \dots, m$ ). Należy dodać, że neurony warstwy wyjściowej posiadały liniową funkcję aktywacji (Rivals & Personnaz, 2000, 2003). Dla sieci dwuwarstwowej (ryc. 2) sygnał wyjściowy  $z$  wyraża zależność zapisana w postaci macierzowej (Żurada i in., 1996):

$$\mathbf{z} = \Gamma[\mathbf{W}\mathbf{y}] = \Gamma[\mathbf{W}\mathbf{I}[\mathbf{V}\mathbf{x}]], \quad (4)$$


gdzie  $\mathbf{W}$  jest macierzą wag w warstwie wyjściowej,  $\mathbf{V}$  jest macierzą wag w warstwie ukrytej, natomiast  $\Gamma$  jest operatorem nieliniowym w postaci macierzy diagonalnej zawierającej na głównej przekątnej wartości funkcji aktywacji  $f(\text{net})$ . Uczenie przeprowadzono metodą propagacji wstecznej błędu, wykorzystującą znane z teorii optymalizacji metody gradientowe. Podczas procesu uczenia wagi sieci są korygowane według zależności:

$$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) + \eta \mathbf{p}(n), \quad (5)$$

gdzie  $n$  odpowiada aktualnemu krokowi uczenia,  $\mathbf{p}(n)$  jest kierunkiem minimalizacji, zaś  $\eta$  – współczynnikiem uczenia.

Do rozwiązania zadania polegającego na aproksymacji przebiegu warstw geologicznych na obszarze Pradoliny Głogowsko-Barudzkiej wykorzystano metody gradientowe, a mianowicie: metodę największego spadku, metodę zmiennej metryki, metodę Levenberga–Marquardta oraz metodę gradientów sprzężonych (Riedmiller & Braun, 1992; Duch i in., 2000; Osowski, 2000). Zestawienie metod gradientowych wraz ze sposobem wyznaczenia kierunku minimalizacji  $\mathbf{p}(n)$  w poszczególnych iteracjach zawiera tabela 1. Ważnym zagadnieniem jest dobór kryterium zatrzymania algorytmu propagacji wstecznej błędu. Jest oczywiste, że w przypadku osiągnięcia minimum (lokalnego lub globalnego) wektor gradientu  $\mathbf{g}(\mathbf{w}(n))$  przyjmie wartość 0. Działanie algorytmu było zatrzymywane, jeżeli wartość normy euklidesowej wektora gradientu spadła poniżej założonego progu, wynoszącego  $1e^{-10}$ .

Oceny jakości aproksymacji za pomocą sieci neuronowych przy zastosowaniu wymienionych metod gradientowych dokonano na podstawie wartości pierwiastka błędu



Ryc. 2. Sztuczna sieć neuronowa  
Fig. 2. Artificial neural network

Tab. 1. Gradientowe metody optymalizacji  
Table 1. Gradient optimization methods

Metoda optymalizacji <i>Optimization method</i>	Kierunek minimalizacji $\mathbf{p}(n)$ <i>Direction to minimize <math>\mathbf{p}(n)</math></i>
metoda największego spadku <i>gradient descent method</i>	$\mathbf{p}(n) = -\mathbf{g}(\mathbf{w}(n)) = -\nabla E(\mathbf{w}(n))$
metoda zmiennej metryki <i>quasi-Newton method</i>	$\mathbf{p}(n) = -[\mathbf{H}(\mathbf{w}(n))]^{-1} \mathbf{g}(\mathbf{w}(n))$
metoda Levenberga–Marquardta <i>Levenberg–Marquardt method</i>	$\mathbf{p}(n) = -\frac{\mathbf{g}(\mathbf{w}(n))}{v_n}$
metoda gradientów sprzężonych <i>conjugate gradient method</i>	$\mathbf{p}(n) = -\mathbf{g}(\mathbf{w}(n)) + \beta_{n-1} \mathbf{p}_{n-1}$

średniokwadratowego RSME (ang. *root mean square error*) definiowanego wzorem:

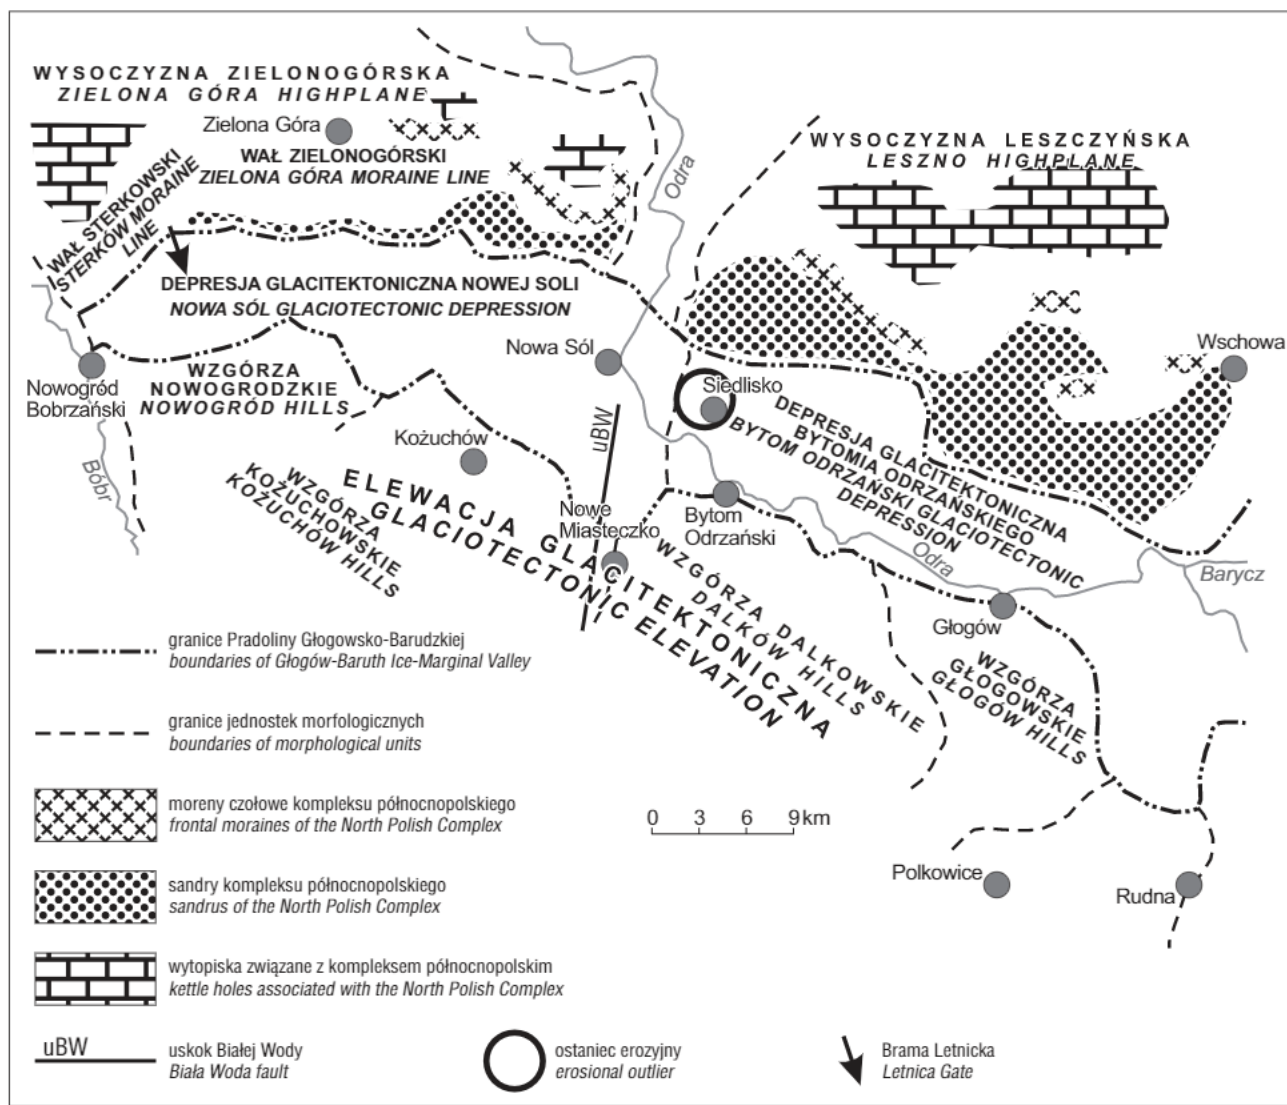
$$\text{RMSE} = \sqrt{\sum_{j=1}^p [d_j - z_j]^2}. \quad (6)$$

## ZAŁOŻENIA BUDOWY GEOLOGICZNEJ

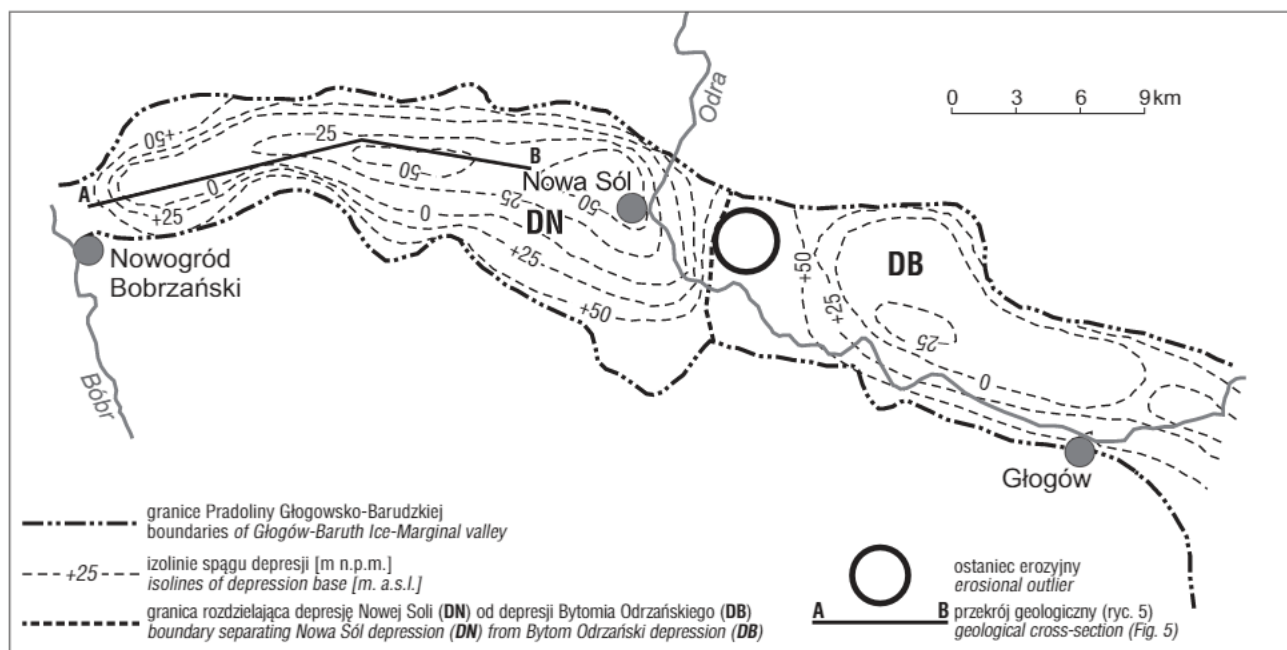
Depresja glacitektoniczna Nowej Soli została udokumentowana w pracach Kotowskiego i Kraińskiego (1986, 1988, 1988, 1992, 1995, 1997a) i Markiewicz (1995, 2003) jako jedna z dwóch w obrębie fragmentu Pradoliny Głogowsko-Barudzkiej (drugą jest depresja Bytomia Odrzańskiego). Obie formy mają analogiczne założenia, związane z działalnością lodolodu warty. Jednostka glacitektoniczna Nowej Soli rozciąga się między doliną Odry a doliną Bobru, natomiast depresja Bytomia Odrzańskiego obejmuje fragment dzisiejszej doliny Odry (ryc. 3). Struktury są oddzielone m.in. uskokiem Białej Wody, a w powierzchni współczesnej morfologii elementem rozdzielającym jest również ostaniec erozyjny Siedliska.

Analizując położenie powierzchni spągowej przedstawionej na rycinie 4, można zauważyć istotne zróżnicowanie powierzchni terenu, w tym obniżenie dna depresji Nowej Soli wynoszące 25 m. Wśród osadów wypełniających depresję glacitektoniczną Bytomia Odrzańskiego dominują piaski wodnolodowcowe z udokumentowanym stanowiskiem interglacjalu ceamskiego (Kuszell & Szałajdewicz, 1997).






Ryc. 3. Mapa rozmieszczenia depresji glacioteclonicznych we fragmencie Pradoliny Głogowsko-Barudzkiej (Kotowski & Kraiński, 1995)  
Fig. 3. Map of the distribution of glacioteclonic depressions in part of the Głogów-Baruth Ice-Marginal Valley (Kotowski & Kraiński, 1995)



Ryc. 4. Mapa powierzchni spągu depresji glacioteclonicznej Nowej Sól i Bytomia Odrzańskiego (Kotowski & Kraiński, 1995)  
Fig. 4. Map of the base of the Nowa Sól and Bytom Odrzański glacioteclonic depression (Kotowski & Kraiński, 1995)






Ryc. 5. Przekrój geologiczny wzdłuż fragmentu depresji glacitektonicznej Nowej Sól (Kotowski & Kraiński, 1995). Lokalizacja przekroju – zob. ryc. 4

Fig. 5. Geological cross-section along a part of the Nowa Sól glaciectonic depression (Kotowski & Kraiński, 1995). For location of cross-section see Fig. 4

Fakt ten jest o tyle istotny, że w depresji glacitektonicznej Nowej Sól, będącej w podobnej sytuacji (również hipsometrycznie), zalega warstwa torfów. Schemat budowy geologicznej przedstawiono na rycinie 5.

#### WYNIKI BADAŃ GEOLOGICZNYCH DEPRESJI GLACITEKTONICZNEJ NOWEJ SÓL

Wielowarstwowe sieci neuronowe wykorzystano do wyznaczenia przebiegu warstw geologicznych na obszarze depresji glacitektonicznej Nowej Sól o powierzchni ok. 297 km<sup>2</sup>. Na omawianym terenie zlokalizowano 137 otworów badawczych, z których 90 tworzyło zbiór uczący, a 47 – zbiór testowy. Położenie otworów badawczych oraz ukształtowanie terenu przedstawiono na rycinie 6. Uczenie sieci neuronowych metodą propagacji wstecznej błęd przy zastosowaniu gradientowych metod optymalizacji przeprowadzono dla różnych wariantów architektury sieci. Wektor wejściowy sieci neuronowej przyjęty w procesie uczenia i testowania dla powierzchni terenu oraz poszczególnych warstw geologicznych stanowiły współrzędne ( $x$ ,  $y$ ). Wektor wyjściowy dla powierzchni terenu stanowiły wysokości terenowe poszczególnych otworów badawczych, natomiast wektor wyjściowy dla warstw geologicznych zestawiono w postaci następujących danych: głębokości stropu, głębokości spągu i miąższości warstw w punktach aproksymowanych. Najbardziej korzystne wyniki dla zbioru testowego i struktury sieci 2-5-1 uzyskano z zastosowaniem metody gradientów sprzężonych i metody Levenberga–Marquardta (dla warstwy II z zastosowaniem metody zmiennej metryki), szczegółowe wyniki w postaci błęd średniokwadratowego RMSE dla jednej z warstw w zależności od metody optymalizacji oraz architektury sieci przedstawiono w tabeli 2.



Ryc. 6. Ukształtowanie powierzchni terenu wraz z położeniem otworów badawczych

Fig. 6. The terrain topography and location of boreholes

Wyniki uzyskane podczas procesu uczenia sieci pozwalają sprecyzować budowę geologiczną depresji glacitektonicznej Nowej Sól, którą przedstawiono w postaci rozkładu warstw geologicznych na rycinie 7. Oczywisty jest fakt, że im głębiej jest położona wyznaczana warstwa geologiczna, tym mniej posiadamy danych, co skutkuje zmniejszeniem dokładności budowanego modelu. Mała ilość danych uniemożliwiła zobrazowanie budowy geologicznej podłoża depresji glacitektonicznej. Jednocześnie z dużym prawdopodobieństwem można przyjąć, że na obszarze krawędziowym dominują iły neogeńskie, a w części spągowej omawianej formy gliny zwałowe (ryc. 5).

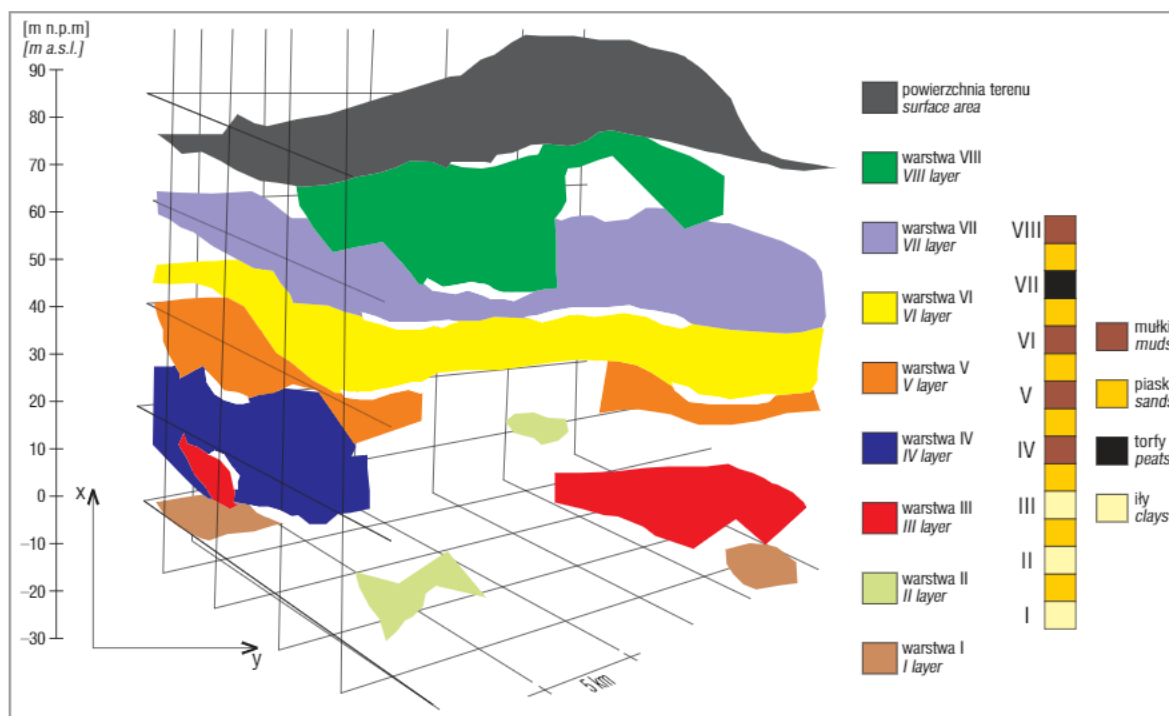
Wyznaczone warstwy geologiczne oznaczono cyframi rzymskimi (ryc. 7), zaczynając od najstarszej. Wszystkie warstwy – z wyjątkiem warstwy VII, w której występują lokalne przewarstwienia torfów – są zbudowane z mułków i iłów. Osady tworzące wydzielone warstwy są na ogół





**Tab. 2.** Błąd RMSE uczenia i testowania sieci neuronowej dla warstwy VIII  
**Table 2.** The RMSE error of learning and testing of the neural network for layer VIII

Gradientowa metoda optymalizacji <i>Gradient optimization method</i>	Błąd RMSE [m] dla zbioru uczącego oraz testowego w zależności od architektury sieci neuronowej i metody optymalizacji <i>RMSE mistake [m] for the learning and testing set based on neural network architecture and optimization method</i>					
	zbiór uczący <i>learning set</i>			zbiór testowy <i>testing set</i>		
	2-3-1	2-5-1	2-8-1	2-3-1	2-5-1	2-8-1
metoda gradientów sprzężonych <i>conjugate gradient method</i>	0,13	0,11	0,07	0,17	0,14	0,16
metoda Levenberga–Marquardta <i>Levenberg–Marquardt method</i>	0,16	0,15	0,10	0,19	0,17	0,21
metoda zmiennej metryki <i>quasi-Newton method</i>	0,15	0,12	0,09	0,18	0,18	0,19
metoda największego spadku <i>gradient descent method</i>	0,36	0,31	0,24	0,38	0,39	0,41



**Ryc. 7.** Rozmieszczenie warstw geologicznych wraz z profilem litologiczno-stratygraficznym  
**Fig. 7.** Distribution of geological strata with lithological-stratigraphic profile

laminowane, dlatego można je nazwać osadami warwowymi, względnie jeziornymi, w zależności od udokumentowania warunków klimatycznych (Kotowski & Kraiński, 1997a).

Dla powierzchni terenu oraz dla warstw oznaczonych numerami VII i VIII przeprowadzono wstępną analizę statystyczną. Szczegółowe wyniki, w postaci wartości najbardziej prawdopodobnej, mediany oraz odchylenia standardowego w rozbięciu na strop, spąg i miąższość obliczone dla wymienionych warstw, przedstawiono w tabeli 3. Wskazują one, że rozdzielenie między poszczególnymi warstwami jest wyraźne i dla danych z tabeli (identyfikowanych jako odpowiednia płaszczyzna stropu lub spągu warstwy) wynosi ok. 10–15 m, a miąższość wydzielonych warstw to ok. 6–8 m. Między tymi warstwami występują osady piaszczysto-żwirowe (od piasków plastycznych do żwirów). Rozciągłość wydzielonych warstw jest znaczna, a w przy-

padku, gdy leżą one blisko powierzchni terenu (warstwy VI i VII), obejmują prawie cały analizowany odcinek pradoliny. Uwagę zwraca też częste występowanie przewarstwień torfów w obrębie warstwy VII (na ogół w jej spągowej części), co umożliwia stosunkowo łatwą identyfikację stratygraficzną, ponieważ torfy te odpowiadają optimum interglacjału eemskiego (Kuszell & Szałajdewicz, 1997).

Jedność litologiczna kompleksu osadów wypełniających formę opisaną jako depresja glacictektoniczna Nowej Soli uzasadnia możliwość ich identyfikacji stratygraficznej według schematu:

– od spągu do poziomy torfów w stropie jako interglacjału eemski oraz w spągu postglacjału (złodowacenie warty), miąższość tego kompleksu sięgać może 80–90 m;

– od powierzchni terenu są to piaski o różnej granulacji, związane ze złodowaceniem wisły, w tym również poziomy sandrowe, miąższość tej serii sięga 20–30 m.



Z rozkładu warstwy VIII, dla której powierzchnia stropowa jest określana na rzędnej 71,2 m n.p.m., wynikają dwa istotne wnioski:

– warstwa ta występuje w zachodniej części terenu, do linii Bramy Letnickiej, która oddziela Wał Sterkowski od Wału Zielonogórskiego;

– połączenie tego faktu ze spadkiem powierzchni pradoliny na wschód (wyłącznie na analizowanym odcinku) powoduje, że bardziej prawdopodobny staje się wniosek o sływie jeziora zastoisowego położonego na północ od wałów Sterkowskiego i Zielonogórskiego w czasie gładcału lub w okresie postgładcałnym przez Bramę Letnicką na wschód od obecnej doliny Odry (Kotowski & Kraiński, 1997b).

Z rozkładu warstw VI i VII w części północno-wschodniej terenu podlegającego analizie wynika, że obie warstwy zostały pokryte materiałem lodowcowym (morena czołowa) i sandrową, związanymi ze zlodowaceniem wisły.

Szczegółowy obraz wybranej warstwy geologicznej w rozbiciu na strop i spąg przedstawiono na rycinie 8. Należy zwrócić uwagę na to, że na rycinie tej zastosowano bardzo duże przewiększenie, aby pokreślić istniejące nierówności warstw geologicznych.

## WNIOSKI

Wykorzystując sztuczne sieci neuronowe, wyznaczono powierzchnie stropowe i spągowe warstw mułkowo-iłowych przewarstwionych osadami piaszczystymi dla wybranego fragmentu Pradoliny Głogowsko-Barudzkiej, która stanowi tzw. depresję gładitektoniczną Nowej Soli. Na podstawie uzyskanych wyników zbudowano model geologiczny omawianego obszaru o powierzchni ok. 297 km<sup>2</sup>, dzięki któremu można wnioskować o ciągłości tworzących go warstw. W modelu geologicznym wydzielono osiem warstw (I–VIII) o różnym zasięgu, przy czym warstwy najstarsze charakteryzują się małym rozprzestrzenieniem ze względu na kształt depresji gładitektonicznej i w związku z tym w modelu są reprezentowane przez małą liczbę danych.

Wstępna analiza rozmieszczenia warstw geologicznych pozwala na wyciągnięcie dwóch istotnych wniosków, które mogą być przyczynkiem do dalszych badań:

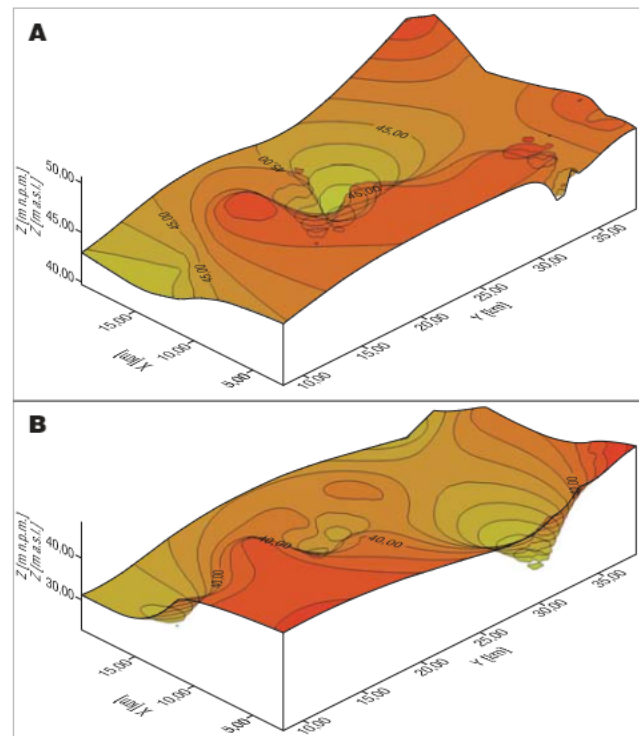
– nachylenie powierzchni Pradoliny Głogowsko-Barudzkiej na odcinku Nowogród Bobrzański–Nowa Sól w kierunku wschodnim może być związane ze sływem jeziora polodowcowego przez Bramę Letnicką;

– w części północnej pradoliny na osadach warstw VI i VII zalegają osady sandrowe oraz być może morenowe, związane ze zlodowaceniem wisły.

Sztuczne sieci neuronowe ze względu na ich nieliniowy charakter stanowią wyrafinowaną technikę modelowania i są zaliczane do metod inteligencji numerycznej. Sieci neuronowe mają właściwości wykorzystywane w wielu zastosowaniach praktycznych, ponieważ są uniwersalnym układem aproksymującym, mają zdolność uczenia się, jak również zdolność adaptacji do zmieniających się warunków. Zastosowanie sztucznych sieci neuronowych uczonych metodą propagacji wstecznej błędu z wykorzystaniem gradientowych metod optymalizacji pozwoliło na prześledzenie rozmieszczenia warstw geologicznych na podstawie informacji pozyskanych z otworów badawczych.

**Tab. 3.** Wyniki wstępnej analizy statystycznej  
**Table 3.** Preliminary analysis of the data

Powierzchnia terenu/ Surface area			
	strop top		
wartość najbardziej prawdopodobna [m n.p.m.] the most probable value [m a.s.l.]	80,5		
mediana [m n.p.m.] median [m a.s.l.]	79,9		
odchylenie standardowe [m n.p.m.] standard deviation [m a.s.l.]	7,5		
Warstwa VIII/ VIII layer			
	strop top	spąg base	miąższość thickness
wartość najbardziej prawdopodobna [m n.p.m.] the most probable value [m a.s.l.]	71,2	65,1	6,1
mediana [m n.p.m.] median [m a.s.l.]	71,5	64,9	5,8
odchylenie standardowe [m n.p.m.] standard deviation [m a.s.l.]	3,7	5,6	2,6
Warstwa VII (torf)/ VII layer (peat)			
	strop top	spąg base	miąższość thickness
wartość najbardziej prawdopodobna [m n.p.m.] the most probable value [m a.s.l.]	56,9	49,4	7,5
mediana [m n.p.m.] median [m a.s.l.]	56,5	49,4	6,9
odchylenie standardowe [m n.p.m.] standard deviation [m a.s.l.]	2,6	4,6	4,0



**Ryc. 8.** Powierzchnia stropu (A) i spągu (B) warstwy VI  
**Fig. 8.** Top surface (A) and basal surface (B) of layer VI

Dokładność uzyskanych wyników zależy od zastosowanej metody optymalizacji, a także od odpowiednio dobranej architektury sieci (liczby warstw oraz liczby neuronów



w warstwach). Najkorzystniejsze wyniki dla większości warstw geologicznych i dla danych tworzących zbiór testowy, przy relatywnie niskiej ilości iteracji, uzyskano, stosując metodę gradientów sprzężnych oraz metodę Levenberga–Marquardta. Najmniej korzystne rezultaty osiągnięto metodą największego spadku, co wynika ze zbieżności liniowej tej metody. Porównując zastosowaną metodę z metodami klasycznymi i z geostatystyką, można stwierdzić, że sieci neuronowe, będące relatywnie nowym narzędziem, pozwalają na uzyskanie korzystniejszych rezultatów rozkładu wartości wyznaczanych parametrów przy jednoczesnym zmniejszeniu nakładu pracy.

## LITERATURA

BISHOP CH.M. 1995 – Neural networks for pattern recognition. Oxford Univ. Press, USA.  
BISHOP CH.M. 2006 – Pattern recognition and machine learning. Springer, New York.  
DUCH W., KORBICZ J., RUTKOWSKI L. & TADEUSIEWICZ R. 2000 – Sieci neuronowe. [W:] M. Nałęcz (red.) Biocybernetyka i inżynieria biomedyczna. T. 6. Akad. Oficyna Wyd. Exit, Warszawa.  
KOTOWSKI J. & KRAIŃSKI A. 1986 – Związek kier glaciektonicznych z depresjami glaciektonicznymi. [W:] Interpretation of glaciektonic structures. V<sup>th</sup> Glacitectonic Symposium: 75–84. Wyd. WSI Zielona Góra.  
KOTOWSKI J. & KRAIŃSKI A. 1988 – Bau und Genese der Glacitektonische Scholie des Dalkowie – Hugellands bei Głogów VR Polen. Z. Geol. Wissenschaft, Band 16, 99: 153–156.  
KOTOWSKI J. & KRAIŃSKI A. 1992 – Kry glaciektoniczne w okolicy Kożuchowa. [W:] Glacitectonic deformations in Western Poland. VII<sup>th</sup> Glacitectonic Symposium, Zielona Góra: 65–76. Wyd. WSI Zielona Góra.  
KOTOWSKI J. & KRAIŃSKI A. 1995 – Budowa geologiczna depresji glaciektonicznych Nowej Soli i Bytomia Odrzańskiego. [W:] Regional Glacitectonic of Western Poland. VIII<sup>th</sup> Glacitectonic Symposium, Zielona Góra: 117–136. Wyd. WSI Zielona Góra.

KOTOWSKI J. & KRAIŃSKI A. 1997a – Warunki sedymentacji w początkowym okresie istnienia depresji glaciektonicznej Nowej Soli. Wyd. Politechniki Zielonogórskiej, Zesz. Nauk., 113: 25–37.  
KOTOWSKI J. & KRAIŃSKI A. 1997b – Uwagi o budowie geologicznej Bramy Letnickiej. Wyd. Politechniki Zielonogórskiej, Zesz. Nauk., 113: 49–63.  
KRAIŃSKI A. & MRÓWCZYŃSKA M. 2010 – Próba budowy modelu geologicznego pradoliny głogowsko-barudzkiej w okolicy Nowej Soli z wykorzystaniem sztucznych sieci neuronowych. Zesz. Nauk. Uniw. Zielonogórskiego, Inż. Środ., 139: 47–66.  
KUSZELL T. & SZALAJDREWICZ J. 1997 – Stanowisko interglacjału eemskiego w Katarzynowie koło Bytomia Odrzańskiego. [W:] Problemy zlodowaceń środkowopolskich w Polsce południowo-zachodniej. IV Konferencja Stratygrafia Plejstocenu Polski, Kamieniec Ząbkowicki: 181–183. Państw. Inst. Geol., Wrocław.  
MARKIEWICZ A. 1995 – Halotektonika soli cechsztyńskich w strefie dyslokacyjnej środkowej Odry a zaburzenia glaciektoniczne we Wzgórzach Dalkowskich. [W:] Regional Glacitectonic of Western Poland. VIII<sup>th</sup> Glacitectonic Symposium, Zielona Góra: 175–192. Wyd. WSI Zielona Góra.  
MARKIEWICZ A. 2003 – Halotektoniczne uwarunkowania sedymentacji i deformacji osadów kenozoicznych w południowej części monokliny przedsudeckiej (SW Polska). Zesz. Nauk. Uniw. Zielonogórskiego, Budow., 130: 115–124.  
OSOWSKI S. 2000 – Sieci neuronowe do przetwarzania informacji. Oficyna Wyd. Politech. Warsz., Warszawa.  
RIEDMILLER M. & BRAUN H. 1992 – RPROP – a fast adaptive learning algorithm. Technical Report. Univ. Karlsruhe, Germany.  
RIVALS I. & PERSONNAZ L. 2000 – Construction of confidence intervals for neural networks based on least squares estimation. Neural Networks, 13: 463–484.  
RIVALS I. & PERSONNAZ L. 2003 – MLPs (mono-layer polynomials and multi-layer perceptrons) for nonlinear modeling. J. Mach. Learn. Res., 3: 1383–1398.  
ŻURADA J., BARSKI M. & JĘDRUCH W. 1996 – Sztuczne sieci neuronowe. Podstawy teorii i zastosowania. Wyd. Nauk. PWN, Warszawa.

Praca wpłynęła do redakcji 11.06.2012 r.  
Po recenzji akceptowano do druku 3.10.2012 r.

