

ANDRZEJ KRAIŃSKI \*  
MARIA MRÓWCZYŃSKA \*

## PRÓBA BUDOWY MODELU GEOLOGICZNEGO PRADOLINY GŁOGOWSKO–BARUDZKIEJ W OKOLICY NOWEJ SOLI Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

### *Streszczenie*

*W artykule podjęto próbę wyznaczenia przebiegu warstw geologicznych dla fragmentu obszaru pradoliny głogowsko – barudzkiej, wykorzystując w tym celu sieci neuronowe jednokierunkowe wielowarstwowe typu sigmoidalnego uczone metodą propagacji wstecznej błędu, która bazuje na znanych z teorii optymalizacji metodach gradientowych. Wyznaczenie przebiegu poszczególnych warstw zostało wykonane na podstawie współrzędnych (x,y) oraz danych w postaci wysokości stropu, głębokości spągu oraz miąższości warstw uzyskanych na podstawie badań terenowych.*

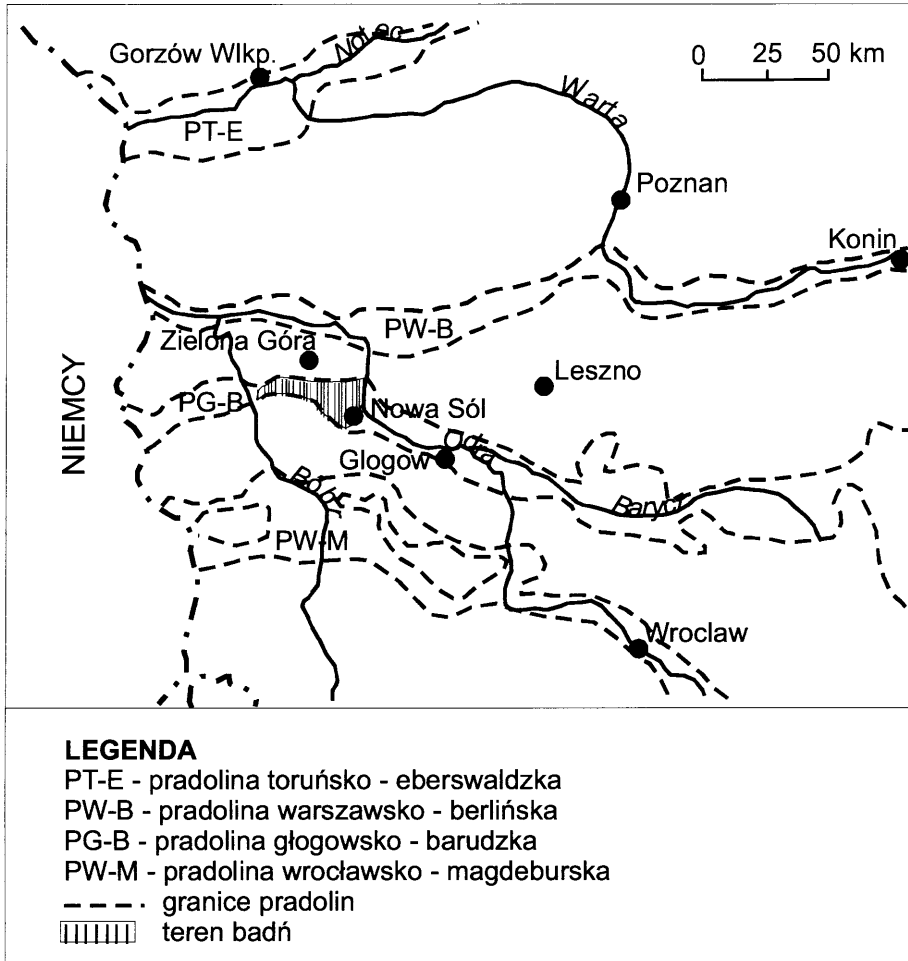
Słowa kluczowe: pradolina, depresja glacitektoniczna, sztuczne sieci neuronowe, gradientowe metody optymalizacji,

### **Model sieci neuronowej**

Do budowy modelu warstw geologicznych na obszarze pradoliny głogowsko barudzkiej (rys. 1) wykorzystano sztuczne sieci neuronowe jednokierunkowe oraz jednokierunkowe wielowarstwowe o sigmoidalnych funkcjach aktywacji (perceptron wielowarstwowy), które znalazły zastosowanie do rozwiązywania wielu problemów praktycznych z różnych dziedzin wiedzy. Stanowią wówczas najczęściej element sterujący procesem bądź są częścią decyzyjną przekazującą sygnał wykonawczy do elementów urzędzenia, nie związanego bezpośrednio z sieciami neuronowymi.

---

\* Uniwersytet Zielonogórski, Wydział Inżynierii Łądowej i Środowiska, Zakład Geotechniki i Geodezji, ul. Z.Szafrana 1, 65-516 Zielona Góra



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

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

Sieci neuronowe pełnią funkcje, które można przedstawić w kilku podstawowych grupach: aproksymacja i interpolacja, rozpoznawanie i klasyfikacja wzorców, kompresja, identyfikacja oraz predykcja. W każdym z tych zastosowań sieć pełni rolę uniwersalnego aproksymatora funkcji wielu zmiennych, który realizuje funkcję nieliniową:

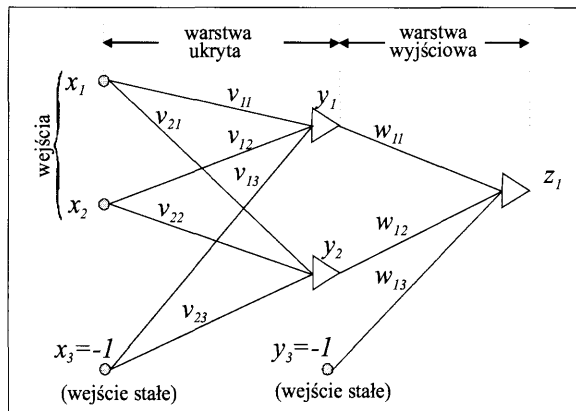
$$y = f(x) \quad (1)$$

gdzie  $\mathbf{x}$  jest wektorem wejściowym, natomiast  $\mathbf{y}$  realizowaną funkcją wielu zmiennych.

Realizacja zadań za pomocą sieci neuronowych wymaga nauczenia sieci prawidłowego przetwarzania informacji. Uczenie sieci polega na wyznaczeniu wag neuronów w taki sposób, żeby na podstawie danych wprowadzonych do obliczeń (wektor wejściowy  $\mathbf{x}$ ) uzyskać taki wektor wyjściowy  $\mathbf{y}$ , którego współrzędne  $y_i$  byłyby pod względem wartości najbliższe współrzędnym  $d_i; i=1,2,K M$  wektora zadanego  $\mathbf{d}$ . Minimalizacja różnic między wartościami sygnałów wyjściowych  $y_i$  a wartościami zadanymi  $d_i$  odpowiada minimalizacji funkcji celu  $E$ , definiowanej z wykorzystaniem metryki euklidesowej jako [Osowski 2000, Rutkowski 2006]:

$$E = \frac{1}{2} \sum_{i=1}^N \|\mathbf{y}_i - \mathbf{d}_i\|^2 = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^M (y_i^j - d_i^j)^2, \quad (2)$$

gdzie  $N$  jest liczbą wektorów wejściowych  $M$  liczbą współrzędnych wektora wyjściowego. Schemat sieci neuronowej dwuwarstwowej, wykorzystanej w niniejszym artykule został przedstawiony na rys. 2.



Rys. 2. Sieć neuronowa jednokierunkowa dwuwarstwowa  
Fig. 2. One-way two-layer neural network

Adaptacja wektora wag (uczenie sieci) przebiega zgodnie z regułą:

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \eta p(\mathbf{w}^{(k)}) \quad (3)$$

gdzie  $k$  oznacza numer kolejnej iteracji,  $\eta$  - współczynnik uczenia,  $p(\mathbf{w}^{(k)})$  jest kierunkiem minimalizacji w przestrzeni wielowymiarowej  $\mathbf{w}$ .

Metody gradientowe wykorzystują informacje dotyczące gradientu funkcji celu, który wykazuje kierunek największego wzrostu funkcji. Określenie gradientu wymaga rozwinięcia funkcji  $E(\mathbf{w})$  w dowolnie bliskim otoczeniu aktualnego rozwiązania  $\mathbf{w} = [w_1, w_2, \dots, w_n]^T$  w szereg Taylora

$$E(\mathbf{w} + \mathbf{p}) = E(\mathbf{w}) + [\mathbf{g}(\mathbf{w})]^T \mathbf{p} + \frac{1}{2} \mathbf{p}^T \mathbf{H}(\mathbf{w}) \mathbf{p} + \Lambda, \quad (4)$$

gdzie

$$\mathbf{g}(\mathbf{w}) = \nabla E(\mathbf{w}) = \left[ \frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_n} \right]^T - \text{gradientu } \mathbf{w} \text{ kierunku } \mathbf{p},$$

$$\mathbf{H}(\mathbf{w}) = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \Lambda & \frac{\partial^2 E}{\partial w_1 \partial w_n} \\ \mathbf{M} & \mathbf{O} & \mathbf{M} \\ \frac{\partial^2 E}{\partial w_n \partial w_1} & \Lambda & \frac{\partial^2 E}{\partial w_n \partial w_n} \end{bmatrix} - \text{hesjan.}$$

Rozwinięcie w szereg Taylora funkcji  $E(\mathbf{w})$  z uwzględnieniem składnika drugiego rzędu dostarcza informacji na temat krzywizny funkcji zawartej w hesjanie. Pominięcie tego składnika, jak to ma miejsce w przypadku stosowania metody największego spadku, pozwala jedynie uzyskać zbieżność liniową szczególnie w pobliżu punktu optymalnego. Jeżeli  $\mathbf{g}(\mathbf{w})^{(k)} = 0$  oraz hesjan  $\mathbf{H}(\mathbf{w})^{(k)}$  jest dodatnio określony, wówczas wartość funkcji celu  $E(\mathbf{w})$  w dowolnym punkcie należącym do bliskiego otoczenia punktu  $\mathbf{w}^{(k)}$  ma wartość większą niż w punkcie  $\mathbf{w}^{(k)}$ . Zatem punkt  $\mathbf{w}^{(k)}$  jest rozwiązaniem odpowiadającym minimalnej wartości funkcji celu.

Powszechnie stosowanym algorytmem wyboru kierunku minimalizacji jest algorytm największego spadku, który w procesie aktualizacji wag przyjmuje postać

$$w_{ij}^{(k+1)} = w_{ij}^{(k)} - \eta \frac{\partial E}{\partial w_{ij}}. \quad (5)$$

Metoda największego spadku zyskuje uznanie głównie ze względu na prostą realizację numeryczną oraz nie wymagającą zbyt dużej pamięci operacyjnej. W tym miejscu rozpatrywane zagadnienie należy uzupełnić uwagą, że korekta wag następuje w kierunku ujemnego wektora gradientu funkcji celu.

Metoda zmiennej metryki należy do metod quasi-newtonowskich, wykorzystujących w algorytmie informacje na temat krzywizny minimalizowanej funkcji bez konieczności kłopotliwego w realizacji jawnego wyznaczenia macierzy hesjanu. W metodach quasi – newtonowskich macierz hesjanu jest aproksymowana za pomocą różnicy pochodnych pierwszego rzędu. Ten tok postępowania nie wymaga trudnego do spełnienia (w ogólnym przypadku) warunku dodatniej określoności hesjanu w każdej iteracji, co ułatwia praktyczną implementację algorytmu. Zatem, stacjonarny punkt  $\mathbf{w}^*$  minimum funkcji celu  $E(\mathbf{w})$  będziemy poszukiwać na kierunku

$$\mathbf{p}^{(k)} = -[\mathbf{G}(\mathbf{w})^{(k)}]^{-1} \mathbf{g}(\mathbf{w})^{(k)}, \quad (6)$$

przy czym macierz odwrotna przybliżonego hesjanu  $\mathbf{V}^{(k)} = [\mathbf{G}(\mathbf{w})^{(k)}]^{-1}$  jako macierz modyfikowana z poprzedniej iteracji (wartość startowa  $\mathbf{V}^0 = \mathbf{I}$ ) została opisana rekurencyjną zależnością (algorytm Davidona – Fletchera – Powella [Osowski 2000, Stachurski&Wierzbicki 2001])

$$\mathbf{V}^{(k)} = \mathbf{V}^{(k-1)} + \frac{\mathbf{s}^{(k)}(\mathbf{s}^{(k)})^T}{(\mathbf{s}^{(k)})^T \mathbf{r}^{(k)}} - \frac{\mathbf{V}^{(k-1)} \mathbf{r}^{(k)}(\mathbf{r}^{(k)})^T \mathbf{V}^{(k-1)}}{(\mathbf{r}^{(k)})^T \mathbf{V}^{(k-1)} \mathbf{r}^{(k)}} \quad (7)$$

gdzie  $\mathbf{s}^{(k)}$  oraz  $\mathbf{r}^{(k)}$  oznaczają odpowiednio przyrost wektora wag  $\mathbf{w}$  oraz gradientu  $\mathbf{g}(\mathbf{w})$  w dwóch kolejnych iteracjach, tj.  $\mathbf{s}^{(k)} = \mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}$ ,  $\mathbf{r}^{(k)} = \mathbf{g}(\mathbf{w})^{(k)} - \mathbf{g}(\mathbf{w})^{(k-1)}$ .

Metoda Levenberga – Marquardta jest bardzo zbliżona do metody zmiennej metryki. Jej zaletą jest to, że prawie zawsze jest zbieżna i nie „zwalnia zbieżności”, co często występuje w metodzie największego spadku. Analogicznie jak w metodzie zmiennej metryki wykorzystuje się kwadratowe przybliżenie funkcji celu  $E(\mathbf{w})$  oraz aproksymowaną wartość hesjanu  $\mathbf{G}(\mathbf{w})$  z uwzględnieniem czynnika regularyzacji  $r^{(k)} \mathbf{I}$ .

Metoda gradientów sprzężonych wykorzystuje model kwadratowy funkcji celu bez konieczności wykonania w każdej iteracji szeregu operacji macierzowych. Kierunki  $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n$  nazywamy kierunkami sprzężenia, które

generowane są na podstawie informacji o nowych pochodnych i poprzednich kierunkach. Wektor kierunkowy w  $k$  – tej iteracji przyjmuje postać

$$\mathbf{p}^{(k)} = -\mathbf{g}(\mathbf{w})^{(k)} + \beta^{(k-1)} \mathbf{p}^{(k-1)} \quad (8)$$

gdzie:  $\mathbf{g}(\mathbf{w})^{(k)}$  - wektor gradientu,  $\beta^{(k-1)}$  - współczynnik sprzężenia.

Spśród wielu reguł wyznaczenia współczynnika sprzężenia  $\beta^{(k-1)}$ , najczęściej stosowane są metoda Polaka – Riebiere’a oraz metoda Fletchera – Reevesa [Osowski 2000, Stachurski&Wierzbicki 2001]:

Algorytm, który pozwala na uzyskanie bardzo dobrych wyników uczenia, przy relatywnie niskiej ilości iteracji jest algorytm *Resilient Backpropagation* (algorytm RPROP). Umożliwia on przyspieszanie zbieżności i zmniejsza ryzyko zatrzymania procesu w lokalnym minimum. Istota algorytmu polega na aktualizacji wag w zależności od znaku składowych gradientu, zaś sama jego wartość jest pomijana [Duch i in. 2000, Osowski 2000, Riedmiller&Braun 1992].

Korekta wag przebiega według zależności

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} - \eta^{(k)} \operatorname{sgn}(\nabla E(\mathbf{w})^{(k)}), \quad (9)$$

w której współczynnik uczenia  $\eta$  jest zależny od znaku gradientu. Współczynnik  $\eta$  jest dobierany w każdym cyklu dla każdej wagi  $w$  indywidualnie. Wzrost wartości tego współczynnika następuje wtedy, gdy znak gradientu w dwóch kolejnych iteracjach jest jednakowy, natomiast w przeciwnym wypadku następuje jego redukcja. W związku z tym

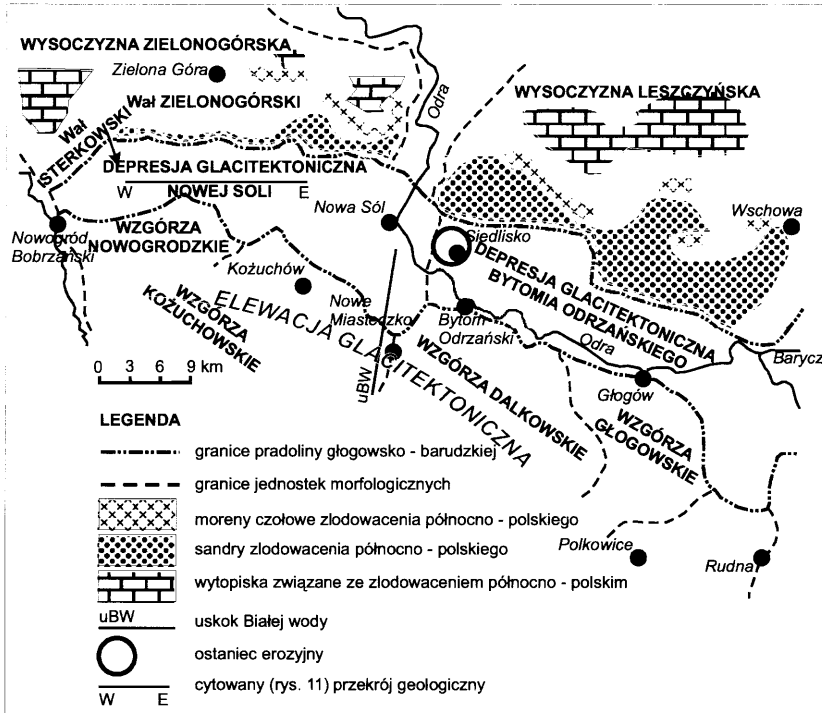
$$\eta^{(k)} = \begin{cases} \min(a\eta^{(k-1)}, \eta_{\min}) & \text{dla } \nabla E(\mathbf{w})^{(k)} \nabla E(\mathbf{w})^{(k-1)} > 0 \\ \max(b\eta^{(k-1)}, \eta_{\max}) & \text{dla } \nabla E(\mathbf{w})^{(k)} \nabla E(\mathbf{w})^{(k-1)} < 0. \\ \eta^{(k-1)} & \text{w innym przypadku} \end{cases} \quad (10)$$

Zawarte we wzorach symbole  $a$  i  $b$  są stałymi:  $a = 1.2$ ,  $b = 0.5$ , natomiast  $\eta_{\min}$  i  $\eta_{\max}$  oznaczają odpowiednio minimalną i maksymalną wartość współczynnika uczenia, równą w algorytmie RPROP odpowiednio  $10^{-6}$  oraz 50 [Duch i in. 2000, Osowski 2000, Riedmiller&Braun 1992].

Oceny jakości aproksymacji za pomocą sieci neuronowych przy zastosowaniu wyżej wymienionych metod gradientowych dokonano na podstawie wartości pierwiastka błędu średniokwadratowego *RSME* (ang. *Root Mean Square Error*), definiowanego wzorem

$$RMSE = \sqrt{\sum_{j=1}^p [d_j - z_j]^2} \quad (10)$$

gdzie:  $d_j$  - sygnał oczekiwany na wyjściu,  $z_j$  - sygnał uzyskany na wyjściu.



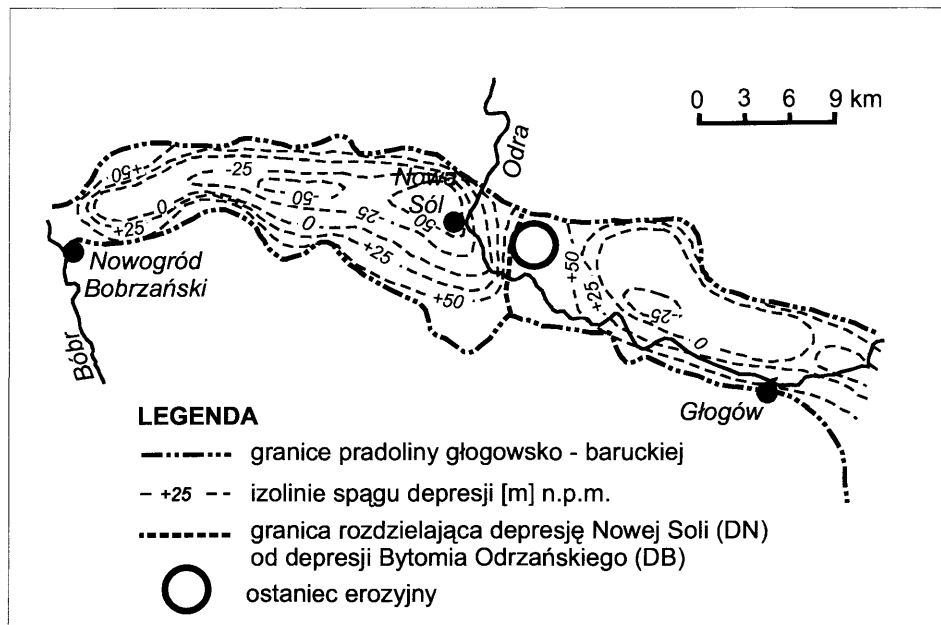
Rys. 3. Mapa rozmieszczenia depresji glacitektonicznych we fragmencie pradoliny głogowsko – barudzkiej [Kotowski&Kraiński 1995a]

Fig. 3. Map of the location of glacial tectonic depression in the passage great-valley Głogów [Kotowski&Kraiński 1995a]

### Założenia budowy geologicznej

Depresja glacitektoniczna Nowej Soli została udokumentowana w pracach Kotowskiego i Kraińskiego [1986, 1988, 1989, 1992, 1995a, 1996] oraz Markiewicza [1995, 2003], jako jedna z dwóch w obrębie fragmentu pradoliny głogowsko – barudzkiej, drugą jest depresja Bytomia Odrzańskiego. Obie depresje mają analogiczne założenia, związane z działalnością lądolodu warty.

Depresja glacitektoniczna Nowej Soli rozciąga się pomiędzy doliną Odry a doliną Bobru, natomiast depresja Bytomia Odrzańskiego obejmuje fragment dzisiejszej doliny Odry (rys. 3). Obie depresje oddzielone są m.in. uskokiem Białej Wody a w powierzchni współczesnej morfologii elementem rozdzielającym jest również ostaniec erozyjny Siedliska.

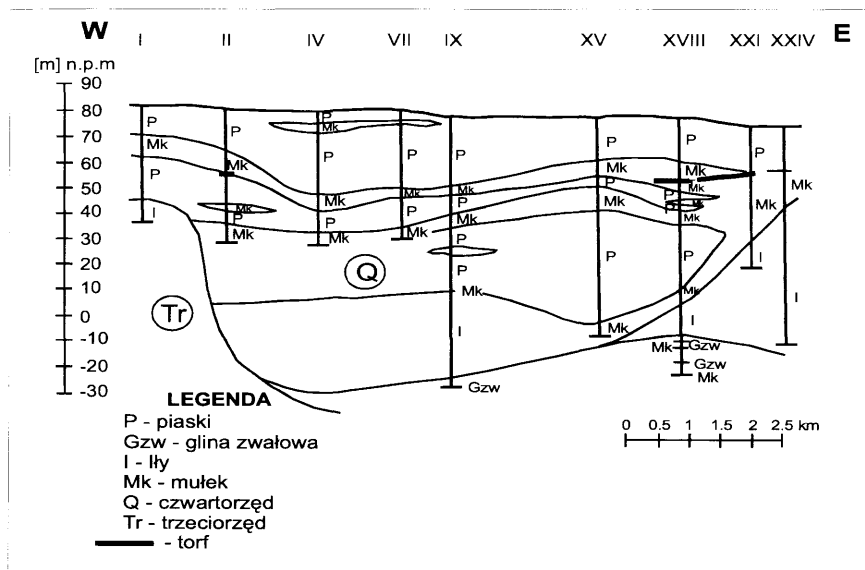


Rys. 4. Mapa powierzchni spągu depresji glacitektonicznej Nowej Soli i Bytomia Odrzańskiego [J.Kotowski&Kraiński 1995a]

Fig. 4. Map of the floor area of glacitectonic depression of Nowa Sól and Bytom Odrzański [J.Kotowski&Kraiński 1995a]

Analizując położenie powierzchni spągowej, przedstawionej graficznie na rys. 4, można zauważyć istotne zróżnicowanie powierzchni terenu, w tym obniżenie dna depresji Nowej Soli wynoszące 25m. W budowie geologicznej depresji glacitektonicznej Bytomia Odrzańskiego dominują piaski wodnolodowcowe z dokumentowanym stanowiskiem interglacjału emskiego [Kuszell&Szałajdewicz 1997], fakt ten jest o tyle istotny, że w depresji glacitektonicznej Nowej Soli będącej w podobnej sytuacji (również hipsometrycznie) zalega warstwa torfów. Przykład budowy geologicznej przedstawiono graficznie na rys. 5.






Rys. 5. Przekrój geologiczny wzdłuż fragmentu depresji glacitektonicznej Nowej Sól [Kotowski&Kraiński 1995a]

Fig. 5. Geological cross-section along a portion of glaciectonic depression of Nowa Sól [Kotowski&Kraiński 1995a]

### Wyniki badań geologicznych depresji glacitektonicznej Nowej Sól

Sieci neuronowe wielowarstwowe zostały wykorzystane do wyznaczenia przebiegu warstw geologicznych na obszarze depresji glacitektonicznej Nowej Sól o powierzchni około 297 km<sup>2</sup>. Na omawianym terenie zostało zlokalizowanych 135 punktów pomiarowych, 90 punktów tworzyło zbiór uczący, 47 punktów zbiór testowy. Położenie punktów pomiarowych oraz ukształtowanie terenu na omawianym obszarze zostało przedstawione na rys. 6. Uczenie sieci neuronowych zostało przeprowadzone metodą propagacji wstecznej błędu przy zastosowaniu gradientowych metod optymalizacji, 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 punktów pomiarowych, natomiast wektor wyjściowy dla warstw geologicznych został zestawiony w postaci następujących danych: głębokości stropu, głębokość spągu oraz miąższość warstw w punktach aproksymowanych. Najbardziej korzystne wyniki uzyskano z zastosowaniem metody gradientów sprzężonych oraz metody RPROP, szczegółowe wyniki w postaci błędów średnio-

kwadratowego *RMSE* dla jednej z warstw w zależności od metody optymalizacji oraz architektury sieci zostały przedstawione w tabelicy 1.

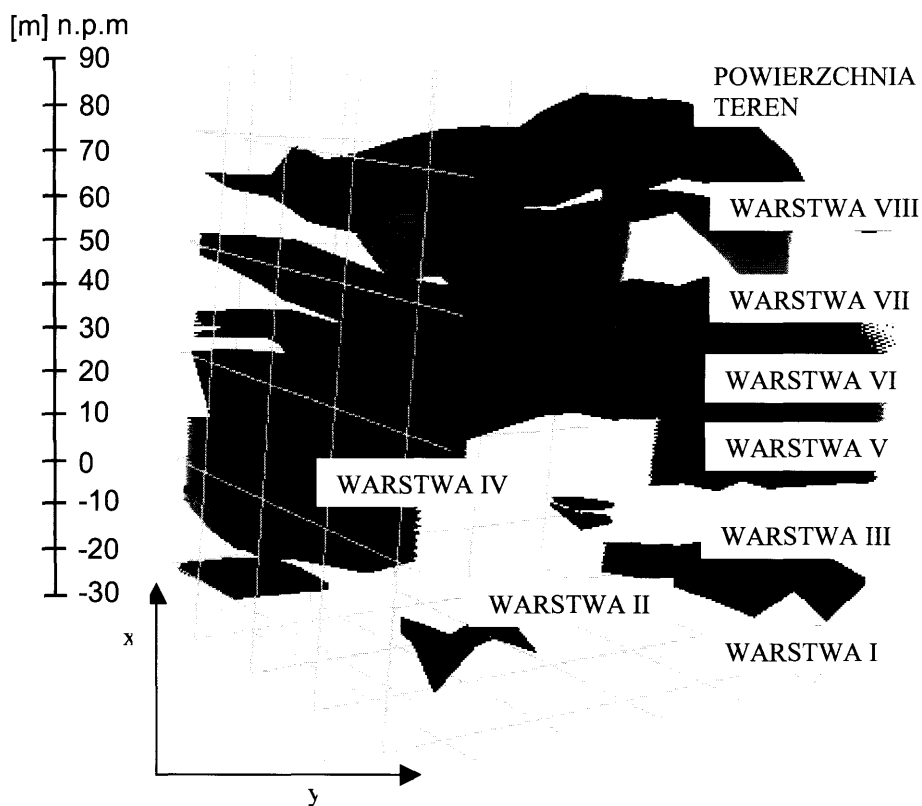


Rys. 6. Ukształtowanie powierzchni terenu wraz z położeniem otworów  
Fig. 6. The lie of the land surface and the location of holes


Tablica 1. Wyniki uczenia i testowania sieci neuronowej dla warstwy VIII w zależności od architektury sieci i metody optymalizacji  
Table 1 The results of learning and testing the neural network layer VIII, depending on network architecture and optimization methods

Gradientowa metoda optymalizacji	Błąd <i>RMSE</i> [m] dla zbioru uczącego oraz testowego w zależności od architektury sieci neuronowej					
	Zbiór uczący			Zbiór testowy		
	2-5-1	2-10-1	2-15-1	2-5-1	2-10-1	2-15-1
metoda gradientów sprzężonych	0,18	0,15	0,11	0,22	0,17	0,15
algorytm <i>RPROP</i>	0,19	0,16	0,10	0,24	0,18	0,16
metoda zmiennej metryki	0,22	0,20	0,15	0,26	0,24	0,22
Metoda Levenberga – Marquardta	0,35	0,31	0,29	0,38	0,36	0,35
metoda największego spadku	0,55	0,54	0,52	0,51	0,49	0,48

Prezentowane dane pozwalają sprecyzować budowę geologiczną depresji glaciektonicznej Nowej Soli, która została przedstawiona graficznie w postaci rozkładu warstw geologicznych na rys. 7 i rys. 8. Oczywisty jest fakt, że im głębiej położona jest wyznaczana warstwa geologiczna tym mniej posiadamy danych co skutkuje zmniejszeniem dokładności budowanego modelu. Mała ilość danych spowodowała również brak możliwości wyznaczenia budowy geologicznej podłoża depresji glaciektonicznej. Jednocześnie z dużym prawdopodobieństwem można przyjąć, że na obszarze krawędziowym dominują ropy trzeciorzędowe w częściach brzeżnych oraz gliny zwałowe w części spągowej omawianej formy (rys. 5).



Rys. 7. Rozmieszczenie warstw geologicznych  
Fig. 7. Distribution of geological strata



*Rys. 8. Rozmieszczenie warstw geologicznych (zmienna perspektywa)*  
*Fig. 8. Distribution of geological strata (variable perspective)*

Wyznaczone warstwy geologiczne oznaczono cyframi rzymskimi (rys. 7) poczynając od najmłodszej. Wszystkie warstwy, z wyjątkiem warstwy VII, w której występują lokalne przewarstwienia torfów, zbudowane są z mułków i iłów. Osady stanowiące wydzielone warstwy są na ogół laminowane, stąd można je nazwać osadami warwowymi, względnie jeziornymi w zależności od udokumentowania warunków klimatycznych [Kotowski&Kraiński 1997a].

Dla powierzchni terenu oraz dla warstw oznaczonych symbolami VI, VII, VIII (rys. 7, rys. 8) przeprowadzono wstępną analizę statystyczną. Szczegółowe wyniki w postaci wartości najbardziej prawdopodobnej, mediany oraz odchylenia standardowego w rozbiciu na strop, spąg i miąższość obliczone dla wymienionych warstw zostały przedstawione w tablicy 2.

*Tablica 2. Wyniki wstępnej analizy statystycznej*

*Table 2. The results of the preliminary statistical analysis*

<b>Warstwa VI</b>			
	strop	spąg	miąższość
wartość najbardziej prawdopodobna [m] n.p.m.	46,7	39,3	7,4
mediana [m] n.p.m.	47,4	39,7	6,4
odchylenie standardowe [m] n.p.m.	2,0	5,3	4,9
<b>Warstwa VII (TORF)</b>			
	strop	spąg	miąższość
wartość najbardziej prawdopodobna [m] n.p.m.	56,9	49,4	7,5
mediana [m] n.p.m.	56,5	49,4	6,9
odchylenie standardowe [m] n.p.m.	2,6	4,6	4,0
<b>Warstwa VIII</b>			
	strop	spąg	miąższość
wartość najbardziej prawdopodobna [m] n.p.m.	71,2	65,1	6,1
mediana [m] n.p.m.	71,5	64,9	5,8
odchylenie standardowe [m] n.p.m.	3,7	5,6	2,6
<b>Powierzchnia terenu</b>			
	strop		
wartość najbardziej prawdopodobna [m] n.p.m.	80,5		
mediana [m] n.p.m.	79,9		
odchylenie standardowe [m] n.p.m.	7,5		

Przedstawione w tablicy 2 wyniki analizy statystycznej wskazują, że rozdzielenie pomiędzy poszczególnymi warstwami jest wyraźne i wynosi dla danych prezentowanych w tabeli (identyfikowanych jako odpowiadająca płaszczyzna stropu lub spągu warstwy) około 10-15m, a miąższość wydzielonych warstw to około 6-8m. Pomiedzy wydzielonymi warstwami występują osady piaszczysto – żwirowe (od piasków plastycznych do żwirów). Rozciągłość wydzielonych warstw jest znaczna, a w przypadku ich bliskiego położenia w stosunku do powierzchni terenu (warstwy VI i VII) obejmują one

prawie cały analizowany odcinek pradoliny. Uwagę zwraca też częste występowanie przewarstwienia torfów w obrębie warstwy VII (na ogół w jej spągowej części), co umożliwia stosunkowo łatwą identyfikację stratygraficzną, ponieważ torfy te odpowiadają optimum interglacjału eemskiego.

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

**od spągu do poziomu torfów jako interglacjał eemski w stropie oraz spągu postglacjał (złodowacenie warty), miąższość tego kompleksu sięgać może 80-90 metrów,**

**od powierzchni terenu są to piaski o różnej granulacji, związane ze złodowaceniem wisły, w tym i poziomy sandrowe, miąższość tej serii sięga 20-30 metrów.**


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

**warstwa ta występuje w zachodniej części terenu, do linii tzw. Bramy Letnicy, która oddziela Wał Sterkowski od Wału Zielonogórskiego,**


**połączenie tego faktu ze spadkiem powierzchni pradoliny (wyłącznie na analizowanym odcinku) powoduje, że bardziej prawdopodobny staje się wniosek o splywie jeziora zastoisowego położonego na północ od Wału Sterkowskiego i Wału Zielonogórskiego w okresie postglacjalnym przez Bramę Letnicką na wschód od obecnej doliny Odry [Kotowski& Kraiński 1997b].**

Z rozkładu warstwy VI i VII w części północno – wschodniej terenu podlegającego analizie wynika, że obie warstwy zostały pokryte akumulacją lodowcową (morena czołowa) i sandrową, związanymi ze złodowaceniem wisły [Kraiński, w opracowaniu].


Szczegółowy obraz wybranych warstw geologicznych w rozbiciu na strop i spąg został przedstawiony graficznie na rys. 9,10,11. Należy zwrócić uwagę, że na poniższych rysunkach zastosowano bardzo duże przewiększenie dla pokreślenia istniejących nierówności warstw geologicznych.



Rys. 9a. Powierzchnia stropu warstwy VI  
Fig. 9a. Ceiling surface layer VI

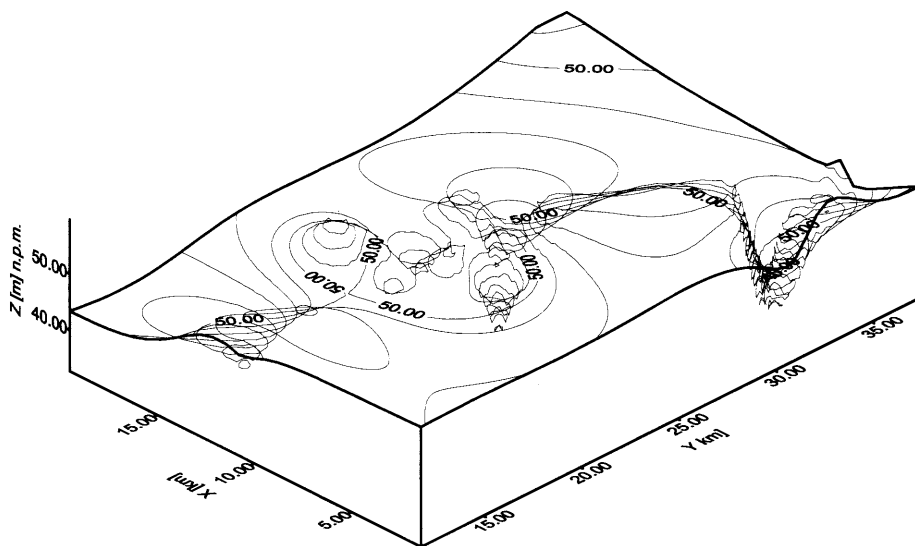


Rys. 9b. Powierzchnia spagu warstwy VI  
Fig. 9b. Floor surface layer VI



Rys. 10a. Powierzchnia stropu warstwy VII


Fig. 10a. Ceiling surface layer VII



Rys. 10b. Powierzchnia spągu warstwy VII


Fig. 10b. Floor surface layer VII





Rys. 11a. Powierzchnia stropu warstwy VIII

Fig. 11a. Ceiling surface layer VIII



Rys. 11b. Powierzchnia spagu warstwy VIII

Fig. 11b. Floor surface layer VIII

## 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 glacitektoniczną Nowej Soli. Na podstawie uzyskanych wyników został zbudowany model geologiczny omawianego obszaru, na podstawie którego można wnioskować o ciągłości warstw dla całego analizowanego obszaru o powierzchni ok. 297 km<sup>2</sup>. W modelu geologicznym wydzielono ogółem osiem warstw (I – VIII) o różnym zasięgu, przy czym warstwy najstarsze ze względu na małą liczbę danych wejściowych oraz sam kształt depresji mają ograniczone rozprzestrzenianie.

Wstępna analiza wzajemnego rozmieszczenia warstw geologicznych pozwala na postawienie 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 splywem 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.**

Zastosowanie sztucznych sieci neuronowych uczonych metodą propagacji wstecznej błędu z wykorzystaniem gradientowych metod optymalizacji, pozwoliło na wyznaczenie rozmieszczenia warstw geologicznych na podstawie dostępnych danych pomiarowych. Najkorzystniejsze wyniki, przy relatywnie niskiej ilości iteracji, uzyskano stosując metodę gradientów sprzężnych oraz algorytm *RPROP*.

## Literatura

- DUCH W., KORBICZ J., RUTKOWSKI L., TADEUSIEWICZ R.: *Sieci neuronowe*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000
- KOTOWSKI J., KRAIŃSKI A.: *Bau und Genese der Glacitektonische Scholie des Dalkowie – Hugellands bei Głogów VR Polen*. Zeitschrift Geologische Wissenschaft, Band 16, Heft 2, 99.153-156, Berlin 1988
- KOTOWSKI J., KRAIŃSKI A.: *Budowa geologiczna depresji glacitektonicznych Nowej Soli i Bytomia Odrzańskiego*. VIII-th Glacitectonic Symposium. Wydawnictwo WSI Zielona Góra, pp. 117-136, 1995a
- KOTOWSKI J., KRAIŃSKI A.: *Kry glacitektoniczne w okolicy Koźuchowa*. VII-th Glacitectonic Symposium. Wydawnictwo WSI Zielona Góra, pp. 65-76, 1992

- KOTOWSKI J., KRAIŃSKI A.: *Uwagi o budowie geologicznej Bramy Letnickiej*. Wydawnictwo Politechniki Zielonogórskiej, Zeszyty Naukowe nr 113, pp. 49-63, Zielona Góra 1997b
- KOTOWSKI J., KRAIŃSKI A.: *Warunki sedymentacji w początkowym okresie istnienia depresji glacitektonicznej Nowej Soli*. Wydawnictwo Politechniki Zielonogórskiej, Zeszyty Naukowe nr 113, pp. 25-37, Zielona Góra 1997
- KOTOWSKI J., KRAIŃSKI A.: *Zjawiska glacitektoniczne w północnej krawędzi depresji glacitektonicznej Bytomia Odrzańskiego*. VIII-th Glacitectonic Symposium. Wydawnictwo WSI Zielona Góra, pp. 137-1150, 1995b
- KOTOWSKI J., KRAIŃSKI A.: *Związek kier glacitektonicznych z depresjami glacitektonicznymi*. V-th Glacitectonic Symposium. Wydawnictwo WSI Zielona Góra, pp. 75-84, 1986
- KRAIŃSKI A.: *Zastoisko zbąszyńsko – nowosolskie/ Przegląd geologiczny*, vol.50, nr 8, pp. 698-700, Warszawa 2002
- KUSZELL T., SZAJDEWICZ J.: *Stanowisko interglacjału eemskiego w Katarzynowie koło Bytomia Odrzańskiego*. VI Konferencja Stratygrafii plejstocenu Polski, pp. 181-183, Kamieniec Żąbkowski 1997
- MARKIEWICZ A.: *Halotektonika soli cechsztyńskich w strefie dyslokacyjnej środkowej Odry a zaburzenia glacitektoniczne we Wzgórzach Dalkowskich*. VIII-th Glacitectonic Symposium. Wydawnictwo WSI Zielona Góra, pp. 175-192, 1995
- MARKIEWICZ A.: *Halotektoniczne uwarunkowania sedymentacji i deformacji osadów kenozoicznych w południowej części monokliny przedsudeckiej (SW Polska)*. Oficyna Wydawnicza UZ, Zeszyty Naukowe nr 130, pp. 115-124, Zielona Góra 2003
- OSOWSKI S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000
- RIEDMILLER M., BRAUN H.: *A fast adaptive learning algorithm*, Technical Report, University Karlsruhe, Germany 1992
- RUTKOWSKI L.: *Metody i techniki sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa 2006
- STACHURSKI A., WIERZBICKI A.: *Podstawy optymalizacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2001.

---

GEOLOGICAL MODEL TEST CONSTRUCTION  
OF GREAT-VALLEY GŁOGÓW IN AREA A NOWA SÓL  
WITH THE USE OF NEURAL NETWORKS

*S u m m a r y*

*This article attempts to determine the course of geological strata for a great-valley area Głogów, using the multilayer neural network the sigmoidal type training by back propagation method, which is based on the known theory of gradient optimization methods. Determination of the experience of individual layers was made on the basis of the coordinates (x,y), and data in the form of ceiling height, depth and thickness of floor obtained from field studies.*

**Key words:** neural networks, gradient methods of optimalization, great-valley, glacitectonic depression