

*sieci neuronowe  
geologia*

Paweł GOLDSZTEJN, Anna ADAMCZYK-LORENC, Monika DERKOWSKA –  
SITARZ\*

## ZASTOSOWANIE SIECI NEURONOWYCH W GEOLOGII - PRZYKŁADY Z LITERATURY ŚWIATOWEJ

Sztuczne sieci neuronowe znajdują coraz szersze zastosowanie w naukach przyrodniczych, zwłaszcza przy rozwiązywaniu skomplikowanych zagadnień, co do których brakuje danych i zrozumienia procesów je wywołujących. Autorzy przedstawili krótki przegląd wykorzystania sztucznych sieci neuronowych w dziedzinach nauki związanych z geologią. Zaprezentowane zostały sposoby wykorzystania sztucznych sieci neuronowych w przewidywaniu osiadania gruntu i powstawania osuwisk, przewidywaniu częstotliwości występowania trzęsień ziemi, identyfikacji litofacji w górnictwie naftowym i gazowym, szacowaniu zasobów złóż rud oraz wód podziemnych, zarządzaniu zasobami wody i w określaniu przydatności kruszywa łamanego do zastosowań w drogownictwie. Szersze omówienia prac dotyczących wyżej wymienionych zastosowań zakończone zostały krótkim przedstawieniem innych dziedzin związanych z geologią, w których użycie sztucznych sieci neuronowych również znajduje zastosowanie.

### 1. WSTĘP

Konwencjonalne metody obliczeniowe i statystyczne niekiedy nie są skuteczne przy rozwiązywaniu niektórych problemów geologicznych. W ostatnich kilkunastu latach na świecie badacze próbują do rozwiązywania zagadnień geologicznych stosować metody oparte na sztucznych sieciach neuronowych.

Sztuczne sieci neuronowe (ang. *Artificial Neural Networks*) inspirowane są zasadą działania komórek nerwowych mózgu ludzkiego, będąc jego uproszczonym modelem. Model taki składa się z „neuronów” przetwarzających w pewien sposób dane do nich docierające. Poszczególne warstwy neuronów są ze sobą połączone, połączenia między nimi zdefiniowane są przez wagi. Poprzez połączenia neuron otrzymuje sygnały z neuronów poszczególnych (sąsiadujących) warstw sieci neuronowej.

Sieci neuronowe można podzielić na sieci jednokierunkowe (ang. *Feed-Forward*) i na sieci rekurencyjne (ang. *Recurrent*). Wśród sieci jednokierunkowych można

---

\* Instytut Górnictwa Politechniki Wrocławskiej, pl. Teatralny 2, 50-051 Wrocław,  
e-mail: pawel.goldstejn@pwr.wroc.pl

wymienić wielowarstwowe sieci sigmoidalne, sieci radialne (ang. *Radial Basis Function*) oraz sieci z kontrpropagacją (ang. *Counter – Propagation*) (Tadeusiewicz, 1993). Wśród sieci rekurencyjnych można wyróżnić sieci Hopfielda, Hamminga, Elmana, sieci typu BAM (ang. *Bidirectional Associative Memory*) oraz sieci typu RTRN (ang. *Real Time Recurrent Network*) (Tadeusiewicz, 1993). Większość z tych sieci należy do grupy sieci, których uczenie przebiega pod nadzorem – istotną rolę odgrywa istnienie zadanego wzorca wyjściowego stowarzyszonego ze wzorcem wejściowym. Drugą grupą stanowią sieci samoorganizujące się, nie wymagające nadzoru na etapie uczenia. Sieci te w trakcie uczenia same wykrywają istotne cechy powiązań między czynnikami, ucząc się ich, aby w fazie odtworzeniowej skorzystać z tych właściwości do wyznaczenia rozwiązania dla wzorców nie uczestniczących w uczeniu (Osowski, 1996). Wśród tej klasy sieci wydzielić można sieci rezonansowe (ang. *Adaptive Resonance Theory – ART*), sieci typu Haulta-Juttana, sieci Kohonena i odwzorowanie Sammona (Osowski, 1996). Sztuczne sieci neuronowe z uwagi na zróżnicowanie geometrii stosowane są przy rozwiązywaniu różnego rodzaju problemów i zadań (Ambrozić i Turk, 2003). Sieci Hopfielda i Hamminga zwykle używane są do danych binarnych oraz do klasyfikacji danych w klasy, zaś jednokierunkowe sieci wielowarstwowe i sieci Kohonena szczególnie nadają się do określania nieznanymi zależności między danymi wejściowymi i wyjściowymi (Ambrozić i Turk, 2003).

W niniejszej pracy przedstawione zostały zastosowania sztucznych sieci neuronowych w kilku obszarach z dziedziny geologii.

## 2. PRZEGLĄD BADAŃ NAD ZASTOSOWANIEM SIECI NEURONOWYCH W ROZWIĄZYWANIU PROBLEMÓW GEOLOGICZNYCH

### 2.1. OSIADANIE GRUNTÓW W WYNIKU DZIAŁALNOŚCI GÓRNICZEJ

Ambrozić i Turk (2003) opisali za pomocą sztucznych sieci neuronowych sposób przewidywania osiadania powierzchni terenu, będącego wynikiem działalności górniczej. Dotychczas problem ten rozwiązywany był empirycznie przy zastosowaniu korelacji poszczególnych parametrów gruntu i wielkości osiadania, użyciu funkcji wpływu cząstkowych regionów wyrobiska na całkowite osiadanie gruntów wokół niego, oraz modeli fizyczno-matematycznych wykorzystujących metodę elementów skończonych i metodę różnic skończonych, zaś Ambrozić i Turk zastosowali jednokierunkową wielowarstwową sieć neuronową. Możliwość wykorzystania sztucznej sieci neuronowej dla przewidywania osiadania gruntów sprawdzona została najpierw dla różnych modeli (model osiadania zgodny z zaprogramowaną krzywą osiadania, model stochastyczny i jednorodny model przewidywania dla odkrywkowej kopalni węgla brunatnego Velenje). W wyniku badań zaproponowana została sztuczna sieć neuronowa z dwiema warstwami ukrytymi i 40 neuronami w każdej warstwie.

Ustalono, że prawidłowość przewidywania sieci nie zależy od sposobu w jaki wprowadzono dane dotyczące osiadania.

Uzyskano małe odchylenia między przewidywanymi a pomierzonymi wartościami, niezależnie od tego czy osiadanie wprowadzono w postaci siatki dyskretyzacyjnej punktów na powierzchni czy za pomocą punktów w profilu gruntowym. Praktyczne zastosowanie sztucznych sieci neuronowych pokazano w warunkach rzeczywistych wyeksploatowanych poziomów odkrywki i w odniesieniu do danych na powierzchni wokół niej. Wyniki uzyskane za pomocą sztucznych sieci neuronowych nie zależą od geologicznych i mechanicznych parametrów stropu złoża. Jest to istotne, gdyż zwykle trudno określić, które parametry mają wpływ na osiadanie, a jeszcze trudniej jest określić wielkość tego wpływu (Ambrozic i Turk, 2003). Zaletą wykorzystania sztucznych sieci neuronowych przy rozwiązywaniu tego zagadnienia jest to, że nie jest konieczne dokładne rozpoznanie geologicznych i fizyko - mechanicznych warunków w skarpie ponad odkrywką (Ambrozic i Turk, 2003). Do rozwiązania zagadnienia osiadania niezbędne są natomiast dane na temat odkrywki i przemieszczeń gruntu (np. z inklinometrów). Dane te są dużo łatwiejsze do uzyskania niż określenie wpływu poszczególnych czynników na osiadanie, co niezbędne było w poprzednio stosowanych metodach przewidywania osiadania gruntu (Ambrozic i Turk, 2003).

## 2.2. OSUWISKA

Powstawanie osuwisk jest istotnym problemem w obszarach górskich i wyżynnych, są one zagrożeniem dla bezpieczeństwa ludzi, a także są czynnikiem niszczącym infrastrukturę komunikacyjną (drogi i linie kolejowe), sieci przesyłowe (ropociągi, gazociągi i sieć wodno - kanalizacyjna) negatywnie wpływającym na rolnictwo i w drastyczny sposób przyczyniającym się do zmian krajobrazu.

Badania nad wykorzystaniem sztucznych sieci neuronowych w tej dziedzinie są autorstwa Lee i in. (2003). Zastosowali oni współpracującą z systemem GIS sztuczną sieć neuronową do analizy podatności na osuwiska dwóch górskich obszarów w Korei Południowej. Pierwszym krokiem było określenie czynników mających wpływ na powstawanie osuwisk. Następnie zastosowano algorytm wstecznej propagacji błędu do określenia wag w zależności od ilości czynników, które wprowadzono jako mające wpływ na powstanie osuwiska (eksperymentowano z 4, 8 i 14 czynnikami). Najlepsze rezultaty autorzy uzyskali przy wprowadzeniu 8 czynników (nachylenie stoku, topografia, krzywizna stoku, morfologia terenu, skład gleby, charakter drenażu gleby, geologia i pokrycie roślinnością), po usunięciu tych, które miały najmniejsze wagi na końcowy wynik działania sieci. Zastosowano trójwarstwową sztuczną sieć neuronową (z jedną warstwą ukrytą) o strukturze  $8 \times 18 \times 2$  neurony. Wyniki tych badań wykazały, że w połączeniu z systemem informacji przestrzennej (zawierającym dane o topografii, glebach i zalesieniu obszaru), sztuczne sieci neuronowe mogą być użyteczne do określania wskaźnika podatności terenu na powstanie osuwiska (Lee

i in., 2003). Co więcej, dopasowywanie wag dla poszczególnych czynników istotnych przy powstawaniu osuwiska skutkuje uszeregowaniem ich według względnej istotności. Sztuczna sieć neuronowa okazała się łatwa do adaptacji i zdolna do generalizacji; może ona także działać gdy dane są niekompletne lub obciążone błędem. Sieć taka dobrze radzi sobie z nieliniowymi i kompleksowymi zależnościami między zmiennymi w całym systemie czynników (Lee i in., 2003).

Sztuczne sieci neuronowe ze wsteczną propagacją błędu wykorzystane zostały także przez Neupane i Acheta (2004) do monitoringu osuwisk w Himalajach. Do przewidywania przemieszczeń stoków wykorzystali oni czterowarstwową sztuczną sieć neuronową (dwie warstwy ukryte) o strukturze  $6 \times 4 \times 9 \times 1$  neuronów. Na podstawie wprowadzonych istotnych zmiennych (czynników), mających wpływ na powstawanie osuwisk (współczynnik infiltracji, wielkość poprzedzającego infiltrację deszczu, profil stoku, położenie zwierciadła wody oraz wytrzymałość gruntu na ścinanie), model sprawnie przewiduje wielkość ruchu zbrocza. Model funkcjonuje dobrze mimo niedostatecznej ilości informacji geotechnicznych (Neupane i Achet, 2004). Jednak jeśli dobrze zidentyfikowane są zmienne mające wpływ na powstawanie osuwisk i dostępna jest wystarczająca ilość wiarygodnych danych, to taka sztuczna sieć neuronowa działa sprawnie. Całość badacze wykonali w oparciu o oprogramowanie Matlab (Neupane i Achet, 2004).

### 2.3. CZĘSTOTLIWOŚĆ TRZĘSIEŃ ZIEMI

Przewidywanie trzęsień ziemi jest jednym z największych nierozwiązanych problemów sejsmologii. Złożoność zjawisk sejsmicznych sprawia, że wszelkie metody przewidywania w pewnym stopniu odnoszą się do obserwacji poprzednich trzęsień ziemi. Długoterminowe przewidywanie trzęsień ziemi bazuje na katalogach danych sejsmicznych, będących najpewniejszym zbiorem informacji mogących służyć do ilościowego podejścia w poszukiwaniu wzorców zwiastunów wstrząsów. Jedną z pierwszych koncepcji rozwiązania problemu przewidywania wstrząsów sejsmicznych była idea statystycznego przewidywania dużych trzęsień ziemi (Bak i Tang, 1989), która dała badaczom motywację do dalszych badań w kierunku prawdziwego przewidywania trzęsień ziemi. Sztuczne sieci neuronowe mogą być dobrym narzędziem odzwierciedlającym wiele elementów składających się na charakter sejsmiki danego obszaru (Bodri, 2001). Sztuczna sieć neuronowa, jako swego rodzaju „czarna skrzynka” (ang. *black-box*), nadaje się do zastosowania w przypadku nieliniowej, i mającej wiele zmiennych, natury procesów sejsmicznych oraz niewystarczającej wiedzy na temat ich podstaw fizycznych (Bodri, 2001).

Bodri (2001) skonstruował model sztucznej sieci neuronowej do przewidywania czasu powstania dużych trzęsień ziemi na podstawie danych sejsmicznych (obejmujących czas powstania fali sejsmicznej i magnitudę trzęsienia) na obszarze karpacko-panońskim na Węgrzech oraz w regionie Peloponezu w Grecji. Niezależnie

od pewnej nieadekwatności zestawu uczącego, z uwagi na niedostatek danych o dużych trzęsieniach ziemi, działalność sieci dała satysfakcjonujące rezultaty i podtrzymała nadzieję na przydatność sztucznych sieci neuronowych do rozwiązywania podobnych problemów. Poza naturą „czarnej skrzynki”, technika sztucznych sieci neuronowych różni się od innych metod wykorzystywanych do rozwiązywania tego typu problemów, tym że wykorzystuje średnią aktywność sejsmiczną w czasie pomiędzy dużymi trzęsieniami ziemi, zamiast rozważania sekwencji zmian lub empirycznie określonych wartości progowych (alarmowych) w identyfikowaniu znaczących anomalii (Bodri, 2001). Takie podejście sprawia, że możliwe jest także wzięcie pod uwagę informacji o poprzednim, starszym trzęsieniu ziemi. W badaniach Bodri’ego (2001), z różnych parametrów charakteryzujących przestrzenny, czasowy i wielkościowy rozkład populacji trzęsień ziemi, do analiz używana jest wielkość aktywności sejsmicznej. Badacz postuluje aby w przyszłości włączać w proces uczenia sieci neuronowej także inne parametry sejsmiczne. W swoich badaniach Bodri zastosował trójwarstwową (jedna warstwa ukryta) sztuczną sieć neuronową ze wsteczną propagacją błędów. Po etapie treningu na danych archiwalnych sieć ta została „nauczona” przewidywać czas wystąpienia następnego dużego trzęsienia ziemi. Już po wykonaniu eksperymentu, w Grecji 7 września 1999 r. miało miejsce trzęsienie ziemi o dużej magnitudzie, sieć „przewidziała” jego wystąpienie około 10 grudnia 1999 r. (Bodri, 2001). Taka różnica mieści się jednak w granicach błędów szacowania (zważywszy na fakt, że średnio takie trzęsienie występuje raz na kilka lat).

#### 2.4. IDENTYFIKACJA LITOFACJI W GÓRNICTWIE NAFTOWYM I GAZOWYM

Identyfikacja litofacji (typu skały) jest istotna przy porównywaniu istotnych cech jednostek geologicznych, takich jak mineralizacja, struktura osadu, zawartość skamieniałości lub domniemana geneza osadu. Określenie litofacji skał zbiornikowych węglowodorów jest bardzo ważne przede wszystkim w górnictwie naftowym i gazowym (Chang i in., 2000). Konwencjonalne algorytmy liczące i metody statystyczne okazały się mało przydatne przy rozwiązywaniu pewnych problemów geologicznych (Baldwin i in., 1990, Doveton, 1994), szczególnie przy ocenie zasobów złóż węglowodorów. Zautomatyzowaną metodę określania litofacji skał zbiornikowych (skały węglanowe lub silikoklastyczne) na podstawie danych geofizycznych z wierceń przedstawił Chang i in. (2000). Metoda ta pozwala na przewidywanie litofacji w otworach nierdzewionych, czyli bez makroskopowego opisu skały. Badacze wykorzystali sieci rezonansowe, która są przykładem sztucznej sieci neuronowej „bez nauczyciela”. Sztuczne sieci neuronowe „bez nauczyciela” w zagadnieniach rozpoznawania litofacji wykorzystywane były także przez Baldwina i in. (1990). Chang i in. (2000) wykorzystali algorytm ART2 przedstawiony przez Fausett (1994). Stworzony został system łączący sztuczne sieci neuronowe, logikę rozmytą i system ekspercki. Taki system okazał się mieć wiele zalet w porównaniu do

tradycyjnych metod. Po pierwsze, taki system rozpoznawania sprawnie identyfikuje litofacje na podstawie danych z geofizyki wiertniczej. Litofacje mogą być identyfikowane automatycznie lub subiektywnie (przy asyście geologa). Po drugie, system może być dużo dokładniejszy niż sama sztuczna sieć neuronowa w sytuacji skomplikowanej geologicznie, kiedy należy wykorzystać wiedzę geologów. Po trzecie, ostateczna identyfikacja litofacji okazuje się w przypadku sieci ART2 dokładniejsza niż przy zastosowaniu sztucznej sieci neuronowej ze wsteczną propagacją błędu (Chang i in., 2000). Badacze przeprowadzili eksperyment sprawdzenia wykonanego przez siebie systemu, który wykazał dużą zgodność (79,3 %) identyfikacji litofacji z danych geofizycznych z rzeczywistą budową geologiczną skał określoną z badań rdzeni wiertniczych.

Chang i in., w kolejnej pracy (2002), zaprezentowali także inną technikę identyfikacji litofacji, wykorzystującą samoorganizujące się sieci Kohonena. Sieci Kohonena także należą do grupy sztucznych sieci neuronowych uczonych „bez nauczyciela”. Tworzy się za ich pomocą mapy klasyfikujące dane wejściowe na klastry (grupy) różniące się formą topologiczną, których wydzielenie związane jest z trendami występującymi w danych wejściowych. W wyniku badań Changa wydzielonych zostało 11 klastrów, które następnie zostały porównane z litofacjami oznaczonymi podczas makroskopowego opisu rdzeni wiertniczych (określono także litofacje niejednoznaczne – np. piaskowiec na pograniczu mułowca). Następnie klastry te zostały uporządkowane we wzorzec sekwencji depozycji osadów (zgodny z opisem rdzeni). Takie podejście pozwoliło w kolejnych pracach na zastosowanie sieci Kohonena do interpretacji danych geofizyki wiertniczej i przewidywania sekwencji litofacji w nierozpoznanym rdzeniami obszarze (Chang i in., 2002). Uzyskano 78,8 % dokładności działania sieci (porównując z danymi znanymi z rdzeni). Określenie sekwencji litofacji jest bardzo istotne w górnictwie naftowym i pozwala na podejmowanie strategicznych decyzji odnośnie eksploatacji złóż węglowodorów. Rezultaty uzyskane przy użyciu sieci Kohonena są dużo bardziej satysfakcjonujące niż przy wykorzystaniu wielowarstwowych sztucznych sieci neuronowych ze wsteczną propagacją błędu czy sieci rezonansowych (te metody nie pozwoliły na uzyskanie wzorców sekwencji litofacji) (Chang i in., 2002).

## 2.5. SZACOWANIE ZASOBÓW ZŁÓŻ RUD

W górnictwie określenie granic złoża rudy jest bardzo istotne z ekonomicznego punktu widzenia, gdyż zależy od tego jakość wydobywanego urobku. W tradycyjnym szacowaniu zasobów informacje o mineralizacji skał pochodzą z wierceń. Informacje te można uzyskać także z badań geofizycznych przy wykorzystaniu analiz statystycznych (Carlsten i in., 1989) i analizy korelacji (Wanstedt, 1992), jednak dokładność tych metod jest niewystarczająca (Huang, Wanstedt, 1998). Sztuczne sieci neuronowe do interpretacji wyników geofizyki wiertniczej w celu wyznaczenia granic złoża zastosowali Huang i Wanstedt (1998). Wykorzystali oni czterowarstwową (dwie

warstwy ukryte) sztuczną sieć neuronową ze wsteczną propagacją błędu o strukturze  $4 \times 15 \times 5 \times 3$  neuronów, do wydzielenia trzech klas skał (skała niezmineralizowana, skała po części zmineralizowana, ruda użyteczna) na podstawie danych geofizycznych, takich jak profilowanie gamma, gamma-gamma, neutron i opornościowe. Po etapie uczenia sieci uzyskano bardzo dobrą korelację danych wyjściowych będących wynikiem działania sieci i rzeczywistych danych pochodzących z rdzeni wiertniczych (Huang, Wanstedt, 1998).

Szacowaniem zasobów rud przy zastosowaniu sztucznych sieci neuronowych zajmowali się także Wu i Zhou (1993).

Szacowaniem rozprzestrzenienia złoża zajął się także w swojej pracy Caers (2001), który porównał zastosowanie tradycyjnych metod statystycznych (krigingu bazującego na wariogramie badającym zależność poszczególnych par punktów) i sztucznej sieci neuronowej, która bazuje na całej populacji danych wejściowych jednocześnie. Zastosował on trójwarstwową (jedna warstwa ukryta) sztuczną sieć neuronową ze wsteczną propagacją błędu. Po etapie „uczenia” uzyskał korelację  $R = 0,86$  między rzeczywistymi wartościami a przewidywaniami sieci (Caers, 2001).

## 2.6. OKREŚLANIE JAKOŚCI KRUSZYWA ŁAMANEGO

Kruszywo łamane jest wykorzystywane w drogownictwie do produkcji nawierzchni. Przed jego wykorzystaniem do tego celu konieczne jest określenie jakości materiału skalnego – gęstości skał, cech mechanicznych, składu mineralnego itp. (Huang, Wanstedt, 1998). Tradycyjnie do określania przydatności kruszywa stosuje się kosztowne i czasochłonne testy laboratoryjne. W ciągu wielu lat badań zdefiniowano 26 czynników wpływających na jakość kruszywa i wiele prac opisuje wzajemne związki i korelacje między nimi. Huang i Wanstedt (1998) zastosowali wielowarstwowe sztuczne sieci neuronowe ze wsteczną propagacją błędu do określenia trzech podstawowych parametrów jakości kruszywa na podstawie gęstości skały, obciążenia skupionego, zawartości kwarcu i zawartości minerałów kruchych.

## 2.7. SZACOWANIE ZASOBÓW WÓD PODZIEMNYCH

Wong i Shibli (2001) wykorzystali sztuczne sieci neuronowe do oceny porowatości skał na podstawie danych geofizycznych. Sztuczne sieci neuronowe, w przeciwieństwie do tradycyjnych metod statystycznych, mogą odzwierciedlić nieliniowe relacje przestrzenne pomiędzy danymi z wierceń a składającymi się z wielu zmiennych danymi geofizycznymi, bez mozolnego modelowania macierzy kowariancji (Wong i Shibli, 2001). Metoda została przetestowana na zbiorniku wód podziemnych w obrębie drobnoziarnistych piasków, rozpoznany za pomocą studni. Zastosowano trójwarstwową (jedna warstwa ukryta) sztuczną sieć neuronową ze wsteczną propagacją błędu. Jako dane wejściowe zastosowano współrzędne lokalizacji studni oraz prędkość i długość fal sejsmicznych, natomiast wynikiem

działania sieci była porowatość skał. Wyniki obdarzone są małym błędem i wysoce korelują się z rzeczywistymi parametrami skał ( $R^2 = 0,84$ ) (Wong i Shibli, 2001). Z tych badań wynika, że uczenie sztucznej sieci neuronowej przy pomocy głównych parametrów fal sejsmicznych może mieć praktyczne zastosowanie w modelowaniu zasobów wód podziemnych, dostarczając wiarygodny obraz rozkładu parametrów skały wodonośnej.

Sieci neuronowe zostały zastosowane także do modelowania wydajności źródeł wód leczniczych. Liber i Liber-Madziarz (2003) w swoich badaniach zastosowali czterowarstwową (dwie warstwy ukryte) sieć neuronową realizującą regresję uogólnioną GRNN (ang. *Generalized Regression Neural Networks*). Badacze Ci wybrali sieć GRNN do symulacji wydajności ujęć wód leczniczych, gdyż dobrze nadaje się ona do generalizacji procesów. Uwzględnienie czynników atmosferycznych w sieci neuronowej pozwoliło badaczom na uzupełnienie struktury sieci o dodatkowe wejścia na które podawane mogą być dane meteorologiczne (Liber i Liber-Madziarz, 2003). Taka sieć neuronowa zdolna jest do przewidywania przyszłych wartości wydajności ujęć na podstawie zbioru pomiarów pochodzących z dowolnie długiego okresu wcześniejszego.

## 2.8. INNE ZASTOSOWANIA SZTUCZNYCH SIECI NEURONOWYCH W GEOLOGII

Poza szeroko opisanymi powyżej przykładami, sztuczne sieci neuronowe były wykorzystywane także w badaniach geotechnicznych do aproksymacji krzywych osiadania edometrycznego (Turk i in., 2001) oraz do modeli powstawania poszczególnych typów gleb (Logar i Turk, 1997). Ghaboussi i Sidarata (1998) wykorzystali sieć rezonansową do modelowania zachowania się piasku mokrego i suchego podczas trójosiowego ścinania. Modelowaniem wytrzymałości na ścinanie laterytów za pomocą sztucznych sieci neuronowych zajmowali się Attoh-Okine i Fekpe (1996). Ruch ścian w wyrobiskach górniczych z obudową kotwową był przy zastosowaniu sztucznych sieci neuronowych badany przez Shi i in. (1998). Kompleksowe zagadnienia z zakresu analizy wpływu wielu czynników składających się na cechy inżynierskie skał na mechanikę górotworu za pomocą sztucznych sieci neuronowych badali Yang i Zhang (1998). Ciśnienie górotworu w czasie rzeczywistym z wykorzystaniem sztucznych sieci neuronowych określał Feng i in. (1996). Sztuczne sieci neuronowe mogą być także narzędziem do określania względnej wielkości wpływu czynników wpływających na stabilność obiektów podziemnych (Yang i Zhang, 1997). Ciekawe prace powstały także na temat wykorzystania sztucznych sieci neuronowych do określania źródeł wstrząsów skorupy ziemnej (trzęsienie ziemi, strzelania górnicze, wybuchy chemiczne itp.) na podstawie danych sejsmologicznych (Finnie, 1999; Musil i Plesinger, 1996). Podobny temat podjęty był także przez Rudajeva i Čiža (1999), którzy za pomocą sztucznych sieci neuronowych określali częstotliwość wstrząsów górniczych.



Na polu zdalnej obserwacji satelitarnej, sztuczne sieci neuronowe wykorzystywane były do wydzielenia regionów o zmiennej litologii (Hafner i Komac, 1998).

Szczepańska i Kmiecik (2001) zastosowały sieć neuronową do oceny czasu oddziaływania składowiska odpadów górniczych na środowisko wodne. Sieć neuronowa wykorzystana była do modelowania stężenia jonów  $\text{SO}_4^{2-}$  w odciekach z odpadów.

### 3. PODSUMOWANIE

W geologii sztuczne sieci neuronowe są wykorzystywane w coraz szerszym stopniu. Najczęściej znajdują zastosowanie przy rozwiązywaniu zagadnień będących wynikiem wpływu wielu czynników. Użycie sztucznej sieci neuronowej jest szczególnie przydatne w przypadku, gdy w nie w pełni jest znany przebieg wszystkich procesów wywołujących dane zjawisko, znane są natomiast dane na temat charakteru wywołujących je czynników. Do rozwiązywania zagadnień przy wykorzystaniu sieci neuronowych najczęściej stosowane są wielowarstwowe sztuczne sieci neuronowe z wsteczną propagacją błędów oraz samoorganizujące się sieci Kohonena. Po etapie „uczenia” sieci na znanym zestawie czynników i znanym wyniku ich wpływu, „nauczona” sieć może sprawnie przewidywać rezultat procesu znając tylko nową charakterystykę wywołujących go czynników. Algorytm wstecznej propagacji błędów znalazł zastosowanie między innymi przy przewidywaniu osiadań górotworu spowodowanych działalnością górniczą, przy przewidywaniu wielkości osuwisk w obszarach górskich, określaniu częstotliwości trzęsień ziemi, szacowaniu zasobów złóż i zasobów wód podziemnych oraz do określania jakości kruszywa łamanego dla celów drogownictwa. Sieci Kohonena z powodzeniem stosowane są do rozpoznawania wzorców sedymentacji i przewidywania litofacji na podstawie wyników geofizyki wiertniczej. Z pewnością metody bazujące na sztucznych sieciach neuronowych mogą znajdować zastosowanie w rozwiązywaniu wielu skomplikowanych zagadnień, jednak z zastrzeżeniem, że dane wprowadzane na wejściu sieci muszą być wiarygodne.

### LITERATURA

- AMBROZIC T., TURK G., 2003. *Prediction of subsidence due to underground mining by artificial neural networks*. Computers & Geosciences 29, 627-637
- ATTOH-OKINE N.O., FEKPE E.S.K., 1996. *Strength characteristics modeling of lateric soils using adaptive neural networks*. Construction and Building Materials 10, 577-582
- BAK P., TANG C., 1989. *Earthquakes as self-organized critical phenomena*. Journal of Geophysical Research 94, 15635-15637
- BALDWIN J.L., BATEMAN A.R.M., WHEATLEY C.L., 1990. *Application of neural networks to the problem of mineral identification from well logs*. The Log Analyst 31, 279-293
- BODRI B., 2001. *A neural-network model for earthquake occurrence*. Journal of Geodynamics 33, 289-310

- CAERS J., 2001. *Geostatistical reservoir modelling using statistical pattern recognition*. Journal of Petroleum Science and Engineering 29, 177-188
- CARLSTEN S., LINDQVIST L., OLSSON O., 1989. *Comparison between radar data and geophysical, geological and hydrogeological borehole parameters by multivariate analysis of data*. SKB Technical Report 89-15. Swedish Geological Company, Sweden
- CHANG H-C., KOPASKA-MERKEL D.C., CHEN H-C., DURRANS S.R., 2000. *Lithofacies identification using multiple adaptive resonance theory neural networks and group decision expert system*. Computers & Geosciences 26, 591-601
- CHANG H-C., KOPASKA-MERKEL D.C., CHEN H-C., 2002. *Identification of lithofacies using Kohonen self-organizing maps*. Computers & Geosciences 28, 223-229
- DOVETON J.H., 1994. *Geologic Log Analysis Using Computer Methods*. American Association of Petroleum Geologists, Tulsa, Oklahoma.
- FAUSETT L.V., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Prentice Hall Inc., New Jersey
- FENG X.T., WANG Y.J., YAO J.G., 1996. *A neural network model for real-time roof pressure prediction in coal mines*. International Journal of Rock Mechanics and Mining Science and Geomechanics Abstracts 33, 647-653
- FINNIE G.J., 1999. *Using neural networks to discriminate between genuine and spurious seismic events in mines*. Pure and Applied Geophysics 154, 41-56
- GHABOUSSI J., SIDARATA D.E., 1998. *New Nested Adaptive Neural Networks (NANN) for constitutive modelling*. Computers and Geotechnics 22, 29-52.
- HAFNER J., KOMAC M., 1998. *Landsat TM lithological classification of Koper-Kozina area. Neural networks approach versus statistical clustering*. W: Proceedings of the International conference on GIS for Earth Science Applications, Ljubljana, Slovenia, str. 41-55
- HUANG Y., WANSTEDT S., 1998. *The introduction of neural network system and its applications in rock engineering*. Engineering Geology 49, 253-260
- LEE S., RYU J-H., LEE M-J., WON J-S., 2003. *Use of artificial neural network for analysis of the susceptibility to landslides at Boun, Korea*. Environmental Geology 44, 820-833
- LIBER A., LIBER-MADZIARZ E., 2003. *Nowe badania wydajności ujęć eksploatowanych samoczynnie na przykładzie wód leczniczych w Sudetach*, [W:] Współczesne Problemy Hydrogeologii Tom XI, cz. 1, Wydział Budownictwa Wodnego i Inżynierii Środowiska Politechniki Gdańskiej
- LOGAR J., TURK G., 1997. *Neural Network as a constitutive model of soil*. Zeitschrift für Angewandte Mathematik und Mechanik 77, 195-196
- MUSIL M., PLESINGER A., 1996. *Discrimination between local microearthquakes and quarry blasts by multi-layer perceptrons and Kohonen maps*. Bulletin of the Seismological Society of America 86, 1077-1090
- NEUPANE K.M., ACHET S.H., 2004. *Use of backpropagation neural network for landslide monitoring: a case study in the higher Himalaya*. Engineering Geology 74, 213-226
- OSOWSKI S., 1996. *Sieci neuronowe w ujęciu algorytmicznym*. Wydawnictwa Naukowo-Techniczne, Warszawa
- RUDAJEV V., CIZ R., 1999. *Estimation of mining tremor occurrence by using neural networks*. Pure and Applied Geophysics 154, 57-72.
- SHI J., ORTIAGO J.A.R., BAI J., 1998. *Modular neural networks for predicting settlements during tunnelling*. J. Geotech, Geo-Env. Engg ASCE 124, 389-394
- SZCZEPAŃSKA J., KMIECIK E., 2001. *Wykorzystanie sieci neuronowych do oceny czasu oddziaływania składowiska odpadów górniczych na środowisko wodne*, [W:] Współczesne Problemy Hydrogeologii, Tom X, cz. 2, Sudety Oficyna Wydawnicza Oddziału Wrocławskiego PTTK, Wrocław.
- TADEUSIEWICZ R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa
- TURK G., LOGAR J., MAJES B., 2001. *Modelling soil behaviour in uniaxial strain conditions by neural networks*. Advances in Engineering Software 32, 57-64
- WANSTEDT S., 1992. *Geophysical borehole logging in Malmberget*. Technical Report 1991:14T. Lulea University of Technology, Sweden

- WONG P.M., SHIBLI S.A.R., 2001. *Modelling a fluvial reservoir with multipoint statistics and principal components*. Journal of Petroleum Science and Engineering 31, 157-163
- WU X., ZHOU Y., 1993. *Reserve estimation using neural networks techniques*. Computers and Geosciences 19, 567-575
- YANG Y., ZHANG Q., 1997. *A hierarchical analysis for rock engineering using artificial neural networks*. Rock Mechanics and Rock Engineering 30, 207-222.
- YANG Y, ZHANG Q., 1998. *The Application of Neural Networks to Rock Engineering Systems (RES)*. International Journal of Rock Mechanics and Mineral Sciences 35, 727-745

*neural networks  
geology*

## NEURAL NETWORKS APPLICATIONS IN GEOLOGY - EXAMPLES FROM LITERATURE

Artificial neural networks (ANN) are broadly used in earth sciences, especially in solving problems that lack of data and understanding about processes that cause them. Authors showed a brief review of applications of artificial neural networks in some scientific areas connected with geology. ANN usage in surface subsidence, landslides prediction, large earthquakes prediction, lithofacies identification in petroleum mining, ore and groundwater resources estimation, drinking water management and aggregate usage in road building was shown. Other areas where ANN are used in geology were also shortly indicated.