

*Dorota Pawluś\**

## PRÓBA ZASTOSOWANIA SIECI NEURONOWYCH DO PROGNOZOWANIA OSIADAŃ POWIERZCHNI TERENU POWSTAŁYCH NA SKUTEK EKSPLOATACJI GÓRNICZEJ\*\*

---

### 1. Wstęp

Na powierzchnię terenu oraz znajdujące się na niej obiekty budowlane wpływa niekorzystnie podziemna eksploatacja. Wynikiem jej są przekształcenia hydrologiczne i przyrodnicze oraz zmiana ukształtowania terenu, co często przyczynia się to uszkodzeń obiektów znajdujących się na powierzchni. Dlatego istotne jest wyznaczanie oraz przewidywanie deformacji terenu. Tak w Polsce, jak i na świecie, wpłynęło to na rozwój wiedzy dotyczącej oddziaływania podziemnej eksploatacji górniczej na powierzchnię i obiekty jej zagospodarowania oraz rozwój sposobów minimalizacji powstających szkód górniczych. Powstało wiele metod obliczania deformacji, których podstawę stanowią wzory empiryczne bądź takie, które są wynikiem uogólnień i dedukcji [1, 2].

W artykule przedstawiono próbę zastosowania na podstawie parametrów dotyczących eksploatacji sieci neuronowych do prognozowania osiadającej powierzchni terenu objętej eksploatacją górniczą. Wyznaczono osiadania w dowolnym punkcie zadanego obszaru.

Zaletą sieci neuronowej, jako narzędzia prognozującego, jest to, że w wyniku procesu uczenia sieć może nabyć zdolności przewidywania wyjściowych sygnałów wyłącznie na podstawie obserwacji tzw. ciągu uczącego. Można to uzyskać bez konieczności stawiania w sposób jasny hipotez o naturze związku pomiędzy wejściowymi danymi a przewidywanymi wynikami [3].

Do tworzenia sieci neuronowych wykorzystano pakiet Statistica. Natomiast do obliczenia osiadań powierzchni dla modeli teoretycznych skorzystano z programów z pakietu bk (biblioteka niecka) [4].

---

\* Wydział Górnictwa i Geoinżynierii, Akademia Górniczo-Hutnicza, Kraków


\*\* Artykuł został napisany przy wykorzystaniu badań prac statutowych na 2006 r., nr umowy 11.11.100.588, pt.: „Badanie zjawisk fizykomechanicznych wywołanych działalnością górniczą”, zadanie 14: „Zastosowanie metod data mining do wyznaczania deformacji powierzchni terenu powstałych na skutek eksploatacji górniczej

## 2. Budowa i działanie sieci neuronowej

Sztuczne sieci neuronowe stanowią intensywnie rozwijającą się dziedzinę wiedzy, którą stosuje się w wielu obszarach nauki. Stanowią one uniwersalny układ aproksymacyjny, odwzorowujący wielowymiarowe zbiory danych, dzięki temu mają zdolność uczenia się i adaptacji do zmieniających się warunków, a także zdolność uogólniania nabytej wiedzy, stanowiąc pod tym względem system sztucznej inteligencji.

Sieć neuronowa jest uproszczonym modelem ludzkiego mózgu. Składa się ona często z dużej liczby (nawet do kilkudziesięciu tysięcy) elementów przetwarzających informacje. Elementy te nazywane są neuronami. Neurony są powiązane w sieć za pomocą połączeń o parametrach (zwanymi wagami) modyfikowanych w trakcie procesu uczenia. Topologia połączeń oraz ich parametry stanowią program działania sieci, zaś sygnały pojawiające się na jej wyjściach w odpowiedzi na określone sygnały wejściowe są rozwiązaniami stawianych jej zadań [3].

Neurony są elementami, z których buduje się sieci charakteryzujące się występowaniem wielu wejść i jednego wyjścia (rys. 1).



Rys. 1. Model neuronu

Najpierw sygnały wejścia są mnożone przez wagi i przekazywane do sumatora, który oblicza potencjał neuronu [5]

$$u_i = \sum_{j=1}^n x_j w_{ij} \quad (1)$$

Często wprowadza się dodatkowy składnik tzw. bias, który pełni rolę wartości progowej. Jest on dodawany do wartości potencjału. Potencjał  $u$  jest przetwarzany na sygnał wyjściowy  $y$  w następujący sposób:  $y = F(u)$ , gdzie  $F(u)$  — funkcja aktywacji.

Sposoby połączeń neuronów między sobą i ich wzajemne współdziałania spowodowały powstanie różnych typów sieci. Każdy typ sieci jest z kolei ściśle powiązany z odpowiednią metodą doboru wag (uczenia).

Większość współcześnie budowanych sieci ma budowę warstwową, przy czym ze względu na dostępność w trakcie procesu uczenia wyróżnia się warstwy: wejściową, wyjściową oraz tzw. warstwy ukryte [3].

Wartości wag odgrywają w dziedzinie sieci neuronowych podobną rolę jak programy w dziedzinie obliczeń numerycznych. Zostają one ustalone w procesie uczenia sieci.

Do rozwiązania problemu dotyczącego wyznaczania osiadań powierzchni użyto sieci wielowarstwowych jednokierunkowych (jednokierunkowy przepływ sygnału od neuronów wejściowych do wyjściowych) uczonych metodą pod nadzorem. Uczenie pod nadzorem (z nauczycielem) polega na prezentacji danych sieci wraz z pożądanymi wynikami. Podajemy zatem sieci pary złożone  $z:(x(N \times 1), z(M \times 1)) = (\{x_1, \dots, x_N\}, \{z_1, \dots, z_M\})$  — tzw. wzorce. Sieć przetwarza podany sygnał wejścia  $x(N \times 1)$  w sygnał wyjścia  $y(M \times 1)$ . Następnie postępując według zadanego algorytmu uczenia, zmienia się parametry sieci (np. wagi połączeń) tak, aby uzyskany z obliczeń wektor „upodobnić” do zadanego. Wielokrotne przepuszczenie zbioru wzorcowych par  $(x, z)$  pozwala nauczyć interakcyjnie sieć na tym zbiorze. Zaprezentowanie sieci wszystkich par wchodzących w skład zbioru uczącego i wyznaczenie wartości błędu nosi nazwę epoki

Uczenie takie ma rację bytu wtedy, gdy mamy pewną ilość danych oraz odpowiadające im wyniki (np. z doświadczeń), a od sieci oczekujemy znalezienia praw rządzących transformacją dane — wyniki (np. w celu dokonania interpolacji bądź predykcji). Możemy w ten sposób nauczyć sieć funkcji, której wzoru nie znamy, ale mamy jej stabilizowane wartości.

Najbardziej pożądaną cechą sieci neuronowej jest zdolność generalizacji jej wiedzy na nowe przypadki. Zastosowanie do uczenia sieci jednego zbioru danych może doprowadzić do jej przeuczenia tj. zbytniego dopasowania do konkretnych przypadków. W celu uniknięcia tego, wydziela się ze zbioru uczącego zbiór sprawdzający (walidacyjny). Dane należące do tego zbioru nie są bezpośrednio używane w trakcie uczenia sieci, są natomiast wykorzystywane do przeprowadzania niezależnej kontroli postępów uczenia.

Aby zwiększyć poziom zaufania do ostatecznego modelu sieci, zwykle wydziela się ze zbioru uczącego (o ile jego wielkość na to pozwala) dodatkowo trzeci zbiór, zwany zbiorem testującym. Ostatecznie sieć nauczona na podstawie zbioru uczącego i sprawdzona za pomocą zbioru walidacyjnego jest dodatkowo testowana za pomocą zbioru testowego.

Przy tworzeniu zbiorów: uczącego, walidacyjnego oraz testowego, istotną rzeczą jest, aby dane należące do tych zbiorów były reprezentatywne dla opisywanej zależności. Jest to bardzo ważne i często bardzo trudne zadanie, zwłaszcza w przypadku niewielkiej ilości dostępnych danych [6].

### **3. Wyznaczanie osiadania powierzchni przy użyciu sieci neuronowych**

Rozważono następujący problem. Dla zadanego obszaru mamy dane: głębokość i grubość pokładu oraz położenie i wielkość pola eksploatacyjnego. Należy znaleźć wartość osiadania w dowolnym punkcie obszaru.

Do utworzenia zbiorów uczącego, walidacyjnego i testującego wzięto pod uwagę dane z dziewięciu pól eksploatacyjnych, usytuowanych w środku prostokątnego obszaru o szerokości 2000 m i długości 3000 m. Szerokości i długości pól są przedstawione w tabeli 1. Dla każdego pola przyjęto grubość eksploatacji 3 m oraz trzy wartości głębokości: 300, 500 i 800 m.

Punkty na powierzchni, dla których znano wielkość osiadania rozmieszczono na obszarze  $2000 \times 3000$  m na równomiernej siatce o gęstości  $40 \times 60$ . Łączna ilość wzorców w zbiorze uczącym, walidacyjnym oraz testującym wyniosła więc  $64\,800$  ( $9 \times 3 \times 40 \times 60$ ).

TABELA 1

**Szerokości i długości pól eksploatacyjnych wykorzystanych do utworzenia danych oraz do uczenia i sprawdzania sieci neuronowych**


Szerokość pola [m]	100	100	100	200	200	200	300	300	300
Długość pola [m]	600	1000	1500	600	1000	1500	600	1000	1500

Do rozwiązywania zadania zastosowano sieci liniowe, perceptron wielowarstwowy (MLP) i sieci o radialnych funkcjach bazowych (RBF). Oprócz poszukiwania najlepszej (do rozwiązania tego problemu) architektury sieci oraz odpowiednich algorytmów uczących prowadzono także badania nad wyborem, spośród zaproponowanych na początku, optymalnych danych wejściowych. Mają one bowiem kluczowe znaczenia w procesie tworzenia sieci i w znacznym stopniu wpływają na to co sieć wyznaczy.

Do rozwiązania problemu zostały użyte sieci jednokierunkowe. Początkowo jako wartości wejściowe do sieci przyjęto:

- $x, y$  — współrzędne punktu P,
- $d1, d2, d3, d4$  — odległości pomiędzy punktem P a wierzchołkami wybranego pola,
- $H$  — głębokość pokładu,
- $g$  — grubość pokładu,
- $S$  — pole powierzchni wybranego obszaru.

Przy wartościach wejściowych na wyjściu oczekiwano odpowiedniej wielkości osiadania (rys. 2).



**Rys. 2.** Schemat wejścia i wyjścia z sieci neuronowej

Po skończeniu procesu uczenia i sprawdzania gotową sieć zastosowano do wyznaczenia osiadań dla nowych danych. Utworzono zbiór testujący zawierający dane, które nie były użyte w procesie uczenia i sprawdzania sieci. Dane dotyczące głębokości eksploatacji oraz

wielkości pól eksploatacyjnych umieszczono w tabeli 2. Punkty, dla których wyznaczano osiadania rozmieszczono analogicznie, tak jak w przypadku modeli zawierających dane do uczenia sieci.

TABELA 2


**Dane dotyczące pól eksploatacyjnych wykorzystanych do utworzenia zbioru testującego sieć neuronową**

	Pole 1	Pole 2	Pole 3	Pole 4	Pole 5	Pole 6
Szerokość pola [m]	250	250	300	300	150	150
Długość pola [m]	700	700	1200	1200	1100	1100
Głębokość eksploatacji [m]	350	550	600	450	350	525


Najlepsze wyniki otrzymano dla sieci MLP o architekturze 7–10–6–1, czyli mającej siedem neuronów w warstwie wejściowej, jeden w warstwie wyjściowej oraz dwie warstwy ukryte zawierające odpowiednio 10 i 6 neuronów. Jako wartości wejściowe do sieci użyto zdefiniowanych wcześniej wielkości:  $d_1$ ,  $d_2$ ,  $d_3$ ,  $d_4$ ,  $H$ ,  $g$  oraz  $S$ .

Sieć uczono algorytmem wstecznej propagacji błędów z parametrem szybkości uczenia równym 0,01 i bezwładnością 0,3 przez 100 epok oraz metodą gradientów sprzężonych przez 23 epoki.


Na rysunkach 3 i 4 przedstawiono wybrane wyniki uzyskane przez zastosowanie sieci neuronowej dla zbioru testowego (tab. 2). Wykresy zawierają osiadania wyznaczone dla punktów leżących na dwóch liniach nad polem 3. Układ linii pokazano na rysunku 5.



**Rys. 3.** Porównanie wyników z sieci neuronowej z danymi teoretycznymi dla linii 1



Rys. 4. Porównanie wyników z sieci neuronowej z danymi teoretycznymi dla linii 2



Rys. 5. Schemat układu linii z punktami nad polem 1

#### 4. Podsumowanie

W artykule przedstawiono wyniki prac zmierzających do utworzenia sieci neuronowej, za pomocą której można będzie prognozować osiadanie powierzchni na danym terenie na podstawie danych dotyczących planowanej eksploatacji, takich jak: głębokość i grubość pokładu, położenie, wielkość oraz kształt pola eksploatacyjnego. Warunkiem utworzenia sieci, który trafnie będzie wyznaczał osiadania powierzchni terenu, jest odpowiednia duża ilość danych do jej nauczania.

Sieć neuronowa zawsze uczy się najprostszyc dla niej cech. Należy więc w ciągu uczącym odwzorować wszelkie warunki, które mogą panować w trakcie późniejszego działania sieci.

Problem prognozowania osiadań jest niewątpliwie skomplikowany, ponieważ na wielkość obniżenia terenu wpływa wiele czynników. Stąd też ilość danych potrzebna do nauczania sieci może wynosić kilka, a nawet kilkadziesiąt tysięcy. Jest to związane także z tym, że tak duża ilość danych jest niezbędna nie tylko dla zbioru uczącego, ale także walidacyjnego i testującego.

Duże znaczenie odgrywa również rozmieszczeni punktów z danymi osiadania na powierzchni terenu. W analizowanym przykładzie zastosowano zbiory zawierające punkty równomiernie rozmieszczone na całej powierzchni.

Biorąc jednak pod uwagę dane pomiarowe, należy tak zaprojektować linie pomiarowe, aby spełniały następujące warunki:

- pomiary powinny dotyczyć ustalonego stanu przemieszczeń;
- linie pomiarowe powinny być usytuowane nad polami eksploatacyjnymi tak, aby wszystkie pola były objęte pomiarami;
- linie pomiarowe powinny przechodzić przez środek pól eksploatacyjnych najlepiej prostopadle i równoległe do linii frontu górniczego.

Przedstawione w artykule wyniki nie są ostateczne, odnoszą się bowiem do stosunkowo prostych modeli. Aktualnie prowadzone są badania nad utworzeniem sieci bardziej uniwersalnych, które dodatkowo będą brać pod uwagę dane dotyczące własności górotworu oraz systemu eksploatacji.

Trzeba jednak pamiętać, że większość kopalni nie posiada odpowiedniej ilości pomiarów dotyczących jednego rejonu. Mało jest także obszarów, na których występuje eksploatacja jednokrotna. Nie ma więc wystarczającej ilości danych rzeczywistych, aby stworzyć sieć. Stąd planowane jest utworzenia sieci na podstawie modeli teoretycznych, a następnie douczanie jej na podstawie konkretnych przypadków rzeczywistych tak, aby można ją było zastosować dla danego obszaru lub obszarów o podobnych parametrach górniczych i geologicznych.

#### LITERATURA

- [1] *Kwiatek J.*: Ochrona obiektów budowlanych na terenach górniczych. Katowice, WGIG 1997
- [2] Ochrona powierzchni przed szkodami górniczymi. Katowice, Wydawnictwo „Śląsk” 1980

- [3] *Tadeusiewicz R.*: Sieci neuronowe. Warszawa, Akademicka Oficyna Wydawnicza RM 1993
- [4] *Flisiak J.*: Zastosowanie mikrokomputerów do prognozowania deformacji górotworu. Zeszyty Naukowe AGH, Górnictwo, z. 142, 1989, 129–144
- [5] *Rutkowska D., Piliński M., Rutkowski L.*: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Warszawa, PWN 1997
- [6] Wprowadzenie do sieci neuronowych. StatSoft Polska Sp. z o.o., Kraków 2001