

*Dorota Pawluś**

PROGNOZOWANIE OSIADAŃ POWIERZCHNI TERENU PRZY UŻYCIU SIECI NEURONOWYCH**

1. Wstęp

Eksploatacja górnicza złóż ma niekorzystny wpływ na powierzchnię i znajdujące się na niej obiekty budowlane. Wydobycie kopalin użytecznych spod terenów zagospodarowanych, a także tendencja do minimalizacji ujemnych skutków podziemnej eksploatacji w środowisku człowieka spowodowały w Polsce, tak jak i w świecie, rozwój wiedzy dotyczącej wpływu podziemnej eksploatacji górnicznej na powierzchnie i znajdujące się na niej obiekty. Powstało wiele metod obliczania deformacji, których podstawę stanowią wzory empiryczne bądź wzory będące wynikiem uogólnień i dedukcji [1, 2].

Artykuł dotyczy zastosowania sieci neuronowych do przewidywania osiadań powierzchni terenu powstałych w wyniku eksploatacji górnicznej.

Celem pracy było utworzenie sieci, które miały wyznaczać obniżenia terenu na podstawie danych dotyczących planowanej eksploatacji, takich jak: głębokość i grubość pokładu, położenie, wielkość oraz kształt pola eksploatacyjnego, a także kąt zasięgu wpływów głównych oraz współczynnik eksploatacji (parametry zdefiniowane w teorii Budryka–Knothego). Dane do uczenia sieci uzyskano z modeli teoretycznych. Wartości osiadań obliczono na podstawie teorii Budryka–Knothego.

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

2. Sieci neuronowe — budowa i działanie

Sieci neuronowe od wielu lat są z powodzeniem stosowane do rozwiązywania niezwykle szerokiego zakresu problemów. Znajdują zastosowanie w rozpoznawaniu i klasyfikacji


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

** Artykuł powstał na podstawie badań w ramach prac statutowych AGH na 2007 r., nr 11.11.100.588

wzorców (przydzielaniu wzorcom kategorii), predykcji szeregów czasowych, analizie danych statystycznych, odsumianiu i kompresji obrazu i dźwięku oraz w zagadnieniach sterownia i automatyzacji [6].

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 (rys. 1) są powiązane w sieć za pomocą połączeń o parametrach (zwanych 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, charakteryzują się występowaniem wielu wejść i jednego wyjścia.



Rys. 1. Model neuronu

Najpierw sygnały wejścia są mnożone przez wagi i przekazywane do sumatora, który oblicza potencjał i -tego 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).

Do rozwiązania przedstawionego w artykule zadania dotyczącego prognozowania osiadań powierzchni użyto sieci wielowarstwowych, jednokierunkowych (jednokierunkowy przepływ sygnału od neuronów wejściowych do wyjściowych) uczonych metodą pod nadzorem.

Sieci jednokierunkowe wielowarstwowe (nazywane często perceptronem wielowarstwowym) zawierają co najmniej jedną warstwę ukrytą neuronów, która pośredniczy w przekazywaniu sygnałów między węzłami wejściowymi a warstwą wyjściową. Sygnały wejściowe przekazywane są na pierwszą warstwę ukrytą, która z kolei stanowi źródło sygnałów dla kolejnej warstwy. Przykład sieci jednokierunkowej wielowarstwowej przedstawiono na rysunku 2.



Rys. 2. Sieć jednokierunkowa wielowarstwowa

Najbardziej pożądaną cechą sieci neuronowej jest zdolność generalizacji nabytej w procesie uczenia wiedzy na nowe przypadki. Zastosowanie do uczenia sieci jednego zbioru danych może doprowadzić do przeuczenia sieci, tj. zbytowego dopasowania do konkretnych przypadków. W celu uniknięcia takiej sytuacji 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 bardzo ważne jest, aby dane należące do tych zbiorów były reprezentatywne dla opisywanej zależności. Jest to istotne i często bardzo trudne zadanie, zwłaszcza w przypadku niewielkiej liczbie dostępnych danych [6].

3. Zastosowanie sieci neuronowych do prognozowania osiadań powierzchni

Rozważono następujące zadanie: należało przewidzieć osiadania powierzchni w zadanych punktach wybranego obszaru na podstawie następujących danych: głębokość i grubość pokładu, położenie pola eksploatacyjnego, kąt zasięgu wpływów głównych β , współczynnik eksploatacji a .

Do utworzenia zbiorów uczącego i walidacyjnego wzięto pod uwagę dane z 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 trzy wartości grubości eksploatacji: 3, 4 i 6 m, oraz trzy wartości głębokości: 300, 500 i 800 m. Przyjęto współczynnik eksploatacji $a = 0,8$ oraz trzy wartości kąta zasięgu wpływów głównych β — 54° , 60° i 70° .

TABELA 1

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

Szerokość pola, m	100	100	200	200	250	250	400	400	300
Długość pola, m	400	1000	400	1000	600	1500	600	1500	1500

Początkowo punkty na powierzchni, dla których znano wielkość osiadania, rozmieszczono na obszarze 2000×3000 m na równomiernej siatce o gęstości 40×60 . Łączna liczba wzorców w zbiorach uczącym, walidacyjnym oraz testującym wyniosła więc 583 200 ($9 \times 3 \times 3 \times 3 \times 40 \times 60$). Niestety ze względu na moc obliczeniową posiadanego komputera trzeba było znacznie zredukować ilość danych. Biorąc pod uwagę fakt, że pola eksploatacyjne leżą w środku zadanego obszaru oraz są symetryczne względem linii 1, 2 (rys. 3), do zbiorów przyjęto punkty leżące na obszarze o wymiarach 1000×1500 m (x od 0 do 1000 m, y od 0 do 1500 m).

Jako wartości wejściowe do sieci przyjęto:

d_1, d_2, d_3, d_4 — odległości pomiędzy punktem, dla którego wyznaczamy osiadanie, a wierzchołkami wybranego pola eksploatacyjnego,

S — pole powierzchni wybranego obszaru,

G — współczynnik zdefiniowany wzorem

$$G = a \cdot g,$$

gdzie:

a — współczynnik eksploatacji,

g — grubość pokładu,


r — współczynnik zdefiniowany wzorem

$$r = \text{ctg}\beta$$

gdzie:

H — głębokość,

β — kąt zasięgu wpływów głównych.



Rys. 3. Układ linii nad polem 1

W związku z ograniczeniem danych w zbiorach uczącym i walidacyjnym do jednej ćwiartki pola eksploatacyjnego wielkości $d1, d2, d3, d4$ zostały posortowane rosnąco.

Rozwiązania zadania szukano wśród sieci liniowych, wielowarstwowych (MLP) oraz sieci o radialnych funkcjach bazowych (RBF). Sieci, dla których uzyskano zadowalające wyniki, były sprawdzane za pomocą zbioru testującego zawierającego dane, które nie były użyte w procesie uczenia i sprawdzania sieci. Dane dotyczące pól eksploatacyjnych, na pod-

stawie których utworzono zbiór testujący, umieszczono w tabeli 2. Dla każdego pola przyjęto współczynnik eksploatacji $a = 0,8$ oraz trzy wartości kąta zasięgu wpływów głównych β — 54° , 60° i 70° . Punkty, dla których wyznaczano osiadania, rozmieszczono na obszarze 2000 m na 3000 m na równomiernej siatce o gęstości 40×60 .


TABELA 2

Dane dotyczące pól eksploatacyjnych wykorzystanych do utworzenia zbioru testującego sieć neuronową

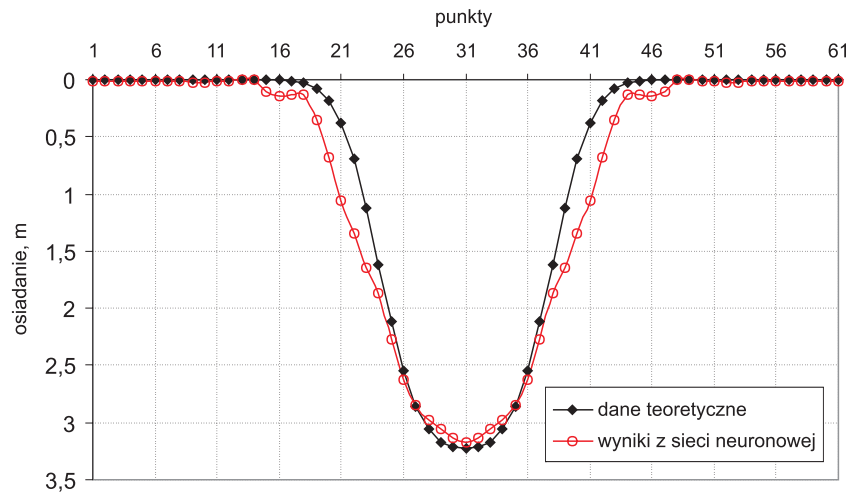
Numer pola	Pole 1	Pole 2	Pole 3	Pole 4	Pole 5	Pole 6	Pole 7
Szerokość pola, m	250	250	250	300	300	150	150
Długość pola, m	700	700	700	1200	1200	1100	1100
Głębokość eksploatacji, m	550	350	350	600	450	350	525
Grubość pokładu, m	6	3	5	4.5	3	3.5	4

Najlepsze wyniki otrzymano dla sieci MLP o architekturze 6–34–29–1 (czyli mającej dwie warstwy ukryte zawierające odpowiednio 45 i 30 neuronów) uczonej algorytmem wstecznej propagacji błędów przez 100 epok oraz metodą gradientów sprzężonych przez 64 epoki.

Na rysunkach 4 i 5 przedstawiono wybrane wyniki uzyskane przy użyciu sieci dla danych ze zbioru testowego. Wykresy zawierają osiadania wyznaczone dla punktów leżących na dwóch liniach nad polem 1. Do obliczeń przyjęto $a = 0,8$, $\beta = 60^\circ$. Układ linii pokazano na rysunku 3.



Rys. 4. Porównanie wyników wyznaczonych za pomocą sieci neuronowej z danymi teoretycznymi dla punktów leżących na linii 1



Rys. 5. Porównanie wyników wyznaczonych za pomocą sieci neuronowej z danymi teoretycznymi dla punktów leżących na linii 2

4. Podsumowanie

Artykuł prezentuje etap pracy nad utworzeniem sieci neuronowych prognozujących osiadania powierzchni terenu. Otrzymane wyniki są zadowalające, choć uzyskana sieć nie rozwiązuje jeszcze całkowicie zadanego problemu i posiada pewne ograniczenia.

Zawężenie wzorców uczących do punktów leżących w jednej ćwiartce obszaru zawierającego pole eksploatacyjne pozwoliło wyeliminować powtarzające się dane i nie wpłynęło niekorzystnie na proces uczenia. Znacznie natomiast zmniejszył się czas uczenia sieci.

Dane do uczenia sieci uzyskano z obszarów zawierających pola eksploatacyjne o kształcie prostokąta. Ogranicza to możliwość zastosowania uzyskanej sieci neuronowej do pól eksploatacyjnych o nieregularnych kształtach lub pól nie będących czworokątami. Rozwiązaniem tego problemu może być zastąpienie danego pola układem prostokątnych pól. Dlatego dalsze badania mają na celu znalezienie sieci lub zespołu sieci, które wyznaczałyby osiadania powierzchni dla obszaru zawierającego więcej niż jedno pole eksploatacyjne.

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, 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.* Kraków, StatSoft Polska Sp. z o.o. 2001