

## Wykorzystanie sieci neuronowych do prognozy zagrożenia sejsmicznego

### The use of neural networks for seismic hazard prognosis



*Dr hab. inż. Piotr Bańka,  
prof. Pol. Śl. \*)*



*Mgr inż. Tomasz Cichy \*)*



*Dr inż. Piotr Kołodziejczyk,  
doc. Pol. Śl. \*)*

**Treść:** Obserwowany poziom sejsmiczności indukowanej prowadzonymi robotami górnictwa jest w dużym stopniu zależny od występujących warunków geologiczno-górnictwa. Warunki te (w szczególności górnictwa) mogą być w sposób ilościowy opisywane metodami analitycznymi. Wyniki wcześniejszych prac pozwoliły stwierdzić istnienie zależności korelacyjnych pomiędzy szacowanymi stanami energetycznymi górnictwa (zmianami energii właściwej odkształcenia sprężystego) a rejestrowaną liczbą i wydatkiem energetycznym wstrząsów. Opracowano proste modele regresji umożliwiające prognozowanie zmian sejsmiczności towarzyszącej prowadzonym robotom górnictwa. W artykule przedstawiono wyniki dalszych badań, których celem było określenie możliwości wykorzystania do prognozy zmian poziomu sejsmiczności indukowanej wybiórczo złoża sieci neuronowych. Podstawową cechą sieci neuronowych jest zdolność generalizacji, czyli uogólniania wiedzy dla nowych danych, nieznanych wcześniej, niedostępnych w trakcie nauki. Wykazują one odporność na nieciągłości, zaburzenia lub braki w zbiorze uczącym. Zalety sieci neuronowych sprawiają, że są one coraz częściej wykorzystywanym narzędziem do rozwiązywania różnych problemów, m.in. geofizycznych i geomechanicznych. Rezultaty obliczeń wykonanych dla silnie zagrożonego sejsmicznie rejonu robót górnictwa prowadzonych w kopalni węgla kamiennego potwierdziły możliwość zastosowania sieci neuronowych do szacowania zmian wielkości sejsmiczności indukowanej towarzyszącej eksploatacji złoża. Odpowiednio wytrenowana (nauczona) sieć neuronowa może być wykorzystywana do oceny poziomu zagrożenia wstrząsami na wybiegach projektowanych robót w tym samym rejonie.

**Abstract:** The observed seismicity induced by mining works is largely dependent on the existing geological and mining conditions. These conditions (particularly the mining ones) can be described quantitatively by analytical methods. The results of previous works allowed to find a correlation between the estimated states of rock mass energy (change of energy in the elastic deformation) and the recorded number of tremors and their energy output. Simple regression models enabling prediction of seismic changes due to mining works were developed. In this paper we present the results of further studies, describing the possibility of using neural networks to forecast changes in the level of seismicity induced by deposit excavation. The main feature of neural networks is the ability of generalization, which allows to update the knowledge to new, previously unknown data, which was not available in the learning process. Neural networks show resistance to discontinuity, disorders or deficiencies in the training set. The advantages of neural networks promote their increasingly common use in solving various problems, including geophysical and geomechanical ones. The results of calculations made for a highly seismic region threatened by mining operations, confirmed the possibility of using neural networks to estimate the changes of seismic activity induced by deposit exploitation. Properly trained neural network can be used to assess the level of tremor risk in the planned mining area.

#### **Słowa kluczowe:**

*energia odkształcenia sprężystego, sejsmiczność indukowana, sieci neuronowe*

#### **Key words:**

*elastic strain energy, induced seismicity, neural networks*

\*) Politechnika Śląska w Gliwicach

## 1. Wprowadzenie

W ciągu ostatnich lat w Górnośląskim Zagłębiu Węglowym następuje stały proces ograniczania wydobycia w kopalniach węgla kamiennego. Mimo znacznego spadku wydobycia, nie zaobserwowano zmniejszenia się liczby rejestrowanych wstrząsów wysokoenergetycznych (o umownie przyjętej energii sejsmicznej większej od  $1 \times 10^5$  J). Podobnie brak jest zależności pomiędzy malejącym poziomem wydobycia a liczbą tąpnięć. W perspektywie najbliższych lat zagrożenie sejsmiczne i tąpnięciami nie będzie malało, pomimo przypuszczalnego dalszego spadku wydobycia węgla kamiennego. Utrzymywanie się obserwowanego poziomu zagrożenia (a nawet jego wzrost) będzie spowodowane m.in. ograniczeniem inwestycji związanych z udostępnianiem nowych rejonów eksploatacyjnych i związaną z tym intensyfikacją wydobycia w już udostępnionych partiach złoża, a także koniecznością sięgania po rezerwowane zasoby, zalegające na coraz większych głębokościach. Eksploatacji prowadzonej w takich warunkach z reguły towarzyszą wysokoenergetyczne wstrząsy górotworu i duże zagrożenie tąpnięciami.

W trakcie dotychczasowych badań prowadzonych w Instytucie Eksploatacji Złóż Politechniki Śląskiej stwierdzono istnienie zależności korelacyjnych pomiędzy analitycznie obliczanymi zmianami energii właściwej odkształcenia sprężystego, akumulowanej w górotworze w następstwie naruszania go eksploatacją górnictwem, a poziomem sejsmiczności indukowanej. W procesie niszczenia ośrodka skalnego potencjalna energia sprężysta przechodzi w inne, praktycznie niewyznaczalne ilościowo rodzaje energii, w tym – w energię kinetyczną fal sprężystych. W ten sposób zmiany energii potencjalnej mają wpływ na obserwowaną sejsmiczność indukowaną.

W artykule przedstawiono przykład wykorzystania do prognozy zmian poziomu sejsmiczności indukowanej odpowiednio wytrenowanej sieci neuronowej. Ze względu na wiele zalet sieci neuronowej są coraz częściej wykorzystywane do rozwiązywania różnych zagadnień geofizyki górniczej i geomechaniki [5, 6, 7, 8, 10].

W prezentowanych badaniach informację wejściową stanowiły wskaźniki charakteryzujące zmiany energetyczne zachodzące w wytrzymałych, wstrząsogennych warstwach skalnych oraz poziom sejsmiczności indukowanej opisywany poprzez określanie gęstości energii wstrząsów mierzonej w  $J/m^3$ . Poligon badawczy stanowił wybrany, silnie zagrożony wstrząsami rejon kopalni węgla kamiennego w GZW. Dla rejonu tego wykonano wcześniej analizy związków pomiędzy poziomem sejsmiczności i stanami energetycznymi z wykorzystaniem metody analizy regresji, których wyniki podano w [1].

## 2. Metodyka obliczania zmian ilości energii właściwej odkształcenia sprężystego akumulowanej w górotworze

Do szacowania zmian energetycznych zachodzących w wytrzymałych warstwach skalnych wykorzystywana jest metoda analityczna opierająca się na rozwiązaniu przemieszczeniowego zadania brzegowego liniowej teorii sprężystości, podanym przez H. Gila [4], określającym rozkład naprężeń i odkształceń w półprzestrzeni wokół pustki o kształcie prostokąta. Przyjęty model górotworu (ośrodek ciągły, jednorodny, izotropowy oraz liniowo-sprężysty) stanowi bardzo duże uproszczenie górotworu rzeczywistego. Z tego względu niezbędne jest wykonywanie prognoz rozkładów naprężeń i odkształceń metodą porównawczą. Oznacza to, że przed przystąpieniem do właściwych obliczeń prognostycznych

przeprowadza się obliczenia testowe dla zrealizowanych już robót górniczych. W ich trakcie tak dobiera się wartości parametrów, by uzyskane rezultaty były zgodne z wynikami obserwacji dołowych [3]. Energię właściwą odkształcenia sprężystego określa wzór Clapeyrona

$$\Phi = 0,5T_e T_e, \quad (1)$$

gdzie:

- F – energia właściwa odkształcenia sprężystego,  $J/m^3$
- Ts – tensor stanu naprężenia, MPa
- Te – tensor stanu odkształcenia.

Po rozpisaniu:

$$\Phi = \frac{1}{2} (\sigma_x \epsilon_x + \sigma_y \epsilon_y + \sigma_z \epsilon_z + \tau_{xy} \gamma_{xy} + \tau_{yz} \gamma_{yz} + \tau_{zx} \gamma_{zx}) \quad (2)$$

Wartości energii właściwej ulegają silnym zmianom w okresie, gdy górotwór jest pod wpływem postępującego frontu eksploatacyjnego [2, 3]. Wstrząsy indukowane eksploatacją górnictwem występują zarówno na wybiegach, jak i w zrobach prowadzonych ścian (w trakcie obciążania, jak i odciażania deformowanej warstwy skalnej). Oba procesy zachodzą z różną intensywnością, zależną m.in. od położenia rozpatrywanego punktu w stosunku do frontu ścianowego, od parametrów prowadzonej eksploatacji i od sposobu ukształtowania zaszczości eksploatacyjnych. Dlatego uzasadnione jest porównywanie wielkości sejsmiczności indukowanej zarówno z obliczanymi przyrostami, jak i spadkami energii właściwej. Ponadto, dyssypacja zakumulowanej energii przebiega inaczej w sytuacji, gdy skały nie są zniszczone, a inaczej, gdy skały uległy już zniszczeniu (wskutek oddziaływania wcześniej prowadzonych robót górniczych).

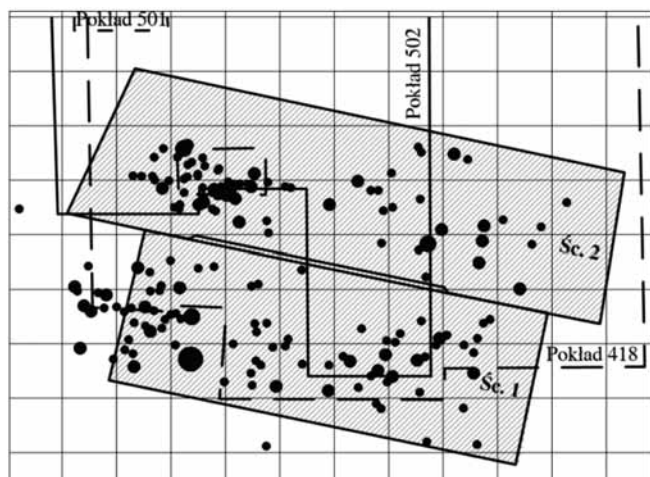
Biorąc to pod uwagę, w prowadzonych badaniach uwzględniano osobno obliczane w wytypowanych, wstrząsogennych warstwach skalnych, przyrosty oraz spadki energii właściwej, z rozdzieleniem na zachodzące przed hipotetycznym zniszczeniem skały oraz po nim.

## 3. Ogólna charakterystyka rejonu badań

Próbę prognozy zagrożenia sejsmicznego z wykorzystaniem sieci neuronowych przeprowadzono, wykorzystując dane pochodzące z rejonu robót prowadzonych w warunkach dużego zagrożenia wstrząsami i tąpnięciami w jednej z kopalń GZW. Eksploatacja prowadzona była w polach ścian 1 i 2 w pokładzie 506 (rys. 1). Miąższość pokładu zmienia się od 2 m do 3 m, głębokość zalegania wynosi około 1030 m, upad warstw:  $3^\circ \div 14^\circ$  w kierunku południowym. W rejonie występują krawędzie eksploatacji wytworzone w wyżej zalegających pokładach, m.in.: 418 w odległości około 140 m, 501 w odległości około 100 m i 502 w odległości około 80 m. Obliczenia zmian energetycznych przeprowadzono dla czterech potencjalnie wstrząsogennych warstw piaskowca o miąższościach: 20 m, 24 m, 27 m i 21 m, zalegających w odległościach odpowiednio: 230 m, 170 m, 110 m i 30 m nad pokładem 506. Rozpatrywanej eksploatacji towarzyszył wysoki poziom sejsmiczności. Ogółem zarejestrowano tu ponad 8000 wstrząsów o sumarycznej energii blisko  $5 \times 10^8$  J, w tym: 130 o energii rzędu  $10^5$  J, 39 o energii rzędu  $10^6$  J i 3 o energii rzędu  $10^7$  J. Najsilniejszy wstrząs, który wystąpił w trakcie prowadzenia ściany 1, osiągnął energię  $2 \times 10^8$  J.

## 4. Ogólna charakterystyka sieci neuronowych

Intensywnie rozwijane w ciągu ostatnich kilkadziesiąt lat sieci neuronowe stanowią uniwersalny układ aproksy-




Rys. 1. Kontury ścian 1 i 2, krawędzie eksploatacji zatrzymanej w wyżej zalegających pokładach, epicentra zarejestrowanych wstrząsów wysokoenergetycznych

Fig. 1. Longwalls 1 and 2 contours, edges of exploitation discontinued in the highly-lying seams, registered epicentres of high-energy tremors

macyjny, pozwalający odwzorowywać wielowymiarowe zbiory danych, mający zdolność uczenia się i adaptacji do zmieniających się warunków środowiskowych, zdolność uogólniania nabytej wiedzy, stanowiąc pod tym względem system sztucznej inteligencji [9]. Sieci neuronowe powstały w wyniku badań, które dotyczyły budowy modeli podstawowych struktur występujących w mózgu. Jak wynika z badań, mózg człowieka składa się z bardzo dużej liczby (około 10 miliardów) elementarnych komórek nerwowych – neuronów połączonych ze sobą w formie skomplikowanej sieci. Na jeden neuron przypada przeciętnie kilka tysięcy połączeń. Neuron w uproszczeniu posiada wiele wejść informacyjnych, ciało scalające sygnały z tych wejść oraz pojedyncze włókno przewodzące informację wyjściową. Pobudzony przez sygnały wejściowe neuron przechodzi do stanu aktywnego, gdy łączny docierający sygnał przekroczy poziom progowy. W stanie aktywnym wysyła on sygnał do połączonych z nim kolejnych neuronów poprzez złącza, modyfikujące sygnały i stanowiące nośnik pamięci. Proces uczenia się polega m.in. na wprowadzaniu zmian w parametrach połączeń pojedynczych neuronów.

Sztuczne sieci neuronowe korzystają z uproszczonego modelu neuronu, w którym przyjęto, że obliczana jest ważona suma sygnałów wejściowych i gdy przekroczy ona poziom progowy, sygnał podawany jest na wyjście – rys. 2. Funkcja aktywacji  $f$  może mieć różną postać. W wykorzystanym

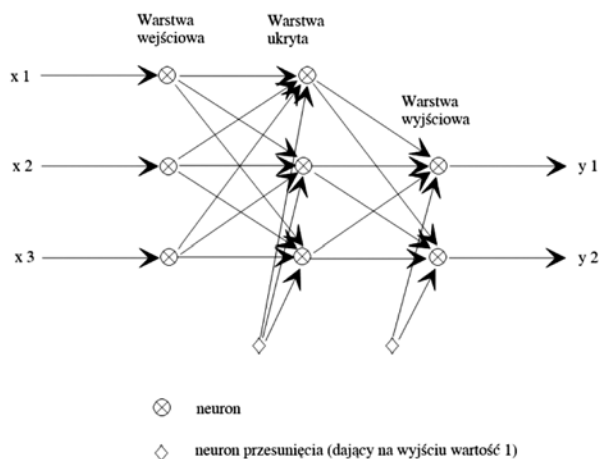


Rys. 2. Model neuronu  
Fig. 2. Neuron model

w prowadzonych badaniach pakiecie „Statistica” dostępne są następujące jej postacie: liniowa, logistyczna, tangens hiperboliczny, wykładnicza oraz sinus.

W odróżnieniu od metod parametrycznych (np. metody analizy regresji), wymagających znajomości funkcji wiążących zmienne niezależne ze zmiennymi zależnymi, sieci neuronowe, będące metodami nieparametrycznymi, nie zakładają posiadania takiej apriorycznej informacji – automatycznie uczą się na podanych przez użytkownika danych pokazujących, jak manifestuje się interesująca zależność. Sieci neuronowe mają wyjątkową zdolność znajdowania sensu i znaczenia, reguł i trendów w skomplikowanych strukturach zaszumionych i nieprecyzyjnych danych. Można ich używać do wykrywania ukrytych wzorców i zależności sterowanych przez tak skomplikowane funkcje, że bardzo trudne lub niemożliwe wręcz byłoby ich analityczne, parametryczne modelowanie. Sieci neuronowe posiadają ponadto zdolność do uogólniania, polegającą na tym, że nauczono na pewnym zestawie danych z powodzeniem stosują zdobytą wiedzę do nowych danych o takiej samej strukturze [11].

Możliwość różnego sposobu połączenia neuronów między sobą i ich współdziałania spowodowała powstanie różnych typów sieci neuronowych i związanych z nimi metod doboru wag (uczenia sieci). Do najprostszych, mających jednak praktyczne znaczenie, można zaliczyć sieci jednokierunkowe, wielowarstwowe (rys. 3). Sieci te składają się z warstwy wejściowej, wprowadzającej do sieci dane wejściowe. Neurony z warstw ukrytych i z warstwy wyjściowej połączone są z wszystkimi neuronami z poprzedniej warstwy. Wartości zmiennych wejściowych przekazywane są do neuronów wejściowych, następnie do neuronów warstw ukrytych i warstwy wyjściowej. W każdym neuronie obliczana jest ważona suma wejść. Następnie wyznaczana jest wartość wyjściowa, zależna od informacji wejściowej i przyjętej funkcji aktywacji. Wynik działania całej sieci pojawia się na wyjściach neuronów warstwy wyjściowej. W każdej warstwie neuronów jest też dodatkowy neuron, który na wyjściu zawsze daje 1 (składnik przesunięcia). Wartość ta, po wymnożeniu przez wyznaczoną wagę, podawana jest na wszystkie neurony następnej warstwy.



Rys. 3. Model sieci jednokierunkowej, wielowarstwowej  
Fig. 3. One-way, multilayer network model

### 5. Próba prognozy wydatku energetycznego wstrząsów z wykorzystaniem sieci neuronowej

Korzystając z danych o czasoprzestrzennym przebiegu eksploatacji górniczej w rozpatrywanej partii złoża, wykonano obliczenia zmian energii właściwej odształcenia sprężystego w czterech potencjalnie wstrząsogennych warstwach

skalnych, w siatce regularnie rozmieszczonych (co 25 m) 3445 punktów obliczeniowych. Uwzględniono 7-dniowe jednostkowe przedziały czasu – kroki postępu frontów eksploatacyjnych.

- Okres prowadzenia robót podzielono na dwa podokresy:
- 1.01.2010 ÷ 1.07.2012 – wykorzystując dane o zarejestrowanej sejsmiczności w tym okresie i obliczone wartości wskaźników charakteryzujących zmiany energetyczne, przeprowadzono naukę sieci neuronowej,
  - 1.07.2012 ÷ 1.12.2014 – dla którego, wykorzystując wytrenowaną sieć neuronową, przeprowadzono obliczenia zmian gęstości energii wstrząsów. Prognozowane zmiany sejsmiczności porównano z zaobserwowanymi w trakcie prowadzenia robót w polu ściany 2.


Obliczenia wykonano pakietem „Statistica”. Zbiór danych charakteryzujący zmiany wartości wskaźników energetycznych oraz wartości gęstości energii wstrząsów został podzielony na 3 podzbiory: danych uczących (70% przypadków), danych testowych (15% przypadków) oraz danych walidacyjnych (15% przypadków). Pierwszy z powyższych zbiorów jest wykorzystywany do nauki sieci, drugi – do sprawdzania postępów trenowania sieci i zakończenia procesu uczenia przed wystąpieniem tzw. przeuczenia sieci – zjawiska polegającego na nadmiernym dopasowaniu do konkretnego zbioru przypadków kosztem utraty zdolności uogólniania wiedzy. Ostatni z wymienionych zbiorów pozwala ocenić jakość sieci i porównywać różne warianty sieci zastosowanych do konkretnego zadania. Na omawianym, początkowym etapie badań, przyjęto możliwie najprostszą budowę sieci – pojedynczą warstwę ukrytą zawiera jedynie 1 lub 2 neurony. Spośród wielu dostępnych funkcji aktywacji analizowano możliwość wykorzystania najprostszych: funkcji liniowej (Lin) i tangensa hiperbolicznego (Tgh). Tak prosta budowa sieci może powodować stosunkowo słabe odwzorowanie zbioru danych uczących, zabezpiecza jednak bardzo skutecznie przed zbyt dużym dopasowaniem do tego zbioru kosztem utraty informacji o charakterystycznych związkach pomiędzy danymi wejściowymi a sygnałem wyjściowym. Wystąpienie takiego zjawiska (tzw. przeuczenie sieci) praktycznie uniemożliwia wykorzystanie danej sieci w celach prognostycznych.

Wyniki obliczeń – uczenia sieci w oparciu o dane zaobserwowane w trakcie prowadzenia ściany 1 podano w tabl. 1. Wyniki zostały posortowane według jakości sieci, wyrażonej wartością współczynnika korelacji liniowej pomiędzy wartością na wyjściu i danymi uczącymi.

Do dalszych analiz została wybrana najlepsza z rozpatrywanych sieci, zawierająca dwa neurony w warstwie ukrytej. Przyjętą funkcją aktywacji neuronów ukrytych był tangens

hiperboliczny, natomiast neuronu wyjściowego funkcja liniowa. Przebieg uczenia sieci pokazano na rys. 4.

Wartość błędu na osi rzędnych jest równa sumie kwadratów różnic pomiędzy zarejestrowanymi i obliczonymi przez sieć wartościami gęstości energii wstrząsów, przeskalowanymi do zakresu 0-1.



Rys. 4. Przebieg uczenia sieci neuronowej

Fig. 4. Neural network learning process

Na rys. 5 zaprezentowano zaobserwowane (a) i obliczone (b) siecią neuronową rozkłady gęstości energii wstrząsów sporządzone dla okresu prowadzenia ściany 1. Wyznaczona wartość współczynnika korelacji liniowej pomiędzy rozpatrywanymi wielkościami wynosi 0,92; wartość współczynnika determinacji wynosi 0,85, czyli 85% obserwowanej zmienności gęstości energii wstrząsów jest wyjaśniana przez sieć neuronową. Wartość błędu średniokwadratowego wynosi 3 J/m<sup>3</sup>.

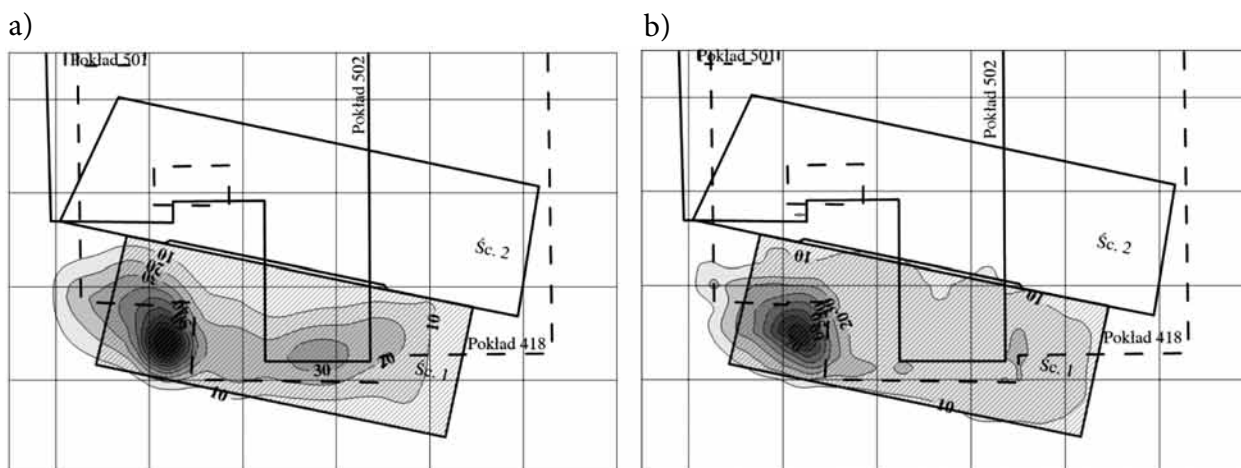
W kolejnym etapie prac, sieć neuronowa wytrenowana w oparciu o dane dotyczące sejsmiczności indukowanej w trakcie prowadzenia ściany 1, została zastosowana do sporządzenia prognozy zmian gęstości energii wstrząsów na wybiegu ściany 2. Wyniki tak sporządzonej prognozy wartości wydatku energetycznego wstrząsów (rys. 6b) porównano z wartościami zaobserwowanymi (rys. 6a).

Zastosowana sieć neuronowa, pomimo jej prostoty, umożliwiła stosunkowo dokładną prognozę sejsmiczności indukowanej na wybiegu ściany 2. Największe niedoszacowanie prognozowanej wartości gęstości energii wstrząsów wynosi 45 J/m<sup>3</sup>, podczas gdy maksymalne przeszacowanie osiąga mniejszą wartość, wynoszącą 26 J/m<sup>3</sup>. Wartość błędu średniokwadratowego wynosi około 10 J/m<sup>3</sup>, wartość współczynnika

Tablica 1. Wyniki uczenia uwzględnionych w badaniach sieci neuronowych

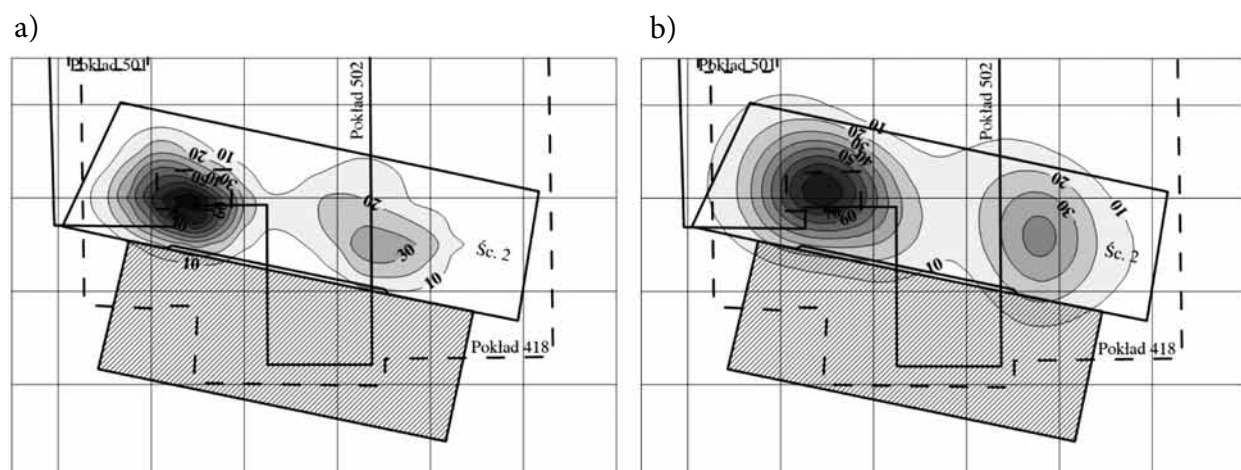
Table 1. Learning results included in neural network studies

| Struktura sieci | Współczynnik korelacji – zbiór: |         |             | Błąd dopasowania – zbiór: |         |             | Funkcja aktywacji – neurony |           |
|-----------------|---------------------------------|---------|-------------|---------------------------|---------|-------------|-----------------------------|-----------|
|                 | uczący                          | testowy | walidacyjny | uczący                    | testowy | walidacyjny | ukryte                      | wyjściowy |
| 16-2-1          | 0,90                            | 0,93    | 0,85        | 7,04                      | 4,86    | 11,48       | Tgh                         | Lin       |
| 16-2-1          | 0,89                            | 0,94    | 0,84        | 7,66                      | 4,39    | 11,98       | Tgh                         | Tgh       |
| 16-1-1          | 0,85                            | 0,85    | 0,81        | 10,27                     | 9,69    | 13,79       | Lin                         | Lin       |
| 16-2-1          | 0,85                            | 0,85    | 0,81        | 10,27                     | 9,69    | 13,79       | Lin                         | Lin       |
| 16-1-1          | 0,85                            | 0,85    | 0,81        | 10,33                     | 9,61    | 13,72       | Tgh                         | Lin       |
| 16-1-1          | 0,84                            | 0,85    | 0,81        | 10,63                     | 9,85    | 13,84       | Lin                         | Tgh       |
| 16-2-1          | 0,84                            | 0,85    | 0,81        | 10,63                     | 9,85    | 13,83       | Lin                         | Tgh       |
| 16-1-1          | 0,84                            | 0,85    | 0,81        | 10,78                     | 9,79    | 13,93       | Tgh                         | Tgh       |



Rys. 5. Rozkład – a) wartości zaobserwowanej i b) obliczonej siecią neuronową gęstości energii wstrząsów [ $J/m^3$ ] w okresie prowadzenia ściany 1


Fig. 5. Distribution of: a) the observed values and b) value calculated with the neural network of energy density of tremors [ $J/m^3$ ] during the mining period of longwall 1



Rys. 6. Rozkład a) wartości zaobserwowanej i b) prognozowanej siecią neuronową gęstości energii wstrząsów [ $J/m^3$ ] w okresie prowadzenia ściany 2

Fig. 6. Distribution of: a) the observed value and b) value predicted with the neural network of energy density of tremors [ $J/m^3$ ] during the mining period of longwall 2

korelacji liniowej pomiędzy wartościami obserwowanymi i prognozowanymi wynosi 0,81 (wartość współczynnika determinacji: 0,66). Na rys. 7 pokazano rozkład wartości błędu bezwzględnego prognozy.



Rys. 7. Rozkład wartości błędu bezwzględnego prognozy gęstości energii wstrząsów [ $J/m^3$ ]

Fig. 7. Distribution of the absolute prediction error of energy density of tremors [ $J/m^3$ ]

## 6. Podsumowanie

Obliczenia przeprowadzone dla wybranego rejonu pozwoliły stwierdzić możliwość wykorzystania sieci neuronowej do opisu zmian wielkości sejsmiczności indukowanej w oparciu o szacowane zmiany stanów energetycznych zachodzące we wstrząsogennych warstwach skalnych. Odpowiednio wytrenowana sieć neuronowa może być wykorzystywana do oceny poziomu sejsmiczności na wybiegach projektowanych robót w danym rejonie. W trakcie dalszych badań ustalona zostanie optymalna konfiguracja wykorzystywanej sieci neuronowej, zweryfikowana zostanie także zdolność uogólniania wiedzy – możliwość wykonywania oszacowań w różnych rejonach aktywnych sejsmicznie.

## Literatura

1. Bańka P., Cichy T.: Przykład prognozy zagrożenia sejsmicznego z wykorzystaniem szacowanych zmian energii właściwej odkształcenia sprężystego (w druku).
2. Bańka P.: Modelowanie zmian sejsmiczności indukowanej na podstawie szacowanych stanów energetycznych górotworu. Wyd. Pol. Śl., Gliwice 2013.

3. *Bańka P., Jaworski A., Plewa F.*: Ocena zagrożenia wstrząsami i tapaniami wyrobisk podziemnych metodami analitycznymi. „Przeгляд Górnicy” 2012, nr 1, s. 13-19.
4. *Gil H.*: The Theory of Strata Mechanics. PWN, Warszawa 1991.
5. *Jakubowski J., Tajduś A.*: Predictive regression models of monthly seismic energy emissions induced by longwall mining. Arch. Min. Sci., vol.59 (2014), No 3, pp.705-720.
6. *Jakubowski J., Lenart Ł., Ożóg Ł.*: Predykcijny model dobowej emisji energii sejsmicznej indukowanej eksploatacją górnictw. „Przeгляд Górnicy” 2014, nr 3, s. 18-25.
7. *Kabiesz J. i in.*: Prediction of mining – induced seismic activity with the use of neural networks on displacement field of rocks in its vicinity. New techniques and Technologies in Mining. Proceedings of the School of Underground Mining. Dnipropetrovs'k/Yalta. CRC Press. Balkema. Taylor&Francis Group, Ukraine, 12-18 September 2010, pp. 175-187.
8. *Kabiesz J.*: Badanie kategoryzacji zagrożenia tapaniami z wykorzystaniem sieci neuronowych. Prace Naukowe GIG: „Górnictwo i Środowisko”, 2008, nr 7, s. 93-104.
9. *Ossowski S.*: Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
10. *Poulton M.M.*: Computational neural networks for geophysical data processing. Elsevier Science Ltd, 2001.
11. StatSoft, Inc. (2011). STATISTICA (data analysis software system), version 10. www.statsoft.com.

---

---

***Zwiększajmy prenumeratę  
najstarszego – czołowego miesięcznika  
Stowarzyszenia Inżynierów i Techników Górnictwa!***

Liczba zamawianych egzemplarzy określa zaangażowanie jednostki  
gospodarczej w procesie podnoszenia kwalifikacji swoich kadr!