

Krystyna Kuźniar

Wpływ klasyfikacji wzorców na dokładność neuronowej prognozy przekazywania drgań pochodzenia górniczego z gruntu na fundament budynku

Wstęp

Podziemna działalność górnicza jest źródłem losowo występujących (podobnie jak przy trzęsieniach ziemi) pęknięć skał w górotworze. W Polsce jednym z najbardziej aktywnych sejsmicznie regionów górniczych jest Legnicko-Głogowski Okręg Miedziowy (LGOM). Eksploatacji rud miedzi w LGOM od kilkudziesięciu lat towarzyszą wstrząsy górnicze, przy czym intensywność najsilniejszych z nich zbliżona jest do słabych trzęsień ziemi. Fale wstrząsowe propagują się do powierzchni i oddziałują na zabudowę. Pojawia się więc problem oceny potencjalnych skutków drgań od wstrząsów górniczych. W tym celu, w Głównym Instytucie Górnictwa opracowana została empiryczna górnicza skala intensywności (skala GSI-2004) do praktycznego stosowania w przypadku wstrząsów z obszaru LGOM [2]. Wśród parametrów używanych w GSI-2004 do oceny oddziaływań drgań na obiekty powierzchniowe znajduje się wypadkowa przyśpieszeń drgań poziomych gruntu.

Z przekazywaniem drgań z gruntu na budynek związane jest zjawisko wzajemnego oddziaływania (współpracy) układu konstrukcja-podłoże, nazywane interakcją dynamiczną. Jednocześnie rejestrowane przebiegi drgań fundamentów budynków i gruntu w ich pobliżu mogą różnić się znacząco [4, 6]. Ponieważ dokładniejszej oceny szkodliwości drgań dla budynków dokonuje się na podstawie drgań ich fundamentów [7], to gdy pomiarów drgań dokonuje się tylko na gruncie (co jest częstym przypadkiem w praktyce), potrzebne jest na ich podstawie prognozowanie drgań fundamentów budynków.

Praca dotyczy prognozowania przekazywania drgań, których źródłem były wstrząsy górnicze w Legnicko-Głogowskim Okręgu Miedziowym, z gruntu na fundamenty pięciokondygnacyjnego budynku mieszkalnego. W przypadku każdego ze wstrząsów porównywano maksymalne wartości wypadkowych przyśpieszeń drgań poziomych gruntu i fundamentu budynku, wyznaczanych na podstawie zarejestrowanych w tym samym czasie przebiegów drgań gruntu i fundamentu.


Do prognozowania przekazywania drgań z gruntu na fundament budynku zaproponowano wykorzystanie sztucznych sieci neuronowych (SSN). Zdecydowano się na podział wszystkich analizowanych wstrząsów górniczych na klasy i uwzględnienie

informacji o przynależności do danej klasy wstrząsów w wektorze wejścia sieci neuronowej. Zaproponowano również sposób „rozmnożenia” danych uczących sieci, który umożliwił uzyskanie dokładniejszych wyników aproksymacji neuronowej.

Wyniki badań doświadczalnych

Eksperymentalna analiza przekazywania drgań pochodzenia górniczego z podłoża na konstrukcję dotyczyła typowego mieszkalnego budynku o pięciu kondygnacjach, a więc należącego do klasy obiektów o średniej wysokości. Jest to budynek o konstrukcji ścianowej, prefabrykowany, z poprzeczno-podłużnym układem ścian nośnych, posadowiony na ławach fundamentowych.

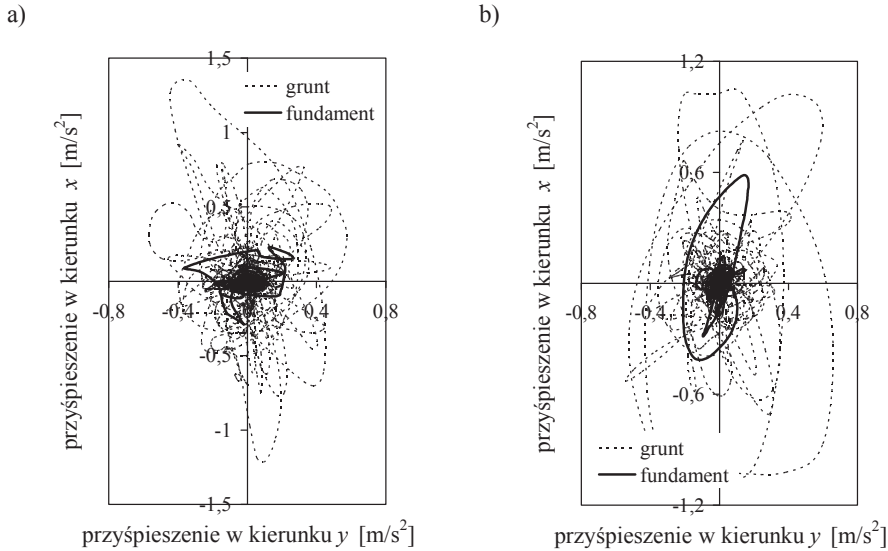
Źródłem drgań były wstrząsy górnicze w LGOM o energiach z przedziału $En=7.4E3-2E9$ [J] i odległościach epicentralnych z przedziału $r_e=270-5815$ [m]. Gęstości prawdopodobieństwa rozkładu normalnego odpowiednio energii i odległości epicentralnych rozważanych wstrząsów oraz wartości średnie pokazano na rys. 1.



Rys. 1. Gęstość prawdopodobieństwa rozkładu normalnego energii (a) i odległości epicentralnych (b) rozważanych wstrząsów górniczych w LGOM

Za pomocą aparatury „czuwającej” mierzono przyspieszenia drgań gruntu w odległości kilku metrów od budynku i drgań budynku na fundamentach.

Analizowano przebiegi drgań zarejestrowane równocześnie na gruncie i w budynku od wielu wstrząsów górniczych [4–6]. Pod uwagę wzięto dwie składowe drgań poziomych: x i y , równoległe odpowiednio do osi poprzecznej i podłużnej budynku. Stwierdzono, że różnice w drganiach gruntu i fundamentu, odbywających się w tym samym czasie, mogą być znaczące, co widać na rys. 2, na którym pokazano przykładowe trajektorie końca wypadkowego wektora przyspieszeń drgań zarejestrowanych jednocześnie na gruncie i na fundamencie rozważanego budynku.



Rys. 2. Trajektorie końca wypadkowego wektora przyspieszeń drgań jednocześnie zarejestrowanych na gruncie i na fundamencie rozważanego budynku od wstrząsu górniczego: a) $En=1.7E8J$, $r_e=912m$; b) $En=1.2E7J$, $r_e=698m$

Na podstawie pomierzonych składowych przebiegów przyspieszeń drgań w kierunkach x i y , w przypadku każdego wstrząsu wyliczono maksymalne wartości wypadkowego przyspieszenia drgań poziomych PGA i PFA , odpowiednio na gruncie i na fundamencie budynku:

$$PGA = \max_t \left(\sqrt{a_{gx}^2(t) + a_{gy}^2(t)} \right), \quad (1a)$$


$$PFA = \max_t \left(\sqrt{a_{fx}^2(t) + a_{fy}^2(t)} \right), \quad (1b)$$

gdzie: $a_{gx}(t)$, $a_{gy}(t)$ oraz $a_{fx}(t)$, $a_{fy}(t)$ – odpowiednio przyspieszenia drgań na gruncie oraz na fundamencie w kierunkach x i y w kolejnych chwilach czasu.


Oceny przekazywania drgań z gruntu na fundament dokonano w prosty i często spotykany sposób – poprzez porównanie maksymalnych amplitud wypadkowych przyspieszeń drgań jednocześnie zarejestrowanych na fundamencie budynku i gruncie obok budynku. W tym celu wyliczano ułamek $rw = PFA/PGA$. Na rys. 3 przedstawiono gęstość prawdopodobieństwa rozkładu normalnego otrzymanych wartości ułamka rw , a na rys. 4 przykładowo pokazano zależność rw od odległości epicentralnych (r_e) w przypadku wszystkich badanych wstrząsów.

Na podstawie analizy wyników badań doświadczalnych stwierdzono, że określenie precyzyjnej zależności ułamka rw od parametrów charakteryzujących

wstrząsy górnicze, takich jak energia wstrząsu (En), odległość epicentralna (r_e), maksymalna wartość wypadkowego przyspieszenia drgań poziomych na gruncie (PGA), a więc też ocena przekazywania drgań od wstrząsów górniczych z gruntu na budynek o średniej wysokości jest bardzo trudna, a wręcz niemożliwa ze względu na niejednoznaczny sposób tego przekazywania drgań oraz duży rozrzut wartości ułamka rw (por. np. rys. 4).



Rys. 3. Gęstość prawdopodobieństwa rozkładu normalnego wartości ułamka rw



Rys. 4. Zależność $rw = PFA/PGA$ od odległości epicentralnych (r_e)

Klasyfikacja analizowanych wstrząsów górniczych

Duży rozrzut wartości ułamka rw w analizowanych zakresach energii wstrząsów, odległości epicentralnych oraz maksymalnych wartości wypadkowych przyspieszeń drgań gruntu może być przesłanką do podziału wszystkich rozważanych wstrząsów na klasy, a więc dekompozycję zgromadzonego zbioru danych na podzbiory, w których dane opisane będą poprzez wybrane cechy. Chodzi zatem o dokonanie tzw. analizy skupień lub inaczej – klasyfikacji (klasteryzacji) [8]. Klasyfikacja ma na celu formowanie danych w grupy i jednocześnie oddzielenie ich od pozostałych elementów zbioru danych. Spodziewanym efektem takiego zabiegu może być np. uzyskanie dokładniejszych wyników uczenia sztucznej sieci neuronowej poprzez wykorzystanie tylko tych danych, które są niezbędne do wyznaczenia relacji między danymi wejściowymi i wyjściowymi sieci.


Istnieje wiele metod klasyfikacji, a więc zaliczenia analizowanego obiektu do jednej z klas obiektów, np. wykorzystanie sieci neuronowych [1, 3, 8, 10], metody statystyczne [1, 3]. Najpopularniejszą grupą sposobów klasyfikacji jest zbiór metod, w których stopień podobieństwa obiektów określany jest za pomocą różnych modyfikacji algorytmu „najbliższego sąsiada” [3, 8].

Zdecydowano się na podział analizowanych wstrząsów górniczych na klasy według wielkości parametrów: En , r_e i PGA . Granice przedziałów poszczególnych parametrów zaproponowane w celu klasyfikacji wstrząsów podano w tabeli 1. W ten sposób utworzono 24 klasy rozważanych wstrząsów ($2 En \times 3 r_e \times 4 PGA$), które oznaczono kolejnie od C1 do C24.

Tab. 1. Przedziały wartości parametrów En , r_e i PGA zaproponowane w celu klasyfikacji wstrząsów

	Przedział 1	Przedział 2	Przedział 3	Przedział 4
En [J]	$\leq 5E7$	$> 5E7$	-	-
r_e [m]	$r_e \leq 800$	$800 < r_e \leq 1500$	$r_e > 1500$	-
PGA [m/s ²]	$\leq 0,300$	$0,301 - 0,600$	$0,601 - 0,900$	$> 0,900$

Na rys. 5 pokazano zakresy (przedziały) wartości ułamka rw w poszczególnych klasach wstrząsów górniczych. Zaznaczono również wartości średnie i podano liczbę zarejestrowanych wstrząsów z danej klasy.



Rys. 5. Wartości ułamka rw w poszczególnych klasach wstrząsów górniczych

Z analizy danych doświadczalnych dotyczących przekazywania drgań od wstrząsów górniczych na rozważany budynek widać, że są one mocno rozwarstwione. Nawet w przypadku wstrząsów górniczych zaliczanych do tej samej, bardzo wąskiej klasy, obserwuje się duży rozrzut wartości rw . Taki znaczący problem w przewidywaniu wartości ułamka rw pojawia się np. w klasie C2, C3, C6, C19.

Prognozowanie przekazywania drgań z podłoża na budynek z wykorzystaniem sieci neuronowych

W celu prognozowania wartości ułamka $rw = PFA/PGA$ na podstawie parametrów wstrząsów górniczych i drgań gruntu zaproponowano zastosowanie sztucznych sieci neuronowych (SSN) uczonych i testowanych z użyciem zgromadzonych wyników badań eksperymentalnych.

Przyjęto wektor wejścia sieci neuronowej (sieć nr 1) w postaci:

$$\mathbf{x}_{(3 \times 1)} = \{En, r_e, PGA\} \quad (2)$$

gdzie: En – energia wstrząsu górniczego; r_e – odległość epicentralna; PGA – maksymalna wartość (amplituda) wypadkowej przyspieszeń drgań poziomych gruntu.

W kolejnym wariancie wektora wejścia (sieć nr 2) informację wejściową wzbogacono poprzez dodanie parametru określającego klasę, do której zaliczono wstrząs:

$$\mathbf{x}_{(4 \times 1)} = \{En, r_e, PGA, c\} \quad (3)$$

gdzie: En, r_e, PGA – jak w relacji (2); c – parametr opisujący klasę, do której zaliczono wstrząs górniczy (wartości parametrów c , przypisane poszczególnym klasom, zawarte są w przedziale [0.100; 0.882] i przyjęte wg procedury: $c = 0.1 + (CN - 1) \cdot 0.034$, gdzie CN jest numerem klasy).

Oczywiście informacja o przynależności wstrząsu górniczego do danej klasy jest już zawarta w trzech pierwszych składowych wektora wejścia. Poprzez dołączenie parametru c tylko ją dodatkowo „wzmocniono”.

Na wyjściu z tych sieci (nr 1 i nr 2) wyliczano odpowiednią wartość ułamka rw :

$$\mathbf{y}_{(1 \times 1)} = \{rw\}. \quad (4)$$

Wyniki badań doświadczalnych pozwoliły na przygotowanie po $P = 226$ wzorców w przypadku każdego wariantu wektora wejścia. W obu przypadkach do uczenia sieci przeznaczono losowo wybrane $L = 113$ z tych wzorców, do walidacji wykorzystano $V = 56$, a pozostałych $T = 57$ wzorców użyto do testowania.

Sieć uczy się na zasadzie minimalizacji błędu średniokwadratowego w całym zbiorze uczącym. Zatem jeżeli w zbiorze uczącym jest stosunkowo mało wzorców z danej klasy, istnieje niebezpieczeństwo, że sieć nie nauczy się prawidłowo tej klasy, co może skutkować jej słabymi właściwościami prognozowania w innych przypadkach z tej klasy [9, 11]. Jak widać z rys. 1, a zwłaszcza z danych z rys. 5, dotyczących zarejestrowanych wstrząsów górniczych w poszczególnych klasach, liczba wstrząsów zaliczonych do każdej klasy jest znacząco różna. Przykładowo, najczęściej rejestrowano wstrząsy o parametrach z klasy C2. Tak „niezrównoważona” struktura danych może potencjalnie wywoływać „tendencyjność” w uczeniu neuronowym. W celu zniwelowania tego efektu, zaproponowano „rozmnożenie” danych uczących. Do $L = 113$ wzorców uczących uzyskanych z pomiarów dodano kopie losowo wybranych wzorców uczących z klas C1, C3–C24 tak, aby liczba wzorców uczących z tych klas była równa liczbie wzorców uczących z najliczniejszej klasy C2. W ten sposób osiągnięto $L = 600$ wzorców uczących. Zbiór walidujący i testujący pozostawiono bez zmian.

Wpływ klasyfikacji wzorców na dokładność neuronowej prognozy przekazywania drgań... [115]

„Rozmnożonego” zbioru uczącego użyto do uczenia sieci neuronowej (sieć nr 3) o wektorze wejścia w postaci (2) oraz kolejnej sieci (sieć nr 4) z wektorem wejścia, w którym przyjęto pięć parametrów:

$$\mathbf{x}_{(4 \times 1)} = \{En, r_e, PGA, c, Pr\} \quad (5)$$

gdzie: En, r_e, PGA, c – jak w relacji (3); Pr – parametr określający prawdopodobieństwo wystąpienia wstrząsu z klasy c .

Wektory wyjścia tych sieci (nr 3 i nr 4) mają postać (4), a więc taką jak w przypadku sieci, do uczenia których użyto danych eksperymentalnych w rzeczywistych proporcjach (sieci nr 1 i nr 2).

Wykorzystano sieci neuronowe typu wstecznej propagacji błędu (WPB) z algorytmem uczenia Resilient back-propagation (Rprop) i sigmoidalną unipolarną (logistyczną) funkcją aktywacji. Wykorzystano symulator neuronowy SNNS, wersja 4.2 [12].

Jako miarę błędu aproksymacji neuronowej stosowano błąd średniokwadratowy (*Mean Square Error*) MSE oraz błędy względne ep :

$$(Q) = \frac{1}{Q} \sum_{p=1}^Q (z_p - y_p)^2, \quad (6)$$

$$ep = |1 - y_p/z_p| \cdot 100\% , \quad (7)$$

gdzie: $Q = L, V, T$ – liczba wzorców w zbiorze uczącym (L), walidującym (V) i testującym (T); z_p i y_p – wartość stosunku rw wyznaczona na podstawie zarejestrowanych przebiegów drgań oraz wyliczona neuronowo dla p -tego wzorca.

Do oceny dokładności przeprowadzonych obliczeń wykorzystano również tzw. procent sukcesu (*Success Ratio*) $SR[\%]$ w zależności od błędu względnego $ep[\%]$. SR określa, jaki procent wzorców uzyskano z predykcji neuronowej z błędem nie większym niż ep .

Wykonano wiele prób numerycznych w celu zaprojektowania optymalnej architektury sieci. W tabeli 2 zestawiono błędy aproksymacji neuronowej sieci nr 1–4. W celach porównawczych, we wszystkich tych sieciach zdecydowano się na taką samą warstwę ukrytą: 6+5 neuronów.

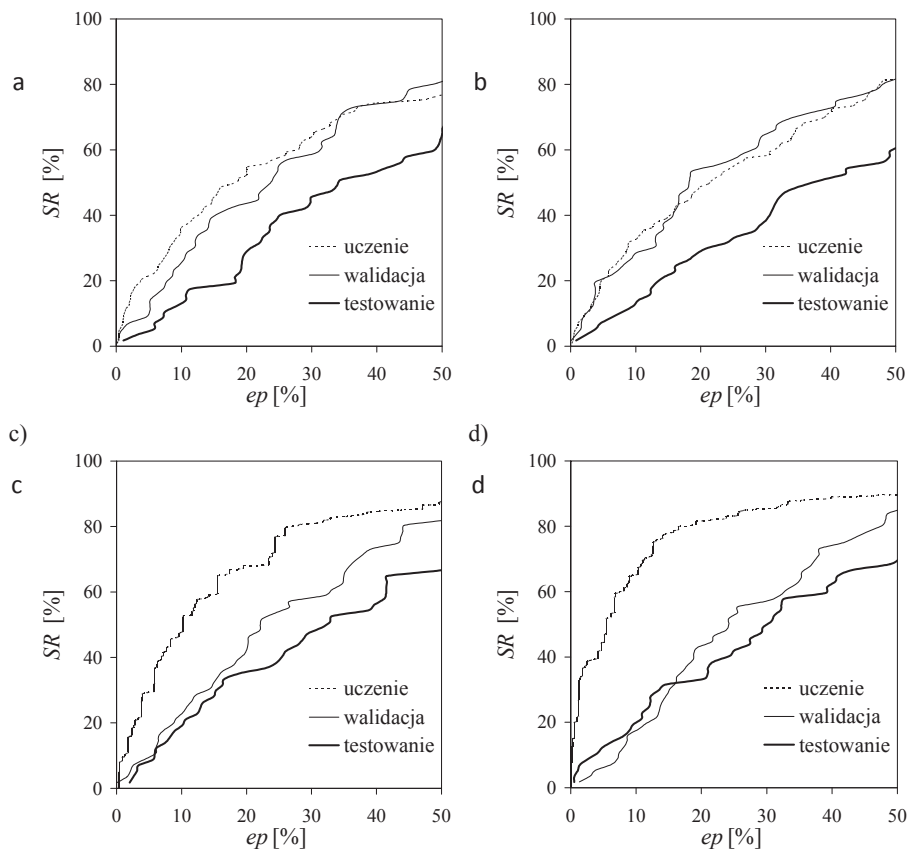
Na rys. 6 pokazano procent sukcesu SR uczenia, walidacji i testowania rozważanych sieci neuronowych nr 1–4.

Zgodnie z oczekiwaniami, wzbogacenie informacji wejściowej sieci neuronowej poprzez dodanie parametru c określającego klasę, do której zaliczono wstrząs, ma niewielki wpływ na dokładność aproksymacji. Wprawdzie porównując rezultaty obliczeń przeprowadzonych z wykorzystaniem sieci nr 2, a więc z parametrem c na wejściu sieci oraz sieci nr 1 – bez jawnej informacji w wektorze wejścia o przynależności wstrząsu do danej klasy, stwierdzono znacznie mniejszy błąd testowania

$MSE(T)$ i mniejszy błąd walidacji $MSE(V)$ w przypadku sieci nr 2 (por. tab. 2). Niemniej jednak różnica w procencie sukcesu SR uczenia, walidacji i testowania sieci nr 2 oraz sieci nr 1 jest praktycznie bardzo mała, co widać na rys. 6a i 6b.

Tab. 2. Błędy uczenia, walidacji i testowania rozważanych sieci

Nr sieci	Parametry wejścia	Struktura sieci	L	Błąd średniokwadratowy		
				$MSE(L)$	$MSE(V)$	$MSE(T)$
1	En, r_e, PGA	3-6-5-1	113	0,01434	0,01887	0,03437
2	En, r_e, PGA, c	4-6-5-1	113	0,01537	0,01734	0,02503
3	En, r_e, PGA	3-6-5-1	600	0,00819	0,01635	0,02154
4	En, r_e, PGA, c, Pr	5-6-5-1	600	0,00599	0,01880	0,01866



Rys. 6. Procent sukcesu SR uczenia, walidacji i testowania sieci neuronowych: a) nr 1; b) nr 2; c) nr 3; d) nr 4

Wpływ klasyfikacji wzorców na dokładność neuronowej prognozy przekazywania drgań... [117]

Zdecydowane zwiększenie dokładności prognozowania ułamka rw uzyskano, gdy „rozmnóżono” zbiór wzorców uczących w zaproponowany sposób. Sieć nr 3, do której uczenia użyto $L = 600$ wzorców (a więc „rozmnóżonego” zbioru uczącego), a która ma taką samą strukturę i wektor wejścia jak sieć nr 1, pozwoliła na istotne zmniejszenie błędów uczenia, walidacji i testowania w stosunku do sieci nr 1 (por. tab. 2). Krzywe procentu sukcesu SR z rys. 6a i 6c potwierdzają to spostrzeżenie.

Na dalsze zwiększenie dokładności obliczeń pozwoliło wykorzystanie sieci nr 4. Do uczenia tej sieci użyto także „rozmnóżonego” zbioru uczącego. Dodatkowo, w jej wektorze wejścia informacja została rozwinięta poprzez przyjęcie pięciu parametrów: En , r , PGA , c , Pr (por. formuła (5)). Widać zatem, że podanie w wektorze wejścia sieci neuronowej oprócz parametru klasy c także prawdopodobieństwa wystąpienia wstrząsu z klasy c może mieć wpływ na zwiększenie dokładności neuronowego prognozowania ułamka rw .

Wnioski

Określenie sposobu przekazywania drgań pochodzenia górniczego z gruntu na fundament budynku pięciokondygnacyjnego w zakresie redukcji maksymalnych wypadkowych przyspieszeń drgań poziomych stwarza wiele trudności z uwagi na jego niejednoznaczność. W związku z tym wydaje się, że sieć neuronowa nauczona i przetestowana z użyciem wzorców utworzonych na podstawie danych doświadczalnych może być przydatna do prognozowania różnic w maksymalnych wartościach przyspieszeń jednocześnie występujących poziomych drgań wypadkowych gruntu i fundamentu budynku.

Zaproponowany sposób zwiększenia liczby wzorców uczących sieci neuronowej, uwzględniający przynależność wstrząsu górniczego do danej klasy wstrząsów pozwala na skuteczne zwiększenie dokładności obliczeń.

Literatura

- [1] Bishop C.M., *Pattern Recognition and Machine Learning*, Springer 2006
- [2] Dubiński J., Jaśkiewicz K., Lurka A., Mutke G., *Instrukcja prowadzenia powierzchniowych pomiarów sejsmometrycznych, interpretacji wyników oraz oceny i prognozowania drgań sejsmicznych wywołanych wstrząsami górniczymi na powierzchni LGOM w oparciu o skalę GSI-2004*, 2004
- [3] Homenda W., *Zastosowanie inteligentnych metod obliczeniowych do przetwarzania informacji muzycznych*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2007
- [4] Kuźniar K., *Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych*, Monografia 310, seria: Inżynieria Łódzka, Wydawnictwo Politechniki Krakowskiej, Kraków 2004
- [5] Kuźniar K., Maciąg E., *Zastosowanie SSN w wyznaczaniu wpływu parametrów wstrząsów górniczych na interakcję dynamiczną grunt-budynek*, Zeszyty Naukowe Politechniki Białostockiej, Budownictwo, z. 28, tom 2, Białystok 2006, s. 187–196
- [6] Kuźniar K., Maciąg E., Tataro T., *Acceleration response spectra from mining tremors*, First European Conference on Earthquake Engineering and Seismology (ECEES), Geneva 2006, Switzerland, Abstract Book (full paper on CD), 2006, s. 466–467

[118]

Krystyna Kuźniar

- [7] Maciąg E., *Ocena szkodliwości wstrząsów górniczych dla budynków na podstawie drgań ich fundamentów czy gruntu?*, Inżynieria i Budownictwo, 12/2005
- [8] Marciniak A., Korbicz J., Kuś J., *Wstępne przetwarzanie danych*, [w:] W. Duch, J. Korbicz, L. Rutkowski, R. Tadeusiewicz (red.), *Sieci neuronowe*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000
- [9] Masters T., *Sieci neuronowe w praktyce. Programowanie w języku C++*, Wydawnictwa Naukowo-Techniczne, Warszawa 1996
- [10] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006
- [11] Yan L., Fraser M., Elgamal A., Fountain T., Oliver K., *Neural Networks and Principal Component Analysis for Strain-Based Vehicle Classification*, Journal of Computing in Civil Engineering ASCE, 2008, vol. 22, no 2, s. 123–132
- [12] Zell A. (ed.), *SNNS – Stuttgart Neural Network Simulator, User's Manual, Version 4.2*, Stuttgart 1998

Patterns classification influence on the accuracy of the neural prediction of mine-induced ground vibrations transmission to building foundation

Abstract

The paper deals with the prediction of the soil-structure interaction in the case of transmission of ground vibrations from mining tremors to medium-height building foundations. Neural networks were proposed for the prediction of mine-induced ground vibrations transmission to building foundation. The information about mining tremors classification was taken into account in the neural network input vector. The procedure of neural network training patterns reproduction was also proposed in order to obtain better results of neural network approximation.

Keywords: neural networks, classification, mining tremors

Krystyna Kuźniar
Uniwersytet Pedagogiczny w Krakowie
Instytut Techniki
ul. Podchorążych 2
30-084 Kraków