

Krystyna Kuźniar

Zmienne lingwistyczne w neuronowej analizie wybranych problemów drgań budynków podlegających wstrząsom górniczym

Wiele istniejących budynków znajduje się w bliskim sąsiedztwie eksploatowanych kamieniołomów lub w strefie wstrząsów górniczych, a więc na obszarach objętych wpływami dynamicznymi. Kopalnie odkrywkowe z urobkiem kamienia prowadzonym metodą odstrzałów materiału wybuchowego szczególnie często występują w Polsce południowej. Z kolei spośród wielu regionów górniczych w Polsce, do najbardziej aktywnych sejsmicznie należy Legnicko-Głogowski Okręg Miedziowy (LGOM). Eksploatacja odbywa się w nim w dużej części pod terenami gęsto zaludnionymi, w tym i pod miastami. Najsilniejsze wstrząsy powodują uszkodzenia budynków i wywołują duży niepokój mieszkańców.

Do bardzo ważnych problemów w analizie dynamicznej budynków zaliczyć trzeba określenie właściwości dynamicznych obiektu (przede wszystkim okresów drgań własnych) oraz analizę interakcji dynamicznej układu podłoże–budynek.

Zagadnienia te rozważano z użyciem sztucznych sieci neuronowych (SSN), które stanowią nowe, obiecujące narzędzie do rozwiązywania problemów dynamiki budowli. Sieci neuronowe mają bowiem właściwości pożądane w wielu zastosowaniach praktycznych: stanowią uniwersalny układ aproksymacyjny odwzorowujący wielowymiarowe zbiory danych, mają zdolności uczenia się i adaptacji, zdolność uogólniania nabytej wiedzy stanowiąc pod tym względem system sztucznej inteligencji. Podstawą działania sieci są algorytmy uczące, umożliwiające zaprojektowanie odpowiedniej struktury sieci i dobór parametrów tej struktury dopasowanych do rozwiązywanego problemu.

Dane uczące i testujące sieci pochodzą z wieloletnich badań doświadczalnych przeprowadzonych na obiektach rzeczywistych, w skali naturalnej. Niektóre z tych parametrów określane są w sposób przybliżony. Do takich wielkości należą na przykład: współczynnik sprężystego równomiernego pionowego ugięcia podłoża, odległość epicentralna czy energia wstrząsu górniczego. Można więc uznać, że wiedza

o nich jest niepełna lub niepewna. Uzasadnione jest więc użycie do ich opisu terminów lingwistycznych, które stanowią pojęcia nieostre, rozmyte (fuzzy).


Wyniki badań doświadczalnych

Przeprowadzone badania doświadczalne obejmują dwie grupy pomiarów: pomiary dynamiczne rzeczywistych budynków oraz pomiary drgań powierzchniowych wzbudzanych przez wstrząsy typu górniczego.

Badania budynków prowadzono w skali naturalnej, wielokrotnie w okresie wielu lat [1, 2, 5]. Źródłem ich drgań były przede wszystkim odstrzały materiału wybuchowego w pobliskich kamieniołomach i wstrząsy górnicze, ale również: wiatr i mikrosejsmy, uderzenia łyżki koparki o grunt, uderzenie spadającego ciężaru o grunt w pobliżu budynku, kołysanie się ludzi na górnej kondygnacji budynków. Z prowadzonych badań dynamicznych budynków należących do klasy ścianowych budynków prefabrykowanych o średniej wysokości (5-kondygnacyjnych), otrzymano między innymi wiele danych dotyczących ich okresów drgań własnych (tak w kierunku osi poprzecznej, jak i podłużnej). Wykorzystując różne źródła drgań parasejsmicznych badanych budynków i niezależnie od stosowanej metody obróbki zarejestrowanych przebiegów drgań (krzywe rozkładu okresów drgań; spektra Fouriera; przemieszczeniowe, prędkościowe i przyspieszeniowe spektra odpowiedzi; analiza widmowa; FFT) otrzymywano takie same wartości okresów drgań własnych. Analizując te wartości stwierdzono, że w kierunku poprzecznym mieszczą się one w przedziale 0.155–0.294 s, a w kierunku podłużnym w przedziale 0.169–0.294 s [5]. Tak więc rozrzut tych wartości jest duży zarówno w kierunku poprzecznym, jak i podłużnym. Badane budynki są o tej samej lub niewiele się różniące wysokości – wszystkie mają pięć kondygnacji, jednak wartości okresów drgań własnych budynków, wykonanych nawet w tej samej technologii, różnią się znacznie. Istotny wpływ na wartości podstawowych okresów drgań własnych tych budynków mają: podłoże gruntowe, na którym są posadowione oraz wymiar budynku w kierunku równoległym do kierunku drgań [7, 8].

Badania przeprowadzone w skali naturalnej miały również na celu eksperymentalną analizę przekazywania się drgań z podłoża na budynek. Przekazywanie się drgań od wstrząsów górniczych na budynek analizowano w odniesieniu do wysokiego (12-kondygnacyjnego) wielokopłtowego budynku mieszkalnego. Źródłem drgań były wstrząsy górnicze w LGOM. Do pomiarów przyspieszeń drgań zarówno gruntu, jak i budynku stosowano aparaturę „czuwającą”. Czujniki pomiarowe na gruncie umieszczone są w odległości 6 m od budynku. Odległość taka pozwala na zminimalizowanie oddziaływania drgań budynku na drgania gruntu w miejscu ich pomiaru. Czujniki w budynku ustawione są na fundamentach. Główną uwagę skupiono na dwóch składowych poziomych drgań: x i y , równoległych odpowiednio do osi poprzecznej i podłużnej budynku. Analizowano przebiegi drgań zarejestrowane równocześnie

na gruncie i w budynku od wielu wstrząsów górniczych. Zarejestrowane drgania były wynikiem wstrząsów o różnych energiach (En) i różnych odległościach epicentralnych (r_e). Na rys. 1 pokazano przykładowy przebieg przyspieszeń drgań jednocześnie zarejestrowany na gruncie i w dolnej części rozważanego budynku.



Rys. 1. Przebiegi przyspieszeń drgań od wstrząsu górniczego: 30.07.2002, $En = 1.3E8J$, $r_e = 650$ m, kierunek x

Oceny przekazywania się drgań z gruntu na fundament dokonano poprzez porównanie maksymalnych wartości (amplitud) jednocześnie zarejestrowanych przyspieszeń drgań dolnej części budynku (a_{fmax}) i gruntu obok budynku (a_{gmax}). W tym celu wyliczono stosunek: $r = a_{fmax} / a_{gmax}$ [6]. Maksymalne amplitudy na gruncie i na fundamencie nie zawsze pojawiają się w tym samym czasie, a ocena przekazywania się drgań poprzez amplitudy jest pewnym uproszczeniem, gdyż nie uwzględnia istotnego parametru drgań jakim jest częstotliwość.


Na rys. 2 pokazano zależność ułamka r od maksymalnej amplitudy drgań gruntu w przypadku wszystkich badanych wstrząsów górniczych. Z kolei w wierszu 1 tabeli 1 zamieszczono średnie r wyliczone w kolejnych przedziałach wartości amplitud drgań gruntu. Widać, że chociaż na podstawie rys. 2 trudno jest określić jednoznacznie zależność r od a_{gmax} , to z wyników zamieszczonych w tabeli 1 (wiersz 1) widać, że średnia wartość r maleje wraz ze zwiększaniem się a_{gmax} . Zatem średnio biorąc, redukcja drgań fundamentu jest tym większa, im większa jest amplituda przekazywanych na niego drgań gruntu.

Z kolei na rys. 3 pokazano zależność r od energii wstrząsu górniczego En również we wszystkich badanych przypadkach, a w wierszu 2 tabeli 1 zamieszczono średnie wartości r wyliczone w przedziale energii wstrząsów do $5E7J$ oraz w przedziale energii większych od $5E7J$. Widać, że średnio biorąc redukcja drgań przy przekazywaniu się ich z podłoża na budynek jest mniejsza w przypadku większych energii. Natomiast określenie „precyzyjnego trendu” jest niemożliwe.


Lp.	Parametry wstrząsów i drgań		Wartość średnia $r = a_{fmax}/a_{gmax}$	
1	$a_{gmax} [m/s^2]$	≤ 0.300	0.55	
		0.301–0.600	0.51	
		0.601–0.900	0.41	
		> 0.900	0.34	
2	$En[J]$	$\leq 5E7$	0.50	
		$>5E7$	0.62	
3	$r_e[m]$	$r_e \leq 800$	$x \ i \ y$	0.36
			x	0.28
			y	0.44
		$800 < r_e \leq 1500$	$x \ i \ y$	0.49
			x	0.46
			y	0.52
		$r_e > 1500$	$x \ i \ y$	0.64
			x	0.74
			y	0.55

Tabela 1. Zależność wartości średniej $r = a_{fmax}/a_{gmax}$ od parametrów wstrząsów i drgań

Badano również zależność wartości ułamka r od odległości epicentralnej wstrząsu r_e . Rys. 4 przedstawia rezultaty tych analiz w odniesieniu do wszystkich dokonanych pomiarów, a więc dotyczących obu kierunków: równoległego do osi poprzecznej x oraz osi podłużnej y budynku. Można zauważyć, że generalnie „chmura punktów” przesuwana się w stronę większych wartości r wraz ze wzrastającą odległością epicentralną. Potwierdzają to też wartości średnie r obliczone w trzech przedziałach odległości epicentralnych zamieszczone w wierszu 3 tabeli 1. Obok wartości średnich r wyliczonych dla obu kierunków, w tabeli podano też te wartości z „rozbiciem” na kierunki. W kierunku osi poprzecznej x , w przypadku małych odległości epicentralnych, drgania gruntu „słabo” przekazują się na budynki, natomiast przy większych odległościach epicentralnych – „łatwiej”. W kierunku osi podłużnej y nie dostrzega się wyraźnej różnicy w przekazywaniu się drgań z gruntu na fundament budynku w zależności od odległości epicentralnej.




Rys. 2. Zależność $r = a_{fmmax}/a_{gmax}$ od maksymalnej wartości przyspieszenia drgań gruntu a_{gmax}



Rys. 3. Zależność $r = a_{fmmax}/a_{gmax}$ od energii wstrząsu górniczego En

Z analizy wyników badań doświadczalnych widać, że ocena przekazywania się drgań od wstrząsów górniczych z gruntu na budynek stwarza wiele trudności z uwagi na niejednoznaczny sposób tego przekazywania się drgań [5]. Charakter drgań fundamentu budynku może być odmienny dla różnych wstrząsów górniczych i różnych odległości epicentralnych i różnić się istotnie od drgań gruntu obok budynku. Można dopatrywać się wpływu energii wstrząsu, odległości epicentralnej, wielkości maksymalnej amplitudy drgań gruntu i kierunku drgań (równoległego do osi poprzecznej lub podłużnej budynku) na wielkość tej redukcji. Jednak wyznaczenie dokładnej zależności nie jest możliwe.



Rys. 4. Zależność $r = a_{fmax}/a_{gmax}$ od odległości epicentralnej r_e (kierunek x i y)

Zastosowanie zmiennych lingwistycznych w neuronowej identyfikacji podstawowych okresów drgań własnych budynków i w analizie przekazywania się drgań od wstrząsów górniczych

Zbiory rozmyte

Tradycyjny sposób reprezentowania elementu zbioru bazuje na zmiennych typu numerycznego. Inny typ informacji oparty jest na teorii zbiorów rozmytych. Pojęcie zbiorów rozmytych (ang. *fuzzy sets*) zostało wprowadzone przez L. Zadeha [10]. W odróżnieniu od zbiorów o nierozmytej przynależności, w zbiorach rozmytych nie ma ostrej granicy między elementami, które do danego zbioru należą, a tymi, które należą do innych zbiorów [3, 4]. W teorii zbiorów rozmytych obok zmiennych typu numerycznego istnieją zmienne lingwistyczne i wartości im przypisane. Określenia lingwistyczne typu: „mały”, „duży”, „bardzo mały”, „bardzo duży”, wobec niezbyt precyzyjnie zdefiniowanych różnic między nimi, stanowią pojęcia nieostre, rozmyte (fuzzy).

I tak tradycyjny („ostry”) sposób reprezentowania elementu x zbioru A odbywa się za pośrednictwem funkcji charakterystycznej $\mu_A(x)$ równej jeden, gdy element ten należy do zbioru A , lub zero, gdy do tego zbioru nie należy. W systemach rozmytych element może należeć do każdego zbioru częściowo. Stopień przynależności do zbioru A , stanowiący uogólnienie funkcji charakterystycznej, nazywa się funkcją przynależności $\mu_A(x)$, przy czym $\mu_A(x) \in [0, 1]$. Zatem wartości funkcji przynależności są liczbami rzeczywistymi z przedziału $[0, 1]$, gdzie 0 oznacza brak przynależności do

zbioru, a 1 – pełną przynależność. Konkretna wartość funkcji przynależności nosi nazwę stopnia przynależności.

Systemy rozmyte mogą być charakteryzowane dowolnymi kształtami funkcji przynależności $\mu_A(x)$. Ze względów praktycznych bardzo często używana jest symetryczna funkcja trójkątna [4]:

$$\mu_A(x; c, d) = \begin{cases} 1 - \frac{|x - c|}{d} & \text{dla } x \in |c-d, c+d| \\ 0 & \text{poza tym przedziałem} \end{cases} \quad (1)$$

W niniejszej pracy pokazano próbę wykorzystania zmiennych typu lingwistycznego w neuronowej identyfikacji podstawowych okresów drgań własnych budynków i do oceny przekazywania się drgań od wstrząsów gómiczych. W analizie obu tych problemów zastosowano sieci neuronowe typu wstecznej propagacji błędu (WPB) z algorytmem uczenia Resilient back-propagation (Rprop) i sigmoidalną funkcją aktywacji. Obliczenia przeprowadzono przy użyciu symulatora sztucznych sieci neuronowych SNNS [11].

Dokładność otrzymywanych wyników oceniana była na podstawie błędów uczenia i testowania (Mean Square Error, MSE), standardowego błędu resztkowego ($st\varepsilon$) oraz błędów względnych ep i eV_{avr} :

$$MSE(V) = \frac{1}{V} \sum_{p=1}^V (y_p - \hat{y}_p)^2, \quad st\varepsilon = \sqrt{\frac{1}{P} \sum_{p=1}^P (y_p - \hat{y}_p)^2} \quad (2)$$

$$ep = \left| 1 - \hat{y}_p / y_p \right| \cdot 100\%, \quad eV_{avr} = \frac{1}{V} \sum_{p=1}^V ep.$$

gdzie: $V = L, T, P$ – odpowiednio liczba: wzorców uczących (L), wzorców testujących (T), wszystkich ($P = L + T$); y_p and \hat{y}_p – wartość oczekiwana i wyliczona.

Do oceny uzyskanych rezultatów obliczeń wykorzystano również współczynnik korelacji liniowej dla wszystkich wzorców – $r(P)$ oraz tzw. procent sukcesu (Success Ratio) $SR[\%]$ w funkcji błędu względnego $ep[\%]$. SR określa jaki procent wzorców uzyskano z predykcji neuronowej z błędem nie większym niż ep .

Neuronowa identyfikacja podstawowych okresów drgań własnych analizowanych budynków

Wyniki badań doświadczalnych na obiektach rzeczywistych wskazują, że podstawowe okresy drgań własnych prefabrykowanych budynków ścianowych o średniej wysokości w istotny sposób zależą od podłoża gruntowego, na którym posadowiony jest budynek, oraz od wymiaru budynku w kierunku równoległym do kierunku drgań. Stąd sieć neuronowa zaproponowana do identyfikacji podstawowych okresów drgań

analizowanych budynków zawiera w wektorze wejścia dwa parametry: C_2 – współczynnik sprężystego równomiernego pionowego ugięcia podłoża [MPa/m] i b – wymiar budynku w kierunku drgań [m]. Podstawowe okresy drgań własnych T_1 otrzymane w wyniku badań doświadczalnych na obiektach rzeczywistych przyjęto jako wartości oczekiwane na wyjściu z sieci.

Zgodnie z powyższym, sieć ma następujący wektor wejścia i skalarnie wyjście [5]:

$$x_{(2 \times 1)} = \{C_2, b\}, \quad y_{(1 \times 1)} = T_1. \quad (3)$$


Parametry dla poszczególnych rodzajów gruntów określano na podstawie dokumentacji geologicznych budynków według normy [9] jako wartości średnie z przedziału dla danego gruntu. W przypadku, gdy w skład podłoża wchodziły różne typy gruntów (np. glina piaszczysta i wietrzelnina wapienna), przyjmowano wartości średnie z ich parametrów. Biorąc pod uwagę współczynnik podłoża C_2 , norma [9] grupuje grunty w czterech zasadniczych kategoriach: I – bardzo małej sztywności, II – małej sztywności, III – średniej sztywności, IV – dużej sztywności. Jest to więc rodzaj informacji lingwistycznej, operującej pojęciami opisowymi, nie związanymi ściśle z wartościami numerycznymi. Użycie terminów lingwistycznych ma tu szczególne uzasadnienie. Chodzi bowiem o wiedzę niepełną lub niepewną, co ma miejsce w przypadku parametrów podłoża.

Zaproponowano więc wprowadzenie w wektorze wejścia sieci zmiennej lingwistycznej C_{2l} w miejsce „ostrej” wartości C_2 :

$$C_{2l} = \{\mu_{CS}, \mu_{CM}, \mu_{CL}\} \quad (4)$$

gdzie: $\mu_{CS}, \mu_{CM}, \mu_{CL}$ – wartości funkcji przynależności odpowiednio do podłoża o małej (small), średniej (medium) i dużej (large) sztywności.

Przyjęto trójkątne funkcje przynależności zgodnie z rys. 5.



Rys. 5. Trójkątne funkcje przynależności dla parametru C_2


Po wprowadzeniu do sieci zmiennej lingwistycznej C_{2l} zamiast wartości „ostrej” C_2 , wektor wejścia x będzie miał cztery elementy:

$$x_{(4 \times 1)} = \{\mu_{CS}, \mu_{CMP}, \mu_{CL}, b\}. \quad (5)$$

Zaproponowano strukturę (c) 2-3-1 w przypadku sieci z „ostrą” wartością C_z i (l) 4-3-1 dla sieci ze zmienną lingwistyczną C_z . Do uczenia i testowania obu sieci użyto tego samego zbioru wzorców $P = 31$ ($L = 26$, $T = 5$) otrzymanych z badań doświadczalnych na obiektach rzeczywistych. Tabela 2 zawiera błędy uczenia i testowania tych sieci.

Sieć WPB	$MSE(V)$		eV_{avr}			ste	$r(P)$
	L	T	L	T	P		
(c) 2-3-1	0.00025	0.00120	6.5	12.5	7.5	0.020	0.873
(l) 4-3-1	0.00014	0.00098	4.9	10.3	5.8	0.017	0.916

Tabela 2. Błędy uczenia i testowania sieci (c) 2-3-1 i (l) 4-3-1



Rys. 6. Procent sukcesu SR neuronowej predykcji okresów drgań własnych budynków

Rys. 6 przedstawia procent sukcesu SR [%] w funkcji błędem względnym ep [%] dla wszystkich wyliczonych podstawowych okresów drgań własnych budynków. Przykładowo z wykresów widać, że procent okresów drgań uzyskanych z obliczeń neuronowych z błędem $ep \leq 5\%$ wynosi $SR = 58\%$ dla sieci (l) 4-3-1 i $SR = 35\%$ dla sieci (c) 2-3-1.

Na podstawie uzyskanych wyników można stwierdzić, że wprowadzenie zmiennej lingwistycznej do wektora wejścia w miejsce „ostrej” wartości C_z , prowadzi do nieco większej dokładności uzyskanych obliczeniowo podstawowych okresów drgań własnych analizowanych budynków.

Ocena przekazywania się drgań od wstrząsów górniczych na budynek

Wykorzystując wyniki badań eksperymentalnych, podjęto próbę zastosowania techniki neuronowej do prognozowania sposobu przekazywania się drgań od wstrząsów górniczych z gruntu na fundament wysokiego budynku w zależności od różnych parametrów wstrząsów i drgań.

Zaproponowano cztery wersje wektora wejścia:

$$\mathbf{x}_{(4 \times 1)} = \{a_{gmax}, En, r_e, k\} \quad (6a)$$

$$\mathbf{x}_{(3 \times 1)} = \{a_{gmax}, En, r_e\} \quad (6b)$$

$$\mathbf{x}_{(2 \times 1)} = \{a_{gmax}, En\} \quad (6c)$$

$$\mathbf{x}_{(4 \times 1)} = \{a_{gmax}, r_e\} \quad (6d)$$

gdzie: a_{gmax} – maksymalna wartość (amplituda) drgań gruntu; En – energia wstrząsu górniczego; r_e – odległość epicentralna; k – parametr opisujący kierunek drgań, przyjęto: $k = 0.4$ dla kierunku równoległego do osi poprzecznej budynku x , $k = 0.7$ dla kierunku równoległego do osi podłużnej budynku y .

Odpowiednia wartość ułamka $r = a_{fmax} / a_{gmax}$ oczekiwana była w wektorze wyjścia sieci neuronowej:

$$\mathbf{y}_{(1 \times 1)} = \{r\}. \quad (7)$$

Wykorzystując dane doświadczalne, do analizy neuronowej wzięto po 176 wzorców dla każdej kombinacji wektor wejścia – wektor wyjścia. We wszystkich przypadkach połowę z tych wzorców przeznaczano do uczenia sieci, a drugą połowę do testowania. Przeprowadzono wiele obliczeń, przyjmując różną liczbę neuronów w warstwie ukrytej sieci w celu uzyskania najlepszej prognozy r dla każdego wariantu: wektor wejścia – wektor wyjścia. Błędy uczenia i testowania wybranych sieci zamieszczono w wierszach 1–4 tabeli 3.

Stwierdzono, że najdokładniej prognozować można stosunek amplitud r podając w wektorze wejścia informację najbogatszą, a więc w przypadku czteroelementowego wektora wejścia (6a). W sieciach o mniejszych wektorach wejścia (6b, 6c, 6d) średnie błędy względne uczenia są większe, co jest zrozumiałe z uwagi na skromniejszą informację, ale średnie błędy względne testowania są porównywalne z błędami uzyskiwanymi w przypadku sieci o czterech elementach w wektorach wejścia. Dla sieci nr 1 podano w tabeli 3 dodatkowo błędy względne odrębnie dla wzorców pogrupowanych według kierunku równoległego do osi poprzecznej budynku x i osi podłużnej y . Błędy względne w kierunku y są mniejsze niż w kierunku x . Szczególnie dotyczy to testowania. Tak więc kierunek y jest bardziej „przewidywalny” w analizie neuronowej jeśli chodzi o przekazywanie się drgań z podłoża na budynek, co jest zgodne z wynikami analizy pomiarów w skali naturalnej.


Parametry wejścia	Nr	Sieć	MSE(V)		eV_{AVT}			st ϵ	r(P)
			L	T	L	T	P		
a_{gmax}, En, r_e, k	1	4-5-1	0.00895	0.01900	18.1 17.0 (x) 19.1 (y)	33.8 46.3 (x) 21.8 (y)	25.9 31.5 (x) 20.5 (y)	0.118	0.677
a_{gmax}, En, r_e	2	3-4-1	0.01550	0.01592	23.7	31.9	27.8	0.125	0.603
a_{gmax}, En	3	2-3-1	0.01664	0.01700	27.5	33.3	30.4	0.129	0.566
a_{gmax}, r_e	4	2-3-1	0.01661	0.01675	25.9	32.6	29.3	0.129	0.570
$a_{max}, \{En(3)\}, \{r_{e1}\}, k$	5	8-6-1	0.01303	0.01622	22.5	32.5	27.5	0.121	0.639
$a_{max}, \{En(4)\}, \{r_{e1}\}, k$	6	9-7-1	0.00599	0.01870	13.3	29.1	21.2	0.111	0.725
$a_{max}, \{En(5)\}, \{r_{e1}\}, k$	7	10-7-1	0.00365	0.02131	11.2	34.3	22.7	0.112	0.717

Tabela 3. Błędy uczenia i testowania wybranych sieci neuronowych do prognozowania

$$r = a_{fmax} / a_{gmax}$$


W świetle otrzymanych wyników, do praktycznego stosowania zaproponowano sieć 4 – 5 – 1 (sieć nr 1 w tablicy 2). Użycie tej sieci daje błąd względny mniejszy od 30% w przypadku 73% wzorców, co widać na rys. 7. W związku z trudnościami, jakie występują w prognozowaniu różnic w jednocześnie trwających drganiach gruntu i fundamentu budynku wydaje się, że zaproponowana prosta sieć neuronowa może być bardzo przydatna do przewidywania redukcji maksymalnych wartości przyspieszeń drgań przy przekazywaniu ich z gruntu na wysoki budynek.

Energia wstrząsu górniczego $En[J]$ oraz odległość epicentralna $r_e[m]$ są wyznaczone przez sejsmologów na podstawie drgań rejestrowanych jednocześnie podczas wstrząsu w kilku stacjach sejsmicznych rozmieszczonych pod ziemią, w kopalniach. Stąd wartości En i r_e wyznaczone są doświadczalnie w sposób przybliżony. Można więc mówić o przedziałach małych, średnich i dużych energii wstrząsów, jak również przedziałach małych, średnich i dużych odległości epicentralnych. Jest to zatem wprowadzenie zmiennych lingwistycznych związanych z rozmytym charakterem wartości energii wstrząsu $\{En\}$ i odległości epicentralnej $\{r_{e1}\}$ w miejsce „ostrych” wartości En i r_e .



Rys. 7. Procent sukcesu SR neuronowej prognozy przekazywania się drgań z gruntu na fundament budynku

Na rys. 8 pokazano proponowane funkcje przynależności dla odległości epicentralnych.



Rys. 8. Trójkątne funkcje przynależności dla wartości odległości epicentralnych r_e

Zatem w miejsce „ostrej” wartości r_e wprowadzić można zmienną lingwistyczną $\{r_{el}\}$:

$$\{r_{el}\} = \{\mu_{rs}, \mu_{rm}, \mu_{rl}\} \quad (8)$$

gdzie: $\mu_{rs}, \mu_{rm}, \mu_{rl}$ – wartości funkcji przynależności odpowiednio do małych, średnich i dużych odległości epicentralnych.

W przypadku energii wstrząsu analizowano trzy warianty liczby funkcji przynależności. Na rys. 9 pokazano trzy (3), cztery (4) i pięć (5) takich funkcji.

Podobnie jak w przypadku odległości epicentralnych, w miejsce „ostrej” wartości En wprowadzono zmienną lingwistyczną $\{Enl(3)\}$, $\{Enl(4)\}$, $\{Enl(5)\}$:

$$\{Enl(3)\} = \{\mu_{ES}(3), \mu_{EM}(3), \mu_{EL}(3)\} \quad (9)$$

$$\{Enl(4)\} = \{\mu_{ES}(4), \mu_{EMS}(4), \mu_{EML}(4), \mu_{EL}(4)\} \quad (10)$$

$$\{Enl(5)\} = \{\mu_{ES}(5), \mu_{EMS}(5), \mu_{EM}(5), \mu_{EML}(5), \mu_{EL}(5)\} \quad (11)$$

gdzie: μ_{ES} , μ_{EMS} , μ_{EM} , μ_{EML} , μ_{EL} – wartości funkcji przynależności odpowiednio do małych, średniomałych, średnich, średniodużych i dużych energii wstrząsów zgodnie z funkcjami przynależności z rys. 9.

Następnie zmiennych lingwistycznych $\{r_e\}$ oraz $\{Enl(3)\}$, $\{Enl(4)\}$ albo $\{Enl(5)\}$ użyto zamiast wartości „ostrych”. I tak wektor wejścia x w wersji (6a) będzie miał teraz osiem, dziewięć albo dziesięć elementów:

$$x_{(4 \times 1)} = \{a_{gmax}, \{Enl(3)\}, \{r_e\}, k\} \quad (12)$$

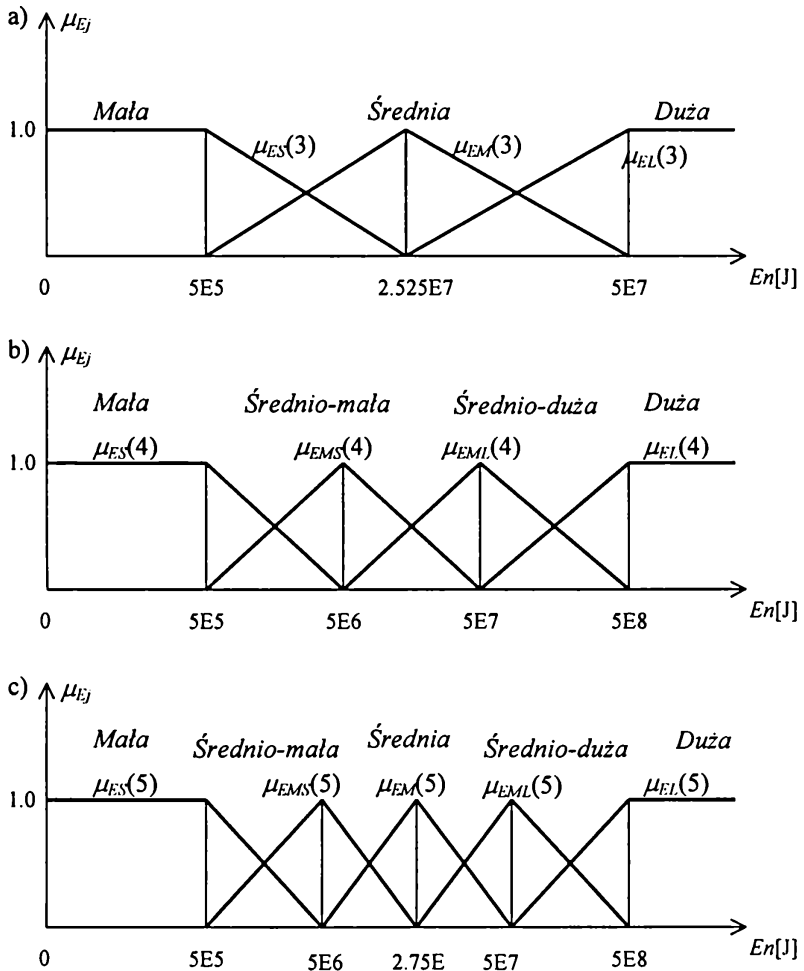
$$x_{(4 \times 1)} = \{a_{gmax}, \{Enl(4)\}, \{r_e\}, k\} \quad (13)$$

$$x_{(4 \times 1)} = \{a_{gmax}, \{Enl(5)\}, \{r_e\}, k\} \quad (14)$$

gdzie: $\{r_e\}$, $\{Enl(3)\}$, $\{Enl(4)\}$, $\{Enl(5)\}$ przyjęto zgodnie z zależnościami (8)–(11).

Odpowiednie sieci neuronowe o strukturze 8–6–1, 9–7–1, 10–7–1 i wektorach wejścia (12)–(14) uczono i testowano z użyciem tych samych wzorców, które wykorzystano w przypadku poprzedniej sieci 4–5–1 z „ostrymi” wartościami En , r_e w wektorze wejścia (6a). W wierszach 5–7 tabeli 3 zamieszczono błędy tych sieci, a na rys. 7 porównano ich procent sukcesu SR z odpowiednim wykresem, otrzymanym dla sieci z „ostrymi” wartościami w wektorze wejścia.

Na podstawie przeprowadzonych obliczeń stwierdzono, że dokładności sieci nr 7 i nr 6 są zbliżone. Wprowadzenie zmiennych lingwistycznych (8) oraz (10) i (11) prowadzi do lepszej dokładności prognozowania neuronowego niż w przypadku sieci z „ostrymi” wartościami En i r_e . Trzy funkcje przynależności nie są wystarczające do opisanie energii wstrząsu, co można tłumaczyć bardzo szerokim przedziałem wartości energii otrzymanych z pomiarów.



Rys. 9. Trójkątne funkcje przynależności dla wartości energii wstrząsu E_n :
 a) 3 funkcje przynależności; b) 4 funkcje przynależności; c) 5 funkcji przynależności

Wnioski

Zastosowanie sieci neuronowych umożliwia wyznaczanie podstawowych okresów drgań własnych budynków oraz prognozę redukcji maksymalnych wartości przyspieszeń drgań przy przekazywaniu ich z gruntu na budynek z dokładnością

zadowalającą w praktyce. Zastąpienie wartości „ostrzych” w wektorze wejścia sieci neuronowej typu wstecznej propagacji błędu odpowiednimi zmiennymi lingwistycznymi, zarówno w przypadku neuronowej identyfikacji podstawowych okresów drgań własnych analizowanych budynków, jak i oceny przekazywania się drgań od wstrząsów górniczych na budynek, prowadzi do dokładniejszych wyników obliczeń. Efekt ten może być też tłumaczony zwiększeniem liczby parametrów sieci bez zwiększania liczby zmiennych fizycznych.

Bibliografia

- [1] Ciesielski R., Kuźniar K., Maciąg E., Tataro T., *Empirical formulae for fundamental natural periods of buildings with load bearing walls*, Archives of Civil Engineering, **38**, 4, 1992, 291–299
- [2] Ciesielski R., Kuźniar K., Maciąg E., Tataro T., *Damping of vibration in precast buildings with bearing concrete walls*, Archives of Civil Engineering, **40**, 3, 1995, 329–341
- [3] Haykin S., *Neural networks – a comprehensive foundation*, Prentice Hall Intern. Inc., Upper Saddle River, NY, 2nd edition, 1999
- [4] Jang J.-S., Sun Ch.-T., Mizutani E., *Neuro-fuzzy and soft computing. A computational approach to learning and machine intelligence*, Prentice Hall Intern. Inc., Upper Saddle River, NY, 1997
- [5] Kuźniar K., *Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych*, Monografia 310, seria: Inżynieria Lądowa, Wydawnictwo Politechniki Krakowskiej, Kraków 2004
- [6] Kuźniar K., Maciąg E., *Ocena przekazywania się drgań od wstrząsów górniczych na wysoki budynek z wykorzystaniem SSN*, Zeszyty Naukowe Politechniki Rzeszowskiej, **222**, Mechanika z. 65, 2005, 241–248
- [7] Maciąg E., *Experimental evaluation of changes of dynamic properties of buildings on different grounds*, Earthquake Engineering and Structural Dynamics, **14**, 1986, 925–932
- [8] Maciąg E., Kuźniar K., *The influence of ground flexibility on the fundamental frequencies of natural vibrations of medium-height buildings with load bearing concrete walls*, Archives of Civil Engineering, **39**, 2, 1993, 139–151
- [9] PN-80/B-03040, *Fundamenty i konstrukcje wsporcze pod maszyny. Obliczenia i projektowanie*
- [10] Zadeh L., *Fuzzy sets*, Information and Control, **8**, 3, 1965, 338–353
- [11] Zell A., editor, *SNNS – Stuttgart Neural Network Simulator, User’s Manual, Version 4.2*, Univ. Stuttgart, 1998

Linguistic variables in neural analysis of selected mine-induced building vibrations problems

Abstract

The paper deals with an application of neural networks for identification of fundamental periods of building vibrations and for evaluation of soil-structure interaction in the case of ground vibrations transmission from mining tremors to building basement. Some parameters are estimated as approximate values found experimentally, therefore the linguistic variables associated with the fuzzy character of the parameters are introduced in the neural network analysis.

Key words: mine induced tremors, neural network, linguistic variable