

*Krystyna Kuźniar***Zastosowanie systemu neuronowego wnioskowania rozmytego w wybranych zagadnieniach drgań budynków**

W ostatnich latach daje się zauważyć intensywny rozwój systemów przetwarzania informacji, które nawiązują do działania organizmów żywych. Wśród tych metod na uwagę zasługują sztuczne sieci neuronowe (SSN). Symulują one w uproszczony sposób działanie biologicznego systemu nerwowego. SSN znajdują zastosowanie szczególnie do modelowania zagadnień o nieznanych, nieliniowych relacjach „wejście – wyjście”, gdy informacje są niepełne lub rozmyte. Zasadnicza różnica między działaniem sieci neuronowych a obliczeniami konwencjonalnymi tkwi w odmiennym sposobie przetwarzania i gromadzenia informacji. W przeciwieństwie do „szeregowego” działania konwencjonalnego komputera, w sieciach neuronowych przetwarzanie informacji odbywa się w sposób równoległy, co pozwala sieciom efektywniej wykonywać złożone zadania obliczeniowe mimo użycia dość powolnych elementów, jakimi są neurony.

Tradycyjne sieci neuronowe zarówno w procesie uczenia, jak i testowania wykorzystują tylko informacje numeryczne, wiążące w sposób ścisły i jednoznaczny dane wejściowe z danymi wyjściowymi. Inny typ informacji oparty jest na teorii „zbiorów rozmytych”. Pojęcie zbiorów rozmytych (*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 [4, 5]. Systemy rozmyte mają postać równoległej struktury wielowarstwowej, przypominającą strukturę klasycznych sieci neuronowych. Są one nazywane sieciami neuronowymi rozmytymi.

W niniejszej pracy pokazano wyniki zastosowania systemu neuronowego wnioskowania rozmytego ANFIS (*Adaptive Neuro-Fuzzy Inference System*) w rozwiązywaniu bardzo ważnych problemów w analizie dynamicznej budynków, do których trzeba zaliczyć analizę interakcji dynamicznej układu podłoże–budynek oraz określenie właściwości dynamicznych obiektu (przede wszystkim okresów drgań własnych). Dane uczące i testujące sieci pochodzą z wieloletnich badań doświadczalnych przeprowadzonych na obiektach rzeczywistych, w skali naturalnej.

System neuronowego wnioskowania rozmytego ANFIS (Adaptive Neuro-Fuzzy Inference System)

W zbiorach rozmytych nie ma ostrej granicy między elementami, które do danego zbioru należą, a tymi, które należą do innych zbiorów [4, 5], co ma miejsce w zbiorach o nierozmytej („ostrej”) przynależności.

„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 $\mu_A(x) \in [0,1]$. Wartości funkcji przynależności są zatem liczbami rzeczywistymi z przedziału $[0,1]$, gdzie 0 oznacza brak przynależności do zbioru, a 1 – pełną przynależność. Wartość funkcji przynależności nosi nazwę stopnia przynależności.

Na zbiorach rozmytych, jako uogólnieniu zbiorów zwykłych, można definiować operacje matematyczne, które są uogólnieniem operacji obowiązujących dla zbiorów nierozmytych [9], np.:

a) suma logiczna zbiorów $A \cup B$

$$\mu_{A \cup B}(x) = \mu_A(x) \cup \mu_B(x) = \text{Max}[A(x), B(x)] \quad (1)$$

gdzie znak \cup oznacza operator Max;

b) iloczyn logiczny zbiorów $A \cap B$

$$\mu_{A \cap B}(x) = \mu_A(x) \cap \mu_B(x) = \text{Min}[A(x), B(x)] \quad (2)$$

gdzie znak \cap oznacza operator Min;

c) iloczyn algebraiczny dwóch zbiorów $A \cdot B$

$$\mu_{A \cdot B}(x) = \mu_A(x) \cdot \mu_B(x). \quad (3)$$

Cechą charakterystyczną zbiorów rozmytych, decydującą o ich znaczeniu praktycznym, jest wnioskowanie. Podstawowa reguła wnioskowania typu: jeżeli – to (*if – then rule*) nazywana jest też implikacją rozmytą. Przyjmuje ona następującą postać:

$$\text{jeżeli } (x \text{ jest } A), \text{ to } (y \text{ jest } B) \quad (4)$$

gdzie A i B są wartościami lingwistycznymi, zdefiniowanymi w sposób rozmyty przez odpowiednie funkcje przynależności zmiennych x i y . Część „ x jest A ” jest przesłanką

(poprzednikiem), a „ y jest B ” – konkluzją (następnikiem). Implikację (4) można zapisać w postaci skróconej: $A \rightarrow B$.

Rozumowanie rozmyte jest procedurą, która pozwala określić konkluzję wynikającą ze zbioru reguł: jeżeli – to. Taki zbiór $R^{(k)}$, $k = 1, \dots, K$ reguł rozmytych przy N zmiennych x_i może przyjąć postać:

$$R^{(k)}: \text{jeżeli } (x_1 \text{ jest } A_1^k \text{ I } x_2 \text{ jest } A_2^k \text{ I } \dots \text{ I } x_N \text{ jest } A_N^k), \text{ to } (y \text{ jest } B) \quad (5)$$

gdzie: $\mathbf{x} = \{x_1, x_2, \dots, x_N\}$, N – wymiarowy wektor wejściowy, y – skalarowe wyjście.

Wektor wejściowy \mathbf{x} stanowi argument przesłanki, w której $A_1^k, A_2^k, \dots, A_N^k$ oraz B oznaczają wartości odpowiedniego współczynnika przynależności $\mu_A(x_i)$ oraz $\mu_B(y)$. Każda zmienna x_i oraz y ma oddzielną funkcję przynależności. Wypadkowa wartość funkcji przynależności $\mu_A(\mathbf{x})$, dotycząca przesłanki implikacji, musi być następnie zinterpretowana zgodnie z operacjami rozmytymi.

Możliwa jest interpretacja w postaci iloczynu logicznego zbiorów, albo w postaci iloczynu algebraicznego:

a) interpretacja w postaci iloczynu logicznego

$$\mu_A(\mathbf{x}) = \min_{i=1, \dots, N} \{\mu_A(x_i)\} \quad (6)$$

b) interpretacja w postaci iloczynu algebraicznego

$$\mu_A(\mathbf{x}) = \prod_{i=1}^N \mu_A(x_i). \quad (7)$$

Przypisanie jednej wartości funkcji przynależności opisującej wielowymiarową przesłankę, nazywana jest agregacją poprzednika. Każdej implikacji $A \rightarrow B$ przypisać można jedną wartość funkcji przynależności $\mu_{A \rightarrow B}(\mathbf{x}, y)$. Najbardziej popularne interpretacje tej funkcji przyjmują postać iloczynu logicznego lub algebraicznego [9]:

a) postać iloczynu logicznego

$$\mu_{A \rightarrow B} = \min\{\mu_A(\mathbf{x}), \mu_B(y)\} \quad (8)$$

b) postać iloczynu algebraicznego

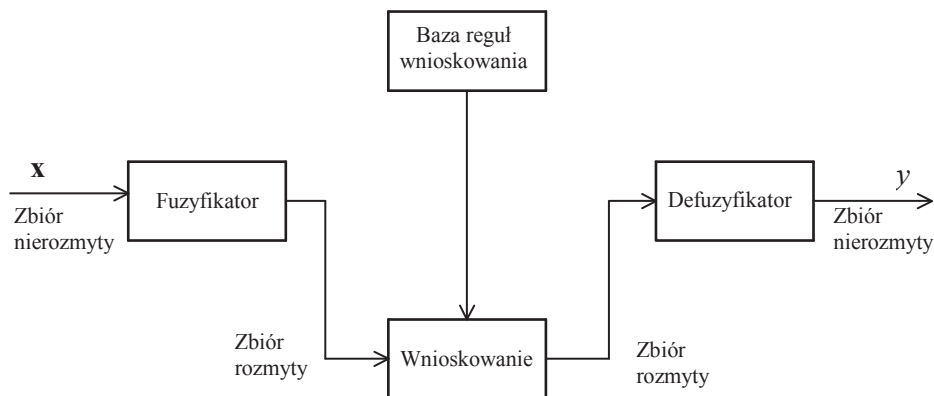
$$\mu_{A \rightarrow B} = \mu_A(\mathbf{x}) \cdot \mu_B(y). \quad (9)$$

Przypisanie jednej wartości funkcji przynależności całej implikacji nazywa się procedurą agregacji na poziomie implikacji.

Elementy teorii zbiorów rozmytych, reguły implikacji i rozumowania rozmytego tworzą system wnioskowania rozmytego. Taki system składa się ze zbioru reguł rozmytych, bazy danych opisujących postacie funkcji przynależności oraz mechanizm wnioskowania i agregacji.

W zastosowaniach praktycznych, w szczególności technicznych, wielkościami wejściowymi i wyjściowymi są zwykle wartości „ostre” (np. otrzymane z pomiarów), przyporządkowujące w sposób nierozmyty wielkościami wejściowym wielkości wyjściowe. Aby możliwe było współdziałanie dwóch rodzajów zbiorów: nierozmytych i rozmytych, wprowadza się system rozmyty z tak zwanym fuzyfikatorem (układem rozmywania) na wejściu i defuzyfikatorem (układem wyostrzania) na wyjściu [5, 9]. Schemat takiego systemu przedstawiono na ryc. 1.

Układ fuzyfikatora przekształca nierozmyty zbiór danych wejściowych w zbiór rozmyty, zdefiniowany za pomocą wartości funkcji przynależności. Zadaniem defuzyfikatora jest działanie odwrotne, tzn. wyznaczenie „ostrej” wartości zmiennej wyjściowej na podstawie wielu wnioskowań rozmytych z członu wykonawczego układu rozmytego. Defuzyfikator dokonuje transformacji zbioru rozmytego w ściśle zdeterminowany punkt rozwiązania y . Zbiór rozmyty przedstawia zależność $\mu(y) = \mu_{A \rightarrow B}(y)$ jako funkcję zmiennej wyjściowej y . Przetworzenie tego zbioru w jedną wartość rozwiązania jest możliwe na wiele sposobów, np. według środka obszaru, według średniej z centrów, według średniej z maksimumów.



Ryc. 1. Schemat układu rozmytego z fuzyfikatorem i defuzyfikatorem

Systemy rozmyte mają postać równoległej struktury wielowarstwowej, przypominającą strukturę klasycznych sieci neuronowych. Są one nazywane sieciami neuronowymi rozmytymi.

System neuronowego wnioskowania rozmytego ANFIS [5] jest modyfikacją standardowego systemu wnioskowania rozmytego.

ANFIS zbudowany jest z wykorzystaniem następujących założeń:

1) odwzorowanie „ostrego” wektora \mathbf{x}_p w „ostry” skalar y_p :

$$\mathbf{x}_p \in R^N \rightarrow y_p \in R^1 \quad (10)$$


gdzie: $p = 1, \dots, P$; P – liczba wzorców,

2) podział przestrzeni wejścia na K podprzestrzeni,

3) reguła wnioskowania rozmytego Sugeno,

4) iloczynowa reguła obliczania wartości wag,

- 5) wzór średniej ważonej poszczególnych reguł do obliczania ostrej wartości wyjścia,
 6) hybrydowa metoda uczenia.



Ryc. 2. Podział dwuwymiarowej przestrzeni wejścia: a) metoda podziału równomiernego; b) metoda podziału rozproszonego na grupy (klastry) danych

Pierwsze założenie jest zgodne z klasyczną ideą systemu wnioskowania rozmytego: wejście i wyjście złożone są z wartości ostrych, natomiast do znalezienia relacji między nimi służą reguły wnioskowania rozmytego.

Podział przestrzeni wejścia ma na celu wydzielenie stref, dla których definiowane są reguły wnioskowania rozmytego. Na ryc. 2 pokazano dwa sposoby podziału przestrzeni dwuwymiarowej na cztery podprzestrzenie: metodę równomiernego podziału przestrzeni wejścia (z j. ang. *grid partition*) i metodę podziału rozproszonego (z j. ang. *scatter partition*) na grupy (klastry) danych.

W systemie ANFIS zastosowany jest model wnioskowania Sugeno:

$$\text{jeżeli } (x_1 \text{ jest } A_1 \text{ I } x_2 \text{ jest } A_2 \text{ I } \dots \text{ I } x_N \text{ jest } A_N), \text{ to } y = f(x_1, x_2, \dots, x_N), \quad (11)$$

który w zapisie wektorowym można przedstawić następująco:

$$\text{jeżeli } (\mathbf{x} \text{ jest } A), \text{ to } y = f(\mathbf{x}) \quad (12)$$

gdzie: $f(\mathbf{x}) = f(x_1, x_2, \dots, x_N)$ – funkcja nierozmyta.

Klasyczną, najczęściej wykorzystywaną w praktyce postacią tej funkcji jest wielomian rzędu pierwszego:

$$y_k = f(\mathbf{x}) = a_k + \sum_{i=1}^N b_i^k x_i, \quad (13)$$

w którym współczynniki: a_k, b_1^k, \dots, b_N^k są wagami liczbowymi, dobieganymi w procesie adaptacji (uczenia).

Jeszcze prostszy model wnioskowania Sugeno otrzymuje się przy założeniu funkcji $f(\mathbf{x})$ jako wielomianu rzędu zerowego:

$$y_k = f(\mathbf{x}) = a_k. \quad (14)$$

Wagi w_k obliczane są zgodnie z regułą iloczynową, odpowiadającą podziałowi przestrzeni wejścia:

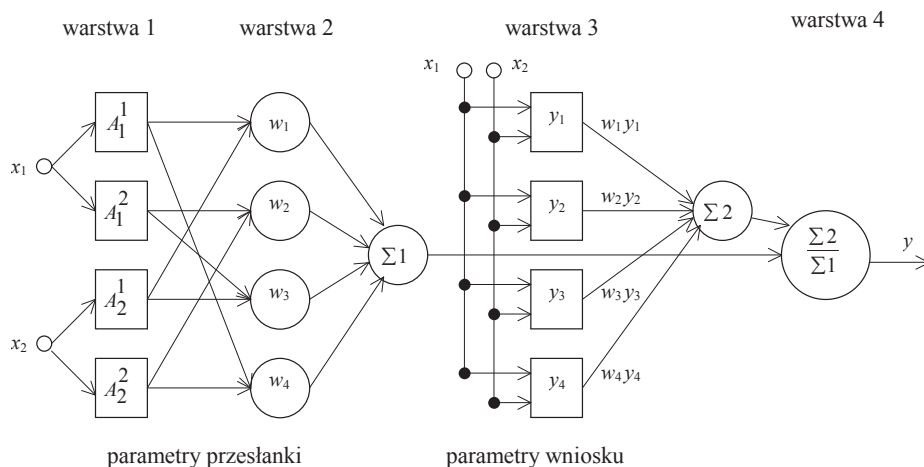
$$w_k = \prod_i \mu_{A_i^k}(\mathbf{x}). \quad (15)$$

Przy wielu (K) regułach występujących w modelu wnioskowania Sugeno, ostre wyjście układu określa się zgodnie ze wzorem średniej ważonej poszczególnych reguł. Przypisując każdej regule wagę w_k , otrzymuje się sygnał wyjściowy w postaci:

$$y = \frac{\sum_{k=1}^K w_k y_k}{\sum_{k=1}^K w_k}. \quad (16)$$

Parametry systemu ANFIS liczone są z wykorzystaniem hybrydowej metody uczenia, tzn. parametry wniosku (13) obliczane są „wprzód” metodą najmniejszych kwadratów, a parametry przesłanki (parametry funkcji przynależności) obliczane są „wstecz” metodą wstecznej propagacji błędu.

Na ryc. 3 pokazano schemat systemu rozmytego ANFIS z równomiernym podziałem dwuwymiarowej przestrzeni wejścia.



Ryc. 3. Schemat systemu rozmytego ANFIS z równomiernym podziałem dwuwymiarowej przestrzeni wejścia

System ANFIS został zaimplementowany w programie Fuzzy Logic Toolbox MATLAB [3]. Program ten pozwala na optymalny, automatyczny podział przestrzeni wejścia oraz wybór liczby reguł wnioskowania Sugeno.

Zastosowanie neuro-rozmytego systemu ANFIS do analizy interakcji dynamicznej podłoże – budynek oraz identyfikacji podstawowych okresów drgań własnych budynków

Uwagi wstępne

Neuronowy system wnioskowania rozmytego ANFIS zastosowano do rozwiązywania bardzo ważnych problemów analizy dynamicznej budynków, do których trzeba zaliczyć interakcję dynamiczną układu podłoże–budynek oraz określenie okresów drgań własnych obiektu. Dane do uczenia i testowania sieci neuro-rozmytych zgromadzono w czasie wieloletnich badań doświadczalnych przeprowadzonych na obiektach rzeczywistych, w skali naturalnej.

Przeprowadzone badania doświadczalne obejmują dwie grupy pomiarów: pomiary dynamiczne rzeczywistych budynków oraz pomiary drgań powierzchniowych wzbudzanych przez wstrząsy typu górniczego. Badania prowadzono w skali naturalnej, wielokrotnie w okresie wielu lat [1, 2, 6].

Obliczenia dla sieci neuro-rozmytych przeprowadzone zostały z użyciem systemu ANFIS z programu Fuzzy Logic Toolbox MATLAB [3].

Dokładność otrzymywanych wyników oceniana była poprzez ich porównywanie z wartościami uzyskanymi z badań doświadczalnych. W tym celu wyliczono błędy uczenia i testowania (*Mean Square Error – MSE*), standardowy błąd resztkowy ($\text{st } \varepsilon$) oraz błędy względne ep i eV_{avr} :

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

$$ep = \left| 1 - \hat{y}_p / y_p \right| \cdot 100\%, \quad eV_{\text{avr}} = \frac{1}{V} \sum_{p=1}^V ep. \quad (17)$$

gdzie: $V = L, T, P$ – odpowiednio liczba: wzorców uczących (L), wzorców testujących (T), wszystkich ($P = L + T$); y_p i \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 .


Analiza interakcji dynamicznej układu podłoże–budynek w przypadku wstrząsów górniczych

Zjawisko współpracy konstrukcji i podłoża albo inaczej: wzajemnego oddziaływania układu konstrukcja–podłoże w trakcie przekazywania się drgań z gruntu na obiekt nazywa się interakcją dynamiczną. W układzie budynek–podłoże występuje sprzężenie. Po pierwsze, propagujące się w podłożu fale pochodzenia sejsmicznego lub parasejsmicznego ulegają modyfikacji z uwagi na zmiany, jakie powoduje w gruncie posadowiony budynek. Po drugie, siły wywołane w podłożu przez drgającą konstrukcję generują deformacje podłoża, co z kolei wpływa na zachowanie się budynku.

Przebiegi drgań zarejestrowane na swobodnej powierzchni gruntu obok budynku różnią się od zarejestrowanych na fundamencie tego budynku. Złożony

charakter drgań sejsmicznych lub parasejsmicznych, własności gruntu i odmienne właściwości dynamiczne budynków powodują, że analiza problemu interakcji dynamicznej jest trudna. Jest to jednocześnie zagadnienie bardzo ważne z inżynierskiego (praktycznego) punktu widzenia. Istotna jest tu m.in. ocena sposobu przenoszenia się drgań na istniejący obiekt.

Zjawisko przekazywania się drgań z podłoża gruntowego na fundament budynku można analizować, porównując przebiegi drgań gruntu z przebiegami drgań najniższej części budynku (fundamentów), które zostały zarejestrowane jednocześnie. Oceny tych różnic można dokonać poprzez porównywanie spektrów odpowiedzi wyznaczonych na podstawie obu przebiegów drgań.



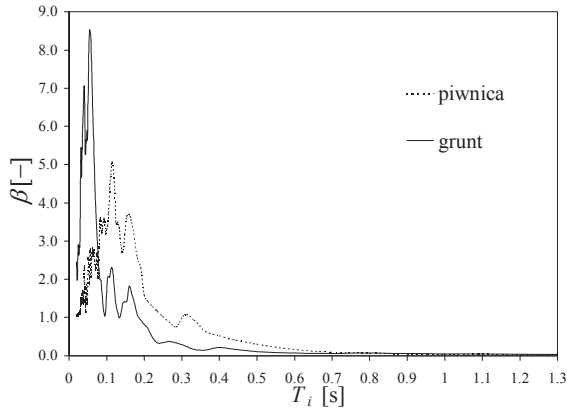
Ryc. 4. Przebiegi przyspieszeń drgań od wstrząsu górniczego: 23.11.2002, $E_n=2.4E6J$, $r_e = 768m$

Rozważano przebiegi drgań zarejestrowane równocześnie na gruncie i w budynku od wielu wstrząsów górniczych będących skutkiem podziemnej eksploatacji rudy miedzi w Legnicko-Głogowskim Okręgu Miedziowym (LGOM). Przekazywanie się drgań z gruntu na budynek analizowano w odniesieniu do budynku mieszkalnego o średniej wysokości (5-cio kondygnacyjnego). Na ryc. 4 pokazano przykładowe przebiegi przyspieszeń drgań jednocześnie zarejestrowane na gruncie i w dolnej części rozważanego budynku (wraz z informacją o energii E_n i odległości epicentralnej r_e wstrząsu górniczego, który był źródłem tych drgań).

Dla wszystkich zarejestrowanych na gruncie i w budynku przebiegów przyspieszeń drgań wyznaczono bezwymiarowe przyspieszeniowe spektra odpowiedzi β . Przy wyznaczaniu spektrów przyjęto ułamek tłumienia krytycznego $\xi = 2\%$ [2].

Okresy drgań (T_i) wzięto z przedziału [0.02, 1.3]s. T_i przyjmowano według związku $T_i = 1/f_p$ przy czym krok próbkowania f_i wynosił 0.25 Hz. Zatem w przypadku każdego zarejestrowanego przebiegu przyspieszeń drgań (zarówno w poziomie gruntu, jak i w dolnej części budynku), otrzymano 198 dyskretnych wartości odpowiednio bezwymiarowego przyspieszeniowego spektrum odpowiedzi. Przykładowe porównanie bezwymiarowych spektrów odpowiedzi od jednocześnie zarejestrowanych przebiegów przyspieszeń drgań na gruncie i na fundamencie (w piwnicy budynku) zamieszczono na ryc. 5.

Dane eksperymentalne wykorzystano jako wzorce do sieci neuro-rozmytych w celu określania związku między spektrami odpowiedzi wyznaczonymi na podstawie przebiegów drgań zarejestrowanych na gruncie przed budynkiem i w dolnej części obiektu.



Ryc. 5. Bezwymiarowe przyspieszeniowe spektra odpowiedzi

Zaproponowano następujący wektor wejścia:

$$x_{(6 \times 1)} = \{\beta_g(T_{i-2}), \beta_g(T_{i-1}), \beta_g(T_i), \beta_g(T_{i+1}), \beta_g(T_{i+2}), T_i\} \quad (18)$$

gdzie: T_{i-2} , T_{i-1} , T_i , T_{i+1} , T_{i+2} – kolejne okresy drgań, $i = 3, \dots, 196$; β_g – bezwymiarowe przyspieszeniowe spektrum odpowiedzi z przebiegów drgań zarejestrowanych na gruncie.

Odpowiednia wartość bezwymiarowego przyspieszeniowego spektrum odpowiedzi wyznaczonego na podstawie pomierzonych przebiegów drgań w dolnej części budynku ($\beta_f(T_i)$) oczekiwana była jako wyjście z sieci neuronowej:


$$y_{(1 \times 1)} = \{\beta_f(T_i)\} \quad (19)$$

gdzie: $i = 3, \dots, 196$ dla każdej analizowanej pary: grunt – dolna część budynku.

Do budowy wzorców w analizie neuro-rozmytej, z danych doświadczalnych użyto dwunastu par przebiegów drgań poziomych: grunt – budynek. Uzyskano zatem $P = 2328$ wzorców – 194 wzorce w każdej z dwunastu par przebiegów drgań. Połowę wzorców wzięto do uczenia sieci (sześć par spektrów), a pozostałe 50% wzorców (sześć par spektrów) użyto do testowania. Obliczenia dla sieci neuro-rozmytej przeprowadzone zostały z użyciem systemu ANFIS z programu Fuzzy Logic Toolbox MATLAB [3]. Funkcje przynależności przyjęto w postaci funkcji Gaussa. Dokonano równomiernego podziału przestrzeni wejścia. Zastosowano regułę wnioskowania Sugeno rzędu pierwszego, iloczynową regułę obliczania wartości wag, wzór średniej ważonej do obliczania ostrej wartości wyjścia i hybrydową metodę uczenia. Błędy uczenia i testowania tej sieci zamieszczono w tabeli 1, a na ryc. 6 pokazano wykres procentu sukcesu przy użyciu tej sieci. Natomiast na ryc. 7 porównano przykładowe bezwymiarowe przyspieszeniowe spektrum odpowiedzi z przebiegu drgań w dolnej części budynku uzyskane przy zastosowaniu sieci neuronowej typu ANFIS z odpowiadającym mu spektrum wyznaczonym numerycznie na podstawie pomierzonego przebiegu przyspieszeń drgań.

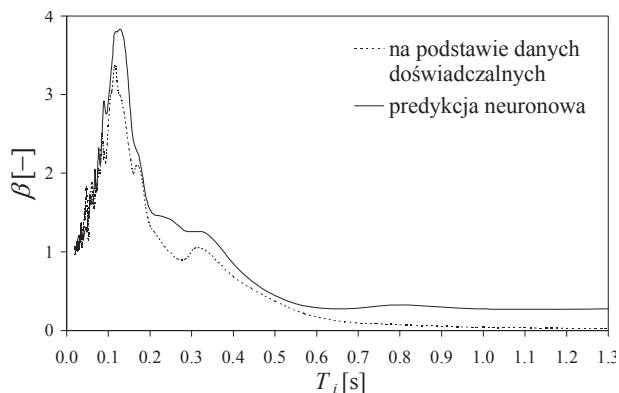
Tab. 1. Błędy uczenia i testowania sieci neuronowej typu ANFIS do analizy interakcji dynamicznej podłoże–budynek poprzez przyspieszeniowe spektra odpowiedzi

Sieć	MSE(V)		Liczba epok se	eV _{avr} [%]			r(P)	(st ε) (P)
	MSE(L)	MSE(T)		L	T	P		
ANFIS	0.00234	0.01578	8	8.8	17.3	13.1	0.695	0.095



Ryc. 6. Procent sukcesu $SR(ep)$ neuronowej predykcji (ANFIS) przyspieszeniowych spektrów odpowiedzi od przebiegów drgań w dolnej części budynku

Stwierdzono, że w wyniku zastosowania sieci neuro-rozmytych typu ANFIS można stosunkowo dokładnie odwzorowywać przyspieszeniowe spektra odpowiedzi od przebiegów drgań zarejestrowanych na gruncie przed budynkiem, w odpowiednie spektra związane z drganiami fundamentu budynku, a więc analizować skutki przekazywania się drgań z podłoża gruntowego na budynek (interakcję dynamiczną podłoże–budynek).



Ryc. 7. Bezwymiarowe przyspieszeniowe spektrum odpowiedzi od wstrząsu górniczego

Identyfikacja podstawowych okresów drgań własnych budynków

Do bardzo ważnych zagadnień w analizie dynamicznej budynków trzeba zaliczyć określenie właściwości dynamicznych obiektu, w szczególności okresów drgań własnych.

W praktyce stosowane są różne sposoby ich wyznaczania:

- obliczeniowy, z wykorzystaniem mniej lub bardziej skomplikowanych modeli,
- przybliżony, na podstawie wzorów empirycznych proponowanych w literaturze lub normach,
- na podstawie badań doświadczalnych wykonywanych na obiektach w skali naturalnej (na obiektach rzeczywistych),
- na podstawie badań laboratoryjnych na modelach budynków.

Najbardziej miarodajnym sposobem są pomiary drgań prowadzone na obiektach rzeczywistych. Tego rodzaju badania przeprowadzone zostały w odniesieniu do typowych obiektów należących do klasy budynków wielkowymiarowych o średniej wysokości (5-cio kondygnacyjnych) [1]. W dalszej kolejności do wyznaczenia podstawowych okresów drgań własnych tego typu budynków użyto sieci neuro-rozmytych. Zbiory uczące i testujące bazują na wynikach badań doświadczalnych.

Podstawowe okresy drgań własnych prefabrykowanych budynków o średniej wysokości znacząco zależą od podłoża gruntowego, na którym posadowiony jest budynek, oraz od wymiaru budynku w kierunku równoległym do kierunku drgań [7, 8]. Przeprowadzone analizy prowadziły do stwierdzenia, że sztywność na zginanie oraz sztywność na ścinanie w równym stopniu wpływają na drgania budynków o średniej wysokości.

Biorąc pod uwagę czynniki wpływające na wartości podstawowych okresów drgań własnych analizowanych budynków, w warstwie wejściowej sieci neuronowej zaproponowano cztery parametry: C_z – współczynnik sprężystego równomiernego pionowego ugięcia podłoża w [MPa/m]; b – wymiar budynku (szerokość lub długość) w kierunku drgań [m]; s – rozłożoną sztywność giętą typowej kondygnacji budynku, $s = \sum_i EI_i / a$; r – rozłożoną sztywność na ścinanie typowej kondygnacji budynku, $r = \sum_i GA_i / a$; gdzie: E , G – odpowiednio: moduł Younga i Kirchhoffa [MPa], I_p , A_i – odpowiednio: moment bezwładności [m⁴] i pole przekroju [m²] i -tej ściany, a – wymiar budynku [m] w kierunku prostopadłym do kierunku drgań. W warstwie wyjściowej oczekiwano wektora jednoelementowego: T_1 – podstawowy okres drgań własnych budynku [s].

Stąd rozważana sieć neuro-rozmyta typu ANFIS ma następujący wektor wejścia i wyjścia:

$$\mathbf{x}_{(4 \times 1)} = \{C_z, b, s, r\}, \quad \mathbf{y}_{(1 \times 1)} = T_1. \quad (20)$$

Uzyskane z danych doświadczalnych $P = 31$ wzorców podzielono na wzorce uczące i testujące: $L = 26$, $T = 5$.


Obliczenia dla sieci neuro-rozmytej przeprowadzono, korzystając z systemu ANFIS z programu Fuzzy Logic Toolbox MATLAB [3]. Przyjęto: funkcje

przynależności w postaci funkcji Gaussa, równomierny podział przestrzeni wejścia, regułę wnioskowania Sugeno rzędu pierwszego, iloczynową regułę obliczania wartości wag, wzór średniej ważonej do obliczania ostrej wartości wyjścia i hybrydową metodę uczenia.

Błędy uczenia i testowania proponowanej sieci neuronowej typu ANFIS zamieszczono w tabeli 2, a wykres procentu sukcesu (SR) predykcji podstawowych okresów drgań własnych budynków pokazano na ryc. 8.

Tab. 2. Błędy uczenia i testowania sieci neuronowej typu ANFIS do identyfikacji podstawowych okresów drgań własnych budynków o średniej wysokości

Sieć	Liczba epok se	$MSE(L)$	$MSE(T)$	$eV_{ovt}[\%]$			$r(P)$	(st ϵ) (P)
				L	T	P		
ANFIS	20	0.0000001	0.00027	0.15	7.3	1.3	0.987	0.007



Ryc. 8. Związek między procentem sukcesu i błędem względnym $SR(ep)$ dla sieci typu ANFIS z wektorem wejścia: $\mathbf{x}_{(4x1)} = \{C_r, b, s, r\}$

Wartości T_1 wyznaczone z wykorzystaniem neuro-rozmytej sieci typu ANFIS należałoby uznać za wystarczająco bliskie otrzymanym z pomiarów. Wyznaczenie okresów drgań odbywa się z zadowalającą w praktyce inżynierskiej dokładnością. Widać (ryc. 8), że w przypadku 87% wzorców błędy względne ep nie przekraczają 5%.

Wnioski

Uzyskane wyniki pozwalają na stwierdzenie, że sztuczne sieci neuronowe z wnioskowaniem rozmytym stwarzają nowe możliwości efektywnego rozwiązywania typowych problemów dynamiki konstrukcji. Zastosowanie ich pozwala na

stosunkowo łatwą analizę interakcji dynamicznej podłoże–budynek poprzez odwzorowywanie przyspieszeniowych spektrów odpowiedzi z przebiegów drgań zarejestrowanych na gruncie przed budynkiem, w odpowiednie spektra związane z drganiami fundamentu budynku. Z kolei na etapie wyznaczania podstawowego okresu drgań własnych budynku użycie zaprojektowanej, nauczonej i prawidłowo przetestowanej wcześniej sieci neuronowej jest wygodniejsze niż budowa i weryfikacja modelu dla rozważanego budynku. Przygotowana sieć o dobrych właściwościach generalizacyjnych może być wykorzystywana do wyznaczania podstawowych okresów drgań własnych wielu budynków z analizowanej klasy. Poza tym, sieci neuronowe pozwalają na uniknięcie formułowania w jawny sposób związków między parametrami „wejściowymi” i „wyjściowymi”.

Bibliografia

- [1] Ciesielski R., Kuźniar K., Maciąg E., Tatara T., *Empirical formulae for fundamental natural periods of buildings with load bearing walls*, Archives of Civil Engineering, **38**, 4, 1992, pp. 291–299
- [2] Ciesielski R., Kuźniar K., Maciąg E., Tatara T., *Damping of vibration in precast buildings with bearing concrete walls*, Archives of Civil Engineering, **40**, 3, 1995, pp. 329–341
- [3] *Fuzzy Logic Toolbox for Use with MATLAB*, User's Guide, Version 2, The Math Works Inc. 2001
- [4] Haykin S., *Neural networks – a comprehensive foundation*, Prentice Hall Intern. Inc., Upper Saddle River, NY, 2nd edition, 1999
- [5] 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
- [6] Kuźniar K., *Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych*, Wyd. Politechniki Krakowskiej, Kraków 2004
- [7] Maciąg E., *Experimental evaluation of changes of dynamic properties of buildings on different grounds*, Earthquake Engineering and Structural Dynamics, **14**, 1986, pp. 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, pp. 139–151
- [9] Osowski S. *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000
- [10] Zadeh L., *Fuzzy sets*, Information and Control, **8**, 3, 1965, 338–353

The application of fuzzy neural networks in the selected building vibrations problems

Abstract

The paper deals with an application of fuzzy neural networks of ANFIS type for evaluation of soil-structure interaction in case of the transmission of ground vibrations from mining tremors to building basement and for identification of fundamental periods of building vibrations

Key words: soil-structure interaction, fundamental period of vibrations, fuzzy neural network