

mgr inż. Anna Jakubczyk-Galczyńska^{1*)}
 dr inż. Adam Kristowski¹⁾
 prof. dr hab. inż. Robert Jankowski¹⁾

Wykorzystanie sztucznych sieci neuronowych do szacowania wpływu drgań na budynki jednorodzinne

Usage of artificial neural networks for estimating the impact of traffic-induced vibration on residential buildings

DOI: 10.15199/33.2016.06.50

(Studium przypadku)

Streszczenie. W artykule przedstawiono metodę prognozowania wpływu drgań na budynki mieszkalne z wykorzystaniem sztucznych sieci neuronowych. Drgania komunikacyjne mogą doprowadzić do uszkodzenia elementów konstrukcyjnych, a nawet do awarii budynku. Najczęstszym efektem są jednak rysy, pęknięcie tynku i wypraw. Metody oparte na sztucznej inteligencji są przybliżone, ale stanowią wystarczająco dokładną i ekonomiczną alternatywę dla tradycyjnych pomiarów.

Słowa kluczowe: drgania komunikacyjne, sztuczna inteligencja, SSN, budynki mieszkalne.

Abstract. The article presents the method of forecasting the impact of vibrations on residential buildings using the artificial neural networks. Traffic – induced vibrations may damage to structural elements or even lead to structural collapse. However the most common effect is cracking of plaster. Methods based on artificial intelligence are approximate, but they are enough reliable and economical alternative way to traditional measurements.

Keywords: traffic-induced vibrations, artificial intelligence, ANN, residential buildings.

Artykuł dotyczy wykorzystania sztucznych sieci neuronowych do prognozowania wpływu drgań komunikacyjnych wywołanych przez pojazdy kołowe na budynki. Wibracje występujące w wyniku ruchu drogowego są przenoszone przez grunt na fundamenty pobliskich konstrukcji [6]. W wyniku tego elementy budynków jednorodzinnych mogą ulec uszkodzeniu [2, 4]. Chcąc określić istotność wpływu drgań komunikacyjnych, należy wykonać pomiary przy użyciu specjalnego sprzętu wg zasad omówionych w rozdziale 2 oraz w [9]. Po ustaleniu charakterystyki sytuacyjno-badawczej wykonuje się pomiary drgań, tworzy wibrogram, filtruje wyniki i porównuje z wartościami normowymi zawartymi w [9].

Oczywiście niemożliwe byłoby przeprowadzanie takich badań dla wszystkich budynków zlokalizowanych przy drodze. Jedną z metod jest prognozowanie z wykorzystaniem np. sztucznych sieci neuronowych.

Metoda wykonywania pomiarów

Dotychczas wykonano pomiary polowe drgań czterech jednorodzinnych budynków mieszkalnych spełniających założenia normy [9]. Źródłem występowania drgań były pojazdy o różnym tonażu i liczbie osi, poruszające się z różną prędkością.

Badania drgań w celu określenia strefy wpływów dynamicznych wykonano dla obciążeń stałych, czyli występujących powyżej 30 min na dobę. Czujniki piezoelektryczne przyspieszenia zamontowano w dwóch lub trzech miejscach na obiekcie od strony źródła drgań zgodnie z [5, 9]. Punkty pomiarowe umieszczono na fundamentcie lub na ścianie w poziomie gruntu. Pomiary wykonano dla poziomych składowych drgań funda-

mentu lub ścian nośnych w poziomie terenu. Następnie przeprowadzono analizę ekstremalnych przyspieszeń [m/s^2] w pasmach 1/3 oktaowych w przedziale częstotliwości 1 – 100 Hz. Wyznaczono ekstremalne wartości amplitud dla wymienionych częstotliwości środkowych i naniesiono je na normowy wykres skali wpływów dynamicznych [9]. Następnie odczytano, w jakiej strefie znajduje się obiekt. Na tej podstawie ustalono, że trzy budynki znajdują się w I strefie, co oznacza brak wpływu drgań komunikacyjnych, a jeden budynek w II strefie, co oznacza brak wpływu na samą konstrukcję. Istnieje jednak duża możliwość przyspieszonego zużycia tynków. W takim przypadku wykonywanie bardzo pracochłonnych i kosztownych pomiarów okazuje się bezpodstawne. Optymalne jest zastosowanie algorytmu, którego ideę przedstawiono w [3] oraz w artykule.

Wykorzystanie sztucznych sieci neuronowych


Sztuczne sieci neuronowe zostały już wykorzystane do rozwiązywania pokrewnych problemów inżynierskich m.in. do prognozowania przekazywania drgań pochodzenia górniczego z gruntu na budynek [1], do oceny stopnia zużycia technicznego wybranej grupy budynków mieszkalnych [12] oraz też do analizy wstrząsów górniczych przedstawionej w [7]. Są to metody obliczeniowe wykorzystujące zasadę działania ludzkich neuronów, czyli komórek nerwowych. Neuron przetwarza docierające do nich informacje i zapamiętuje je, aby wykorzystać w przyszłości. Sztuczne systemy działają w ten sam sposób. Dane są wstawiane do systemu, przetwarzane i zapamiętywane, a także poprawiane.

Budowę sieci neuronowej podzielono na kilka etapów zgodnie z zasadami i sugestiami zawartymi w publikacjach [8, 10, 11]. Pierwszym z nich było utworzenie bazy danych z wyników pomia-

¹⁾ Politechnika Gdańska, Wydział Inżynierii Lądowej i Środowiska

^{*)} Adres do korespondencji:
e-mail: annjakub@pg.gda.pl

rów połowych drgań. Następnym etapem jest budowa algorytmu. Należało określić czynniki, które mogą mieć wpływ na wyniki otrzymane w badaniach podczas tworzenia bazy. Wyniki stanowią sygnały wyjściowe. Niezależnie prowadzona była faza weryfikacji. Oprócz tego przed zakończeniem budowy sieci wyznaczono próbki testujące. Sygnał wyjściowy porównano z wyznaczonym poza siecią i określono błędy poszczególnych próbek. Utworzono 6 sieci z jedną warstwą ukrytą, różniących się między sobą uwzględnianymi parametrami oraz liczbą neuronów w warstwie ukrytej (przyjęto 1, 3 i 10 neuronów dla każdej z sieci). Po znormalizowaniu uwzględniano losowo wybraną kombinację czynników: rodzaj drogi (D_r); rodzaj (D_n) i stan nawierzchni (D_{sn}); prędkość (D_p) i ciężar pojazdów (D_c); długość drgań (D_d); kształt i wymiary przedmiotowego budynku (B_o), odległość budynku od drogi (B_o) oraz przyspieszenie na kierunku x i y (a_{xy}). Na wyjściu, wielkością oczekiwaną była informacja, czy badany budynek znajduje się w strefie braku wpływu – sygnał wyjściowy = 0 (I strefa wg SWD I [9]) czy też wpływ jest możliwy – sygnał wyjściowy = 1 (strefa II i wyższe). Po przeprowadzeniu procesu uczenia sieci uzyskano wyniki zamieszczone w tabeli, a model sztucznej sieci neuronowej pokazano na rysunku.



Model sztucznej sieci neuronowej: „X” – wektor wejściowy, „Y” – wektor wyjściowy, „e” – funkcja wewnętrznego przetwarzania, „f” – funkcja aktywacji

Model of Artificial Neural Networks: X – input vector, Y – output vector, „e” – the function of internal processing, „f” – activation function

Jako porównanie sieci przedstawiono błąd średniokwadratowy (MSE – Mean Square Error). Wyniki podane w tabeli wskazują, iż błędy działania sztucznych sieci neuronowych są małe i nie przekraczają $7,79053 \times 10^{-1}$ dla próbek uczących, $1,02362 \times 10^0$ dla próbek weryfikujących oraz $1,02362 \times 10^0$ dla próbek testujących. Najmniejszy błąd próbek weryfikujących ($2,27980 \times 10^{-28}$) uzyskano w przypadku sieci nr 5 o strukturze 6-10-1. Najmniej efektywna okazała się sieć nr 3 (9-10-1), dla której błąd był największy i wyniósł $1,02362 \times 10^0$ w przypadku próbek weryfikujących i testujących.

Wnioski

Na podstawie dotychczas wykonanych obliczeń uzyskano małe wartości błędów działania sztucznych sieci neuronowych o różnej budowie. Wyniki są zatem obiecujące i świadczą o efektywności działania opracowanego algorytmu. Należy jednak podkreślić, iż aktualna baza wyników uzyskanych dzięki przeprowadzonym badaniom stanowi mało zróżnicowane przypadki i jest za skromna w stosunku do oczekiwanych rezultatów dla poszczególnych sytuacji pomiarowych. Z tego powodu kolejnym etapem badań będzie wykonanie pomiarów na dużo większej liczbie budynków mieszkalnych, następnie modyfikacja utworzonych sieci, a także sprawdzenie innych algorytmów sztucznej inteligencji, np. maszyny wektorów nośnych. Planuje się również zastosowa-

Charakterystyka sieci neuronowych oraz błędy próbek Characteristics of neural networks and errors of samples

Nr sieci i architektura	Czynniki	MSE – próbki uczące [-]	MSE – próbki weryfikacji [-]	MSE – próbki testujące [-]
Sieć nr 1: 9-10-1	D_r, D_n, D_{sn}	$2,47794 \times 10^{-17}$	$1,62121 \times 10^{-18}$	$4,06741 \times 10^{-18}$
Sieć nr 1: 9-3-1	D_r, D_c, D_d	$3,46064 \times 10^{-5}$	$1,58528 \times 10^{-16}$	$7,64646 \times 10^{-16}$
Sieć nr 1: 9-1-1	$B_o, B_o, a_{xy(max)}$	$1,65689 \times 10^{-18}$	$2,21324 \times 10^{-26}$	$1,01970 \times 10^{-17}$
Sieć nr 2: 9-10-1	D_r, D_n, D_{sn}	$1,28870 \times 10^{-3}$	$1,62256 \times 10^{-4}$	$6,29987 \times 10^{-7}$
Sieć nr 2: 9-3-1	D_r, D_c, D_d	$5,22570 \times 10^{-17}$	$1,65730 \times 10^{-17}$	$3,76164 \times 10^{-5}$
Sieć nr 2: 9-1-1	B_o, B_o, a_{xy}	$1,79537 \times 10^{-15}$	$1,02692 \times 10^{-13}$	$7,75498 \times 10^{-16}$
Sieć nr 3: 9-10-1	D_r, D_n, D_{sn}	$4,55243 \times 10^{-3}$	$1,02362 \times 10^0$	$1,02362 \times 10^0$
Sieć nr 3: 9-3-1	D_r, D_c, D_d	$3,43871 \times 10^{-1}$	$4,15107 \times 10^{-5}$	$6,56568 \times 10^{-5}$
Sieć nr 3: 9-1-1	B_o, B_o, a_{xy}	$2,03905 \times 10^{-1}$	$2,74634 \times 10^{-1}$	$2,74634 \times 10^{-1}$
Sieć nr 4: 4-1-1	D_{sn}, D_c	$1,55050 \times 10^{-24}$	$4,15857 \times 10^{-24}$	$1,92069 \times 10^{-24}$
Sieć nr 4: 4-3-1	$B_o, a_{xy(max)}$	$1,55700 \times 10^{-17}$	$8,39782 \times 10^{-17}$	$6,40031 \times 10^{-20}$
Sieć nr 4: 4-10-1	$B_o, a_{xy(max)}$	$3,15400 \times 10^{-1}$	$8,73202 \times 10^{-4}$	$1,01045 \times 10^{-3}$
Sieć nr 5: 6-1-1	D_r, D_n, D_p	$5,12322 \times 10^{-16}$	$2,23518 \times 10^{-15}$	$6,15699 \times 10^{-16}$
Sieć nr 5: 6-3-1	$D_c, B_o, a_{xy(max)}$	$2,61417 \times 10^{-15}$	$3,52028 \times 10^{-16}$	$8,18162 \times 10^{-18}$
Sieć nr 5: 6-10-1	$D_c, B_o, a_{xy(max)}$	$2,69607 \times 10^{-22}$	$2,27980 \times 10^{-28}$	$1,60244 \times 10^{-24}$
Sieć nr 6: 5-1-1	D_{sn}, D_p, D_c	$1,57872 \times 10^{-16}$	$3,90202 \times 10^{-18}$	$8,80284 \times 10^{-16}$
Sieć nr 6: 5-3-1	$D_d, a_{xy(max)}$	$3,60012 \times 10^{-1}$	$2,42175 \times 10^{-1}$	$2,42175 \times 10^{-1}$
Sieć nr 6: 5-10-1	$D_d, a_{xy(max)}$	$7,79053 \times 10^{-1}$	$2,70029 \times 10^{-3}$	$2,70029 \times 10^{-3}$

nie innego typu sieci w celu porównania wyników, co powinno skutkować powstaniem kompleksowego systemu do oceny drgań komunikacyjnych na budynki.

Literatura

- [1] Chudyba Łukasz. 2011. „Wpływ typu sieci neuronowej na dokładność prognozowania przekazywania drgań pochodzenia górniczego z gruntu na budynek”. *Czasopismo Techniczne* 108 (3): 3 – 12.
- [2] Hunaidi Osama. 2000. „Traffic vibrations in buildings”. *Construction Technology Update* 39: 1 – 6.
- [3] Jakubczyk-Gałczyńska Anna, Adam Kristowski, Robert Jankowski. 2014. „Koncepcja szacowania wpływu drgań komunikacyjnych na budynki i na ludzi przy użyciu sztucznych sieci neuronowych”. *Inżynieria Morska i Geotechnika* 5: 523 – 527.
- [4] Jakubczyk-Gałczyńska Anna, Robert Jankowski. 2014. „Traffic-induced vibrations. The impact on buildings and people”. *International Conference on Environmental Engineering Selected papers*: 1-6.
- [5] Kawecki Janusz, Krzysztof Stypuła. 2008. „Błędy w prognozowaniu i diagnostyce wpływów dynamicznych na budynki”. *Czasopismo Techniczne* 105 (M/2008): 127 – 136.
- [6] Kawecki Janusz, Krzysztof Stypuła. 2013. „Zapewnienie komfortu wibracyjnego ludziom w budynkach narażonych na oddziaływanie komunikacyjne”. Wydawnictwo Politechniki Krakowskiej.
- [7] Kuźniar Krystyna. 2011. „Neural networks for the analysis of mine-induced building vibrations”. *Computer Assisted Mechanics and Engineering Sciences* 18 (3): 147 – 159.
- [8] Ossowski Stanisław. 1996. „Sieci neuronowe w ujęciu algorytmicznym”. Wydawnictwa Naukowo-Techniczne.
- [9] PN-85 B-02170. 1985. „Ocena szkodliwości drgań przekazywanych przez podłoże na budynki”. Polski Komitet Normalizacji Miar i Jakości.
- [10] Stegowski Zdzisław. 2004. „Sztuczne sieci neuronowe”. Wydawnictwa Naukowo-Techniczne.
- [11] Tadeusiewicz Ryszard. 1993. „Sieci neuronowe”. Akademicka Oficyna Wydawnicza.
- [12] Urbański Paweł. 2004. „Zastosowanie sztucznych sieci neuronowych do oceny stopnia zużycia technicznego wybranej grupy budynków mieszkalnych”. *Statystyka i data mining w badaniach naukowych*: 105 – 119.

Przyjęto do druku: 14.04.2016 r.