

ŁUKASZ CHUDYBA\*

WPLYW TYPU SIECI NEURONOWEJ  
NA DOKŁADNOŚĆ PROGNOZOWANIA  
PRZEKAZYWANIA DRGAŃ  
POCHODZENIA GÓRNICZEGO Z GRUNTU NA BUDYNEK

THE INFLUENCE OF NEURAL NETWORK TYPE  
ON THE PREDICTION ACCURACY  
OF THE TRANSMISSION OF MINING TREMORS  
VIBRATIONS FROM THE GROUND TO THE BUILDING

Streszczenie

Artykuł dotyczy analizy wpływu typu sieci neuronowych na dokładność prognozowania przekazywania drgań pochodzenia górniczego z gruntu na fundament typowego budynku mieszkalnego. Zastosowano standardowe sztuczne sieci neuronowe, sieci neuronowe z regularizacją oraz bayesowskie sieci neuronowe. Wzorce uczące, walidujące oraz testujące sieci neuronowych utworzono, wykorzystując wyniki badania doświadczalnych.

*Słowa kluczowe: interakcja dynamiczna podłoże-budynek, sieci neuronowe, bayesowskie sieci neuronowe, przyspieszenie drgań, prędkość drgań*

Abstract

The paper deals with the analysis of the influence of neural network type on the prediction accuracy of the transmission of mining tremors vibrations from the ground to the typical building. Standard neural networks, neural networks with regularization and bayesian neural networks were used. Results of experimental tests were applied as the neural network training, validating and testing patterns.

*Keywords: soil-structure interaction, neural network, bayesian neural network, acceleration of vibrations, velocity of vibrations*

\* Mgr inż. Łukasz Chudyba, doktorant, Wydział Inżynierii Lądowej, Politechnika Krakowska.

## 1. Wstęp

Sztuczne sieci neuronowe powstały na gruncie wiedzy o działaniu systemu nerwowego istot żywych i stanowią próbę wykorzystania zjawisk zachodzących w systemach nerwowych [1]. Stworzono szereg modeli matematycznych, uwzględniając w mniejszym lub większym stopniu funkcjonowanie rzeczywistej komórki neuronowej, a sztuczne sieci neuronowe znalazły zastosowanie w analizie wielu problemów nauki i techniki [2].

W niniejszym artykule sztuczne sieci neuronowe różnego typu wykorzystano do prognozowania przekazywania drgań z gruntu na fundament typowego budynku mieszkalnego. Wzorce do obliczeń pochodziły z rzeczywistych pomiarów drgań powierzchniowych towarzyszących wydobyciu rudy miedzi w Legnicko-Głogowskim Okręgu Miedziowym (LGOM). Intensywność najsilniejszych oddziaływań sejsmicznych w tym regionie jest zbliżona do słabych trzęsień ziemi. Wstrząsy te, tak samo jak w przypadku ruchu podłoża gruntowego wywołanego trzęsieniem ziemi, mają charakter losowy. Nie wiadomo, kiedy mogą wystąpić.

Wzajemne oddziaływanie podłoża i posadowionej na nim konstrukcji podczas działań dynamicznych nosi nazwę „interakcji dynamicznej”. Jest to zagadnienie bardzo ważne z inżynierskiego punktu widzenia. Istotne jest zarówno prognozowanie wpływu drgań na budynek, jak również ocena sposobu przekazywania drgań na ten obiekt.


Zdecydowano się na zastosowanie standardowych sztucznych sieci neuronowych (SSSN) typu wstecznej propagacji błędu, sztucznych sieci neuronowych z regularyzacją (SSN+reg.). Widocznym niedostatkami takich sieci jest ich deterministyczny charakter, dlatego do prognozowania przekazywanych drgań z gruntu na budynek mieszkalny wykorzystano również bayesowskie sieci neuronowe (BNN) [2].

## 2. Wyniki badań doświadczalnych

Przekazywanie przyspieszeń oraz prędkości drgań od wstrząsów górniczych z gruntu na fundament budynku analizowano w odniesieniu do typowego, mieszkalnego, prefabrykowanego budynku ścianowego z poprzeczno-podłużnym układem ścian nośnych, posadowionego na ławach fundamentowych. Obiekt ma pięć kondygnacji i należy do klasy budynków o średniej wysokości. Źródłem drgań były wstrząsy górnicze powstałe na skutek wydobycia rudy miedzi w LGOM. Zarejestrowane przebiegi drgań pochodziły z badań w skali naturalnej, dokonanych przy użyciu aparatury „czuwającej”. Mierzono przebiegi przyspieszeń drgań równocześnie na gruncie i na fundamencie w kierunkach równoległych odpowiednio do poprzecznej ( $x$ ) i podłużnej ( $y$ ) osi budynku od wielu wstrząsów górniczych. Na podstawie pomierzonych składowych przebiegów przyspieszeń drgań, w przypadku każdego wstrząsu górniczego, przez całkowanie wyznaczono przebiegi prędkości drgań. Na podstawie składowych przebiegów przyspieszeń oraz składowych prędkości drgań w kierunkach  $x$  i  $y$ , w przypadku każdego wstrząsu wyliczono przebiegi wypadkowego przyspieszenia drgań poziomych  $PGA$  i  $PFA$ , odpowiednio na gruncie i na fundamencie budynku oraz analogicznie przebiegi wypadkowej prędkości drgań poziomych  $PGV$  i  $PFV$ .

Na rysunkach 1a i 1b przykładowo porównano odpowiednio przebiegi wypadkowych przyspieszeń oraz prędkości drgań występujących jednocześnie na gruncie oraz fundamen-

cie od jednego ze wstrząsów górniczych. Stwierdzono, że różnice w drganiach gruntu oraz fundamentu odbywających się w tym samym czasie mogą być znaczące tak w zakresie wypadkowych przyspieszeń, jak i wypadkowych prędkości.

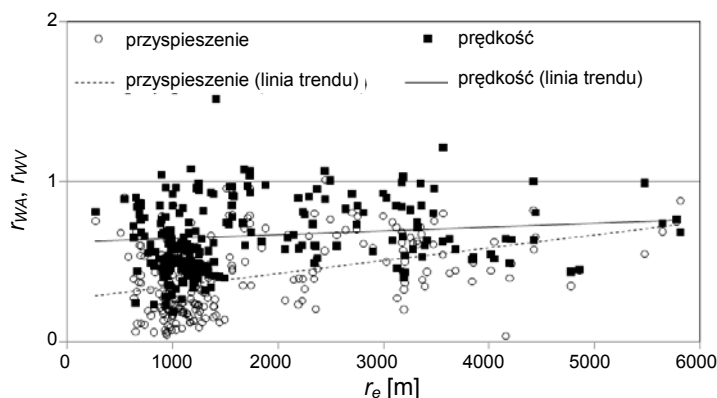


Rys. 1. Przebiegi wypadkowych przyspieszeń dla wstrząsu:  $E_n = 9,6E7J$ ,  $r_e = 2494$  m (a) oraz wypadkowych prędkości dla wstrząsu  $E_n = 1,2E7J$ ,  $r_e = 698$  m (b) pomierzonych równocześnie na gruncie oraz fundamencie badanego budynku

Fig. 1. Time history of resultant accelerations from the tremor:  $E_n = 9,6E7J$ ,  $r_e = 2494$  m (a) and resultant velocities from the tremor  $E_n = 1,2E7J$ ,  $r_e = 698$  m (b) in the same time on the ground and building foundation

Oceny przekazywania drgań z gruntu na fundament dokonano poprzez porównanie maksymalnych wartości wypadkowych przyspieszeń drgań jednocześnie zarejestrowanych na fundamencie budynku ( $PFA$ ) i gruntu obok budynku ( $PGA$ ) oraz analogiczne porównanie odpowiednich prędkości drgań. W tym celu w przypadku przyspieszeń drgań wyliczano stosunek:  $r_{WA} = PFA/PGA$ , a dla prędkości:  $r_{WV} = PFV/PGV$ ;  $PGV$ ,  $PFV$  – odpowiednio: maksymalna wartość wypadkowej prędkości drgań fundamentu i gruntu obok budynku. Łącznie rozważono 226 par przyspieszeń drgań  $PGA-PFA$  (pary grunt-fundament) oraz 226 par prędkości drgań  $PGV-PFV$ .

Przeprowadzono analizę zależności ułamków  $r_{WA}$  i  $r_{WV}$  od podstawowych parametrów wstrząsów górniczych, tj. odpowiednio maksymalnego wypadkowego przyspieszenia na gruncie ( $PGA$ ) albo maksymalnej wypadkowej prędkości na gruncie ( $PGV$ ), energii wstrząsu górniczego ( $E_n$ ), odległości epicentralnej ( $r_e$ ) oraz współrzędnych sejsmologicznych ( $X$ ,  $Y$ ). Na rysunku 2 przykładowo przedstawiono zależność ułamków  $r_{WA}$ ,  $r_{WV}$  od odległości epicentralnej wraz z liniami trendu.



Rys. 2. Zależności  $r_{WA}$  i  $r_{WV}$  od odległości epicentralnych  $r_e$

Fig. 2. Ratios  $r_{WA}$  and  $r_{WV}$  versus epicentral distances  $r_e$

Stwierdzono, że niemożliwe jest precyzyjne określenie zależności ułamków  $r_{WA}$  i  $r_{WV}$  od poszczególnych parametrów charakteryzujących wstrząsy górnicze. Można jedynie dopatrywać się pewnych trendów [3, 4, 5]. Zarówno przyspieszenia, jak i prędkości wypadkowych drgań gruntu przekazują się stosunkowo dobrze na fundament budynku przy dużych odległościach epicentralnych wstrząsów. W przypadku zależności ułamków  $r_{WA}$  i  $r_{WV}$  od energii wstrząsów górniczych, zauważono, że większa redukcja jest w przypadku mniejszych energii wstrząsów. Stwierdzono również, że w przypadku wstrząsów górniczych o takich samych energiach i niemal takich samych odległościach epicentralnych, ale innym epicentrum, przekazywanie drgań z gruntu na fundament budynku może się znacząco różnić [5].

### 3. Prognozowanie przekazywania drgań z podłoża na budynek z wykorzystaniem sieci neuronowych

#### 3.1. Zastosowane typy sieci neuronowych

Do prognozowania przekazywania drgań z gruntu na fundament budynku wykorzystano: standardowe sztuczne sieci neuronowe jednokierunkowe ze wsteczną propagacją błędów (WPB), sztuczne sieci neuronowe z regularyzacją, bayesowskie sieci neuronowe.

W procesie uczenia sieci standardowych poszukuje się minimum funkcji błędów. W przypadku ciągłych funkcji aktywacji stosuje się metodę gradientową największego spadku błędów średniokwadratowego  $MSE(V)$  [1]

$$\Delta w_{ij}^{(p)} = -\eta \cdot \frac{\partial MSE(V)^{(p)}}{\partial w_{ij}^{(p)}} \quad (1)$$

gdzie:

- $\eta$  – parametr uczenia,
- $w_{ij}$  – elementy wektora wag,
- $p$  – całkowita liczba wzorców.

Algorytm propagacji wstecznej określa strategię doboru wag sieci przy wykorzystaniu gradientowych metod optymalizacji i oparty jest na minimalizacji sumy kwadratów błędów uczenia.

Z kolei w przypadku uczenia z regularyzacją, obliczenia wykonuje się z użyciem regularyzatora wag [6]

$$MSW = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (2)$$

gdzie:

- $n$  – liczba uogólnionych wag,
- $w_j$  – wartości wag.

Błąd  $MSW$  pełni rolę funkcji kary we wzorze na błąd regularyzacji

$$MSEREG = \gamma MSE + (1 - \gamma)MSW \quad (3)$$

gdzie  $\gamma$  jest współczynnikiem regularyzacji.

W bayesowskim modelu SSN wagi, wektor wejścia oraz wyjście SSN są przyjęte jako zmienne losowe. Działanie sieci bayesowskich oparte jest na twierdzeniu Bayesa dla gęstości prawdopodobieństwa warunkowego [2, 7]

$$p(\mathbf{w} | \mathbf{X}, \mathbf{t}, \alpha, \beta) = \frac{p(\mathbf{t} | \mathbf{X}, \mathbf{w}, \beta)p(\mathbf{w} | \alpha)}{p(\mathbf{t} | \mathbf{X}, \alpha, \beta)} \quad (4)$$

Mianownik w równaniu (4) przyjmuje postać

$$p(\mathbf{t} | \mathbf{X}, \alpha, \beta) = \int p(\mathbf{t} | \mathbf{X}, \mathbf{w}, \beta)p(\mathbf{w} | \alpha)d\mathbf{w} \quad (5)$$

W powyższych równaniach  $p$  oznacza rozkład prawdopodobieństwa,  $\mathbf{X}$  – zbiór wejść sieci,  $\mathbf{t}$  – zbiór wyjść,  $\alpha$  i  $\beta$  to hiperparametry, natomiast  $\mathbf{w}$  jest wektorem wag sieci neuronowej. Wówczas funkcję błędu można przedstawić w następującej postaci

$$F(\mathbf{w}) = \beta E_D(\mathbf{w}) + \alpha E_W(\mathbf{w}) = \frac{\beta}{2} \sum_{n=1}^N \{t^n - y(x^n; \mathbf{w})\}^2 + \frac{\alpha}{2} \sum_{i=1}^w w_i^2 \quad (6)$$

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

$$MSE(Q) = \frac{1}{Q} \sum_{p=1}^P (z_p - y_p)^2 \quad (7)$$

$$ep = \left| 1 - \frac{y_p}{z_p} \right| \cdot 100\% \quad (8)$$

gdzie:

- $Q = L, V, T$  – liczba wzorców w zbiorze uczącym ( $L$ ), walidującym ( $V$ ) i testującym ( $T$ ),  
 $z_p$  i  $y_p$  – wartości ułamka  $r_{WA}$  lub  $r_{WV}$  wyznaczone na podstawie przebiegów drgań oraz wyliczone neuronowo dla  $p$ -tego wzorca.

Do oceny dokładności uzyskanych rezultatów obliczeń wykorzystywano też 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  $ep$ .

### 3.2. Obliczenia z zastosowaniem sztucznych sieci neuronowych

Z analizy wyników badań doświadczalnych widać trudności w precyzyjnym określeniu zależności ułamków  $r$  od parametrów charakteryzujących wstrząsy górnicze. Trudne jest więc prognozowanie przekazywania drgań od wstrząsów górniczych z gruntu na budynek o średniej wysokości.

Podjęto zatem próbę zastosowania wybranych rodzajów sieci neuronowych do przewidywania sposobu przekazywania drgań od wstrząsów górniczych z gruntu na fundament pięciokondygnacyjnego budynku mieszkalnego.

Bazując na wynikach badań doświadczalnych, sformułowano odpowiednie wzorce uczące, walidujące i testujące sieci. W przypadku przyspieszeń, jak i prędkości drgań, zdecydowano się na analogiczne parametry wejściowe sieci. Przyjęto następujące postacie wektorów wejścia

$$\mathbf{x}_{(3 \times 1)} = \{En, r_e, PGA\} \quad (9)$$

$$\mathbf{x}_{(3 \times 1)} = \{En, r_e, PGV\} \quad (10)$$

$$\mathbf{x}_{(5 \times 1)} = \{En, r_e, X, Y, PGA\} \quad (11)$$

$$\mathbf{x}_{(5 \times 1)} = \{En, r_e, X, Y, PGV\} \quad (12)$$

gdzie:

- $En$  – energia wstrząsu górniczego,  
 $r_e$  – odległość epicentralna,  
 $X, Y$  – współrzędne sejsmologiczne,  
 $PGA$  – maksymalna wartość (amplituda) wypadkowych przyspieszeń drgań gruntu,  
 $PGV$  – maksymalna wartość (amplituda) wypadkowych prędkości drgań gruntu.

W wektorach wyjścia oczekiwano ułamków  $r_{WA}$  oraz  $r_{WV}$

$$\mathbf{y}_{(1 \times 1)} = \{r_{WA}\} \quad (13)$$

$$\mathbf{y}_{(1 \times 1)} = \{r_{WV}\} \quad (14)$$

Wyniki badań doświadczalnych pozwoliły na przygotowanie po  $P = 226$  wzorców, które zastosowano w każdej wersji sieci. W przypadku każdej sieci losowo wybrano  $L = 113$ , które zostały wykorzystane do uczenia sieci,  $V = 56$  do walidacji, a pozostałe  $T = 57$  wzorców użyto do testowania.

Zdecydowano się na zastosowanie standardowej sztucznej sieci neuronowej (SSSN) typu wstecznej propagacji błędu (WPB) z algorytmem uczenia Levenberga-Marquardta (LM) [6, 8], sztucznej sieci neuronowej z regularyzacją [6] oraz bayesowskiej sieci neuronowej (BNN) [2, 7]. Zastosowano sigmoidalną unipolarną (logistyczną) funkcję aktywacji. Do obliczeń wykorzystano program Matlab NN Toolbox [8].

Przeprowadzono szereg obliczeń, w celu zaprojektowania sieci do prognozowania przekazywania przyspieszeń drgań z gruntu na fundament budynku, jak również sieci do prognozowania przekazywania prędkości drgań z gruntu na fundament budynku. Kryterium doboru struktury sieci neuronowej był możliwie najmniejszy błąd MSE dla uczenia, walidacji i testowania. Analizowano sieci z jedną warstwą ukrytą. Poszukiwano optymalnej sieci w zależności od liczby neuronów w warstwie ukrytej oraz liczby epok uczenia. W przypadku sieci neuronowej z regularyzacją dodatkowym parametrem wpływającym na dobór optymalnej sieci była wartość współczynnika regularyzacji  $\gamma$ .

W tabeli 1 zamieszczono informację o architekturze, liczbie epok uczenia rozważanych wariantów sieci i odpowiadających im błędach uczenia, walidacji i testowania.


Tabela 1

Błędy uczenia, walidacji i testowania zaproponowanych sieci neuronowych

Wejście	Wyjście	Typ sieci	Nr sieci	Architektura sieci	Liczba epok uczenia	MSE		
						$L$	$V$	$T$
$PGA, r_e, En$	$r_{WA}$	SSSN	1	3-3-1	40	0,0222	0,0244	0,0262
		BNN	2	3-46-1	80	0,0181	0,0221	0,0221
		SSN+reg.	3	3-40-1	10	0,0210	0,0256	0,0275
$PGV, r_e, En$	$r_{WV}$	SSSN	4	3-6-1	40	0,0052	0,0062	0,0040
		BNN	5	3-12-1	33	0,0079	0,0054	0,0026
$PGA, r_e, X, Y, En$	$r_{WA}$	SSSN	6	5-6-1	55	0,0208	0,0175	0,0192
		BNN	7	5-66-1	18	0,0193	0,0204	0,0214
$PGV, r_e, X, Y, En$	$r_{WV}$	SSSN	8	5-7-1	50	0,0034	0,0049	0,0032
		BNN	9	5-46-1	31	0,0070	0,0037	0,0022


Przykładowo na rysunku 3 przedstawiono zależność błędów  $MSE$  od liczby neuronów w warstwie ukrytej przy 40 epokach uczenia w przypadku sieci nr 1 (por. tabela 1). Zdecydowano się na zastosowanie sieci z 3 neuronami w warstwie ukrytej, w przypadku której uzyskano najmniejsze błędy  $MSE$ . Na kolejnym rysunku 4 pokazano zmiany błędu  $MSE$  w zależności od wartości współczynnika regularyzacji  $\gamma$  w przypadku sieci nr 3 (por. tabela 1). Widać, że dobór wartości współczynnika  $\gamma$  może mieć istotny wpływ na otrzymane błędy  $MSE$  uczenia, walidacji oraz testowania sieci z regularyzacją. Przykładowo, w przypadku prognozowania ułamka  $r_{WA}$  zdecydowano się na sieć ze współczynnikiem  $\gamma = 0,05$ , co spowodowało równoczesne uzyskanie małych błędów  $MSE$  uczenia, walidacji oraz testowania.

Natomiast na rysunku 5 pokazano wyniki analizy wielkości błędu  $MSE$  w zależności od liczby epok uczenia przy 46 neuronach w warstwie ukrytej bayesowskiej sieci nr 9 (por. tabela 1).




Rys. 3. Zależność błędu  $MSE$  od liczby neuronów w warstwie ukrytej sieci neuronowej do przewidywania ułamka  $r_{WA}$

Fig. 3.  $MSE$  vs. the number of neurons in the hidden layer of neural network for the  $r_{WA}$  prediction



Rys. 4. Zależność błędu  $MSE$  od współczynnika regularyzacji  $\gamma$

Fig. 4.  $MSE$  vs. the regularization ratio  $\gamma$

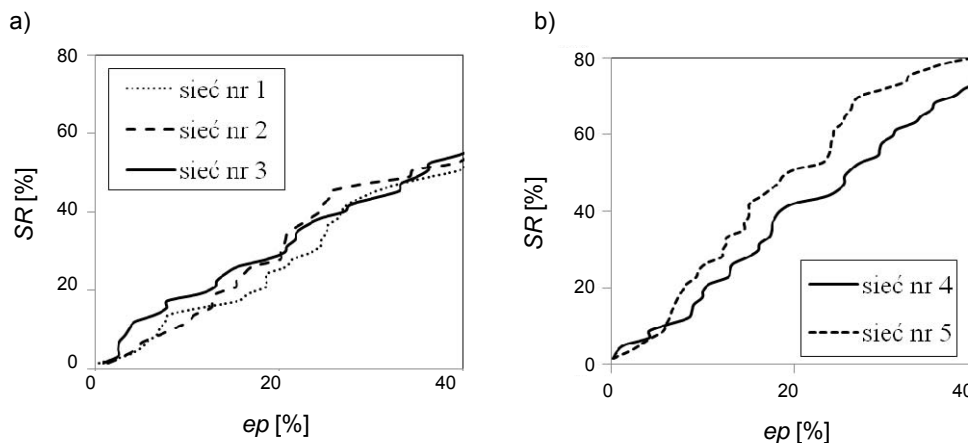


Rys. 5. Zależność błędu  $MSE$  od liczby epok uczenia w przypadku sieci bayesowskiej (sieć nr 9)

Fig. 5.  $MSE$  vs. the number of learning epochs in case of the bayesian network

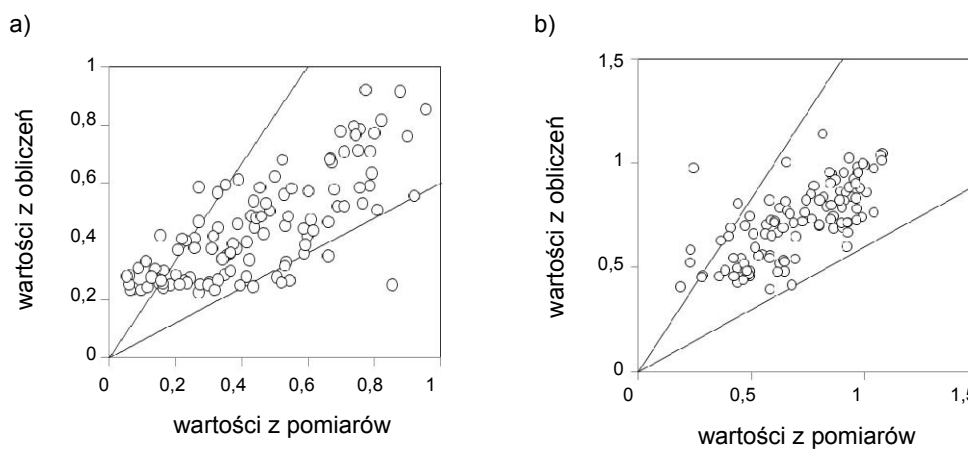
Na rysunku 6 porównano przykładowo procent sukcesu ( $SR$ ) testowania sieci nr 1, 2, 3 (a) oraz sieci nr 4, 5 (b) (por. tabela 1) dla różnego typu zaproponowanych sieci do prognozowania wartości ułamków. Na rysunku 7 przedstawiono porównania wartości ułamków  $r_{WA}$  i  $r_{WV}$  wyznaczonych na podstawie pomiarów i obliczonych za pomocą odpowiednio sieci nr 3 oraz sieci nr 9 w zbiorach testujących. Zaznaczono granice błędu względnego  $ep = 40\%$ . Stwierdzono (rys. 7), że w przypadku wykorzystania w obliczeniach sieci bayesowskich, w zakresie małych wartości ułamków  $r_{WA}$  (do 0,2), w zbiorze testującym otrzymuje się stosunkowo duże różnice między wartościami ułamków uzyskanymi z pomiarów i wartościami z obliczeń. Może być to spowodowane stosunkowo małą liczbą wzorców z ułamkami  $r_{WA}$  o wartościach mniejszych niż 0,2.





Rys. 6. Procent sukcesu  $SR$  neuronowej prognozy przekazywania drgań z gruntu na fundament budynku: a) prognozowanie ułamka  $r_{WA}$ ; b) prognozowanie ułamka  $r_{WV}$

Fig. 6. Success Ratio  $SR$  for the neural prediction of the transmission of ground vibrations to building foundation: a) prediction  $r_{WA}$ ; b) prediction  $r_{WV}$



Rys. 7. Wartości  $r_{WA}$  i  $r_{WV}$  wyznaczone na podstawie pomiarów i obliczone za pomocą proponowanych sieci w zbiorach testujących: a) sieć nr 9, b) sieć nr 3

Fig. 7. Experimentally evaluated values of  $r_{WA}$  i  $r_{WV}$  versus predicted ones with networks proposed in testing sets: a) network nr 9, b) network nr 3

Ze wszystkich przeprowadzonych analiz wynika, że w przypadku prognozowania ułamka  $r_{WA}$  przy zastosowaniu sieci z wektorami wejścia zarówno z trzema parametrami (sieci nr 1, 2, 3), jak i pięcioma parametrami (sieci nr 6, 7) wszystkie zaproponowane sieci dają porównywalne przybliżenia. Podobne rezultaty uzyskano za pomocą sieci nr 8, 9 do prognozowania przekazywania wypadkowych prędkości drgań na podstawie pięciu para-

metrów na wejściu sieci. W przypadku prognozowania ułamka  $r_{WV}$  za pomocą sieci 4, 5 z trzema parametrami w wektorze wejścia, najlepsze wyniki we wszystkich zbiorach (uczącym, walidującym oraz testującym) uzyskano, używając bayesowskich sieci neuronowych.

#### 4. Wnioski

W związku z trudnościami, jakie występują w prognozowaniu różnic w jednocześnie trwających drganiach gruntu i fundamentu budynku, wydaje się, że zaproponowane sieci neuronowe mogą być przydatne do przewidywania redukcji maksymalnych wypadkowych przyspieszeń oraz prędkości drgań. Z porównania przydatności SSSN, SSN z regularyzacją oraz BNN wynika, że nieco dokładniejsze wyniki prognozowania ułamka  $r$  uzyskuje się w przypadku zastosowania bayesowskich sieci neuronowych, np. różnice w procencie sukcesu  $SR$  w poszczególnych zakresach błędów względnych, w zbiorze testującym mogą dochodzić nawet do kilkunastu procent.

#### Literatura

- [1] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
- [2] Waszczyszyn Z., *Bayesowskie sieci neuronowe w analizie problemów regresji*, Zeszyty Naukowe Politechniki Rzeszowskiej 258, Mechanika 74, Rzeszów-Bystre 2008.
- [3] 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, Wydawnictwo Politechniki Białostockiej, 2006, 187-196.
- [4] Kuźniar K., *Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych*, Monografia 310, Inżynieria Ładowa, Wydawnictwo Politechniki Krakowskiej, Kraków 2004.
- [5] Kuźniar K., Chudyba Ł., *Analiza wpływu kierunku propagacji drgań od wstrząsów górniczych na ich przekazywanie z gruntu na budynek*, Materiały 56. Konferencji Naukowej KILiW PAN oraz KN PZITB, „Problemy naukowo-badawcze budownictwa”, Krynica, wrzesień 2010, 182-192.
- [6] Bishop C.M., *Pattern recognition and machine learning*, Springer, New York 2006.
- [7] Foresse F.D., Hagan M., *Gauss-Newton approximation to Bayesian learning*, Proceeding of the 1997 International Joint Conference on Neural Networks, 1997, 1930-1935.
- [8] Demuth H., Beale M., Hagan M., *Neural Network Toolbox for use with Matlab 5, User's Guide*, 2005-2007.