

Krzysztof SCHABOWICZ*
Politechnika Wroclawska

NIENISZCZĄCA IDENTYFIKACJA WYTRZYMAŁOŚCI NA ŚCISKANIE BETONU WYSOKOWARTOŚCIOWEGO PRZY WYKORZYSTANIU SIECI NEURONOWYCH

Streszczenie. W referacie przedstawiono rezultaty zastosowania sztucznych sieci neuronowych do identyfikacji wytrzymałości na ściskanie betonu wysokowartościowego, na podstawie parametrów określonych metodami nieniszczącymi. Bazę dla tego obliczeniowego eksperymentu stanowiły badania doświadczalne kilku betonów wysokowartościowych różniących się składem, w tym ilością domieszki superplastyfikatora i dodatku pyłu krzemionkowego. Wykorzystano parametry określone dla badanych betonów metodami ultradźwiękową, sklerometrycznymi i „pull-out”. Uzyskano pozytywny rezultat predykcji neuronowej wytrzymałości na ściskanie badanych betonów, na podstawie parametrów określonych nieniszczącymi metodami. Na uwagę zasługują otrzymane bardzo wysokie wartości współczynników korelacji i niskie błędy względne. Wynik eksperymentu wskazuje na możliwość dokonywania neuronowej identyfikacji wytrzymałości betonu wbudowanego w konstrukcje budowlane.

NDT IDENTIFICATION OF THE COMPRESSION HIGH-STRENGTH CONCRETE USING NEURAL NETWORKS

Summary. Results of the application of artificial neural networks to the identification of the compression strength of high-quality concrete on the basis of parameters determined by non-destructive testing are presented. Tests were carried out on several high-strength concretes differing in their composition, also in their amounts of superplasticizer and silica fume additives. Their parameters were determined by respectively ultrasonics, sclerometry and “pull-out”. The neural prediction of the compression strength of the concretes on the basis of the parameters determined by non-destructive testing proved to be accurate. Very high correlation coefficients and low relative errors were obtained. The experiment has shown that the neural identification of the strength of concrete built in constructions is viable.

1. Wprowadzenie

W pracy zaprezentowano wyniki, jakie otrzymano podczas nieniszczącej identyfikacji wytrzymałości betonu wysokowartościowego przy wykorzystaniu sztucznych sieci neuronowych. Identyfikacja była przeprowadzona na podstawie parametrów określonych doświad-

* Opiekun naukowy: Prof. dr hab. inż. Jerzy Hoła.

czalnie metodami nieniszczącymi. W doświadczeniu wykorzystano metody: ultradźwiękową, sklerometryczne (sklerometr Schmidta typu N i sklerometr HPS) i „pull-out” (Lok Test). W metodzie ultradźwiękowej określany parametrem jest prędkość podłużnych fal ultradźwiękowych V_L , w metodach sklerometrycznych parametrem jest liczba odbicia L oraz ślad zagłębienia D , a w metodzie „pull-out” wartość siły wyrwijającej P [5, 7, 10, 11].

Warto nadmienić, że wciąż wzrastające zainteresowanie problematyką sztucznych sieci neuronowych (SSN) wynika z możliwości ich zastosowania w wielu dziedzinach wiedzy. Są one wykorzystywane również w licznych problemach inżynierskich, w tym również w symulacji, identyfikacji parametrów materiałów oraz ich ocenie [6, 8, 12, 13].

2. Zakres badań

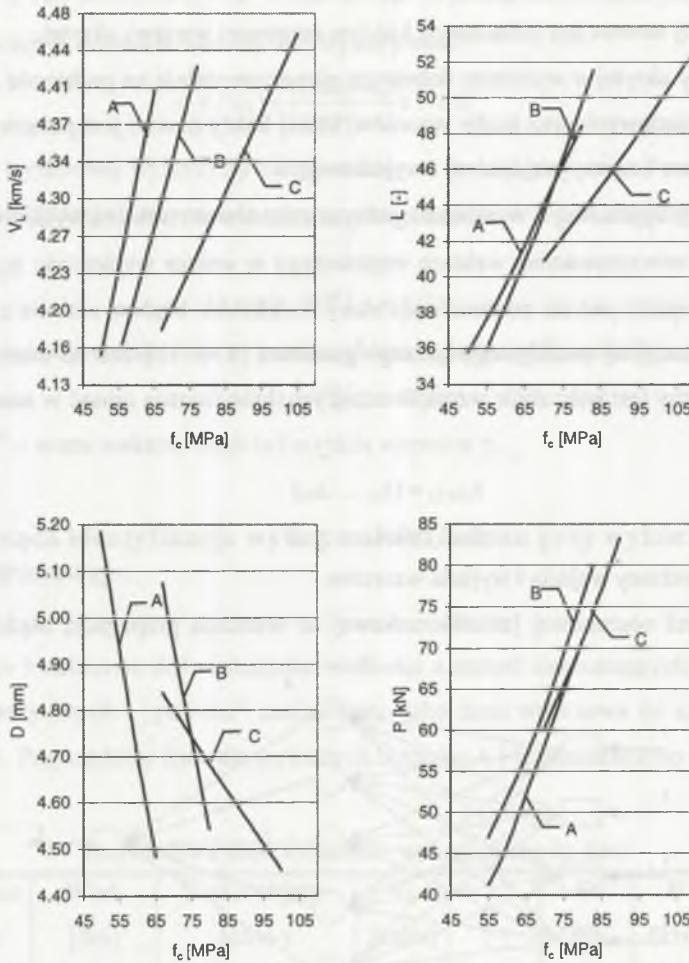
Wykonano trzy betony oznaczone w pracy literami A, B, C o składach podanych w tabeli 1. Ich średnia wytrzymałość na ściskanie mieściła się w przedziale 60 - 100 MPa. Badania tej wytrzymałości, jak również badania metodami nieniszczącymi, przeprowadzono na próbkach sześciennych 15 x 15 x 15 cm.

Skład badanych betonów wysokowartościowych [3]

Tablica 1

Oznaczenie betonów	Składniki w [kg/m ³]					Współczynnik wodno – cementowy w/(c+pk)
	cement	woda	kruszywo	superplastyfikator	pył krzemionkowy	
A	450	180	2029	0	0	0,400
B	450	146	2084	9,00	0	0,324
C	450	140	2069	13,50	31,50	0,291

Zgodnie z zasadami i wymogami zawartymi w [1, 5, 14, 15] przeprowadzono skalowanie w celu dokładnego wyznaczenia związków empirycznych między wytrzymałością na ściskanie badanych betonów i parametrami mierzonymi w metodach ultradźwiękowej, sklerometrycznych oraz „pull-out”. Otrzymane rezultaty przedstawiono w formie wykresów na na rys.1.



Rys. 1. Doświadczalna zależność między wytrzymałością na ściskanie badanych betonów wysokowartościowych a parametrami mierzonymi w metodach: ultradźwiękowej, sklerometrycznych i „pull-out”

Fig. 1. Empirical relationship between compression strength of tested high-grade concretes and parameters measured by ultrasonic technique, sclerometric and “pull-out” technique

3. Sieć neuronowa ze wsteczną propagacją błędów (WPB)

Do realizacji koncepcji identyfikacji wykorzystano sztuczną sieć neuronową warstwową, jednokierunkową ze wsteczną propagacją błędów (WPB). Z doniesień literaturowych wynika, że sieć ta jest szczególnie predysponowana do analizy wielu zagadnień w inżynierii lądowej [4, 9, 13]. Składa się ona z trzech warstw:

- warstwy wejściowej o wymiarze zgodnym z rozmiarem wektora wejściowego, w której każdy neuron jest połączony z każdym neuronem warstwy ukrytej,
- warstwy ukrytej o wymiarze dobranym eksperymentalnie na podstawie liczby wejść, wyjść sieciowych oraz liczby wzorców, której każdy neuron jest połączony z każdym neuronem warstwy wejściowej i wyjściowej,
- warstwy wyjściowej o wymiarze zgodnym z rozmiarem wektora wyjściowego.


Sieć ta jest odwzorowaniem wektora wejściowego w wektor wyjściowy: $x_{(N \times 1)} \rightarrow y_{(M \times 1)}$. Algorytm ten oparty jest na minimalizacji sumy kwadratów błędów uczenia z wykorzystaniem optymalizacyjnej metody największego gradientu [6, 8, 12]. Jest to uczenie z nauczycielem, konieczny jest więc zbiór wzorców uczących, który można opisać w następujący sposób:

$$x_{(N \times 1)} = (x_1, \dots, x_N) \quad (1)$$

$$y_{(M \times 1)} = (y_1, \dots, y_M) \quad (2)$$

gdzie: x_i, y_i – wektory wejścia i wyjścia wzorców.

Schemat sieci neuronowej jednokierunkowej ze wsteczną propagacją błędów przedstawia rys.2.



Rys. 2. Model sieci neuronowej WPB
Fig. 2. Model of neural network BNN

Sygnaly wejściowe x_j mnożone są przez losowo dobrane współczynniki wag w_{ij} , następnie wazone sygnaly są sumowane i jest wyznaczony potencjał v_i :

$$v_i = \sum_{j=1}^N w_{ij} x_j + b_i \quad (3)$$

gdzie: b_i – bias,

x_j – sygnaly wejściowe,

w_{ij} – wagi.

Potencjał v_i jest transformowany w sygnał wyjścia y_i za pomocą sigmoidalnej bipolarnej funkcji aktywacji F , która dla warstwy ukrytej ma postać:

$$y_i = F(v_i) = \frac{1 - \exp(-v_i)}{1 + \exp(-v_i)} \in (-1, 1) \quad (4)$$

Dla warstwy wyjściowej wykorzystywana jest liniowa funkcja aktywacji. Parametry sieci w_{ij} , b_i są obliczane iteracyjnie w procesie uczenia sieci za pomocą zbioru uczącego U , opisanego w postaci:

$$U = \{(x, z)^{(p)} \mid p \in U\} \quad (5)$$

a po nauczaniu sieć jest testowana za pomocą zbioru testującego T , opisanego w postaci:

$$T = \{(x, z)^{(p)} \mid p \in T\} \quad (6)$$

gdzie: $(x, z)^{(p)}$ – znane wektory wejścia i wyjścia wzorców p .

4. Nieniszcząca identyfikacja wytrzymałości betonu przy wykorzystaniu sieci neuronowej

Zmierzone i obliczone doświadczalnie wielkości z metod nieniszczących: ultradźwiękowej, sklerometrycznych i „pull-out” zastosowano jako dane wejściowe do sztucznych sieci neuronowych. Przykładowe dane dla wybranych betonów A i C zamieszczono w tablicy 2.

Tablica 2

Przykładowe dane wejściowe wprowadzane do sieci

Oznaczenia betonów	Wiek [dni]	Ciężar objętościowy [kg/m ³]	V_L [km/s]	L [-]	D [mm]	P [kN]	f_c [MPa]
A	3	2,393	4,11	33,3	5,41	33,3	45,7
	7	2,430	4,21	36,0	5,15	37,5	53,7
	14	2,515	4,27	38,3	4,80	45,3	58,5
	28	2,550	4,40	38,7	4,63	48,4	60,5
C	3	2,490	4,11	38,0	4,97	49,4	60,3
	7	2,519	4,18	40,3	4,86	62,0	68,6
	14	2,539	4,27	43,3	4,80	65,2	73,3
	28	2,565	4,34	46	4,55	80,1	90,7

Wyjście sieci stanowiła jedna wielkość przypisana wytrzymałości betonu na ściskanie. Wszystkie wartości zostały przeskalowane na zakres [0, 1].


Do uczenia sieci zastosowano metodę wstecznej propagacji błędu z członem momentum. W tym celu wykorzystano komputerowy symulator sieci MATLAB – Neural Networks Toolboks [2].

Sieci neuronowe o takiej architekturze uczono na losowo wybranych 128 wzorcach uczących (U) oraz testowano na 24 wzorcach testujących (T). Liczbę neuronów w warstwie ukrytej dobierano eksperymentalnie na podstawie analizy otrzymanych średnich wartości błędu. Sieci uczono do 5000 epok (kroków iteracyjnych). Błąd uczenia obliczono za pomocą wzoru na średni błąd kwadratowy, opisany zależnością:

$$MSE(P) = \frac{1}{P} \sum_{p=1}^P (z_i^{(p)} - y_i^{(p)})^2 \quad (7)$$

gdzie: $P \in \{U, T\}$.

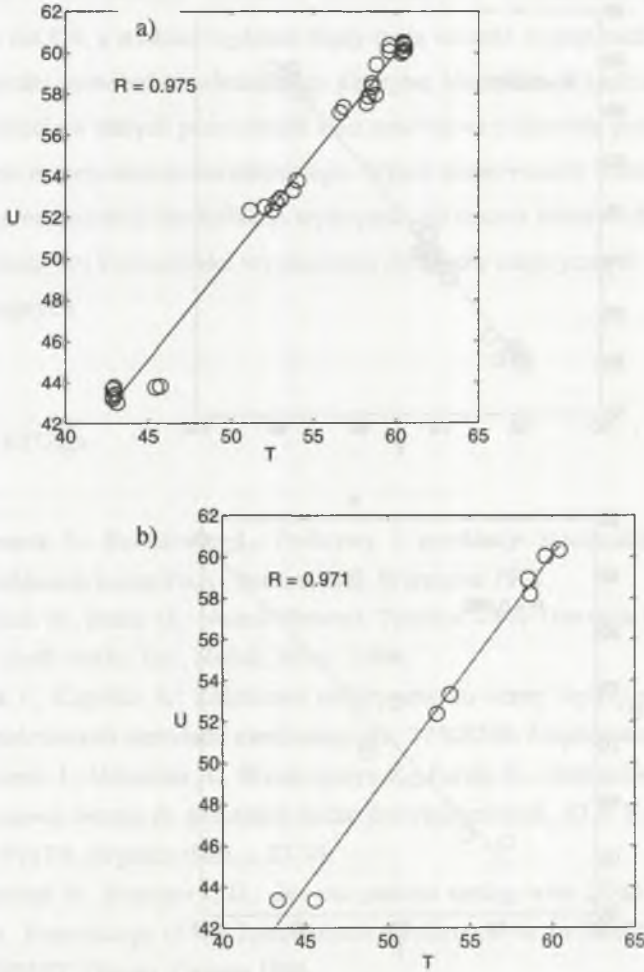
Poziom dokładności szacowano za pomocą współczynnika korelacji R. Po zakończeniu procesu uczenia otrzymano błędy średnie na poziomie $MSE = 0,01$. Przykładowo sporządzone wykresy błędu MSE dla betonu A i C przedstawia rys.3.



Rys. 3. Przykładowe wykresy błędów MSE: a) dla betonu A, b) dla betonu C
 Fig. 3. Illustrative MSE diagrams: a) for concrete A, b) for concrete C

Dla każdego betonu utworzono zbiór składający się z 32 wzorców uczących i 8 testujących. Na wejściu do sieci neuronów podawano cztery wielkości, a na wyjściu jedną. Przyjęto jedną warstwę ukrytą, a korzystając z symulacji wyznaczono liczbę neuronów w tej warstwie. Dla betonu A przyjęto ich dziesięć. Warto nadmienić, że sieć uczona była z momentum.

Współczynnik wykorzystywany przy naliczaniu momentu doświadczalnie przyjmowano z przedziału 0,1 - 0,9. Dla betonu A najlepsze wyniki otrzymano przyjmując jego wartość 0,5. Uzyskane wyniki dla tego betonu, uczenia i testowania sieci wraz z współczynnikami R pokazano na rys. 4.

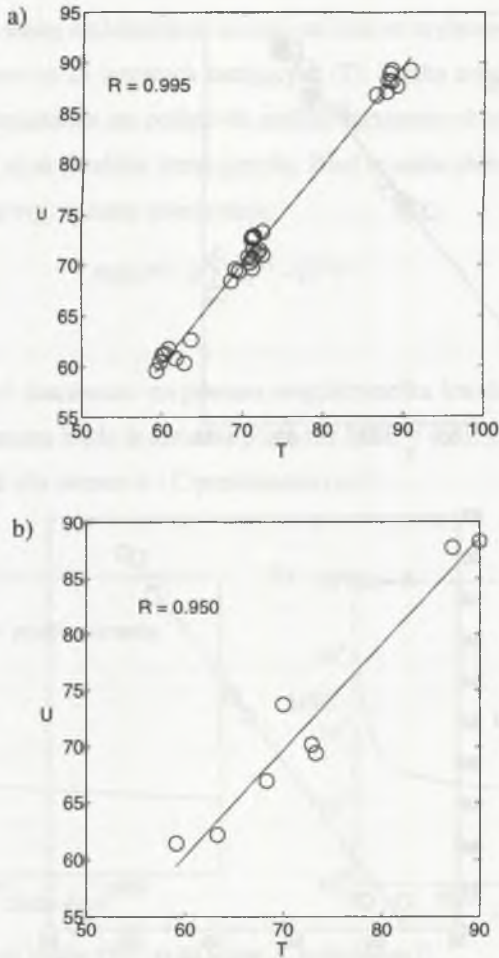


Rys. 4. Beton A. Architektura sieci 6-10-1. Wyniki otrzymane za pomocą sieci neuronowej: a) dla zbioru uczącego, b) dla zbioru testującego

Fig. 4. Concrete A. Network architecture: 6-10-1. Results obtained by means of neural network: a) for teaching set, b) for testing set

Dla betonu C przyjęto taką samą liczbę wejść i wyjść sieciowych, jak dla betonu A. Korzystając z symulacji wyznaczono liczbę neuronów warstwie ukrytej dla tego betonu i przy-

jęto ich dwanaście. Uzyskane wyniki uczenia i testowania sieci pokazano na rys.5. Sieć dla tego betonu uczona była z momentum. Współczynnik dla naliczania momentum doświadczalnie przyjęto jako 0,7. Położenie punktów nie obarczonych żadnym błędem pokazano na linii ciągłej.



Rys. 5. Beton C. Architektura sieci 6-12-1, 32 wzorców uczących i 8 testujących. Wyniki otrzymane za pomocą sieci neuronowej: a) dla zbioru uczącego, b) dla zbioru testującego

Fig. 5. Concrete C. Network architecture: 6-12-1, 32 teaching patterns and 8 testing patterns. Results obtained by means of neural network: a) for teaching set, b) for testing set

5. Podsumowanie

Rezultaty świadczą o tym, że możliwa jest nieniszcząca identyfikacja wytrzymałości betonu wysokowartościowego z wykorzystaniem sztucznych sieci neuronowych na podstawie parametrów określanych metodami nieniszczącymi. Obliczone współczynniki korelacji są wyższe niż 0,9, a średnie względne błędy mają wartość w granicach 10%. Uzyskany poziom dokładności potwierdza założenie, że algorytm identyfikacji spełnia swoje zadanie. Z dużą dokładnością w danych przedziałach sieci neuronowe poprawnie przewidują wytrzymałość na ściskanie betonu wysokowartościowego. Wynik eksperymentu wskazuje na możliwość dokonywania neuronowej identyfikacji wytrzymałości betonu wbudowanego w różne konstrukcje budowlane, bez konieczności wyznaczania związków empirycznych i sporządzania krzywych korelacyjnych.

LITERATURA

1. Brunarski L., Runkiewicz L.: Podstawy i przykłady stosowania metod nieniszczących w badaniach konstrukcji z betonu, ITB, Warszawa 1975.
2. Demuth H., Beale M.: Neural Network Toolbox – For Use with MATLAB, User's Guide, The math works, Inc., Natick, Mass., 1994.
3. Hoła J., Kapelko A.: Zależności empiryczne do oceny wytrzymałości betonów wysokowartościowych metodami nieniszczącymi, 27 KKBN, Międzyzdroje 1998, s. 109-112.
4. Kaliszuk J., Urbańska A., Waszczyszyn Z., Furtak K.: Neuronowa analiza trwałości zmęczeniowej betonu na podstawie badań doświadczalnych, XLV Konf. Nauk. KILiW PAN i KN PZiTB, Krynica 1999, s. 27-34.
5. Krenchel H., Petersen C.G.: „In- situ pullout testing with LOK-TEST. Ten years experience, Proceedings of the International Conference on In-Situ/NDT Testing of Concrete, CANMET, Ottawa, Canada 1984.
6. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe, podstawy i zastosowania, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
7. Moczko A., Wysokowski A.: Współczesne metody oceny jakości betonu w budownictwie komunikacyjnym, Inżynieria i Budownictwo, nr 9, 1996.
8. Osowski St.: Sieci neuronowe, OWPW, Warszawa 1994.

9. Rawicki Z., Obiała R., Waszczyszyn Z.: Wyznaczanie parametrów mechaniki pękania betonów ciężkich systemem neuro-rozmytym ANFIS, XLVI Konferencja. Naukowa KILiW PAN i KN PZiTB, Krynica 2000, s.223-230.
10. Runkiewicz L.: Badania in situ konstrukcji z betonu w rzeczoznawstwie budowlanym, Inżynieria i Budownictwo, nr 11, 1996.
11. Runkiewicz L.: Wpływ wybranych czynników na wyniki badań sklerometrycznych betonu.
12. Tadeusiewicz R.: Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.
13. Waszczyszyn Z.: Zastosowanie sztucznych sieci neuronowych w inżynierii lądowej, XLI Konf. Nauk. KILiW PAN i KN PZiTB, Krynica 1995, Materiały pokonf., tom 9, s. 251-288.
14. Instrukcja stosowania metody ultradźwiękowej do nieniszczącej kontroli jakości betonu w konstrukcji, ITB, Warszawa 1977.
15. Instrukcja stosowania Młotków Schmidta do nieniszczącej kontroli jakości betonu w konstrukcji, ITB, Warszawa 1977.

Recenzent: Dr hab. inż. Jerzy Skrzypczyk, prof. PŚI

Abstract

Results of the application of artificial neural networks to the identification of the compression strength of high-quality concrete on the basis of parameters determined by non-destructive testing are presented. Tests were carried out on several high-strength concretes differing in their composition. The average compression strength of the concretes ranged from 60 to 100 MPa. Their parameters were determined by respectively ultrasonics, sclerometry and "pull-out". A layered, unidirectional, backpropagation neural network with momentum was used. The number of neurons in the hidden layer and the value of moment were determined experimentally on the basis of the average error values. The neural network learning and testing results are given. The neural prediction of the compression strength of the concretes on the basis of the parameters determined by non-destructive testing proved to be accurate. Very high correlation coefficients and low relative errors were obtained. The experiment has shown that the neural identification of the strength of concrete built in constructions is viable.