

MICHAŁ JUSZCZYK*

MODELOWANIE KOSZTÓW REALIZACJI BUDYNKÓW MIESZKALNYCH Z ZASTOSOWANIEM ZESPOŁÓW SZTUCZNYCH SIECI NEURONOWYCH

THE COST MODELLING OF RESIDENTIAL BUILDINGS REALIZATION WITH NEURAL NETWORK COMMITTEES

Streszczenie

W artykule zaprezentowano próbę zastosowania zespołów sieci w oszacowaniach kosztów realizacji obiektów budowlanych we wczesnej fazie budowlanego procesu inwestycyjnego. Przedstawiono zmienne proponowanego modelu, typy rozważanych w trakcie modelowania sieci neuronowych oraz sposób i wyniki trenowania. Dla oceny uzyskanych wyników porównano dokładność oszacowań kosztów uzyskanych na podstawie: zespołu sztucznych sieci neuronowych, pojedynczej sieci neuronowej oraz tradycyjnych metod wykorzystujących wskaźniki kosztów.

Słowa kluczowe: oszacowania kosztów, zespoły sztucznych sieci neuronowych, budynki mieszkalne

Abstract

This paper presents attempt to apply neural network committees in the estimation of the realization costs of residential buildings at the early stage of construction project. The variables of proposed model, types of neural networks concerned and the way of training networks are introduced. For the evaluation of the results obtained the accuracy of the cost estimates obtained on basis of neural network committee model, single neural network and traditional unit price methods are compared.

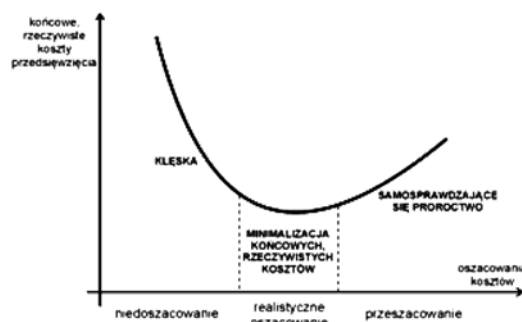
Keywords: cost estimating, committees of neural networks, residential buildings

* Mgr inż. Michał Juszczyk, Zakład Technologii i Organizacji Budownictwa, Wydział Inżynierii Lądowej, Politechnika Krakowska.

1. Wstęp

Oszacowanie kosztów realizacji obiektu budowlanego opiera się na informacji o tym obiekcie. Źródłem informacji jest dokumentacja projektowa opracowywana na kolejnych etapach inwestycyjnego procesu budowlanego od analiz przedprojektowych, poprzez koncepcje projektowe, do projektu budowlanego i wreszcie projektu wykonawczego. Szczegółowość i precyzja dostępnych informacji zmienia się w trakcie postępu prac projektowych – stąd też szacowanie kosztów realizacji obiektu budowlanego powinno być traktowane jako proces, aby rozwojowi prac projektowych towarzyszył wzrost dokładności oszacowań kosztów [11].

Na szczególną uwagę zasługują oszacowania kosztów w początkowej fazie projektowania obiektu, dokonywane na etapie powstawania koncepcji projektowej czy też w początkowej fazie powstawania projektu budowlanego, gdy dostępne są podstawowe informacje o funkcji, formie i konstrukcji. Oszacowania te mają charakter jakościowy pozwalający na określenie pewnego rzędu wielkości kosztów. Mimo to ich znaczenie jest nie do przecenienia. Zarówno przeszacowanie, jak i niedoszacowanie może doprowadzić do nieuzasadnionego wzrostu ostatecznych rzeczywistych kosztów realizacji obiektu budowlanego. Relację tę obrazuje tzw. krzywa Freimana [4] zaprezentowana na rysunku 1.



Rys. 1. Krzywa Freimana

Fig. 1. Freiman's curve

„Decydujący wpływ na kształt i charakter inwestycji mają decyzje podejmowane podczas projektowania – zwłaszcza w jego początkowej fazie. Wtedy również istnieje możliwość najsilniejszego oddziaływania na kształtowanie kosztów. Błędy wówczas popełnione mogą doprowadzić do niepowodzenia całego przedsięwzięcia.”[8]

Celem artykułu jest prezentacja wyników badań prowadzonych przez autora, mających na celu opracowanie modelu regresyjnego opartego na sztucznych sieciach neuronowych pozwalającego na dokonywanie oszacowań kosztów realizacji budynków mieszkalnych wielorodzinnych na etapie powstawania koncepcji projektowej. Proponowany model w założeniach autora powinien wypełnić lukę pomiędzy oszacowaniami wskaźnikowymi stosowanymi w momencie inicjacji budowlanego procesu inwestycyjnego, a metodami kalkulacji kosztorysowej, stosowanymi na etapie projektu budowlanego lub wykonawczego. Spodziewane zalety proponowanego modelu to szybkość oszacowania przy zadowalającej dokładności.

Zaprezentowana problematyka zastosowań zespołów sztucznych sieci neuronowych w oszacowaniach kosztów realizacji budynków mieszkalnych jest kontynuacją pracy badawczej podjętej przez autora artykułu w rozprawie doktorskiej.

2. Zmienne modelu

Przed przystąpieniem do modelowania neuronowego zidentyfikowano zmienne modelu regresyjnego o ogólnej postaci

$$Y = G(X_j; \epsilon), \quad (1)$$

gdzie:

- Y – zmienna opisywana,
- X_j – zmienne opisujące,
- E – błąd modelu,
- G – niejawną zależność funkcyjną realizowaną przez zespół sieci neuronowych.

Zmienną opisywaną Y – zgodnie z przedstawionymi wcześniej założeniami – stanowiły koszty realizacji budynku mieszkalnego lub mieszkalno-usługowego. Koszty realizacji obejmowały:

- koszty robót przygotowawczych placu budowy,
- koszty robót budowlanych (w tym koszty robót stanu początkowego, koszty robót stanu surowego, koszty robót wewnętrznych stanu wykończeniowego, koszty robót zewnętrznych stanu wykończeniowego),
- koszty robót instalacyjnych oraz urządzeń pierwszego wyposażenia.

W oszacowaniu nie uwzględniano kosztów uzbrojenia oraz urządzenia terenu. Zmienna Y przyjmowała wartości numeryczne stanowiące koszty netto bez podatku od towarów i usług VAT.

Identyfikacja zmiennych opisujących przebiegała w następujących etapach:

- analiza literatury, wstępna analiza dokumentacji projektowych, kosztorysowych i rozliczeń kosztów budynków należących do próby badawczej,
- konsultacje proponowanych zmiennych opisujących z ekspertami z dziedziny inwestorskiej kalkulacji kosztorysowej, szacowania kosztów realizacji budowlanych inwestycji mieszkaniowych oraz rozliczeń kosztów budów,
- wytypowanie wstępnego zbioru 33 zmiennych opisujących modelu,
- wielokryterialna analiza porównawcza [9, 12] – redukcja wstępnego zbioru zmiennych opisujących,
- wyłonienie ostatecznego zbioru 13 zmiennych opisujących modelu.

W tabeli 1 przedstawiono ostateczny zbiór zmiennych opisujących wraz z określeniem typów ich wartości.

W ramach badań własnych dokonano analiz dokumentacji projektowej i kosztorysowej oraz rozliczeń kosztów 102 budynków mieszkalnych wielorodzinnych i budynków mieszkalnych wielorodzinnych z wydzieloną funkcją usługową. Budynki stanowiące próbę badawczą wznoszone były w latach 2003–2008 na terenie Krakowa i w najbliższej okolicy (do 10 km w linii prostej od ścisłego centrum miasta). Dokumentacje do analiz pozyskano od podmiotów prowadzących działalność inwestycyjną w zakresie budownictwa mieszkaniowego: przedsiębiorstw deweloperskich, spółdzielni mieszkaniowych oraz towarzystw budownictwa społecznego, przy czym wszelkie dane umożliwiające identyfikację wspo-

mnianych podmiotów zostały zastrzeżone. W efekcie przeprowadzonych badań zgromadzono zbiór 102 próbek danych.

Tabela 1

Zestawienie zmiennych opisujących modelu

Oznaczenie (X_i) i nazwa zmiennej	Wartości zmiennej
X_1 – powierzchnia zabudowy	numeryczne
X_2 – kubatura budynku	numeryczne
X_3 – liczba kondygnacji budynku	numeryczne
X_4 – rodzaj fundamentów	opisowe: ławy, płyta, posadowienie pośrednie
X_5 – konstrukcja budynku	opisowe: tradycyjna, żelbetowa szkieletowa, żelbetowa słupowo ścianowa, żelbetowa ścianowa, żelbetowa monolityczna
X_6 – konstrukcja dachu budynku	opisowe: stropodach płaski o konstrukcji żelbetowej, dach o konstrukcji drewnianej
X_7 – liczba segmentów konstrukcyjnych budynku	numeryczne
X_8 – liczba szybów windowych	numeryczne
X_9 – warunki gruntowe	opisowe: proste, złożone, skomplikowane
X_{10} – powierzchnia użytkowa mieszkań	numeryczne
X_{11} – powierzchnia użytkowa lokali usługowych	numeryczne
X_{12} – powierzchnia użytkowa garaży podziemnych	numeryczne
X_{13} – standard wykończenia budynku	opisowe: standard deweloperski, wykończenie pod klucz

3. Przyjęta koncepcja modelowania neuronowego


Zastosowanie zespołów sztucznych sieci neuronowych¹ stanowi alternatywę dla podejścia polegającego na trenowaniu kilku lub kilkunastu takich sieci i wyborze jednej z nich. Zespół mogą stanowić różne typy sieci o odmiennych architekturach, trenowane z zastosowaniem różnych algorytmów. Wykorzystanie zespołów sieci² (ang. *committees of networks/committee machines*) może prowadzić do zadowalających wyników szczególnie w przypadkach małych zbiorów danych uczących [2, 5].

Na rysunku 2 przedstawiono zasadę zespołowego uśredniania zastosowaną w problemie oszacowań kosztów realizacji budynków mieszkalnych. Zbiór K sieci (tzw. sieci-ekspertów wytrenowanych na tych samych danych) na podstawie danych wejściowych $x(n)$ wyznacza K sygnałów wyjściowych $\hat{y}_i(n)$, $i = 1, \dots, K$. Ostatecznie sygnał wyjściowy zespołu $\hat{y}(n)$ stanowi kombinację sygnałów wyjściowych sieci-ekspertów obliczaną jako średnią arytmetyczną [2, 5]:

¹ Problematyka sieci neuronowych jest szeroko omawiana w literaturze, np. [2, 5, 10, 13]. Spektrum zastosowań sieci neuronowych w inżynierii przedsięwzięć budowlanych przedstawiono syntetycznie w [1, 3].

² We wcześniejszej publikacji [6] przedstawiono próbę zastosowania zespołów sieci do kalkulacji wskaźnika kosztów pośrednich robót budowlanych.

$$\hat{y}(n) = \frac{1}{K} \sum_{i=1}^K \hat{y}_i(n) \quad (2)$$



Rys. 2. Diagram blokowy zespołowego uśredniania

Fig. 2. Ensemble averaging diagram

W omawianym problemie przyjęto następującą koncepcję modelowania neuronowego:

- dane pozyskane w ramach badań własnych podzielono losowo na podzbiory, uczący L , walidacyjny V i testujący T , stanowiące odpowiednio $L = 60\%$, $V = 20\%$, $T = 40\%$ ogółu próbek,
- w rozwiązaniu problemu przyjęto strategię polegającą na wielokrotnym trenowaniu sieci jednokierunkowych warstwowych (MLP) o architekturze 13- H -1, gdzie:
 - 13 – liczba neuronów w warstwie wejściowej sieci wynikająca z liczby zmiennych opisujących,
 - $H = 2, 3, 4$ – liczba neuronów w warstwie ukrytej wynikająca z warunku $L \geq NNP$ (NNP – liczba parametrów sieci),
 - 1 – liczba neuronów w warstwie wyjściowej odpowiadająca liczbie zmiennych opisujących)
- do zespołu kwalifikowano sieci wykazujące najlepszą jakość działania,
- w rozważanych sieciach w neuronach warstwy ukrytej zastosowano alternatywnie następujące funkcje aktywacji:
 - logistyczną:

$$F(v) = \frac{1}{1 + \exp(-\sigma v)} \quad (3)$$

- tangens hiperboliczny (tanh):

$$F(v) = \frac{1 - \exp(-\sigma v)}{1 + \exp(-\sigma v)} \quad (4)$$

- w rozważanych sieciach w neuronach warstwy wyjściowej zastosowano liniową funkcję aktywacji:

$$F(v) = \beta v, \quad (5)$$

gdzie:

- v – potencjał neuronu (odpowiednio w warstwie ukrytej lub wyjściowej),

- rozważane sieci trenowano z zastosowaniem następujących algorytmów uczących:
 - Levenberga-Marquardta (dalej oznaczany LM),
 - Broyden Fletcher Goldfarb Shanno (dalej oznaczany BFGS),
 - gradientów sprzężonych (dalej oznaczanych CG),
- oczekiwaną dokładność modelu określono poprzez dopuszczalny błąd oszacowania, który powinien wynosić nie więcej niż $\pm 25/30\%$ ostatecznych rzeczywistych kosztów realizacji budynku mieszkalnego [por. 7, 13].
Symulacje neuronowe przeprowadzono w pakiecie STATISTICA.

4. Wyniki modelowania neuronowego

Przed przystąpieniem do modelowania neuronowego zgromadzone dane przeskalowano [2] liniowo do przedziału $(0; 1)$ lub $(-1; 1)$ odpowiednio dla sieci z logistyczną lub tangensoidalną funkcją aktywacji w neuronach warstwy ukrytej. Opisane wcześniej rozważane typy sieci trenowano dla 50 losowań podzbiorów L , V i T . Do zespołu zakwalifikowano 5 sieci (przedstawionych w tabeli 2), dla których uzyskano najlepsze wyniki trenowania.

Tabela 2

Charakterystyka sieci wchodzących w skład zespołu

Lp.	Struktura sieci	Algorytm uczący	Funkcja aktywacji neuronów warstwy ukrytej	Liczba epok uczących
1	MLP 13-4-1	BFGS	Logistyczna	102
2	MLP 13-4-1	BFGS	Tanh	114
3	MLP 13-4-1	BFGS	Tanh	81
4	MLP 13-4-1	BFGS	Tanh	94
5	MLP 13-4-1	BFGS	Logistyczna	103

Dla sieci zakwalifikowanych do zespołu (oddzielnie) oraz dla zespołu sieci obliczono współczynniki korelacji R zbiorów wartości zmiennej \hat{Y} uzyskanych w procesach uczenia, testowania i walidacji oraz odpowiadających im znanych (obserwowanych) wartości Y . W tabelach 3 i 4 przedstawiono ustalone wartości błędów uczenia, walidacji i testowania: $RMSE$ dla pojedynczych sieci oraz zespołu, a także $MAPE$ i PE_{max} dla zespołu:

$$RMSE = \sqrt{\frac{1}{P} \sum_{p=1}^P \sum_{i=1}^M (y_i^{(p)} - \hat{y}_i^{(p)})^2} \quad (6)$$

$$MAPE = \frac{1}{P} \sum_{p=1}^P \sum_{i=1}^M \left| \frac{y_i^{(p)} - \hat{y}_i^{(p)}}{y_i^{(p)}} \right| \cdot 100\% \quad (7)$$

$$PE_{max} = \max \left(\left| \frac{y_i^{(p)} - \hat{y}_i^{(p)}}{y_i^{(p)}} \right| \cdot 100\% \right) \quad (8)$$

gdzie:

- P – liczność podzbioru (odpowiednio uczącego, walidującego, testującego),
- P – numer próbki (należącej do podzbioru jw.),
- I – numer neuronu warstwy wejściowej,
- y_i – znane (obserwowane) wartości zmiennej opisywanej,
- \hat{y}_i – wartości zmiennej opisywanej obliczone przez sieć lub zespół.

$RMSE$ (pierwiastek błędu średniokwadratowego – ang. *root mean square error*) stanowił miarę błędu modelu (różnic między wartościami zmiennej opisywanej prognozowanej przez model i wartości zmiennej opisywanej obserwowanej w rzeczywistości) związaną z błędem średniokwadratowym wykorzystywanym w procesie uczenia sieci. $MAPE$ (średni absolutny błąd procentowy – ang. *mean absolute percentage error*) stanowił wyrażoną procentowo miarę dokładności dopasowania wartości zmiennej opisywanej prognozowanej przez model do wartości zmiennej opisywanej obserwowanej w rzeczywistości. PE_{max} (maksymalny błąd procentowy – ang. *maximum percentage error*) stanowił miarę maksymalnego błędu modelu wyrażonego procentowo wyznaczonego jako maksimum spośród różnic par wartości zmiennej opisywanej prognozowanych przez modeli obserwowanych w rzeczywistości.

Tabela 3

Jakość działania pojedynczych sieci zakwalifikowanych do zespołu oraz całego zespołu sieci

Lp.	Struktura sieci	Współczynniki korelacji R			$RMSE$		
		uczenie	walidacja	testowanie	uczenie	walidacja	testowanie
1	MLP 13-4-1	0,9979	0,9948	0,9958	0,913	1,429	1,566
2	MLP 13-4-1	0,9971	0,9940	0,9939	1,091	1,690	1,710
3	MLP 13-4-1	0,9988	0,9971	0,9920	0,688	2,114	1,170
4	MLP 13-4-1	0,9990	0,9944	0,9936	0,639	1,732	1,596
5	MLP 13-4-1	0,9974	0,9948	0,9921	1,021	2,318	1,962
6	Zespół sieci	0,9988	0,9984	0,9979	0,700	1,091	0,918

Tabela 4

Błędy procentowe oszacowań dla zespołu sieci

$MAPE$			PE_{max}		
uczenie	walidacja	testowanie	uczenie	walidacja	testowanie
4,90%	10,70%	4,80%	26,70%	52,30%	18,70%

5. Analiza porównawcza

W tabeli 5 przedstawiono porównanie jakości oszacowań dokonywanych na podstawie: pojedynczej sieci MLP(BFGS)13-4-1³, przedstawionego w niniejszym referacie zespołu

³ Model opracowano podczas wcześniejszej pracy badawczej i przedstawiono w pracy doktorskiej autora referatu.

sieci neuronowych oraz tradycyjnych metod oszacowań wskaźnikowych. Zestawiono błędy *MAPE*, *PEmax* oraz współczynniki korelacji liniowej *R* wyznaczone dla ogółu próbek danych, bez podziału na podzbiory uczący, walidujący i testujący. Najlepszą jakość oszacowań kosztów realizacji budynków mieszkalnych uzyskano dla modelu wykorzystującego zespół sieci neuronowych, na co wskazują najniższe wartości błędów *MAPE* i *PEmax* oraz najwyższy współczynnik korelacji *R*.

Tabela 5

Porównanie jakości oszacowań przy zastosowaniu modeli neuronowych i metod wskaźnikowych

Miara błędu, wsp. korelacji	Błędy oszacowań			
	modele neuronowe		oszacowanie wskaźnikowe	
	pojedyncza sieć	zespół sieci	wg kubatury budynku	wg powierzchni użytkowej budynku
<i>MAPE</i>	12,16%	6,04%	37,41%	35,25%
<i>PEmax</i>	53,34%	52,29%	493,92%	350,22%
<i>R</i>	0,933	0,998	0,796	0,749

6. Wnioski

Przeprowadzone modelowanie neuronowe oraz analiza porównawcza wykazały, że zastosowanie zespołów sieci neuronowych przyniosło poprawę jakości oszacowań kosztów realizacji budynków mieszkalnych względem modelu wykorzystującego pojedynczą sieć oraz tradycyjnych metod wskaźnikowych dla rozpatrywanego zbioru danych badawczych.

W rozważanym problemie najlepsze wyniki trenowania sieci uzyskano dla algorytmu BFGS oraz sieci MLP o strukturze 13-4-1. (Algorytm BFGS oraz struktura MLP 13-4-1 okazały się również najskuteczniejsze w przypadku wcześniejszej pracy badawczej).

W ramach dalszej pracy planowane jest poszerzenie bazy danych uczących oraz dekompozycja zadania umożliwiająca modelowanie neuronowego z podziałem na klasy według kryterium wielkości i kosztu budynków mieszkalnych.

Literatura

- [1] Biernacki J., *Sztuczne sieci neuronowe w inżynierii przedsięwzięć budowlanych*, [w:] praca zbiorowa pod redakcją Kaplińskiego O.: *Metody i modele badań w inżynierii przedsięwzięć budowlanych*, Wyd. PAN, Warszawa 2007.
- [2] Bishop C., *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford 1995.
- [3] Boussabaine A.H., *The use of artificial neural networks in construction management: a review*, Construction Management and Economics, Volume 14, Issue 5, September 1996, 427-436.

- [4] Freiman F., *The Fast Cost Estimating Models*, Transactions of the 27th Annual Meeting of the American Association of Cost Engineers, Philadelphia, 26–29 June 1983.
- [5] Haykin S., *Neural Networks: A Comprehensive Foundation*, Macmillan Publishing, New York 1994.
- [6] Juszczyk M., Leśniak A., *Zastosowanie zespołu sztucznych sieci neuronowych do wyznaczania wskaźnika kosztów pośrednich robót budowlanych*, Konferencja Naukowo-Techniczna, Inżynieria Procesów Budowlanych Wisła 2009, 213-219.
- [7] Kasprówic T., *Inżynieria przedsięwzięć budowlanych*, [w:] praca zbiorowa pod redakcją Kaplińskiego O.: *Metody i modele badań w inżynierii przedsięwzięć budowlanych*, Wyd. PAN, Warszawa 2007, 35-78.
- [8] Kowalczyk Z., Zabielski J., *Kosztorysowanie i normowanie w budownictwie*, WSiP, Warszawa 2005.
- [9] Morrison D.F., *Wielowymiarowa analiza statystyczna*, PWN, Warszawa 1990.
- [10] Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
- [11] Potts K., *Construction cost management. Learning from case studies*, Taylor & Francis, London, New York 2008.
- [12] Szabowski J., Deszcz J., *Metody wielokryterialnej analizy porównawczej. Podstawy teoretyczne i przykłady zastosowań w budownictwie*, Wydawnictwo Politechniki Śląskiej, Gliwice 2001.
- [13] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.