

PRACE NAUKOWO-PRZEGLĄDOWE

Przegląd Naukowy – Inżynieria i Kształtowanie Środowiska nr 55, 2012: 55–64
(Prz. Nauk. Inż. Kszt. Środ. 55, 2012)
Scientific Review – Engineering and Environmental Sciences No 55, 2012: 55–64
(Sci. Rev. Eng. Env. Sci. 55, 2012)

Michał JUSZCZYK, Agnieszka LEŚNIAK

Zakład Technologii i Organizacji Budownictwa, Politechnika Krakowska
Section of Building Technology and Organization, Cracow University of Technology

Przegląd możliwości zastosowania sztucznych sieci neuronowych w zarządzaniu kosztami przedsięwzięć budowlanych

Artificial neural network applications review for cost management in construction projects

Słowa kluczowe: sztuczne sieci neuronowe, zarządzanie kosztami, przedsięwzięcie budowlane
Key words: artificial neural networks, costs management, construction project

Wprowadzenie

Początek zastosowania sztucznych sieci neuronowych w zagadnieniach zarządzania przedsięwzięciami budowlanymi datowany jest na wczesne lata dziewięćdziesiąte ubiegłego wieku (Boussabaine 1996). Problematyka sztucznych sieci neuronowych jest szeroko opisywana w literaturze zagranicznej oraz krajowej (Tadeusiewicz 1993, Haykin 1994, Korbicz i in. 1994, Bishop 1995). Do chwili obecnej podejmowano wiele prób zastosowania sztucznych sieci neuronowych w inżynierii procesów budowlanych w takich problemach, jak: analiza czasu realizacji, efektywność i wydajność

pracy w przedsięwzięciach budowlanych, wspomaganie procesów decyzyjnych w przedsięwzięciach budowlanych, planowanie (harmonogramowanie) przedsięwzięć budowlanych, zarządzanie ryzykiem w przedsięwzięciach budowlanych, zarządzanie przedsiębiorstwem budowlanym. Oprócz wymienionych obszarów podejmowano także próby stosowania sztucznych sieci neuronowych w problemach z zakresu zarządzania kosztami przedsięwzięć budowlanych.

Celem artykułu jest prezentacja wybranych przykładów zastosowania sztucznych sieci neuronowych w zarządzaniu kosztami przedsięwzięć budowlanych. W ramach przeprowadzonego przeglądu przedstawiono problem, zaproponowane rodzaje i budowę sieci, metody ich uczenia, a w przypadku opracowań krajowych – również wyniki prowadzonych przez autorów referatu prac badawczych.

Przykłady zastosowań sztucznych sieci neuronowych w zarządzaniu kosztami przedsięwzięć budowlanych prezentowane w publikacjach zagranicznych

W publikacji Hegazy i Amr (1998) przedstawiono próbę opracowania modelu pozwalającego szacować koszty budowlanych przedsięwzięć drogowych we wczesnym etapie realizacji. Autorzy w modelu zastosowali sztuczną sieć neuronową jednokierunkową warstwową z jedną warstwą ukrytą. Dane do modelowania pozyskano na podstawie informacji z 18 postępowań przetargowych na realizację robót drogowych. Ich analiza pozwoliła autorom na wytypowanie 10 głównych czynników charakteryzujących realizację robót drogowych i mających istotny wpływ na koszty realizacji robót. Czynniki te zakwalifikowano do modelu jako zmienne wejściowe, były to: typ robót, zakres robót, rok realizacji robót, pora roku, w której prowadzone były roboty, lokalizacja robót, czas realizacji robót, ilość robót, liczba pasów drogowych, przeszkody wodne i warunki gruntowe. Zmienną wyjściową modelu stanowił koszt realizacji robót drogowych. Dla ustalenia optymalnych parametrów sieci wykorzystano trzy różne podejścia: uczenie sieci za pomocą algorytmu wstecznej propagacji błędów, optymalizację metodą simplex oraz optymalizację z wykorzystaniem algorytmów genetycznych. Najlepszą sieć otrzymano na podstawie optymalizacji parametrów metodą simplex. Autorzy, wykorzystując przedstawione wyniki badań, zaimplementowali najlepszy uzyskany model do programu komputerowego.

W kolejnej publikacji (Williams 2002) przedstawiono problem predykcji ostatecznych kosztów realizacji budowlanych przedsięwzięć. Celem autora było opracowanie modelu pozwalającego przewidywać ostateczne koszty kontraktów zlecanych w trybie przetargowym. Rozważano możliwość zastosowania sztucznych sieci neuronowych oraz analizy regresji. W celu wytypowania danych wejściowych modelu poddano analizie informacje pozyskane z 302 przetargów na roboty drogowe. Przyjęto następujące dane wejściowe: wartości zwycięskich (najniższych) ofert, odchylenia standardowe wartości złożonych ofert, mediany wartości złożonych ofert, liczby złożonych ofert, oczekiwany czas realizacji robót. Zgodnie z założeniami parametr wyjściowy modelu stanowiły ostateczne koszty realizacji robót. Autorzy przedstawili wyniki badań dla liniowych modeli regresyjnych, sztucznych sieci neuronowych o radialnych funkcjach bazowych i modeli hybrydowych stanowiących połączenie modeli regresyjnych i neuronowych. Zaskakująco najlepsze wyniki predykcji uzyskano dla prostego liniowego modelu regresyjnego.

W ostatniej z prezentowanych publikacji, dotyczących problematyki kosztów budowy dróg – autostrad (Wilmot i Mei 2005), przedstawiono wyniki pracy badawczej, której celem było opracowanie procedury szacowania wzrostu kosztów budowy autostrad w czasie. Wzrost kosztów odzwierciedlał wskaźnik LHCI (Louisiana Highway Construction Index). Wskaźnik LHCI obliczano na podstawie kosztów realizacji pięciu rodzajów robót reprezentatywnych dla kosztów realizacji autostrad: robót ziemnych, nawierzchni betonowych, na-

wierzchni asfaltowych, zbrojenia i robót betonowych. Dla oszacowania wartości wskaźnika LHCI opracowano model kompozytowy, składający się z pięciu submodeli – po jednym dla wymienionych wcześniej rodzajów robót. W submodelach wykorzystano jednokierunkowe warstwowe sztuczne sieci neuronowe z jedną warstwą ukrytą. Dane wejściowe stanowiły następujące informacje: koszty robocizny, materiałów i pracy sprzętu, ilość robót, czas realizacji kontraktu, lokalizacja kontraktu, miejsce zlecenia realizacji kontraktu, liczba ofert składanych w danym roku, wariancja wartości składanych ofert, liczba zmian w projektach i specyfikacjach. Dla trenowania sieci wykorzystano algorytm wstecznej propagacji błędów. Najlepsze wyniki uzyskano dla sieci z czterema lub pięcioma neuronami w warstwie ukrytej.

Zastosowanie sztucznych sieci neuronowych do predykcji przepływów pieniężnych w przedsięwzięciach budowlanych stanowiło jeden z wątków przedstawionych w publikacji (Boussabaine i Kaka 1998). Założeniem autorów było opracowanie modelu pozwalającego przewidywać przepływy pieniężne w przedsięwzięciach budowlanych. Zaproponowano model wykorzystujący sześć sieci neuronowych jednokierunkowych warstwowych, pozwalających na predykcję wartości „cash-flow”. Przyjęto podział czasu realizacji przedsięwzięć na 10 równych okresów. Dane wejściowe sieci stanowiły wartości przepływów pieniężnych z n okresów. Na wyjściu sieci „wracały” prognozę przepływów finansowych na m kolejnych okresów. Dla sieci przyjęto *ad hoc* 40 neuronów w warstwie ukrytej. Do uczenia sieci au-

torzy wykorzystali algorytm wstecznej propagacji błędów.

Kolejny wymieniony we wprowadzeniu problem dotyczył predykcji odchyień kosztów w realizacji przedsięwzięć związanych z remontem obiektów budowlanych (Attala i Hegazy 2003). Autorzy przedstawili wyniki przeprowadzonych prac nad budową modelu pozwalającego przewidywać odchylenie kosztów dla wspomnianego typu robót. Na podstawie analizy 50 przypadków zidentyfikowano czynniki wpływające na odchylenie kosztów w inwestycjach remontowych. Postaci modelu poszukiwano eksperymentalnie. Dane wejściowe modelu stanowiło 18 zmiennych związanych z planowaniem robót, procesem przetargowym, kontrolą postępu, kosztów i jakości robót, komunikacją pomiędzy uczestnikami, kontrolą bezpieczeństwa pracy i odbiorami końcowymi robót. Parametrem wyjścia był wskaźnik odchylenia kosztów CPI, zdefiniowany przez autorów. Ostatecznie zaproponowano do rozwiązania problemu sieć neuronową jednokierunkową warstwową z trzema warstwami ukrytymi. Do trenowania sieci wykorzystano algorytm wstecznej propagacji błędów. Uzyskane wyniki uznano za zadowalające. Autorzy przedstawili także program komputerowy umożliwiający predykcję wskaźnika odchylenia kosztów w praktyce.

Inne zastosowanie SSN, prezentowane w publikacjach zagranicznych, dotyczy oceny wykonania budżetu przedsięwzięcia budowlanego (Chua i in. 1997). Autorzy na podstawie metod statystycznych wyłonili 8 kluczowych czynników wpływających na jakość wykonania budżetu przedsięwzięcia budowlanego: liczbę poziomów organizacyjnych po-

między project managerem a mistrzami, doświadczenie menedżera projektu w realizacji przedsięwzięć o podobnym zakresie, dostępność kompletnych projektów wykonawczych w momencie rozpoczęcia budowy, posiadanie studium wykonalności, rotację członków zespołu zarządzającego projektem, częstotliwość spotkań kontrolnych w trakcie realizacji budowy, częstotliwość aktualizacji budżetu oraz system kontroli budżetu. Miary wymienionych powyżej czynników stanowiły dane wejściowe modelu opartego na jednokierunkowej warstwowej sztucznej sieci neuronowej. Na wyjściu sieć „zwracała” ocenę wykonania budżetu przedsięwzięcia budowlanego. Parametr wyjściowy o wartości: -2, -1, 0, 1, 2, oceniał budżet odpowiednio jako: zły, słaby, średni, dość dobry, dobry. Autorzy w modelu zastosowali sieć o dwóch warstwach ukrytych. Do uczenia sieci zastosowano algorytm wstecznej propagacji błędów.

Ostatnim z prezentowanych przykładów wykorzystania sieci neuronowych jest próba oszacowania kosztów ogólnych budowy (El Sawy i in. 2011). Autorzy zaproponowali model oszacowania kosztów metodą wskaźnikową, w której wartość kosztów wylicza się za pomocą wskaźnika oraz podstawy ich naliczania. W założeniu metody wskaźnik jest wyznaczany przez sieć neuronową, a podstawę stanowią całkowite koszty przedsięwzięcia. Do rozwiązania problemu zaproponowano sieć jednokierunkową wielowarstwową. Parametry wejściowe sieci stanowiło 10 czynników, mających wpływ na koszty ogólne budowy i określonych w badaniach ankietowych: rodzaj firmy, rozmiar przedsięwzięcia, czas trwania, typ inwestycji, lokalizacja,

rodzaj klienta, typ kontraktu, wykonawca – Joint-Venture, specjalne wymagania sprzętowe i dodatkowa siła robocza. Do trenowania sieci wykorzystano algorytm wstecznej propagacji błędów. Model uznano za wiarygodny, a jego dokładność określono na poziomie 80%.

Przykłady zastosowania sztucznych sieci neuronowych w zarządzaniu kosztami przedsięwzięć budowlanych prezentowane w publikacjach krajowych

Można wymienić tu m.in. publikacje, dotyczące wyznaczania wskaźnika kosztów pośrednich robót budowlanych (Biernacki i Leśniak 2004, Biernacki 2007, Leśniak 2007, Juszczyk i Leśniak 2009) oraz modelowania kosztów realizacji budynków mieszkalnych (Juszczyk 2008, 2010).

W pierwszym przykładzie zaproponowano model w postaci sztucznej sieci neuronowej, który zmierzał do wyznaczenia wskaźnika kosztów pośrednich. W kalkulacji kosztorysowej koszty pośrednie najczęściej wylicza się za pomocą wskaźnika tych kosztów oraz ustalonej podstawy ich naliczania (tzw. metoda wskaźnikowa). Ta prosta i szybka metoda nie uwzględnia jednak indywidualnych warunków realizacji i specyfiki robót, co sprawia, że jej istotną wadą jest mała dokładność. Zastosowanie sztucznych sieci neuronowych do wyznaczenia wskaźnika umożliwi uwzględnienie indywidualnego charakteru planowanych robót w postaci parametrów wejściowych.

Do rozwiązania badanego problemu, jako pierwsze podejście, zastosowano

sieci jednokierunkowe wielowarstwowe. Przyjęto najprostszą postać sieci z jedną warstwą ukrytą, o strukturze 7-3-1. Parametrami wejściowymi sieci było 7 czynników opisujących indywidualny charakter robót: rodzaj robót, złożoność przedsięwzięcia, czas realizacji przedsięwzięcia, usytuowanie budowy, odległość placu budowy od siedziby firmy, realizacja robót w okresie zimowym i koszty podwykonawców. Wielkość wskaźnika stanowiła parametr wyjściowy sieci. Naukę sieci przeprowadzono z wykorzystaniem algorytmu Levenberga-Marquardta. Bazę danych stanowiły 72 przypadki zrealizowanych przedsięwzięć budowlanych. Wykonano 100 losowań zbioru uczącego ($L = 50$), pozostawiając pozostałe próbki jako zbiór testujący ($T = 22$). Dla każdego losowania przeprowadzono naukę i testowanie sieci. Wartości pierwiastka ze średniego błędu kwadratowego $RMSE$ dla zbioru uczącego (RMSL) i testującego (RMST) dla 100 losowań przedstawiono w tabeli 1.

W drugim podejściu (Juszczak i Leśniak 2009) założono, że wielkość

wskaźnika będzie parametrem wyjściowym sieci tworzących zespół. Formowanie zespołów sieci, według Bishop (1995) i Haykin (1994), może prowadzić do poprawy wyników, szczególnie gdy baza danych jest małoliczna bądź zaszumiona. Wartość wskaźnika ustalano na podstawie zasady zespołowego uśredniania.

W rozwiązaniu problemu przyjęto strategię, polegającą na wielokrotnym uczeniu sieci jednokierunkowych warstwowych (MLP) o architekturach: 7-2-1, 7-3-1, 7-4-1. Przed przystąpieniem do procesu uczenia losowano zbiór uczący (L), liczący 70% próbek, zbiór testowy (T), liczący 15% próbek, oraz zbiór walidacyjny (V), liczący 15% próbek. Na podstawie 300 symulacji neuronowych utworzono zespół, w skład którego weszło 10 sieci. Charakterystykę 10 sieci tworzących zespół można odnaleźć w pozycji Juszczak i Leśniak (2009). Wartości pierwiastka ze średniego błędu kwadratowego $RMSE$ dla zbioru uczącego (RMSL) i testującego (RMST) dla zespołu sieci przedstawiono w tabeli 2.

TABELA 1. Wyniki uczenia i testowania sieci
TABLE 1. Results of learning and testing of neural network

Dla 100 losowań zbioru uczącego For 100 draws of the training set	Błąd RMS dla zbioru / RMS error for the set	
	RMSL	RMST
Średnia wartość błędu The average value of the error	0,1362	0,1369

Źródło: Biernacki i Leśniak (2004).

TABELA 2. Jakość działania zespołu sieci
TABLE 2. The quality of neural networks committees working

Struktura sieci Network structure	Współczynniki korelacji Correlation coefficients		Błędy sieci Networks errors	
	uczenia (L) learning	testowania (T) testing	RMSL	RMST
Zespół sieci Networks committees	0,8572	0,9715	0,1212	0,1016

Źródło: Juszczak i Leśniak (2009).

Wyniki oszacowania kosztów pośrednich badanych przedsięwzięć na podstawie wskaźnika kosztów pośrednich wyznaczanych przez jednokierunkową SSN oraz zespół sieci porównano z wynikami otrzymanymi przy wykorzystaniu średniego wskaźnika publikowanego na rynku budowlanym (według informacji cenowych „Sekocenbud”). Porównanie dokładności oszacowania kosztów przeprowadzono na podstawie błędu względnego kosztów pośrednich. Wyniki podano w tabeli 3.

Zastosowanie wskaźnika kosztów pośrednich wyznaczanego przez zespół sieci neuronowych zwiększyło dokładność prognozowania kosztów pośrednich w stosunku do próby z zastosowaniem jednej sieci neuronowej. W stosunku do metody szacowania kosztów na podstawie wskaźnika publikowanego różnica średniego błędu względnego sięga blisko 50%.

Drugim przykładem krajowym jest wykorzystanie sieci neuronowych do szacowania całkowitych kosztów realizacji budynków mieszkalnych (Juszczuk 2008, 2010). Najczęściej do szacunkowego określenia kosztów wznoszenia obiektów budowlanych stosuje się jed-

ną z dwóch metod: metodę elementów scalonych i metodę uproszczoną znaną z kalkulacji kosztorysowej. Obie metody pozwalają na szacowanie kosztów obiektu budowlanego na określonym poziomie agregacji robót budowlanych. Przy stopniu agregacji wyższym niż element budowlany stosuje się ceny jednostkowe, będące faktycznie wskaźnikami ustalonymi w odniesieniu do przyjętej jednostki przedmiarowej obiektu budowlanego. Wskaźniki są obliczane na podstawie szczegółowych kalkulacji kilku wzorcowych obiektów budowlanych. Wobec różnorodności rozwiązań konstrukcyjnych, technologicznych i materiałowych, a także indywidualnego charakteru obiektów oszacowanie ma charakter interpolacyjny lub ekstrapolacyjny i jest niedokładne.

Proponowany model z wykorzystaniem SSN (Juszczuk 2010) wypełnia lukę między oszacowaniami wskaźnikowymi, stosowanymi momencie inicjacji budowlanego procesu inwestycyjnego, a metodami kalkulacji kosztorysowej, stosowanymi na etapie projektu budowlanego lub wykonawczego. Bazę danych stanowiły 102 próbki. Były to informacje uzyskane z analiz dokumentacji i rozliczeń kosz-

TABELA 3. Porównanie błędów względnych oszacowania kosztów pośrednich
TABLE 3. Comparison of indirect costs relative estimation errors

Błąd względny Relative error	Wartość błędu / Error value [%]		
	dla prognozy sieci 7-3-1 for 7-3-1 network forecast	dla prognozy zespołu sieci for networks com- mittees forecast	dla prognozy według wskaźnika publiko- wanego for the forecast by the published index
Średni błąd względny The average relative error	31	27,5	52
Maksymalny błąd względny The maximum relative error	122	91,5	167

Źródło: Juszczuk i Leśniak (2009).

tów 102 budynków mieszkalnych. Cechy obiektów to parametry wejściowe sieci. Parametrem wyjściowym były całkowite koszty realizacji budynku. W rozwiązaniu problemu przyjęto strategię, polegającą na wielokrotnym trenowaniu sieci jednokierunkowych warstwowych (MLP) o architekturze 13- H -1, gdzie $H = 2, 3, 4$ – liczba neuronów w warstwie ukrytej. Do zespołu kwalifikowano sieci wykazujące najlepszą jakość działania. W uczeniu sieci wykorzystany został efektywny, szybko zbieżny algorytm BFGS (Broyden-Fletcher-Goldfarb-Shanno). W tabelach 4 i 5 przedstawiono wartości błędów uczenia, walidacji i testowania: $RMSE$ – dla pojedynczych sieci oraz zespołu, a także $MAPE$ (mean

absolute percentage error) i PE_{max} (maximum percentage error) dla zespołu.

Jakość oszacowań dokonywanych na podstawie pojedynczej sieci MLP (BFGS) 13-4-1, zespołu sieci neuronowych oraz tradycyjnych metod oszacowań wskaźnikowych, przedstawiono w tabeli 6. Najlepszą jakość oszacowań kosztów realizacji budynków mieszkalnych uzyskano dla modelu wykorzystującego zespół sieci neuronowych, na co wskazują najmniejsze wartości błędów $MAPE$ i PE_{max} oraz najwyższy współczynnik korelacji R .

Przeprowadzone modelowanie neuronowe oraz analiza porównawcza wykazały, że zastosowanie sieci neuronowych przyniosło poprawę jakości oszacowań kosztów realizacji budynków

TABELA 4. Jakość działania pojedynczych sieci zakwalifikowanych do zespołu oraz całego zespołu
TABLE 4. The quality of single networks and networks committees effectiveness

Lp. No.	Struktura sieci Network architecture	Współczynniki korelacji, R Correlation coefficient			$RMSE$		
		uczenie learning	walidacja validation	testowanie testing	uczenie learning	walidacja validation	testowanie testing
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

Źródło: Juszczak (2010).

TABELA 5. Błędy procentowych oszacowań dla zespołu sieci [%]
TABLE 5. Percentage estimation errors for networks committees [%]

$MAPE$			PE_{max}		
Uczenie Learning	walidacja validation	testowanie testing	uczenie learning	walidacja validation	testowanie testing
4,90	10,70	4,80	26,70	52,30	18,70

Źródło: Juszczak (2010).

TABELA 6. Porównanie jakości oszacowań przy zastosowaniu modeli neuronowych i metod wskaźnikowych

TABLE 6. Comparison of the quality estimation by using neural models and indicator-based method

Wyszczególnienie Specification	Błędy oszacowań / Errors of estimates			
	modele neuronowe models based on neural networks		oszacowanie wskaźnikowe estimates based on cost indices	
	pojedyncza sieć single neural network	zespół sieci network committee	według kubatury budynku by cubic capacity	według powierzchni użytkowej budynku by floor area
MAPE [%]	12,16%	6,04%	37,41%	35,25%
PE max [%]	53,34%	52,29%	493,92%	350,22%
R	0,933	0,998	0,796	0,749

Źródło: Juszczuk (2010).

mieszkalnych względem dostępnych metod wskaźnikowych dla rozpatrywanego zbioru danych badawczych. Analiza porównawcza wykazała także, że zastosowanie zespołów sieci neuronowych zwiększyło dokładność oszacowań kosztów realizacji budynków mieszkalnych względem modelu wykorzystującego pojedynczą sieć.

Podsumowanie

Przeprowadzony przegląd wybranych prac badawczych, dotyczących możliwości zastosowania sztucznych sieci neuronowych w zagadnieniach związanych z kosztami przedsięwzięć budowlanych, wskazuje na wielokrotne próby podejmowane zarówno za granicą, jak i w naszym kraju. Warto zwrócić uwagę, że najczęściej w problemach dotyczących oszacowania kosztów w budownictwie proponowane są sieci jednokierunkowe warstwowe, a dominującym algorytmem uczenia jest algorytm wstecznej propagacji błędów. Autorzy próbują także stworzyć modele bardziej

złożone, takie jak modele hybrydowe czy próby zastosowania zespołów sieci. Modele wykorzystujące SSN zazwyczaj proponują szybkie i dostatecznie wiarygodne (a nawet dokładniejsze od metod tradycyjnych) oszacowanie kosztów. Stanowią zatem efektywne, możliwe do stosowania w praktyce narzędzia do planowania. Należy jednak podkreślić, że jednym z warunków sukcesu jest zbudowanie odpowiednich baz danych, zawierających właściwe i wiarygodne informacje, od których zależeć będzie następnie jakość generowanych wyników, a także zbudowanie odpowiedniego narzędzia wspomagającego zastosowanie proponowanych modeli w praktyce.

Literatura

- ATTALA M., HEGAZY T. 2003: Predicting cost deviation in reconstruction projects: artificial neural networks versus regression. *Journal of Construction Engineering and Management* 129, 4: 405–411.
- BIERNACKI J. 2007: Sztuczne sieci neuronowe w inżynierii przedsięwzięć budowlanych. W: *Metody i modele badań w inżynierii*

- przedsięwzięć budowlanych Red. O. Kapliński. PAN, Warszawa.
- BIERNACKI J., LEŚNIAK A. 2004: Próba wyznaczenia wskaźnika kosztów pośrednich robót budowlanych za pomocą sztucznych sieci neuronowych. *Czasopismo Techniczne* 11-B: 3–10.
- BISHOP C. 1995: *Neural Networks for Pattern Recognition*. Oxford University Press, Oxford.
- BOUSSABAIN A.H. 1996: The use of artificial neural networks in construction management: a review. *Construction Management and Economics* 14, 5: 427–436.
- BOUSSABAIN A.H., KAKA A.P. 1998: A neural networks approach for cost flow forecasting. *Construction Management and Economics* 16, 4: 471–479.
- CHUA D.K.H., KOG Y.C., LOH P.K., JASELSKIS E.J. 1997: Model for construction budget performance – neural network approach. *Journal of Construction Engineering and Management* 123, 3: 214–222.
- EL SAWY I., HOSNY H., RAZEK M.A. 2011: A Neural Network Model for Construction Projects Site Overhead Cost Estimating in Egypt. *International Journal of Computer Science* 8, 3, 1: 273–283.
- HAYKIN S. 1994: *Neural Networks: A Comprehensive Foundation*. Macmillan Publishing, New York.
- HEGAZY T., AMR A. 1998: Neural network model for parametric cost estimation of highway projects. *Journal of Construction Engineering and Management* 124, 3: 210–218.
- JUSZCZYK M. 2008: Szacowanie kosztów realizacji obiektów budowlanych z zastosowaniem sztucznych sieci neuronowych. *Prace Naukowe Instytutu Budownictwa Politechniki Wrocławskiej* 91, *Studia i Materiały* 20: 61–67.
- JUSZCZYK M. 2010: Modelowanie kosztów realizacji budynków mieszkalnych z zastosowaniem zespołów sztucznych sieci neuronowych. *Czasopismo Techniczne, Budownictwo* 1-B, 2: 176–185.
- JUSZCZYK M., LEŚNIAK A. 2009: Kalkulacja wskaźnika kosztów pośrednich robót budowlanych z zastosowaniem zespołów sztucznych sieci neuronowych. Konferencja Naukowo-Techniczna „Inżynieria procesów budowlanych”, 2–4.10.2009, Wisła: 213–219.
- KORBICZ J., OBUCHOWICZ A., UCIŃSKI D. 1994: *Sztuczne sieci neuronowe – podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- LEŚNIAK A. 2007: Zastosowanie metody sztucznej inteligencji do wyznaczenia wskaźnika kosztów pośrednich robót budowlanych. *Przegląd Budowlany* 4: 58–60.
- TADEUSIEWICZ R. 1993: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa.
- WILLIAMS T.P. 2002: Predicting completed project cost using bidding data. *Construction Management and Economics* 20, 3: 225–235.
- WILMOT C.G., MEI B. 2005: Neural network modeling of highway construction costs. *Journal of Construction Engineering and Management* 131, 7: 765–771.

Summary

Artificial neural network applications review for cost management in construction projects. Artificial neural network applications review for cost management in construction projects. The paper presents selected sample applications of artificial neural networks in the scope of widely defined cost management of construction projects. It presents a synthesis of a number of foreign publications, as well as achievements of Polish authors on the applications of artificial neural networks in cost management of construction projects. The review of the proposed methods using artificial neural networks included presentation of the objectives of their applications, the proposed types of artificial neural networks and their learning methods, whilst in the case of home studies, the results of research were also presented.

The results of research confirm that the models using artificial neural networks usually allow for quick and sufficiently reliable (and even more accurate than traditional methods) cost estimations. These models are therefore the proposals of tools, which are effective and possible to use in practice. It should be noted that one of the conditions of success in the application of artificial neural networks in relation to problems in cost management of construction projects is to collect a sufficient number and reliable learning data sets.

Authors' address:

Michał Juszczyk, Agnieszka Leśniak
Politechnika Krakowska
Zakład Technologii i Organizacji Budownictwa
ul. Warszawska 24, 31-155 Kraków
Poland
e-mail: mjuszczuk@izwbit.pk.edu.pl
alesnak@izwbit.pk.edu.pl