

4. WSPOMAGANIE DECYZJI PRZETARGOWYCH WYKONAWCÓW Z ZASTOSOWANIEM METOD MATEMATYCZNYCH

Agnieszka Leśniak¹

4.1. WPROWADZENIE

Udział w przetargach ma znaczący wpływ na funkcjonowanie i rozwój przedsiębiorstwa budowlanego. Działania zmierzające do złożenia oferty wymagają czasu i zaangażowania pracowników, i wiążą się z wykorzystaniem zasobów przedsiębiorstwa i poniesieniem nakładów. Oferty na roboty budowlane nie są powtarzalne. Dotyczą różnych przedsięwzięć, różnych inwestorów i ograniczone są różnymi wymaganiami, co sprawia, że wymagają indywidualnego podejścia i pełnego zaangażowania w ich przygotowanie (Cleden, 2011).

Selekcja przetargów, do których startuje przedsiębiorstwo budowlane, jest ważna w aspekcie kreowania pozycji na rynku i wpływa na jego sukces. Szanse wygrania oferty i uzyskania zlecenia zwiększa udział w dużej liczbie przetargów. Jeżeli jednak wiąże się to z częstymi porażkami wykonawcy, to działanie takie może prowadzić do podważenia jego reputacji na rynku i w konsekwencji generować jedynie koszty. Z drugiej strony nieuzasadniona rezygnacja z przetargu to rezygnacja z możliwości osiągnięcia zysku, nawiązania relacji z nowymi inwestorami, rozszerzenia działalności. W pracy (Starzyk, Juszczak i Kozik 2007) zaproponowano „skuteczność ofertowania” jako wewnętrzny czynnik przedsiębiorstwa budowlanego reprezentujący jego mocną lub słabą stronę.

Podjęcie decyzji o przystąpieniu do przetargu uwarunkowane jest wieloma czynnikami. Badania dotyczące identyfikacji tych czynników przeprowadzono na

¹Politechnika Krakowska, Wydział Inżynierii Lądowej, e-mail: alesniak@L3.pk.edu.pl

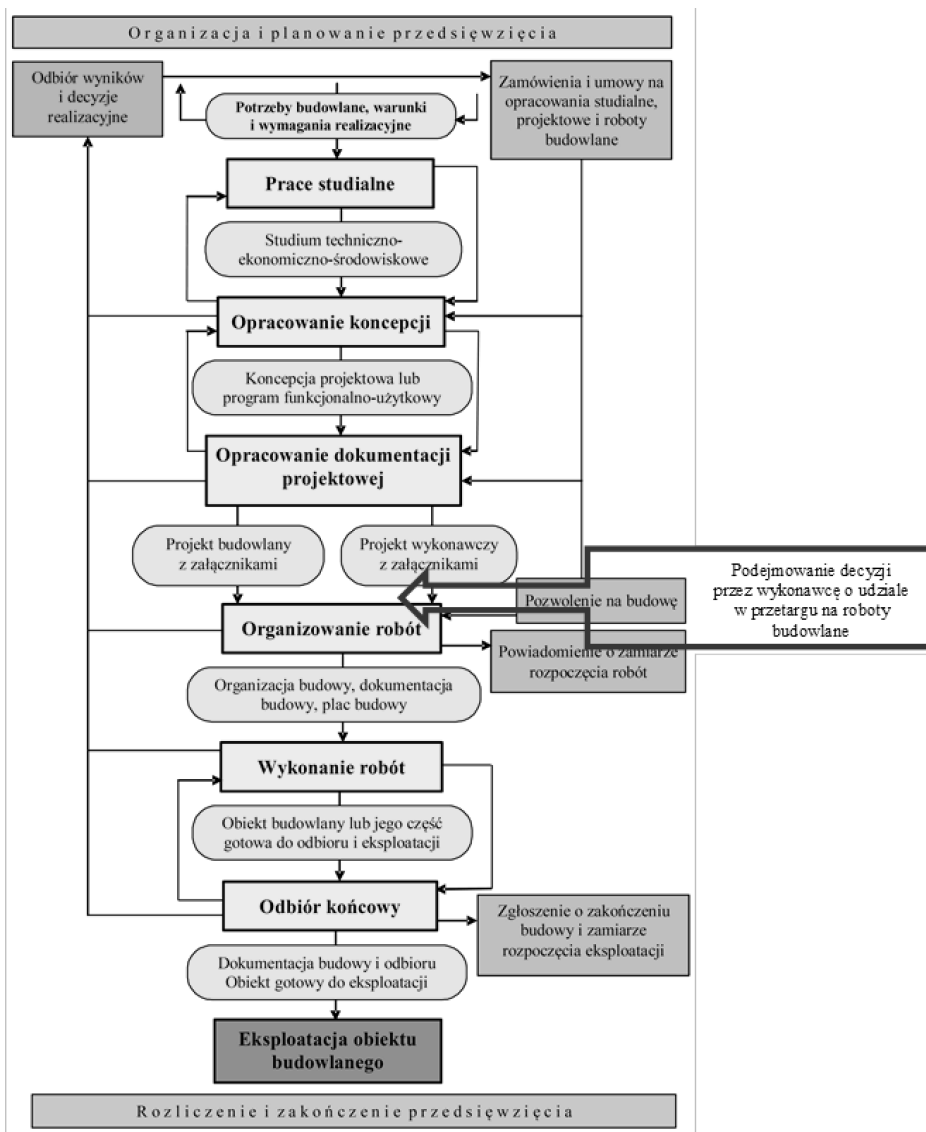
całym świecie już wielokrotnie i zauważono w (Bageis i Fortune, 2009), że w każdym z krajów pojawia się grupa czynników, która jest charakterystyczna tylko dla danego rynku. Wynika z tego, iż czynniki wpływające na decyzje przetargowe zależą nie tylko od przedsięwzięcia, którego dotyczy przetarg, ale także od otoczenia, w którym przedsiębiorstwo działa.

Wykonawca przy podejmowaniu decyzji o przystąpieniu do przetargu najczęściej bazuje na doświadczeniu, subiektywnie postrzeganych informacjach i własnej intuicji. Tymczasem decyzja ta jest złożona, dynamiczna i zależna od wielu czynników (Shash, 1993). Często musi zostać podjęta szybko i w ograniczonym czasie, mimo że związana jest z kwestiami finansowymi. W obliczu dużej konkurencji wykonawcy chętnie poszukują rozwiązań pozwalających maksymalizować szanse na wygranę przetargu i uzyskanie zamówienia.

W celu wspomaganie procesu decyzyjnego i zwiększeniu skuteczności decyzji opracowywane są modele wspomagające ich podejmowanie. Podstawę modeli stanowią najczęściej zidentyfikowane czynniki przetargowe. Model decyzyjny jest w tym przypadku rozumiany jako (Cattell, Bowen i Kaka 2008) matematyczne odwzorowanie rzeczywistości, z proponowaną techniką, która ma na celu pomóc wykonawcy budowlanemu podjąć decyzję o udziale w przetargu, unikając przy tym błędów i przypadkowości. W oparciu o stworzone modele decyzyjne możliwa jest budowa systemów wspomaganie decyzji (SWD), które obejmują (Sroka i Wolny 2009): rozszerzenie zdolności decydenta, pomoc w podejmowaniu decyzji i narzędzia wspomagające użytkownika. System wspomaganie decyzji nie ma na celu zastępowania procesu myślowego decydenta, a jedynie zwiększenie skuteczności podejmowanych decyzji. Dobrze przygotowany proces decyzyjny pozwala zminimalizować ryzyko złe podjętych decyzji, pozwala także wzmocnić pozycję konkurencyjną przedsiębiorstw (Adamska, 2013).

Skuteczne podejmowanie decyzji to jedno z największych wyzwań współczesnego budownictwa (Kapliński, 2011). Wymaga od wykonawcy podejmowania wielu istotnych decyzji w trakcie całego procesu inwestycyjnego. Autorzy wielu prac proponują różne techniki i metody, których celem jest ograniczenie podejmowanego w działalności przedsiębiorstw budowlanych ryzyka (Gajzler, Dziadosz i Szymański 2010; Jaśkowski, Sobotka i Czarnigowska 2014; Kapliński, 2008; Marcinkowski i Koper 2008; Połoński, 2014; Skorupka, 2007; Sobotka, Jaśkowski 2004; Sobotka, Biruk i Jaśkowski 2003). Zagadnienie wspomaganie procesów decyzyjnych wykonawców mieści się w obszarach badawczych inżynierii przedsięwzięć budowlanych (Kapliński, 2007; Kasprowicz, 2015; Kasprowicz, 2002), a w szczególności dotyczy problemów funkcjonowania przedsiębiorstw budowlanych. Miejsce badanego problemu dotyczącego wspomaganie decyzji przetargowych w cyklu realizacji przedsięwzięcia budowlanego przedstawiono na rys. 1.

Celem niniejszej rozdziału jest prezentacja możliwości wspomaganie podejmowania decyzji wykonawcy budowlanego o udziale w przetargu, z wykorzystaniem metod matematycznych.



Rys. 1. Cykl przedsięwzięcia budowlanego z umiejscowieniem badanego problemu.
 Źródło: na podstawie (Kasprowicz, 2015).

Obecnie w obliczu dużej konkurencji, wykonawcy poszukują rozwiązań pozwalających maksymalizować szanse na wygranę przetargu. Na uwagę zasługują spostrzeżenia autorów pracy (Bageis i Fortune 2009), którzy zauważyli, że proces przygotowania oferty, który jest czasochłonny i wymaga wiele wysiłku, może kreować potrzebę posiadania odpowiednich specjalistów. Zazwyczaj duże przed-

siębiorstwa mają większe możliwości zatrudniania takich specjalistów, podczas gdy małe i średnie zdecydowanie bardziej odczuwają potrzebę posiadania narzędzi wspomagających odpowiednią selekcję zleceń i podejmowania decyzji o przystąpieniu do przetargu. Biorąc pod uwagę, że w Polsce wg (danych z Rocznika Statystycznego, 2015) mikro, małe i średnie przedsiębiorstwa stanowią 99,7% podmiotów budowlanych, podjęty temat wydaje się być uzasadniony.

4.2. PRZETARG JAKO FORMA POZYSKIWANIA ZLECEŃ NA ROBOTY BUDOWLANE

Definicję przetargu budowlanego zaproponowano w pracy (Borowicz, 2001) podając, że jest to rodzaj konkursu mającego na celu uzyskanie przez podmiot, który go organizuje, najkorzystniejszej oferty, czyli takiej, która proponuje najkorzystniejsze warunki realizacji roboty lub obiektu budowlanego będącego przedmiotem przetargu. Przetarg nieograniczony to podstawowy tryb udzielania zamówień publicznych (rozdział 2, art. 10 Ustawy Pzp), w którym w odpowiedzi na publiczne ogłoszenie o zamówieniu oferty mogą składać wszyscy zainteresowani wykonawcy (rozdział 3, art. 39 Ustawy Pzp). Tryb ten jest trybem konkurencyjnym, jednoetapowym i jest najczęściej stosowanym trybem w sektorze publicznym, w tym także w zamówieniach na roboty budowlane (Biuletyn Zamówień Publicznych). Tylko w 2016 roku tryb ten został wykorzystany w 79% udzielonych zamówień publicznych (Sprawozdanie Prezesa Urzędu Zamówień Publicznych, 2017). Jego popularność na rynku budowlanym wynika bez wątpienia z braku istnienia ograniczeń do jego stosowania. Zainteresowanie wykonawców przetargami na roboty budowlane jest znaczne, o czym świadczy fakt, że wg (Sprawozdania Prezesa Urzędu Zamówień Publicznych (2017) w 37% ogłoszonych w 2016 roku przetargów składano 5 i więcej ofert.

Stosowanie procedury przetargu nieograniczonego ma istotne zalety (Leśniak, 2016a): nie wymaga uzasadnienia jego stosowania (art. 39 Ustawy Pzp), nie jest skomplikowana, wybór najlepszej oferty odbywa się w oparciu o przyjęte kryteria, czas przebiegu postępowania jest najkrótszy w porównaniu z pozostałymi trybami (Sprawozdanie Prezesa Urzędu Zamówień Publicznych, 2017), jest trybem najbardziej konkurencyjnym – oferty mogą składać wszyscy zainteresowani wykonawcy.

Wśród wad trybu przetargowego można wskazać (Leśniak, 2016a): ryzyko wyboru niesolidnego wykonawcy – zwłaszcza, gdy kryterium ceny jest decydujące, ograniczona możliwość uzgodnienia szczegółów zobowiązań stron ze względu na ograniczone kontakty interpersonalne, konieczność wniesienia wadium (dotyczy zamówień publicznych), koszty przeprowadzenia postępowania ponoszone zarówno przez zamawiającego jak i koszty wykonawcy związane z przygotowaniem odrzuconych ofert.

4.2.1. CZYNNIKI WARUNKUJĄCE UDZIAŁ WYKONAWCY W PRZETARGU


Próby zidentyfikowania czynników wpływających na podejmowanie decyzji o udziale w przetargu były podejmowane wielokrotnie w różnych krajach i na różnych rynkach budowlanych. Pierwsze przeprowadzono wśród wykonawców robót budowlanych w 1988 roku w USA (Ahmad i Minkarah 1988). Szerzej na temat dotychczasowych badań dotyczących czynników przetargowych pisano w pracy (Leśniak, 2016a). Zazwyczaj w badaniach tworzona jest lista czynników, które wg autorów badań mogą mieć znaczący wpływ na decyzje o uczestnictwie w przetargu. W dalszym etapie badań wykonawcy budowlani, w oparciu o swoje doświadczenie, oceniają ważność zaproponowanych czynników, wnosząc często także własne propozycje.

Badania dotyczące czynników wpływających na decyzje polskich wykonawców o przystąpieniu do przetargu przeprowadzono także w Polsce na przełomie 2010/2011 roku (Leśniak, 2016a). W tym celu została opracowana ankieta, w której wykonawcy budowlani określali stopień wielkości wpływu zaproponowanych czynników na decyzję o uczestniczeniu w przetargu. W badaniach wzięło udział 61 wykonawców z południowej części Polski. Uzyskane wyniki były już prezentowane przez autorkę rozdziału w pracach (Leśniak, 2015a; Leśniak, 2016a; Leśniak i Plebankiewicz 2013), poniżej przytoczone zostaną tylko najważniejsze z nich.

W efekcie przeprowadzonych badań wyselekcjonowano 15 czynników wpływających na decyzje o udziale w przetargu w opinii polskich wykonawców: x_1 – rodzaj robót, x_2 – doświadczenie w realizacji podobnych przedsięwzięć, x_3 – warunki umowne, x_4 – reputacja inwestora, x_5 – wartość przedsięwzięcia, x_6 – potrzeba pracy, x_7 – wielkość przedsięwzięcia, x_8 – zyski osiągnięte w przeszłości z podobnych przedsięwzięć, x_9 – czas trwania przedsięwzięcia, x_{10} – kryteria wyboru oferty, x_{11} – lokalizacja przedsięwzięcia, x_{12} – czas na przygotowanie oferty, x_{13} – możliwy udział podwykonawców, x_{14} – konieczność użycia specjalistycznego sprzętu, x_{15} – stopień trudności robót.

Wykonawcy określali stopień ważności wskazanych czynników w skali 1 do 7, gdzie 1 oznaczał bardzo słaby wpływ na decyzję, a 7 bardzo silny. Na podstawie uzyskanych danych dla każdego czynnika wyliczono oceny średnie. W efekcie prowadzonych badań powstała lista rankingowa czynników (rys. 2).

Czynnikami mającymi największy wpływ na podjęcie decyzji o wzięciu udziału w przetargu są: rodzaj robót, doświadczenie w realizacji podobnych przedsięwzięć i warunki umowne (rys. 2). Wyliczone średnie oceny tych czynników są bardzo zbliżone. Czynniki mające najmniejszy wpływ na decyzje przetargowe wg wykonawców to: możliwy udział podwykonawców, konieczność użycia specjalistycznego sprzętu i stopień trudności robót.



Rys. 2. Czynniki wpływające na decyzje przetargowe w opinii wykonawców – wg ważności.
Źródło: (Leśniak, 2016a).

4.3. WSPOMAGANIE DECYZJI O UDZIALE W PRZETARGU Z WYKORZYSTANIEM MODELI KLASYFIKACYJNYCH

Modelowanie decyzji o udziale w przetargu potraktowano jako zagadnienie klasyfikacji. Jest to problem z zakresu eksploracji danych, którego celem jest przypisanie poszczególnych obiektów (przypadków) do odpowiednich predefiniowanych klas, których liczba jest ograniczona. Budowa modelu klasyfikacyjnego, wspomagającego decyzje przetargowe wykonawców, sprowadza się do poszukiwania modelu zależności między możliwymi do ustalenia ocenami czynników decydujących o przystąpieniu do przetargu, a zaliczeniem go do odpowiedniego zbioru klasyfikacyjnego: S – sukces, P – porażka. Jako zmienne wejściowe modelu przyjęto 15 czynników wpływających na decyzje o udziale w przetargu, zidentyfikowanych w Polsce i wspomnianych wcześniej. Wynik przetargu stanowił zmienną wyjściową modelu reprezentującą klasę: S – sukces i P – porażka.

Odpowiedź modelu stanowi zalecenie udziału w przetargu, jeśli zakwalifikowanie przypadku następuje do klasy S – sukces, lub zalecenie rezygnacji, gdy przypadek zostaje przydzielony do klasy P – porażka.

Niezbędnym do opracowania modelu była budowa bazy danych. Zidentyfikowane czynniki posłużyły do oceny przedsięwzięć, o które ubiegali się wykonawcy uczestnicząc w przetargach. Ocena każdego czynnika w danym przedsięwzięciu przebiegała w skali od 1 do 7, gdzie liczby oznaczały: 1 – bardzo mało korzystny (istotny), a 7 – bardzo korzystny (istotny). Drugim istotnym etapem prowadzonych badań było wskazanie rezultatu dla każdego ocenianego postępowania przetargowego w postaci wyniku: S – sukces (przetarg wygrany) oraz P – porażka (przetarg przegrany).

Charakterystykę bazy danych można odnaleźć w pracy (Leśniak, 2016a). Wybrane rekordy bazy danych – oceny czynników z odpowiadającym im rezultatem uzyskanym w przetargu (S – sukces, P - porażka) przedstawiono w tabeli 1. Baza danych objęła ostatecznie dane na temat 88 przetargów.

Tabela 1.

Przykładowe rekordy z bazy danych. Źródło: opracowanie własne.

i	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	Rezultat
2	7	7	3	5	7	7	7	4	4	4	7	6	6	6	6	P
20	5	4	3	3	5	7	5	3	5	4	6	5	7	3	3	S
69	7	7	6	5	3	6	3	4	5	5	6	6	6	6	6	S

4.3.1. WSPOMAGANIE PROCESU DECYZYJNEGO WYKONAWCY Z WYKORZYSTANIEM METODY STATYSTYCZNEJ

Wśród metod statystycznych rozwiązujących problem klasyfikacji wymienia się m.in. analizę dyskryminacyjną (Aczel, 2000; Gatnar, 1998). Analiza dyskryminacyjna jest zespołem metod dyskryminacyjnych oraz klasyfikacyjnych i umożliwia klasyfikację przypadków do jednej z wcześniej ustalonych grup na podstawie zmiennych objaśniających – cech przypadków (Krzyśko, 1990). Wykorzystanie liniowej analizy dyskryminacyjnej jest skutecznie stosowane do wspomaganie różnych procesów decyzyjnych (Fernandez, 2002; Mach, 2013; Leśniak, 2016b).

Metody dyskryminacyjne mają na celu ustalenie, które ze zmiennych objaśniających najsilniej różnicują grupy. Wykorzystuje się do tego funkcje klasyfikacyjne, które najczęściej są funkcjami liniowymi zmiennych wejściowych charakteryzujących przypadki. Liniowa funkcja dyskryminacyjna przyjmuje postać (Aczel, 2000):

$$D_{kj} = \beta_0 + \beta_1 x_{1kj} + \dots + \beta_i x_{ikj}, \quad (1)$$

gdzie:

D_{kj} – wartości kanonicznej dyskryminacyjnej funkcji dla k -tego przypadku w j -tej grupie, $k = 1, \dots, n$ (n – liczebność próby),

$j = 1, \dots, g$ (g – liczba grup),

$i = 1, \dots, p$ (p – liczba zamiennych dyskryminacyjnych),

x_{ikj} – wartość i -tej zmiennej dyskryminacyjnej dla k -tego przypadku w j -tej grupie,

β_i – współczynniki kanonicznej funkcji dyskryminacyjnej wyznaczone na podstawie wartości tej funkcji.

Przydatność każdej funkcji – jej zdolności dyskryminujące – ocenia się za pomocą współczynnika lambda Wilksa Λ (Panek, 2013):

$$\Lambda = \prod_{i=k+1}^q \frac{1}{1 + \lambda_i}, \quad k = 1, 2, \dots, s-1, \quad (2)$$

gdzie:

q – maksymalna liczba funkcji dyskryminacyjnych,

λ_i – i -ta wartość własna.

Wartość Λ mieści się w przedziale $\langle 0, 1 \rangle$. Im wartość statystyki jest bliższa zeru, tym większa jest zdolność dyskryminacyjna funkcji. Stosuje się tu odpowiadającą Λ statystykę testową χ_k^2 o liczbie swobody $(m-k)(n-k-1)$ (Panek i Zwierzchowski 2013). Wyznaczony poziom prawdopodobieństwa statystyki wskazuje istotność funkcji dyskryminacyjnej. Wartość tej statystyki określa się ze wzoru:

$$\chi_k^2 = - \left(n - \frac{s+z}{2} - 1 \right) \ln \Lambda_k. \quad (3)$$

Zmienne objaśniające (cechy opisujące przypadki) nie różnicują grup z jednakową mocą. Należy ustalić, które zmienne wejściowe są istotne ze względu na właściwości dyskryminacyjne, a które nie. Aby ocenić zdolność dyskryminacyjną zmiennych objaśniających X_k wykorzystuje się cząstkowy współczynnik Wilksa (Panek i Zwierzchowski 2013):

$$\Lambda_+ = \frac{\Lambda_k}{\Lambda_k^{(-j)}}, \quad (4)$$

gdzie:

Λ_k – wartość współczynnika lambda Wilksa dla modelu po wprowadzeniu do niego zmiennej X_j ,

$\Lambda_k^{(-j)}$ – wartość współczynnika lambda Wilksa dla modelu przed wprowadzeniem zmiennej X_j .

Wartość współczynnika Λ_+ zawiera się w przedziale $\langle 0, 1 \rangle$ i opisuje wkład danej zmiennej do dyskryminacji grup (im ta wartość jest bliższa zeru, tym wkład tej zmiennej jest większy).

Wyznaczone poziomy prawdopodobieństwa statystyki o rozkładzie *F-Fishera* o $(z-1)$ oraz $(n-z-m+1)$ stopniach swobody wskazuje istotność wkładu zmiennej do funkcji dyskryminacyjnej.

Procedura klasyfikacji oparta na wartościach funkcji klasyfikacyjnych wymaga utworzenia funkcji klasyfikacyjnych dla każdej grupy. Konstrukcja tych funkcji bazuje na zmiennych wejściowych o istotnej mocy dyskryminacyjnej wykazanej przez test lambda Wilksa. W przypadku, gdy liczebność grup nie jest porównywalna, stosuje się zmodyfikowaną postać funkcji klasyfikacyjnej (Panek i Zwierzchowski 2013):

$$K_r = c_{r0} + c_{r1}X_1 + c_{r2}X_2 + \dots + c_{rm}X_m + \ln \frac{n_r}{n}, \quad (5)$$

gdzie:

K_r – r -ta funkcja klasyfikacyjna (dla r -tej grupy przypadków),

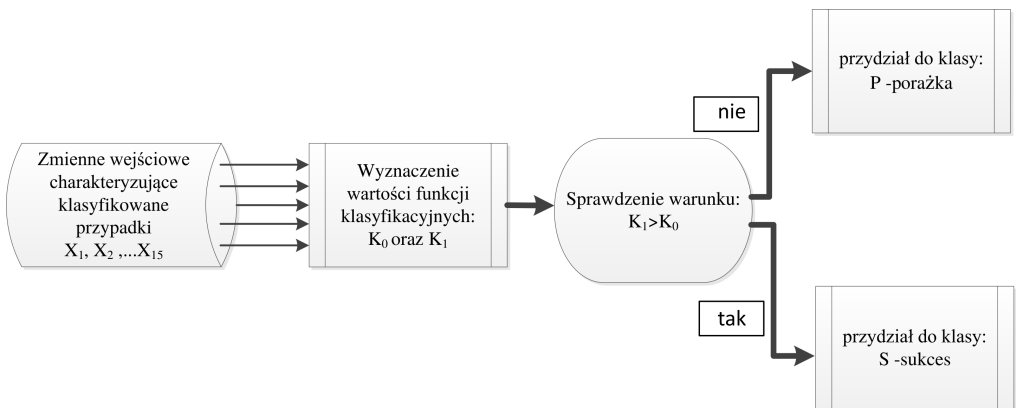
c_{rj} – współczynnik r -tej funkcji klasyfikacyjnej przy j -tej zmiennej wejściowej o istotnej mocy dyskryminacyjnej, $j = 0, 1, \dots, m$,

$c_{r0} = \ln p_{ri}$ – wyraz wolny, prawdopodobieństwo p_i oznacza prawdopodobieństwo a priori zakwalifikowania i -tego obiektu do r -tej grupy,

n_r – liczebność danej grupy,

n – liczebność próby.

W ostatnim kroku dla klasyfikowanego obiektu wylicza się wartości utworzonych funkcji klasyfikacyjnych dla każdej z grup. Obiekt klasyfikuje się do tej grupy, dla której wartość funkcji jest największa. Szczegółowy opis analizy dyskryminacyjnej można znaleźć w m.in. pracach (Aczel, 2000; Gatnar, 1998; Krzyśko, 1990; Panek i Zwierzchowski 2013).



Rys. 3. Ogólny model klasyfikacji dla rozważanego problemu z wykorzystaniem analizy dyskryminacyjnej. Źródło: opracowanie własne.

Działanie modelu

Czynniki przetargowe wykorzystano jako zmienne dyskryminacyjne i poszukiwano równania funkcji dyskryminacyjnej, wskazując te, które istotnie dyskryminują zdefiniowane zbiory: S – sukces i P – porażka. Do budowy modelu zastosowano metodę krokową wsteczną. Zgodnie z zasadami działania tej metody w pierwszym kroku do modelu wprowadza się wszystkie zmienne (krok 0), a następnie w każdym kolejnym kroku usuwa się jedną zmienną – najmniej istotną statystycznie¹.

Po wprowadzeniu do modelu wszystkich zmiennych, tylko cztery zmienne: x_3 , x_5 , x_6 , x_{13} istotnie dyskryminują grupy przy założonym poziomie istotności $\alpha = 0,05$. Parametry modelu przyjęły następujące wartości: *Lambda Wilksa* = 0,41344, odpowiadająca jej statystyka $F(15, 72) = 6,8100$ oraz wartość $p < 0,0000$.

Jako pierwszą usunięto zmienną x_2 – najmniej istotnie dyskryminującą grupy. Parametry modelu przyjęły nowe wartości: *Lambda Wilksa* = 0,41345, statystyka $F(14, 73) = 7,3974$; wartość $p < 0,0000$. Moc dyskryminacyjna modelu poprawiała się nieznacznie. Kolejne kroki ($k = 2, \dots, 15$) pozwoliły na ostateczny wybór istotnie dyskryminujących zmiennych. Wyniki przedstawiono w tabeli 2.

Tabela 2.

Ocena parametrów funkcji dyskryminacyjnej – ostateczny model (6 zmiennych wejściowych).

Źródło: opracowanie własne.

	Lambda Wilksa	Częstkowa Lambda Wilksa	Wartość statystyki F	Wartość p	Tolerancja T_k	Istotny statystycznie*
X_1	0,570048	0,825309	17,14504	0,000084	0,694765	*
X_3	0,495679	0,949133	4,341000	0,040358	0,771227	*
X_5	0,557289	0,844204	14,94840	0,000222	0,541454	*
X_6	0,740919	0,634977	46,56377	0,000000	0,776650	*
X_{13}	0,532386	0,883694	10,66070	0,001605	0,803942	*
X_{15}	0,500913	0,939217	5,242020	0,024650	0,789131	*

W wyniku zastosowania metody krokowej wstecznej w modelu pozostawiono 6 zmiennych wejściowych X_1 , X_3 , X_5 , X_6 , X_{13} , X_{16} istotnie dyskryminujących grupy. Parametry modelu przyjęły wartości: *Lambda Wilksa* = 0,47047; odpowiadająca jej statystyka $F(6, 81) = 15,195$; wartość $p < 0,0000$.

Lambda Wilksa przyjmuje wartość z przedziału $\langle 0, 1 \rangle$. Im jest ona niższa, tym lepszą moc dyskryminacyjną posiada model. W rozważanym przykładzie (0,47047) wartość ta jest akceptowalna.

Współczynnik tolerancji T_k określa część wariancji zmiennej X_k , która nie jest wyjaśniana przez zmienne występujące z nią w modelu. Jeśli współczynnik T_k przyjmuje wartość mniejszą niż domyślną 0,01 to oznacza, że zmienna jest więcej

¹Program wykorzystany do obliczeń: STATISTICA Pakiet Zaawansowany 12 PL.

niż w 99% redundantna z innymi zmiennymi w modelu (Stanisz, 2006). Zmienne o niskich współczynnikach tolerancji mogą powodować jego dużą niedokładność. Jak wynika z tabeli 2 współczynniki T_k dla przyjętych zmiennych przewyższają wartość 0,5.

W kolejnym kroku analizy dokonano sprawdzenia statystycznej istotności funkcji dyskryminacyjnej i wyznaczono jej współczynniki. Parametry oceny istotności statystycznej funkcji dyskryminacyjnej przyjęły następujące wartości:

- Wartość własna = 1,125553; przedstawia ona stosunek wariancji międzygrupowej do wariancji wewnątrz grupowej. Duże wartości własne charakteryzują funkcje o dużej mocy dyskryminacyjnej.
- Korelacja kanoniczna $R = 0,727691$; jest ona miarą wielkości związku pomiędzy zmienną grupującą, a wynikami funkcji dyskryminacyjnej. Mieści się w przedziale od $\langle 0, 1 \rangle$, przy czym 0 oznacza brak związku, a 1 związek maksymalny. Wartość 0,727691 oznacza, że funkcja jest powiązana ze zmienną grupującą.
- Wartość *Lambdy Wilksa* = 0,470466; jest to wartość akceptowalna.
- Wartość $p = 0,000000$; jest ona poniżej krytycznego poziomu istotności 0,05.

Zaproponowana funkcja dyskryminacyjna jest istotna statystycznie. Ostatecznie funkcja dyskryminacyjna przyjmuje następującą postać:

$$D = -12,831 + 0,509x_1 + 0,437x_3 - 0,464x_5 + 1,502x_6 + 0,615x_{13} - 0,429x_{15}. \quad (6)$$

Wielkości współczynników niestandardyzowanych funkcji dyskryminacyjnej (wzór (6)), wskazują o ile wzrośnie lub zmaleje wartość funkcji jeśli wartość zmiennej zmieni się o jedną jednostkę.

Następny etap analizy to procedura kwalifikacyjna z wykorzystaniem funkcji klasyfikacyjnych. W rozważanym w pracy problemie definiowano dwie funkcje klasyfikacyjne. Dany przypadek jest sklasyfikowany do tej grupy, dla której funkcja klasyfikacyjna przyjmuje najwyższą wartość. Ostatecznie funkcje klasyfikacyjne przyjmują postać:

- Funkcja K_0 , klasyfikująca do zbioru P – porażka:

$$K_0 = -181,383 + 7,139x_1 + 13,094x_3 + 0,148x_5 + 21,275x_6 + 15,141x_{13} + 9,958x_{15} + \ln \frac{64}{88}. \quad (7)$$

- Funkcja K_1 , klasyfikująca do zbioru S – sukces:

$$K_1 = -213,841 + 8,338x_1 + 14,123x_3 - 0,946x_5 + 24,813x_6 + 16,590x_{13} + 8,947x_{15} + \ln \frac{24}{88}. \quad (8)$$

Działanie modelu – wartości funkcji klasyfikacyjnych dla wybranych przypadków przedstawiono w tabeli 3.

Tabela 3.

Wartości funkcji klasyfikacyjnych dla wybranych przypadków. Źródło: opracowanie własne.

Przypadek	Wartość funkcji K_0 , klasyfikującej do grupy P – porażka	Wartość funkcji K_1 , klasyfikującej do grupy S – sukces	Wskazana przez model przynależność do grupy:	Obserwowana przynależność do grupy:
28	189,970	186,249	P	P
29*	207,961	206,832	P	S
30	199,490	196,887	P	P
35*	220,759	222,847	S	P

*przypadki sklasyfikowane błędnie.

Ocena wyników

Do oceny przydatności analizy dyskryminacyjnej do klasyfikacji przypadków posłużyła skuteczność klasyfikacji wyrażona jako liczba przypadków poprawnie zidentyfikowanych dla zbioru testującego. Model klasyfikacyjny oparty na metodzie analizy dyskryminacyjnej poprawnie sklasyfikował 86,36% przypadków.

Dane z tabeli 4 umożliwiają wyznaczenie podstawowych parametrów modelu klasyfikacyjnego: czułość, swoistość, wartość predycyjną dodatnią i ujemną, skuteczność oraz współczynnik AUC. Ich definicje i wzory można znaleźć m.in. w pracy (Leśniak, 2016a). Ich wartości zamieszczono w tabeli 5.

Tabela 4.

Zestawianie wyników klasyfikacji. Źródło: opracowanie własne.

Liczności	Klasyfikacja z zastosowaniem analizy dyskryminacyjnej		Wszystkie
	$\hat{y}_i = 1$ (S – sukces)	$\hat{y}_i = 0$ (P – porażka)	
Obserwowane			
$y_i = 1$ (S – sukces)	15	9	24
$y_i = 0$ (P – porażka)	3	61	64
Razem	18	70	88
Poprawne	62,50%	95,31%	86,36%
Niepoprawne	37,50%	4,69%	13,64%
Razem	100,00%	100,00%	100,00%

Tabela 5.

Podstawowe parametry modelu jako klasyfikatora. Źródło: opracowanie własne.

Parametry oceny wyników klasyfikacji					
Czułość	Swoistość	Wartość predycyjna dodatnia (PPV)	Wartość predycyjna ujemna (NPV)	Skuteczność (ACC)	Współczynnik (AUC)
62,50%	95,31%	83,33%	87,14%	86,36%	0,92057

Analizując wartości parametrów modelu klasyfikacyjnego zbudowanego w oparciu o analizę dyskryminacyjną można zauważyć, że model nieco poprawniej przewiduje porażkę (klasyfikacja do zbioru P – 87,14%), niż sukces (83,33%). Pole pod krzywą ROC, tzw. współczynnik AUC to wielkość powszechnie traktowana jako miara jakości klasyfikatora (Krzyśko, 1990; Panek i Zwierchowski 2013). Wielkość pola mieści się w przedziale (0, 1]. Im jest ono większe, tym lepsza jest jakość klasyfikatora. Ocena modelu z wykorzystaniem analizy dyskryminacyjnej jako klasyfikatora jest zadowalająca.

4.3.2. WSPOMAGANIE PROCESU DECYZYJNEGO WYKONAWCY Z WYKORZYSTANIEM METODY OPARTEJ NA SZTUCZNEJ INTELIGENCJI

Sztuczne sieci neuronowe dzięki budowie opartej za wzorcach biologicznych układów nerwowych posiadają niezwykle właściwości, do których zaliczyć można m.in. (Ossowski, 1996; 2000):

- Szybki proces przetwarzania informacji. Obliczenia w sieciach wykonywane są równoległe. Neurony składające się na sieć wykonują przypadające im zadania obliczeniowe równocześnie.
- Zdolność uczenia i uogólniania zdobytej wiedzy. Sieć wytrenowana na wybranej grupie danych uczących potrafi skojarzyć nabytą wiedzę i wykazać dobre działanie na danych nie uczestniczących w procesie uczenia.
- Mała wrażliwość na błędy w zbiorze danych.

Najsłabszą cechą sieci neuronowych w porównaniu do pozostałych technologii jest zdolność wyjaśnień uzyskiwanych wyników oraz odkrywanie wiedzy. Posiadają natomiast wysoko ocenioną cechę uczenia się czyli zdolności pozyskiwania nowej wiedzy, elastyczność rozumianą jako radzenie sobie z niekompletnymi danymi i zdolności adaptacyjne – przystosowanie się do zmian w otoczeniu systemu.

W świetle badań literaturowych SSN wydają się dobrym narzędziem do rozwiązywania problemów klasyfikacji, predykcji czy regresji (Tadeusiewicz, 1993, Tadeusiewicz, 1998). W obszarze zarządzania w budownictwie SSN znalazły zastosowanie m.in. w zagadnieniach harmonogramowania przedsięwzięć budowlanych (Schabowicz i Hoła 2008; Senouci i Adeli 2001), szacowania kosztów robót budowlanych (Juszczyk i Leśniak 2016; Leśniak, 2013; Plebankiewicz i Leśniak, 2013), podejmowania decyzji przez wykonawców budowlanych (Leśniak, 2015b; Li, Shen i Love 1999) czy oszacowania strat inwestora w zamówieniach publicznych (Anysz, Foremny i Kulejewski 2014). Analizę wybranych problemów zastosowania SSN w budownictwie znaleźć można w pracy (Waszczyszyn, 2011).

Do głównych zalet SSN jako metody stosowanej w zadaniach klasyfikacyjnych należą (Ossowski, 1996; Tadeusiewicz, 1998):

- brak hipotez założeń co do postaci funkcji klasyfikacji,

- możliwość wykorzystania wielu zmiennych o charakterze jakościowym i ilościowym,
- szybkość działania,
- zdolność sieci do uczenia się i generalizowania wyników.

Obszerne opisy teoretyczne dotyczące sieci neuronowych znaleźć można m.in. w (Ossowski, 1996; Ossowski 2000; Tadeusiewicz, 1993; Tadeusiewicz, 1998; Tadeusiewicz i Szaleniec, 2015).

Do rozwiązania postawionego problemu klasyfikacji zaproponowano jednokierunkową, wielowarstwową sieć neuronową, zwaną siecią MLP (ang. Multi-Layer Perceptron – perceptron wielowarstwowy), która jest najczęściej opisywaną i najchętniej wykorzystywaną w zastosowaniach praktycznych architekturą neuronową (Tadeusiewicz i Szaleniec, 2015).

W sieciach jednokierunkowych wielowarstwowych (MLP) przepływ sygnałów występuje w jednym kierunku, od wejścia do wyjścia (Ossowski, 1996). Neurony są zorganizowane w dwa wydzielone rodzaje warstw: ukrytą i wyjściową. Warstwy ukryte wprowadzone pomiędzy wejście i wyjście tworzą dodatkową strukturę przetwarzającą informację. Warstwa wyjściowa produkuje sygnały wyjściowe, które stanowią rozwiązanie sieci. W warstwie wejściowej liczba węzłów jest zdefiniowana przez liczbę danych wejściowych, które bierze się pod uwagę przy rozwiązywaniu określonego zadania. Działanie sieci polega na przetworzeniu sygnałów wejścia w sygnały wyjścia. Neurony w sieciach jednokierunkowych nie są połączone ze sobą w obrębie jednej warstwy, natomiast łączą się z węzłami wejściowymi i neuronami innych warstw. Możliwe są różne kombinacje połączeń międzywarstwowych, jednak najczęściej korzysta się ze schematu połączeń typu „każdy z każdym”. Możliwość stosowania tego typu połączeń wynika z faktu, że w trakcie procesu uczenia sieć „sama” wybierze z dostępnych jej początkowo wszystkich połączeń te, które są naprawdę potrzebne, odrzucając (zerując) pozostałe (Tadeusiewicz, i Szaleniec 2015).

Każda warstwa przetwarzania neuronowego może być formalnie opisana jako działanie nieliniowego operatora $F\{\cdot\}$ aktywacji neuronów:

$$N_h x_h = F\{\mathbf{W}_h x_h\}, \quad h = \{1, 2, 3\}, \quad (9)$$

gdzie:

N_h – operator przetwarzania neuronowego h -tej warstwy,

x_h – umowne oznaczenie wektora sygnałów wejściowych dla h -tej warstwy,

\mathbf{W}_h – macierz wag połączeń między warstwami h i $(h-1)$.

Ogólnie odwzorowanie sieci wejście – wyjście może być zapisane za pomocą operatora $N\{\cdot\}$ w postaci:

$$\mathbf{y} = N\{\mathbf{x}\} = F\{\mathbf{W}_3 F\{\mathbf{W}_2 F\{\mathbf{W}_1 \mathbf{x}\}\}\} = N_3 N_2 N_1\{\mathbf{x}\}, \quad (10)$$

gdzie:


$\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ – jest wektorem sygnałów wejściowych,

$\mathbf{y} = [y_1, y_2, \dots, y_M]^T$ – jest wektorem sygnałów wyjściowych.

Mimo wielu zalet i korzyści, stosowanie sieci MPL ma też wady, do których zlicza się (Tadeusiewicz i Szaleniec, 2015):

- trudność w ustaleniu parametrów architektury,
- wpadanie w minima lokalne,
- długi czas uczenia sieci.

Zakwalifikowanie obiektu do klasy dokonuje się na podstawie wartości opisujących go zmiennych objaśniających. Zmienna objaśniana jest zmienną nominalną. Wartość tej zmiennej reprezentują klasy, do których przypisane mogą zostać badane przypadki (rys. 4).



Rys. 4. Ogólny model klasyfikacji dla rozważanego problemu z wykorzystaniem sztucznej sieci neuronowej. Źródło: opracowanie własne.

Zastosowanie wybranej metody

Struktura zaproponowanej sieci MLP obejmuje:

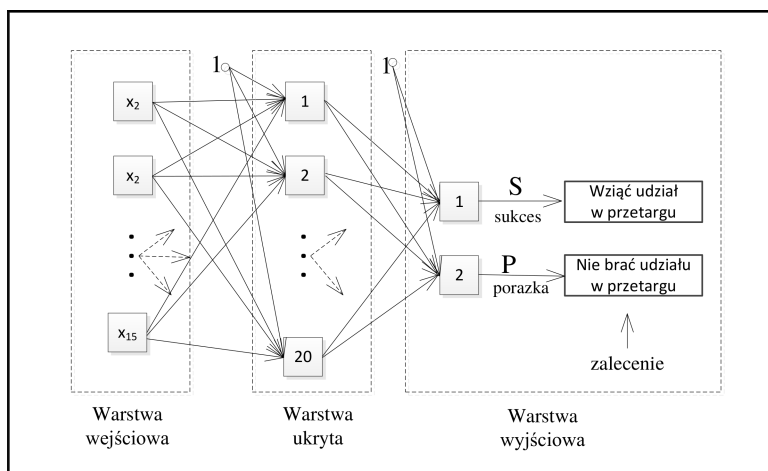
- warstwę wejściową, którą stanowiło 15 neuronów odpowiadających zmiennym opisującym model – czynnikom przetargowym,
- warstwę ukrytą, w której liczba neuronów przyjmowała wartości ze zbioru $\{2, 3, \dots, 20\}$,
- zmienną wyjściową, złożoną z dwóch neuronów, którą stanowiła decyzja o zakwalifikowaniu przypadku do klasy S – sukces, lub P – porażka.

Ogólną postać rozważanej sieci przedstawia rys. 5.

Modelowanie przeprowadzono dwuetapowo. W pierwszym etapie wykorzystano moduł „automatycznego projektanta sieci” dostępny w programie STATISTICA². Umożliwia on poszukiwanie sieci przy różnych funkcjach aktywacji i liczbie neuronów w warstwie ukrytej. Jako kryterium dopasowania sieci pomiędzy odpowiedziami sieci, a wartościami oczekiwanymi liczone błąd uczenia i testowania sieci w postaci funkcji błędu opartej na sumie kwadratów różnic pomiędzy wartościami zadanymi, a wartościami otrzymanymi (MSE – mean of squares) dla n próbek:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2, \quad (11)$$

²Program wykorzystany do obliczeń: Statistica Automatyczne Sieci Neuronowe.



Rys. 5. Ogólny model klasyfikacji dla rozważanego problemu z wykorzystaniem sztucznej sieci neuronowej. Źródło: opracowanie własne.

gdzie:

n – liczba próbek,

t_i – wartość rzeczywista i -tej próbki,

y_i – wartość i -tej próbki oszacowana przez sieć.

Do symulacji neuronowych zastosowano algorytm uczący BFGS (metoda zmiennej metryki, Quasi-Newton), w której wykorzystuje się formułę rekurencyjną zaproponowaną przez Broydena, Fletchera, Goldfarba i Shanno (stąd nazwa BFGS).

Wynikiem pierwszego etapu był wybór ostatecznej struktury sieci neuronowej MLP. W efekcie wytrenowano 250 sieci. Dokonywano losowania zbioru uczącego pięciokrotnie. Dla każdego losowania uczono 50 sieci i zachowywano 5 osiągających najlepsze wyniki (jakość uczenia i testowania). Spośród nich wybrano sieć o strukturze MLP 15-8-2, która osiągnęła wyniki najbliższe wynikom średnim, uzyskanym przez najlepsze 25 sieci. Funkcja aktywacji tej sieci w warstwie ukrytej to funkcja logistyczna, a w warstwie wyjściowej funkcja liniowa. Charakterystykę wybranej sieci prezentuje tabela 6.

Tabela 6.

Charakterystyka sieci MLP 15-8-2. Źródło: opracowanie własne.

Błąd dla zbioru uczącego [%]	Błąd dla zbioru testującego [%]	Funkcja błędu	Aktywacja w warstwie ukrytej	Aktywacja w warstwie wyjściowej
93,55	84,62	MSE	Logistyczna	Liniowa

W drugim etapie uczenia dla wybranej sieci MLP zmieniano liczbę neuronów w warstwie ukrytej od 2 do 12, zachowując jednocześnie funkcje aktywacji: w warstwie ukrytej – logistyczną, a wyjściowej – liniową. Dla każdego przypadku stosowano uczenie za wykorzystaniem 10-krotnej walidacji krzyżowej, aby uzyskać wyniki dla sieci, których działanie będzie jak najmniej obciążone sposobem losowania zbiorów. Uzyskane wyniki dla rozważanych struktur sieci zaprezentowano w tabeli 7.

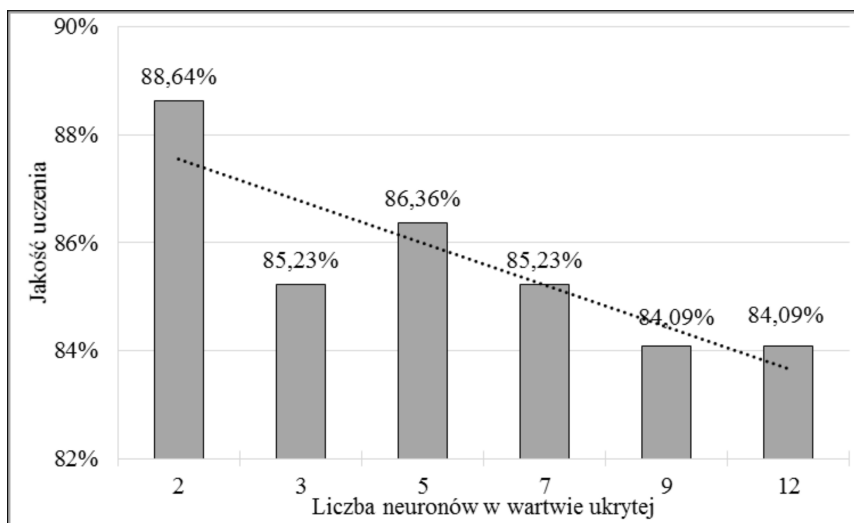
Tabela 7.

Źródło: Charakterystyka wybranych sieci MLP

l.p.	Struktura sieci	Liczba ukrytych neuronów	Jakość uczenia		Funkcja błędu	Aktywacja w warstwie ukrytej	Aktywacja w warstwie wyjściowej
			Zbiór uczący	Zbiór testujący			
1	MLP 15-2-2	2	95,45%	88,64%	MSE	Logistyczna	Liniowa
2	MLP 15-3-2	3	90,91%	85,23%	MSE	Logistyczna	Liniowa
3	MLP 15-5-2	5	90,91%	86,36%	MSE	Logistyczna	Liniowa
4	MLP 15-7-2	7	96,59%	85,23%	MSE	Logistyczna	Liniowa
5	MLP 15-9-2	9	92,05%	84,00%	MSE	Logistyczna	Liniowa
6	MLP 15-12-2	12	93,18%	84,09%	MSE	Logistyczna	Liniowa

Dla sieci MLP 15-2-2 odnotowano najlepsze wyniki. Różnica pomiędzy jakością uczenia dla zbiorów uczącego i testującego wyniosła 6,81%. Warto zauważyć, że maksymalnie różnica ta wyniosła 11,36% dla sieci MLP 15-7-2.

Na rys. 6 przedstawiono osiąganą jakość uczenia sieci w zależności od liczby neuronów w warstwie ukrytej dla zbioru testującego.



Rys. 6. Jakość uczenia sieci w zależności od liczby neuronów w warstwie ukrytej – dla zbioru testującego. Źródło: opracowanie własne.

Analizując powyższy wykres można zauważyć, że najlepsze wyniki uczenia uzyskała sieć 15-2-2. Przy zwiększeniu liczby neuronów do 3 nastąpił spadek jakości uczenia. Przy 5 neuronach w warstwie ukrytej wyniki poprawiły się nieznacznie. Wzrost liczby neuronów w warstwie ukrytej nie poprawił rezultatów. Najslabszą jakość uczenia równą 84,09% osiągnęły sieci z liczbą 9 i 12 neuronów w warstwie ukrytej.

Ocena wyników

Do oceny przydatności sztucznej sieci neuronowej MLP 15-2-2 do klasyfikacji przypadków posłużyła skuteczność klasyfikacji wyrażona jako liczba przypadków poprawnie zidentyfikowanych dla zbioru testującego. Podsumowanie klasyfikacji przedstawiono w tabeli 8.

Tabela 8.

Zestawianie wyników klasyfikacji. Źródło: opracowanie własne.

Liczności	Klasyfikacja z zastosowaniem analizy dyskryminacyjnej		Wszystkie
	$\hat{y}_i = 1$ (S – sukces)	$\hat{y}_i = 0$ (P – porażka)	
Obserwowane			
$y_i = 1$ (S – sukces)	19	5	24
$y_i = 0$ (P – porażka)	5	59	64
Razem	24	64	88
Poprawne	79,17%	92,19%	88,64%
Niepoprawne	20,83%	7,81%	11,36%
Razem	100,00%	100,00%	100,00%

W oparciu o dane z tabeli 8 wyznaczono podstawowe parametry modelu klasyfikacyjnego. Wyniki zamieszczono w tabeli 9.

Tabela 9.

Podstawowe parametry modelu jako klasyfikatora. Źródło: opracowanie własne.

Czułość	Swoistość	Wartość predykcyjna dodatnia (PPV)	Wartość predykcyjna ujemna (NPV)	Skuteczność (ACC)	Współczynnik (AUC)
79,17%	92,19%	79,17%	92,19%	88,64%	0,92578

Uzyskane wartości są wysokie i wykazują dobre działanie sieci. Analizując je można zauważyć, że sieć lepiej klasyfikuje do klasy P – porażka (swoistość 92%), niż do klasy S – sukces (czułość 79%). Wybrana sieć sklasyfikowała poprawnie 88,64% przypadków dla zbioru testującego (skuteczność ACC), popełniając przy tym błąd na poziomie 11%. Współczynnik AUC osiągnął wartość 0,92578. Ocena modelu z wykorzystaniem sztucznej sieci neuronowej typu MLP jest zadowalająca.

4.4. WSPOMAGANIE DECYZJI O WYBORZE PRZETARGU Z WYKORZYSTANIEM METODY ANALIZY WIELOKRYTERIALNEJ – AHP

W praktyce budowlanej wykonawca staje wielokrotnie przed koniecznością wyboru jednego z kilku możliwych przetargów. Wybór zazwyczaj podyktowany koniecznością zaangażowania (zasobów) w celu przygotowania oferty przetargowej. Wybór najkorzystniejszego dla wykonawcy przetargu może wspomóc zastosowanie metod analizy wielokryterialnej. Mają one szereg zalet (Książek, 2011): umożliwiają przyjęcie do oceny dużej liczby kryteriów; jednoznacznie szeregują wybór wariantu najlepszego, obiektywizują oceny ekspertów; ich algorytmy obliczeniowe nie są trudne do implementacji komputerowej.

Istnieje wiele narzędzi wielokryterialnego wspomaganie decyzji w budownictwie a możliwości ich szerokiego zastosowania w budownictwie zaprezentowano na gruncie polskim m.in. w pracach (Dytczak, 2010; Krzemiński i Książek 2009; Leśniak i Radziejowska 2017, Sobotka i Pajak 2008; Szwabowski i Deszcz 2001). Najczęściej wyróżnia się trzy grupy metod (Dytczak, 2010):

1. Metody wieloatrybutowej teorii użyteczności tj. analityczny proces hierarchiczny – AHP, analityczny proces sieciowy – ANP, metoda unitaryzacji zerowanej – MUZ, metoda DEMATEL.
2. Metody relacyjne bazujące na tzw. relacjach przewyższania (synteza systemu preferencji) – tj. rodzina metod ELECTRE, DELPHI, PROMETHEE.
3. Pozostałe, wśród których wymienić można metody addytywne, geometryczne.

Dla analizowanego problemu decyzyjnego polegającego na wyborze najkorzystniejszego dla wykonawcy przetargu, wybrano metodę z pierwszej grupy – AHP (AHP – ang. Analytic Hierarchy Process) i zaprezentowano jej wykorzystanie na przykładzie.

Wybór metody został podyktowany jej zaletami wyróżniającymi ją spośród innych metod analizy wielokryterialnej należących do grupy metod polegających na agregacji ocen cząstkowych w postaci kryterium syntetycznego (Dytczak i Ginda 2006):

- kryteria jakościowe i ilościowe są traktowane w identyczny sposób,
- zasady oceny są proste i czytelne,
- niepewność, ryzyko i rozmytość mogą być efektywnie uwzględnione,
- możliwe jest wykorzystanie metody w grupowym podejmowaniu decyzji,
- możliwy jest wysoki poziom automatyzacji obliczeniowych.

Porównując metodę AHP z innymi metodami analizy wielokryterialnej pod względem popularności jej wykorzystania zarówno w teorii, jak i w praktyce, można śmiało twierdzić, że AHP używana jest najczęściej (Prusak i Stefanów 2011).

Metoda ta została wybrana również z powodu jej ugruntowanych podstaw teoretycznych oraz licznych potwierdzeń zastosowań w praktyce szczególnie w dziedzinie zarządzania w budownictwie w pracach: (Dytczak i Ginda 2006; Dziadosz, 2008; Leśniak, 2014; Leśniak i Zima 2015; Plebankiewicz i Kubek 2015; Skorupka i Duchaczek, 2010; Szewczyk i Radziszewska-Zielina 2015).

Analityczny Proces Hierarchiczny (AHP) jest narzędziem do podejmowania złożonych decyzji w oparciu o znaczną liczbę kryteriów. Metoda została stworzona przez Thomasa L. Saaty w latach 70 (Saaty, 1998; Saaty, 2001). AHP jest ogólnym hierarchicznym podejściem do podejmowania wielokryterialnych decyzji, które pozwala łączyć kryteria ilościowe z jakościowymi oraz obiektywnie mierzalne z subiektywnymi (Prusak i Stefanów 2011). Metoda AHP polega na dekompozycji problemu na prostsze elementy składowe oraz przetwarzaniu ocen ekspertów w oparciu o porównywanie parami.

Algorytm postępowania w metodzie AHP dzielony jest w literaturze na różną liczbę etapów. Poniżej zaprezentowano podział na cztery kolejne kroki (Prusak i Stefanów 2011; Miszczyński, 2007).

1. Budowa modelu decyzyjnego w postaci struktury hierarchicznej.
2. Analiza hierarchii za pomocą porównań parami. Budowa macierzy porównań parami dla n wariantów decyzyjnych osobno w ramach każdego kryterium (macierze $A(1)$, $A(2)$, \dots , $A(k)$) oraz dla samych kryteriów macierzy ($A(0)$).
3. Wyznaczenie rankingów indywidualnych dla każdej macierzy. Ranking wyznacza się postaci wektorów preferencji atrybutów (wektor ocen wariantów decyzyjnych według kolejnych kryteriów).
4. Kontrola poprawności porównań parami (wartości λ_{\max} – maksymalna wartość własna macierzy, C_i – indeks spójności, CR – wskaźnik spójności), szacowanie ogólnych priorytetów – wyznaczenie rankingu wielokryteriowego n wariantów decyzyjnych.

4.4.1. WYBÓR PRZETARGU Z ZASTOSOWANIEM METODY AHP – PRZYKŁAD

Wykonawca rozważa udział w jednym z trzech postępowań przetargowych dotyczących różnych kontraktów budowlanych. Każde z nich ocenione zostało za pomocą 15 kryteriów (zidentyfikowanych w Polsce w wyniku badań i prezentowanych m.in. w pracy (Leśniak, 2016a) jako istotne czynniki przetargowe. Każde kryterium oceniano w skali od 1 do 7, gdzie: 1 – oznaczało bardzo mało korzystne, a 7 – bardzo korzystne. Oceny każdego kryterium w odniesieniu do rozważanego przetargu zawarto w tabeli 10.

Pierwszym krokiem w metodzie AHP jest budowa postaci hierarchicznej modelu, która będzie tworzyła w tym zagadnieniu w trzy poziomy:

- poziom pierwszy – cel ogólny do osiągnięcia to wybór najkorzystniejszego przetargu, ogłoszonego na realizację przedsięwzięcia budowlanego, w którym wykonawca powinien wziąć udział – przygotować i złożyć ofertę.
- poziom drugi – kryteria, które rozpatrywane są podczas podejmowania decyzji (15 czynników przetargowych),
- poziom trzeci – trzy warianty rozpatrywane w zagadnieniu (przetargi na kontrakty A, B i C). Dla uproszczenia zapisu, rozważane warianty oznaczane będą w dalszych rozważaniach symbolami: PA (przetarg dotyczący kontraktu A); PB, (przetarg dotyczący kontraktu B); PC (przetarg dotyczący kontraktu C).

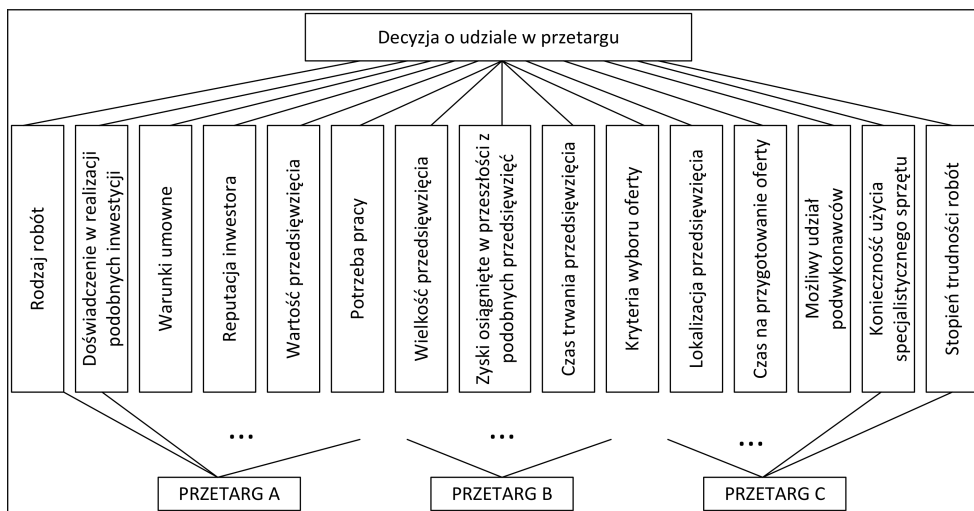
Tabela 10.

Ocena czynników przetargowych dla rozważanych przez wykonawcę kontraktów A, B, C zleczanych drogą przetargu. Źródło: opracowanie własne.

l.p.	Kryteria – czynniki przetargowe	Przetarg na	Przetarg na	Przetarg na
		kontrakt A	kontrakt B	kontrakt C
		Ocena czynników		
k_1	Rodzaj robót	7	6	4
k_2	Doświadczenie w realizacji podobnych przedsięwzięć	7	6	5
k_3	Warunki umowne	3	4	6
k_4	Reputacja inwestora	4	5	6
k_5	Wartość przedsięwzięcia	3	5	1
k_6	Potrzeba pracy	5	4	6
k_7	Wielkość przedsięwzięcia	3	4	1
k_8	Zyski osiągnięte w przeszłości z podobnych przedsięwzięć	4	5	3
k_9	Czas trwania przedsięwzięcia	4	5	2
k_{10}	Kryteria wyboru oferty	3	4	6
k_{11}	Lokalizacja przedsięwzięcia	5	6	7
k_{12}	Czas na przygotowanie oferty	4	2	6
k_{13}	Możliwy udział podwykonawców	4	6	7
k_{14}	Konieczność użycia specjalistycznego sprzętu	6	7	3
k_{15}	Stopień trudności robót	7	6	5

Przedstawiona na rys. 7 struktura hierarchiczna problemu pozwala przejść do drugiego kroku, w którym wyznaczane są macierze porównań parami (wg skali Saaty'ego) ze względu na przyjęte kryteria. Ze względu na obszerność danych w tym kroku w artykule nie zaprezentowano szczegółowych wyników porównań parami oraz obliczeń. Uzyskane w tym etapie macierze unormowano stosując wzór (13):

$$a'_{ij} = \frac{a_{ij}}{\sum_{k=1}^n a_{ik}}. \quad (12)$$



Rys. 7. Postać struktury hierarchicznej modelu. Źródło: opracowanie własne

W tabeli 11 zestawiono uzyskane wektory ważności dla kryteriów oraz wartości: λ_{\max} , CR i CI.

Tabela 11.

Wektory wag wg kryteriów oraz wartości: λ_{\max} , CR i CI. Źródło: opracowanie własne.

kryterium	k_1	k_2	k_3	k_4	k_5	k_{11}	k_{12}	k_{13}	k_{14}	k_{15}
Wektor ważności	0,557	0,539	0,106	0,164	0,26	0,164	0,26	0,123	0,334	0,539
	0,32	0,297	0,260	0,297	0,633	0,297	0,106	0,32	0,568	0,297
	0,123	0,164	0,633	0,539	0,106	0,539	0,633	0,557	0,098	0,164
λ_{\max}	3,023	3,011	3,055	3,011	3,011	3,011	3,055	3,02	3,033	3,011
CI	0,012	0,006	0,028	0,006	0,028	0,006	0,028	0,012	0,016	0,006
CR	0,023	0,011	0,053	0,011	0,053	0,011	0,053	0,023	0,031	0,011
CR < 0,1	CR < 0,1												

Kolejnym etapem procedury jest budowa macierzy porównań parami dla zbioru kryteriów, w celu określenia dominacji kryteriów. Następnie powtarzana jest procedura umożliwiająca wyznaczenie macierzy unormowanej, wektora preferencji i wartości λ_{\max} , CR i CI.

W dalszym kroku przechodzi się do budowy ogólnej macierzy priorytetów (tabela 12).

Ostatecznie ostatni etap agregacji pozwolił uzyskać wskaźniki jednoliczbowe oceny przetargów przedstawione w tabeli 13.

Porównując uzyskane wyniki widać, że najlepszą ocenę uzyskał przetarg na kontrakt nr B. Ogólny priorytet wyniósł 0,351. Wykonawca powinien rozważyć przygotowanie i złożenie oferty do tego przetargu.

Tabela 12.

Ogólna macierz priorytetów dla wyboru przetargu. Źródło: opracowanie własne.

	k_1	k_2	k_3	k_4	k_5	k_6	k_7	k_8	k_9	k_{10}	k_{11}	k_{12}	k_{13}	k_{14}	k_{15}
P_A	0,557	0,539	0,106	0,164	0,26	0,297	0,32	0,297	0,32	0,137	0,164	0,26	0,123	0,334	0,539
P_B	0,32	0,297	0,260	0,297	0,633	0,164	0,557	0,539	0,557	0,239	0,297	0,106	0,32	0,568	0,297
P_C	0,123	0,164	0,633	0,539	0,106	0,539	0,123	0,164	0,123	0,623	0,539	0,633	0,557	0,098	0,164

Tabela 13.

Ogólna macierz priorytetów dla wyboru przetargu. Źródło: opracowanie własne.

Rozważane przetargi	Ogólny priorytet
Przetarg na kontrakt A	$OP_A = 0,271$
Przetarg na kontrakt B	$OP_B = 0,351$
Przetarg na kontrakt C	$OP_C = 0,320$

Zaletą opisanego modelu jest możliwość wprowadzenia ocen zarówno kontraktów, których przetarg dotyczy, jak i stopnia ważności kryteriów, uwzględniając ich wzajemne dominacje. Wśród wad tego modelu wymienić można:

- skomplikowany aparat matematyczny (szczególnie przy dużej liczbie kryteriów), choć podkreślić należy, że wadę tę można wyeliminować korzystając z dedykowanych tej metodzie programów komputerowych,
- konieczność wprowadzania wielu danych (porównań parami przetargów ze względu na wszystkie kryteria, jak również porównań samych kryteriów).

4.5. PODSUMOWANIE

Wykonawca budowlany na każdym etapie działalności musi podejmować szereg istotnych decyzji związanych z funkcjonowaniem przedsiębiorstwa. Decyzja o przystąpieniu do przetargu na roboty budowlane jest jedną z najistotniejszych, gdyż wiąże się z zaangażowaniem zasobów i podjęciem działań zmierzających do przygotowania oferty przetargowej. Bez względu na wynik przetargu, koszty sporządzenia oferty zostaną poniesione. Sprawność ofertowania jest niewątpliwie istotna dla każdego przedsiębiorstwa budowlanego.

By wspomóc decydenta i zwiększyć skuteczność decyzji opracowuje się modele i wykorzystuje metody matematyczne. Tworzone narzędzia nie zastąpią procesu myślowego decydenta, ale zwiększą racjonalność podejmowanych decyzji.

W niniejszym rozdziale zaprezentowano możliwości wspomagania decyzji przetargowych poprzez budowę modeli klasyfikacyjnych i wykorzystanie metody AHP. W pierwszym przypadku zidentyfikowane i ocenione czynniki przetargowe stały się zmiennymi wejściowymi by sklasyfikować rozważany przez wykonawcę przetarg do klasy S – sukces, stanowiący zalecenie udziału w przetargu, lub do klasy P

– porażka – sugerujący rezygnację z udziału. Model wykorzystujący liniową analizę dyskryminacyjną sklasyfikował poprawnie 86,36% badanych przypadków. Jako najbardziej istotnie dyskryminujące zmienne model wskazał 6 czynników przetargowych, przy czym największy, niezależny wpływ na wynik funkcji dyskryminacyjnej wywiera zmienna X6 – potrzeba pracy, natomiast najmniejszy X3 – warunki umowne. Model w postaci sztucznej sieci neuronowej typu MLP o strukturze 15-2-2, wykazał lepsze działanie i poprawnie sklasyfikował 88,64% przypadków. Uzyskane wyniki świadczą o możliwości zastosowania modeli w praktyce i są zadowalające. Drugi przypadek prezentuje możliwości wykorzystania metod analizy wielokryterialnej (tu metody AHP) do wskazania najkorzystniejszego z wielu rozważanych przetargów. Metoda AHP jednoznacznie szereguje wybór najlepszego przetargu, jak to miało miejsce w rozważanym przykładzie. W tej sytuacji decydent może podjąć kolejny krok – dokonać oceny wskazanego przez metodę AHP przetargu z użyciem modelu klasyfikacyjnego.

4.6. BIBLIOGRAFIA

- ACZEL, D.A. (2000). *Statystyka w zarządzaniu*. Warszawa, Wydawnictwo Naukowe PWN.
- ADAMSKA, M. (2013). *Diagnoza czynników warunkujących rozwój małych i średnich przedsiębiorstw*. W: Od naukowej inspiracji do innowacji w przedsiębiorstwie. Praktyczna aplikacja wiedzy Asystentów innowacji, red. M. Szewczuk-Stepień, M. Adamka, Opole, Instytut Trwałego Rozwoju.
- AHMAD, I., MINKARAH, I. (1988). Questionnaire survey on bidding in construction. *Journal of Management in Engineering Division*, Vol. 4, No. 3, 229–243.
- ANYSZ, H., FOREMNY, A. KULEJEWSKI, J. (2014). Estimating potential losses of the client in public procurement in case of collusion utilizing a MLP neural networks. *Technical Transactions Civil Engineering*, 1-B/2014, 105–118.
- BAGEIS, A.S., FORTUNE, C. (2009). Factors affecting the bid/no bid decision in the Saudi Arabian construction contractors. *Construction Management and Economics*, 27, 53–71.
- Biuletyn Zamówień Publicznych, <http://www.bzp.pl/>
- BOROWICZ, A. (2001). *System przetargowy jako warunek sprawnego funkcjonowania polskiego budownictwa*. Łódź, Wydawnictwo Uniwersytetu Łódzkiego.
- CATTELL, D.W., BOWEN P.A., KAKA, A.P. (2008). A simplified unbalanced bidding model. *Construction Management and Economics*, Vol. 26, No. 12, 1283–1290.
- CLEDEN, D. (2011). *Bid Writing for Project Managers*. Gower Publishing, Ltd.
- DYTCZAK, M. (2010). *Wybrane metody rozwiązywania wielokryterialnych problemów decyzyjnych w budownictwie*. Opole, Politechnika Opolska.

- DYTCHAK, M., GINDA, G. (2006). Benefits and costs in selecting fuel for municipality heating systems with the Analytic Hierarchy Process. *Journal of Systems Science and Systems Engineering*, 15(2), 165–177.
- DZIADOSZ, A. (2008). Ocena i selekcja inwestycji budowlanych z wykorzystaniem analitycznego procesu hierarchicznego (AHP). *Czasopismo Techniczne. Budownictwo*, 105, 41–51.
- FERNANDEZ, G.C. (2002). Discriminant analysis: a powerful classification technique in data mining. In: *Proceedings of the SAS Users International Conference*, 247–256.
- GAJZLER, M., DZIADOSZ, A., SZYMAŃSKI, P. (2010). Problematyka wyboru metody wspomagającej podejmowanie decyzji w budownictwie. *Czasopismo Techniczne*, 1-B/2010, 69–84.
- GATNAR, E. (1998). *Symboliczne metody klasyfikacji danych*. Warszawa, Wydawnictwo Naukowe PWN.
- JAŚKOWSKI, P., SOBOTKA A., CZARNIGOWSKA A. (2014). Decision Model for Selecting Supply Sources of Road Construction Aggregates. *ENGINEERING ECONOMICS*, Vol. 25, No. 1, 13–20.
- JUSZCZYK, M., LEŚNIAK A. (2016). Site Overhead Cost Index Prediction Using RBF Neural Networks. *International Conference on Economics and Management (ICEM 2016) Destech Publicat. Inc.* 381–386.
- KAPLIŃSKI, O. (red.). (2007). *Metody i modele badań w inżynierii przedsięwzięć budowlanych*. Warszawa, PAN, KILiW, IPPT, Seria Studia z Zakresu Inżynierii Nr 57.
- KAPLIŃSKI, O. (2008). Development and usefulness of planning techniques and decision-making foundations on the example of construction enterprises in Poland, *Technological and Economic Development of Economy*, Vl. 14, No. 4, 492–502.
- KAPLINSKI, O., TUPENAITE, L. (2011). Review of the multiple criteria decision making methods, intelligent and biometric systems applied in modern construction economics, *Transformation in Business & Economics*, Vol. 10, No. 1, 166–181.
- KASPROWICZ, T. (red.) (2015). *Inżynieria przedsięwzięć budowlanych. Rekomendowane metody i techniki*. Warszawa, PAN, KILiW SIPP.
- KASPROWICZ, T. (2002). *Inżynieria przedsięwzięć budowlanych*. Warszawa, Instytut Technologii Eksploatacji w Radomiu.
- KRZYŚKO, M. (1990). *Analiza dyskryminacyjna*. Warszawa, Wydawnictwo Naukowo Techniczne.
- KRZEMIŃSKI, M., KSIAŻEK, M. (2009). Wielokryterialna analiza wybranych obiektów budowlanych wraz z analizą kryteriów oceny przy zastosowaniu metody entropii. *Problemy przygotowania i realizacji inwestycji budowlanych: warsztaty inżynierów budownictwa*, VI konferencja naukowo-techniczna, Puławy 19-21 października 2009 r., strony 249–254, Puławy, PZITB.

- KSIĄŻEK, M. (2011). Analiza porównawcza wybranych metod wielokryterialnych oceny przedsięwzięć inwestycyjnych, *Budownictwo i Inżynieria Środowiska*, Nr 2, 555–561.
- LEŚNIAK, A. (2013). Application of artificial neural networks in indirect cost estimation. *International Conference on Numerical Analysis And Applied Mathematics 2013 (ICNAAM-2013)*, Rhodes, Greece, AIP Publishing, 1558, 1312–1316.
- LEŚNIAK, A. (2014). The simplified bidding decision model based on AHP method in ordering of investor's supervision service. *14th SGEM GeoConference on Ecology, Economics, Education And Legislation 3. SGEM 2014 Conference Proceedings*, June 19-25 2014 Romania, 3, 501–508.
- LEŚNIAK, A. (2015a). Classification of the Bid/No Bid Criteria-Factor Analysis. *Archives of Civil Engineering*, Vol. 61, No. 4, 79–90.
- LEŚNIAK, A. (2015b). Supporting contractors' bidding decision: RBF neural network application. *International Conference on Numerical Analysis And Applied Mathematics, 23-29 September 2015 (ICNAAM-2015)* Rhodes, Greece, AIP Conference Proceedings, Vol. 1738, 2016, art. No. 200002.
- LEŚNIAK, A. (2016a). *Modelowanie decyzji wykonawcy o udziale w przetargu na roboty budowlane*. Kraków, Wydawnictwo Politechniki Krakowskiej.
- LEŚNIAK, A. (2016b). Wspomaganie decyzji wykonawcy o udziale w przetargu z wykorzystaniem liniowej analizy dyskryminacyjnej, *Materiały Budowlane*, 6, 97–101.
- LEŚNIAK, A., PLEBANKIEWICZ E. (2013). Modeling the Decision-Making Process Concerning Participation in Construction Bidding. *Journal of Management in Engineering*, Vol. 31, No. 2, art. no. 04014032. DOI: 10.1061/(ASCE)ME.1943-5479.0000237.
- LEŚNIAK, A., RADZIEJOWSKA A. (2017). Supporting bidding decision using multi-criteria analysis methods. *Procedia Engineering*, Vol. 208, 76–81. doi.org/10.1016/j.proeng.2017.11.023.
- LEŚNIAK, A., ZIMA, K. (2015). Comparison of traditional and ecological wall systems using the AHP method. *International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management, SGEM, Albena, Bulgaria, 3(5)*, 157–164.
- LI, H., SHEN, L.Y., LOVE P.D.E. (1999). ANN – based mark-up estimation system with self-explanatory capacities. *Journal of Construction Engineering and Management*, Vol. 125, No. 3, 185–189.
- MACH, Ł. (2008). Zastosowanie analizy dyskryminacyjnej i sieci neuronowych do oceny możliwości sprzedaży nieruchomości mieszkaniowych. *Zeszyty Naukowe Wyższej Szkoły Bankowej we Wrocławiu*, 34, 295–306.
- MARCINKOWSKI R., KOPER A. (2008). Ocena ryzyka czasu i kosztów w planowaniu produkcji budowlanej. *Przegląd budowlany*, 79, 70–75.
- MISZCZYŃSKI, M. (2007). *Wielokryteriowa optymalizacja dyskretna; wybrane metody*. Łódź, Uniwersytet Łódzki.

- OSOWSKI, S. (1996). *Sieci neuronowe w ujęciu algorytmicznym*. Warszawa, Wydawnictwo Naukowo-Techniczne.
- OSOWSKI, S. (2000). *Sieci neuronowe do przetwarzania informacji*. Warszawa, Oficyna Wydawnicza Politechniki Warszawskiej.
- PANEK, T., ZWIERZCHOWSKI, J. (2013). *Statystyczne metody wielowymiarowej analizy porównawczej. Teoria i zastosowania*. Warszawa, Oficyna Wydawnicza SGH.
- PLEBANKIEWICZ, E., LEŚNIAK, A. (2013). Overhead costs and profit calculation by polish contractors. *Technological and Economic Development of Economy*, Vol. 19, No. 1, 141–161.
- PLEBANKIEWICZ, E., KUBEK, D. (2015). Multicriteria selection of the building material supplier using AHP and fuzzy AHP. *Journal of Construction Engineering and Management*, Vol. 142, No. 1, 04015057.
- POŁOŃSKI, M. (2014). Budżetowanie przedsięwzięć budowlanych z uwzględnieniem buforów czasu i kosztu. *Budownictwo i Architektura*, 13(4), 389–397.
- PRUSAK, A., STEFANÓW, P. (2014). *AHP – analityczny proces hierarchiczny. Budowa i analiza modeli decyzyjnych krok po kroku*. Warszawa, Wydawnictwo CH Beck.
- Rocznik Statystyczny Rzeczypospolitej Polskiej. Główny Urząd Statystyczny. Zakład Wydawnictw Statystycznych, Warszawa 2015.
- SAATY, T.L. (2001). *Decision making for leaders; The Analytic Hierarchy Process for decisions in a complex world*. Pittsburgh, RWS Publications.
- SAATY, T.L. (1998). *The Analytic Hierarchy Process*. Pittsburgh, RWS Publications.
- SCHABOWICZ, K., HOŁA, B. (2008). Application of artificial neural networks in predicting earthmoving machinery effectiveness ratios. *Archives of Civil and Mechanical Engineering*, Vol. 8, No. 4, 73–84.
- SENOUCI, A., ADELI, H. (2001). Resource scheduling using neural dynamics model of Adeli and Park. *Journal of Construction Engineering and Management*, Vol. 127, No. 1, 28–34.
- SHASH, A.A. (1993). Factors considered in tendering decisions by top UK contractors. *Construction Management and Economics*, Vol. 11, 111–118.
- SKORUPKA, D. (2007). METODA IDENTYFIKACJI I OCENA RYZYKA REALIZACJI PRZEDSIĘWZIĘĆ BUDOWLANYCH. Warszawa, Wojskowa Akademia Techniczna.
- SKORUPKA, D., DUCHACZEK, A. (2010). Zastosowanie metody AHP w optymalizacji procesów decyzyjnych związanych z realizacją przedsięwzięć logistycznych. *Zeszyty Naukowe/Wyższa Szkoła Oficerska Wojsk Lądowych im. gen. T. Kościuszki*, Nr 3, 157, 54–62.
- SOBOTKA, A., BIRUK, S., JAŚKOWSKI, P. (2003). *Zarządzanie w budownictwie*. Lublin, Wydawnictwa Uczelniane, Politechnika Lubelska.

- SOBOTKA, A., JAŚKOWSKI, P. (2004). Badania procesu decyzyjnego doboru podwykonawców do realizacji przedsięwzięć budowlanych. *Przeгляд Budowlany*, 75, 28–32.
- SOBOTKA, A., PAJĄK, M. (2008). Metody wzmocnienia posadowienia zabytkowego budynku i ich ocena za pomocą analizy wielokryterialnej. *Górnictwo i Geoinżynieria*, 32(2) 277–286.
- Sprawozdanie Prezesa Urzędu Zamówień Publicznych o funkcjonowaniu systemu zamówień publicznych w 2016 r. Urząd Zamówień Publicznych, Warszawa 2017.
- SROKA H., WOLNY W. (red.) (2009). *Inteligentne systemy wspomagania decyzji*. Katowice, Wydawnictwo Akademii Ekonomicznej w Katowicach.
- STANISZ, A. (2006). *Przystępny kurs statystyki z zastosowaniem STATISTICA PL na przykładach z medycyny*. Kraków, Statsoft Polska Sp. z o.o.
- STARZYK, E., JUSZCZYK, M., KOZIK, R. (2007). *Analiza strategiczna przedsiębiorstwa budowlanego i jego otoczenia. Wybrane problemy i metody*. Podręcznik dla studentów wyższych szkół technicznych. Kraków, Wydawnictwo Politechniki Krakowskiej.
- SZEWczyk, B., RADZISZEWSKA-ZIELINA, E. (2015). Analiza istotności miar partnerstwa i rodzajów współpracy partnerskiej przy wykorzystaniu metody AHP. *Logistyka*, 4, 5991–6001.
- SZWABOWSKI, J., DESZCZ J. (2001). *Metody wielokryterialnej analizy porównawczej*. Gliwice, Wydawnictwo Politechniki Śląskiej.
- TADEUSIEWICZ, R. (1993). *Sieci neuronowe*. Warszawa, Akademicka Oficyna Wydawnicza RM.
- TADEUSIEWICZ, R. (1998). *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Warszawa, Akademicka Oficyna Wydawnicza PLJ.
- TADEUSIEWICZ, R., SZALENIEC M. (2015). *Leksykon Sieci Neuronowych*. Publikacja finansowana ze środków MNiSW w ramach programu Działalność Upowszechniająca Naukę, Wrocław.
- Ustawa z dnia 29 stycznia 2004 r. – Prawo zamówień publicznych (Dz.U. z 2015 r. poz. 2164).
- WASZCZYŻYN, Z. (2011). Artificial neural networks in civil engineering: another five years of research in Poland. *Computer Assisted Mechanics and Engineering Sciences (CAMES)*, 18, 4, 131–146.