

Agnieszka Jóźwiak

ZASTOSOWANIE WYBRANYCH METOD IŁOŚCIOWYCH DO OCENY JAKOŚCI WYKONYWANIA ZAMÓWIEŃ PUBLICZNYCH

1. Wstęp

Temat zamówień publicznych jest szeroko poruszany w literaturze jako element finansów publicznych. Wejście w życie przepisów nowej Ustawy z dnia 29 stycznia 2004 r. *Prawo zamówień publicznych* (DzU nr 19, poz. 177) zaowocowało szeregiem publikacji dotyczących regulacji prawnych w Polsce w tym zakresie [12; 13]. Ustawa ta dostosowuje polskie przepisy do standardów prawa europejskiego. W myśl ustawy *Prawo zamówień publicznych* przez najkorzystniejszą rozumie się ofertę z najniższą ceną albo ofertę, która przedstawia najkorzystniejszy bilans ceny oraz innych kryteriów odnoszących się do przedmiotu zamówienia, w szczególności jakości, funkcjonalności, parametrów technicznych, zastosowania najlepszych dostępnych technologii w zakresie oddziaływania na środowisko, kosztów eksploatacji, serwisu, wpływu sposobu wykonania zamówienia na rynek pracy w miejscu wykonywania zamówienia, terminu wykonania zamówienia. W praktyce najczęściej cena jest jedynym kryterium wyboru oferty lub cena z wagą 0,95 i termin realizacji zamówienia z wagą 0,05.

Nastawienie na minimalizację kosztów, oprócz zalet z punktu widzenia budżetu państwa bądź jednostki samorządu terytorialnego, ma również wady. Może powodować, że firma biorąca udział w przetargu obniży cenę do tego stopnia, że nie będzie w stanie utrzymać wysokiej jakości wykonywania zamówienia. Obniżenie jakości wykonywania zlecenia powoduje wydłużenie czasu robót, co stanowi wymierny koszt zarówno dla budżetu państwa, jak i dla firm prywatnych. Ponadto nie istnieje mechanizm selekcji spośród oferentów tych firm, które wcześniej wykonywały zlecenia poniżej oczekiwanego poziomu (tzn. częściej niż przeciętnie istniała konieczność interwencji inwestora w proces realizacji zamówienia).

W tej sytuacji zasadne wydaje się określenie, jakie cechy oferenta (zależne od niego lub nie) i w jaki sposób wpływają na jakość wykonywania zamówienia.

Niniejszy artykuł stanowi propozycję wykorzystania wybranych metod ilościowych w kontroli wydatków publicznych poprzez próbę prognozowania jakości wykonywania zamówienia przed podjęciem decyzji o wyborze oferenta na podstawie charakterystyk oferenta i oferty. Zastosowanie wybranych narzędzi zostanie zilustrowane i przetestowane na przykładzie zamówień dotyczących budowy dróg. O istotności problemu świadczy fakt, że wydatki na drogi publiczne stanowią średnio 5% wydatków budżetu państwa.

2. Sformułowanie problemu oceny jakości wykonywania zamówień publicznych

Problem oceny jakości wykonywania zamówień publicznych można sformułować ogólnie w następujący sposób:

$$Y = f(\mathbf{X}),$$

gdzie: Y – zmienna binarna określająca jakość wykonywania zamówienia, przyjmująca wartość 0 dla niezadowalającej jakości oraz 1 dla jakości zadowalającej,

$\mathbf{X}$ – macierz zmiennych niezależnych (charakterystyk oferty i oferenta).

Problem zostanie zilustrowany na przykładzie zamówień dotyczących budowy dróg.

Przedmiotem badań są zamówienia na roboty budowlane o wartości od 100 tys. zł do 2,5 mln zł. Dane obejmują zamówienia publiczne z lat 1999-2003 realizowane na terenie kilku polskich powiatów. W przetargach brało udział od 3 do 8 oferentów, spośród których wyłaniany zostawał zwycięzca. Dane obejmują 110 obserwacji dotyczących oferentów, którzy wygrali przetarg. Zawierają one informacje na temat kondycji finansowej oferenta, możliwości kredytowych przedsiębiorstw, formy prawnej przedsiębiorstwa, zaproponowanej ceny ofertowej, ceny inwestorskiej (na podstawie kosztorysu inwestorskiego), kwalifikacji kadry (wykształcenie, staż pracy), potencjału sprzętowego firmy, doświadczenia zawodowego (referencje) oraz jakości wykonywania zlecenia (na podstawie oceny eksperta).

Zbiór potencjalnych zmiennych objaśniających tworzą:

X_1 – wskaźnik płynności bieżącej 2 lata temu,

X_2 – wskaźnik płynności bieżącej w ubiegłym roku,

X_3 – wskaźnik płynności szybki 2 lata temu,

X_4 – wskaźnik płynności szybki w ubiegłym roku,

X_5 – wskaźnik płynności natychmiastowy 2 lata temu,

X_6 – wskaźnik płynności natychmiastowy w ubiegłym roku,

- X_7 – ROA 2 lata temu,
 X_8 – ROA w ubiegłym roku,
 X_9 – ROE 2 lata temu,
 X_{10} – ROE w ubiegłym roku,
 X_{11} – całkowita wartość dostępnego kredytu,
 X_{12} – poziom wykształcenia kadry kierowniczej mierzony stosunkiem liczby osób z wykształceniem wyższym do liczby osób z wykształceniem średnim,
 X_{13} – przeciętny staż pracy zatrudnionych w firmie w zawodzie,
 X_{14} – liczba pracowników firmy,
 X_{15} – czas działalności firmy na rynku w latach,
 X_{16} – średnia wartość wykonanych dotąd zamówień,
 X_{17} – średnia liczba prac w ciągu roku,
 X_{18} – liczba kontrahentów,
 X_{19} – średni wiek maszyn,
 X_{20} – stosunek ceny zaproponowanej przez oferenta do ceny z kosztorysu inwestorskiego,
 X_{21} – stosunek ceny zaproponowanej przez oferenta do średniej wartości wykonanych dotąd zamówień,
 X_{22} – odległość pomiędzy miejscem wykonania zamówienia a siedzibą oferenta (zmienna jakościowa przyjmująca wartość 1, gdy odległość przekracza 50 km, i 0 – w przeciwnym przypadku); taki sposób konstrukcji zmiennej wynika z faktu, że wszystkie firmy miały zakład produkcyjny w miejscu siedziby,
 X_{23} – forma prawna oferenta (zmienna jakościowa przyjmująca wartość 1, gdy firma działa w formie spółki kapitałowej, i 0 – w przeciwnym przypadku).

Jakość wykonywania poszczególnych zamówień publicznych została oceniona przez niezależnego eksperta w podziale na dwie kategorie:

- 1) jakość niezadowalająca ($Y = 0$), kiedy inwestor był zmuszony interweniować, a oferent musiał wносить wymagane poprawki, co powodowało m.in. wydłużenie czasu trwania robót i związane z tym straty;
- 2) jakość zadowalająca ($Y = 1$), kiedy oferent spełnił wszelkie wymagania inwestora i prace zostały ukończone terminowo.

Ze względu na postać zmiennej objaśnianej do oceny jakości zaproponowano wykorzystanie modelu logitowego, liniowej analizy dyskryminacyjnej Fishera oraz nieparametrycznej metody dyskryminacyjnej (algorytm CART).

3. Model logitowy

Do oceny wykonywania zamówień publicznych wykorzystano dwumianowy model logitowy [3; 14]. Logit L ma postać $L = \ln \frac{p}{1-p}$, gdzie p – prawdopodobieństwo, że zmienna Y przyjmie wartość 1. Model logitowy ma następującą postać:

$$L = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon, \quad (1)$$

gdzie β – wektor parametrów modelu.

Po oszacowaniu parametrów modelu odpowiednie prawdopodobieństwa otrzymuje się, stosując funkcję logistyczną:

$$p = \frac{1}{1 + \exp[-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)]}. \quad (2)$$

Zmienne objaśniające w modelu ekonometrycznym z formalnego punktu widzenia powinny być mocno skorelowane ze zmienną objaśnianą, słabo skorelowane między sobą, mocno skorelowane z tymi potencjalnymi zmiennymi objaśniającymi, które reprezentują, a które ostatecznie nie znalazły się w zbiorze zmiennych objaśniających oraz mieć wystarczająco wysoką zmienność.

Do określenia poziomu zróżnicowania zmiennych użyto współczynnika zmienności V .

Do określenia współzależności cech dla pary zmiennych zero-jedynkowych Z_1 i Z_2 wykorzystano współczynnik skojarzenia Yule'a dany wzorem [6]:

$$\varphi = \frac{ad - bc}{\sqrt{(a+b)(a+c)(b+d)(c+d)}}, \quad (3)$$

gdzie a, b, c, d – liczebności w następującej tabeli:

Liczebności	$Z_2 = 0$	$Z_2 = 1$
$Z_1 = 0$	a	b
$Z_1 = 1$	c	d

Współczynnik φ jest równy 0, gdy zmienne są niezależne. Postać współczynnika φ oparta jest na statystyce chi-kwadrat dla testu niezależności dwóch cech.

Dla pary zmiennych, z których jedna jest zmienną zero-jedynkową Z , a druga zmienną mierzalną na skali przedziałowej X , określano, czy różnica między średnimi wartościami zmiennej X dla $Z = 0$ i dla $Z = 1$ jest statystycznie istotna na podstawie testu t . W przypadku gdy różnica między średnimi jest statystycznie istotna, uznaje się, że zmienne Z i X są współzależne. Jeżeli natomiast różnica okaże się nieistotna, to zmienne uznane zostają za niezależne. Gdy średnia wartość X dla $Z = 1$ jest istotnie większa od średniej wartości X dla $Z = 0$, wówczas zależność

pomiędzy X i Z uznaje się za dodatnią. W przeciwnym wypadku jest to zależność ujemna.

Dla pary zmiennych mierzalnych na skali przedziałowej obliczono klasyczny współczynnik korelacji liniowej Persony.

Po przeprowadzeniu procedury doboru zmiennych w modelu znalazły się:

X_{11} – całkowita wartość dostępnego kredytu,

X_{15} – czas działalności firmy na rynku,

X_{18} – liczba kontrahentów,


X_{20} – stosunek ceny zaproponowanej przez oferenta do ceny z kosztorysu inwestorskiego.

Korzystając z metody największej wiarygodności, oszacowano parametry modelu logitowego. Model ma postać:

$$L = -5,9220 + 0,4053X_{11} + 0,5939X_{15} + 0,0303X_{18} + 0,0617X_{20}.$$

Na rysunku 1 przedstawiono wykres logitów otrzymanych na podstawie prawdopodobieństwa empirycznego i logitów teoretycznych obliczonych na podstawie modelu.

Z wykresu wynika, że model przeszacowuje prawdopodobieństwa bardzo niskie (bliskie 0), natomiast niedoszacowuje prawdopodobieństwa bardzo wysokie (bliskie 1).



Rys. 1. Logity empiryczne i teoretyczne

Źródło: opracowanie własne.

Trzeba jednak zauważyć, że model daje dość dobre wyniki, gdy celem badania jest określenie, czy prawdopodobieństwo zadowolającej jakości wykonania zamówienia publicznego jest wyższe czy niższe niż 0,5. W tej sytuacji model poprawnie klasyfikuje 86% obserwacji.

Wybrane statystyki dla modelu zawiera tab. 1.

Tabela 1. Wybrane statystyki dla modelu logitowego

Zmienna	β	Błąd standardowy β	Statystyka T
X_{11}	0,4053	0,0553	7,3294
X_{15}	0,5939	0,1248	4,7568
X_{18}	0,0303	0,0069	4,3799
X_{20}	0,0617	0,0057	10,7564

Aby obliczyć prawdopodobieństwo, że jakość wykonania zamówienia publicznego będzie wysoka, należy skorzystać z funkcji logistycznej o postaci:

$$p = \frac{1}{1 + \exp[-(-5,9220 + 0,4053X_{11} + 0,5939X_{15} + 0,0303X_{18} + 0,0617X_{20})]}$$

Prawdopodobieństwa empiryczne i teoretyczne oraz klasyfikację obiektów do klas przeprowadzone na ich podstawie zawiera tab. 2.

Tabela 2. Jakość wykonania zamówień publicznych dla danych testowych

Lp.	X_{11}	X_{15}	X_{18}	X_{20}	P	p z modelu	Spodziewana jakość według modelu	Rzeczywista jakość wykonania
1	3	0	10	72,692	0,7	0,52	1	1
2	3,6	0	14	76,68929	0,62	0,67	1	1
3	3,8	1	16	64,72342	0,44	0,67	1	1
4	1,2	0	7	34,10019	0,043	0,04	0	0
5	1,2	0	9	59,64854	0,33	0,19	0	0
6	1,2	0	9	52,84895	0,043	0,13	0	0
7	0,85	0	7	82,55394	0,29	0,43	0	0
8	0,85	0	11	88,61836	0,32	0,56	1	1
9	0,9	0	8	78,86184	0,29	0,39	0	1
10	1,2	0	8	39,10019	0,043	0,06	0	0

Źródło: opracowanie własne.

4. Analiza dyskryminacyjna

Liniowa analiza dyskryminacyjna oparta jest na modelu o następującej postaci ogólnej [11; 16]:

$$Z = a_1 X_1 + a_2 X_2 + \dots + a_n X_n, \quad (4)$$

gdzie: Z – zmienna objaśniana,

$a_1, a_2, \dots, a_n$ – współczynniki dyskryminacyjne (wagi wskaźników),

$X_1, X_2, \dots, X_n$ – zmienne objaśniające – cechy badanego obiektu.

Aby możliwe było prawidłowe oszacowanie parametrów modelu dyskryminacyjnego, zmienne objaśniające muszą mieć rozkład normalny w poszczególnych klasach oraz muszą być wzajemnie niezależne.

Metoda użyta do oceny jakości wykonywania zamówień publicznych, zaproponowana przez Fishera [4], polega na takim doborze wektora $\mathbf{a}$, aby zbiory punktów należących do poszczególnych klas były możliwie najbardziej rozdzielone. W metodzie Fishera maksymalizowana jest następująca formuła, stanowiąca kryterium jakości wektora $\mathbf{a}$:

$$J = \frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}. \quad (5)$$

Przy założeniu, że badane jest N obiektów $\mathbf{x}_n$ ($n = 1, 2, \dots, N$), pochodzących z K klas C_k ($k = 1, 2, \dots, K$) oraz że do k -tej klasy należy N_k obiektów, należy skonstruować macierz rozrzutu międzygrupowego $\mathbf{B}$ oraz macierz rozrzutu wewnątrzgrupowego $\mathbf{W}$ według wzorów [7]:

$$\mathbf{B} = \frac{1}{N} \sum_{k=1}^K N_k (\mathbf{m}_k - \mathbf{m})(\mathbf{m}_k - \mathbf{m})^T, \quad (6)$$

$$\mathbf{W} = \frac{1}{N} \sum_{k=1}^K \sum_{\mathbf{x}_i \in C_k} N_k (\mathbf{x}_i - \mathbf{m}_k)(\mathbf{x}_i - \mathbf{m}_k)^T, \quad (7)$$

gdzie: $\mathbf{m}$ – wektor średnich ze wszystkich obiektów,

$\mathbf{m}_k$ – wektor średnich z obiektów należących do klasy C_k .

Do klasyfikacji zastosowano klasyczny algorytm Bayesa [8] z zero-jedynkową funkcją strat. Odpowiednie rozkłady prawdopodobieństw *a posteriori* dla klas wynoszą:

$$Z_1 = f(Y = 1/Z) = p_1(Y = 1) \cdot f_1(Z/Y = 1), \quad (8)$$

$$Z_2 = f(Y = 0/Z) = p_2(Y = 1) \cdot f_1(Z/Y = 0). \quad (9)$$

Ponieważ hipotezy o normalności rozkładu zmiennych objaśniających w modelu zostały zweryfikowane pozytywnie, można uznać, że na poziomie ufności 0,05 zmienne Z_1 i Z_2 również mają rozkład normalny. Parametry tych rozkładów oszacowano na podstawie próby przyjętej do budowy modelu. Następnie wyznaczono wartość graniczną W_G dla rozkładów zmiennych Z_1 i Z_2 w punkcie ich przecięcia.

Prawdopodobieństwo popełnienia błędów pierwszego i drugiego rodzaju wynosi [11]:

$$P(\text{I}) = \frac{O_1}{P_2 + O_1} \text{ dla } Z > W_G, \quad (10)$$

$$P(\text{II}) = \frac{O_2}{P_1 + O_2} \text{ dla } Z < W_G, \quad (11)$$

gdzie: O_1, O_2 – obszary walidacji (nachodzenia na siebie rozkładów) lewostronnej

i prawostronnej wyrażone wzorami $O_1 = p_1 \int_{-\infty}^{W_G} f_1(Z) dZ$,

$$O_2 = p_2 \int_{W_G}^{\infty} f_2(Z) dZ$$

P_1, P_2 – obszary właściwe rozkładu dla klasy 1 i 2, $P_1 = p_1 \int_{W_G}^{\infty} f_1(Z) dZ$,

$$P_2 = p_2 \int_{-\infty}^{W_G} f_2(Z) dZ.$$

Po przeprowadzeniu testu zgodności Kołmogorowa-Smirnova oraz analizy korelacji do modelu wybrane zostały trzy zmienne:

X_{15} – czas działalności firmy na rynku,

X_{19} – średni wiek maszyn,

X_{21} – stosunek ceny zaproponowanej przez oferenta do średniej wartości wykonanych dotąd zamówień.

W rozważanym przypadku badane jest $N = 100$ obiektów należących do 2 klas o liczebnościach odpowiednio $N_1 = 41$ ($Y = 0$) i $N_2 = 59$ ($Y = 1$).


Model dyskryminacyjny ma postać:

$$Z = -0,00116X_{15} + 0,004673X_{19} - 0,99999X_{21}.$$

Na rysunku 2 przedstawione zostały rozkłady zmiennych Z_1 i Z_2 .

Prawdopodobieństwo przyporządkowania obiektu do niewłaściwej klasy wynosi ponad 0,2.

W tabeli 4 zostały przedstawione wyniki przyporządkowania do klas obiektów ze zbioru testowego.

Rys. 2. Rozkłady zmiennych Z_1 i Z_2

Źródło: opracowanie własne.

Tabela 3. Charakterystyki określające jakość modelu dyskryminacyjnego

Wartość graniczna	Obszary walidacji		Obszary właściwe rozkładów Z_1 i Z_2		prawdopodobieństwa popełnienia błędów I i II rodzaju	
W_G	O_1	O_2	P_1	P_2	$P(I)$	$P(II)$
-0,565	0,1311	0,0851	0,2789	0,5049	0,2338	0,2061

Źródło: opracowanie własne.

Tabela 4. Klasyfikacja obiektów ze zbioru testowego

Lp.	Z	Klasa, z której obiekt pochodzi	Klasa, do której obiekt został przyporządkowany
1	-0,68207	2	2
2	-0,72204	2	2
3	-0,5979	2	2
4	-0,29616	1	1
5	-0,5606	1	1
6	-0,49261	1	1
7	-0,78517	1	2
8	-0,84133	2	2
9	-0,74376	2	2
10	-0,35064	1	1

Źródło: opracowanie własne.

5. Drzewa klasyfikacyjne

W roku 1984 Breiman, Friedman, Olshen i Stone zaproponowali nieparametryczną metodę dyskryminacji polegającą na automatycznej syntezie drzew klasyfikacyjnych [9; 10].

W metodzie tej, zwanej metodą rekurencyjnego podziału, analizowany jest zbiór obiektów (obserwacji) S , którego każdy element charakteryzowany jest przez wektor $M+1$ cech $[X, Y]$. Dysponując obserwacjami wszystkich zmiennych, należy znaleźć relację między Y a X , czyli funkcję taką, że:

$$Y = f(X, \alpha) + \varepsilon. \quad (12)$$

Procedura rekurencyjnego podziału polega na tym, że w każdym kroku wyjściowy obszar dzielony jest w optymalny sposób na dwie lub więcej części za pomocą jednej z cech (X_m). W ten sposób tworzy się podzbiory zbioru S , aż do osiągnięcia maksymalnej ich jednorodności ze względu na wartość zmiennej objaśnianej Y . Dobór zmiennych, które zostaną wprowadzone do modelu, odbywa się na podstawie funkcji heterogeniczności H . Funkcja H jest definiowana jako nieujemna funkcja prawdopodobieństw:

$$p(j|k) = \frac{N_j(k)}{N(k)}, \quad (13)$$

gdzie: $N_j(k)$ – liczba obiektów należących do j -tej klasy, znajdująca się w podzbiorze $S(k)$,

$N(k)$ – liczba obiektów znajdująca się w podzbiorze $S(k)$.

Heterogeniczność została zmierzona za pomocą wskaźnika zróżnicowania Giniego [5]:

$$\Phi[p(1|k), p(2|k), \dots, p(J|k)] = 1 - \sum_{j=1}^J p^2(j|k). \quad (14)$$

Sposób przeprowadzenia podziału zbioru obiektów S na podzbiory zależy, jak przedstawił Gatnar [5], od charakteru zmiennych objaśniających.

Jeśli zmienna X_m jest zmienną nominalną, przyjmującą wartości ze zbioru $V_m = \{v_1, v_2, \dots, v_T\}$, to tworzone są podzbiory S_1 i S_2 definiowane jako:

$$S_1 = \{X_n: X_{nm} \in B\}, S_2 = \{X_n: X_{nm} \notin B\}. \quad (15)$$

Jeśli X_m ma charakter ilościowy i w zbiorze S przyjmuje wartości z uporządkowanego zbioru V_m , to rozważane są podzbiory w postaci:

$$S_1 = \{X_n: X_{nm} \leq C\}, S_2 = \{X_n: X_{nm} > C\}. \quad (16)$$

Zatrzymanie podziału następowało wtedy, gdy liczebności (N_s) podzbioru N_k były mniejsze niż 8 elementów.

W ten sposób powstało drzewo binarne (rys. 3) klasyfikujące konkretne obserwacje do jednej z dwóch klas na podstawie wartości odpowiednich zmiennych objaśniających.


Wykorzystując dodatkowy zbiór testowy liczący 10 elementów obliczono błąd klasyfikacji według wzoru:

$$e^T(D) = \frac{B(T)}{N(T)}, \quad (17)$$

gdzie: $B(T)$ – liczba błędnie sklasyfikowanych obiektów ze zbioru T ,

$N(T)$ – liczebność zbioru testowego.

Dla otrzymanego modelu wskaźnik ten wynosi 0,2.



Rys. 3. Drzewo klasyfikacyjne

Źródło: opracowanie własne.

Jakość modelu dyskryminacyjnego można mierzyć także oceną resubstytucji.

$$\hat{e}^R(S) = \frac{1}{N} \sum_{k=1}^N B(k), \quad (18)$$

gdzie: $B(k)$ – liczba obiektów ze zbioru S , które zostały błędnie przydzielone do podzbioru S_k , tj. dla których wartość zmiennej Y została błędnie określona przez drzewo klasyfikacyjne. Dla otrzymanego drzewa klasyfikacyjnego wskaźnik ten wynosi 0,03. Oznacza to, że 3% obiektów zostało błędnie przydzielone do klas.

Ponieważ jest to wskaźnik oparty na całym zbiorze uczącym, jego wartość jako błędu klasyfikacji jest często niedoszacowana.

Wybór właściwej postaci drzewa klasyfikacyjnego sprowadza się do znalezienia takiego modelu, dla którego koszt błędnej decyzji klasyfikacyjnej będzie najmniejszy przy minimalnej wielkości drzewa. Wielkość pierwotnie skonstruowanego drzewa można ograniczyć, przycinając jego krawędzie, aż do osiągnięcia modelu suboptymalnego. Aby ocenić, jaka wielkość drzewa jest najlepsza, można zastosować metodę sprawdzania krzyżowego (*cross validation*). Polega ona na podziale zbioru uczącego S na V równolicznych i rozłącznych części $S_1, S_2, \dots, S_V$. Następnie tworzy się modele dyskryminacyjne dla zbiorów uczących $S - S_i$ ($i = 1, 2, \dots, V$), a błędy klasyfikacji oblicza się, traktując zbiory S_i jako testowe. Kończącą ocenę błędu klasyfikacji dla modelu oblicza się zgodnie z formułą:

$$\hat{e}^{SK} = \frac{1}{V} \sum_{v=1}^V e^T(v). \quad (19)$$

Wyniki przedstawiono w tab. 5.


Tabela 5. Koszty błędnej klasyfikacji i ich statystyki obliczone dzięki zastosowaniu metody sprawdzania krzyżowego

Poziom przycinania	Koszt błędnej decyzji klasyfikacyjnej	Standardowy błąd oszacowania kosztu błędnej klasyfikacji	Liczba liści drzewa po przycięciu
0	0,18	0,0383	8
1	0,16	0,0365	7
2	0,16	0,0365	4
3	0,15	0,0355	3
4	0,21	0,0386	2
5	0,41	0	1

Źródło: opracowanie własne.

Alternatywną metodę przycinania krawędzi przedstawili B. Cremilleux i D. Fournier [2].

Jeżeli dokonane zostanie przycięcie krawędzi drzewa do poziomu trzeciego (drzewo będzie miało 2 węzły i 3 liście), to koszt błędnej decyzji klasyfikacyjnej będzie najmniejszy i wyniesie 0,15 z błędem oszacowania na poziomie 0,0355. Otrzymane po przycięciu krawędzi drzewo klasyfikacyjne będzie wyglądało następująco (rys. 4):



Rys. 4. Drzewo klasyfikacyjne po przycięciu krawędzi

Źródło: opracowanie własne.

Według modelu do klasyfikacji wystarczy posłużyć się dwiema zmiennymi – w pierwszej kolejności stosunkiem ceny ofertowej do ceny z kosztorysu inwestorskiego, a następnie wskaźnikiem płynności bieżącej oferenta.

6. Wnioski

Największy wpływ na jakość wykonywania zamówień publicznych wydaje się mieć stosunek ceny zaproponowanej przez oferenta do ceny z kosztorysu inwestorskiego, ponieważ ta zmienna występuje we wszystkich zastosowanych modelach.

Użyte w pracy metody statystyczne znacznie różnią się od siebie i w różnym stopniu mogą być wykorzystywane do wspomagania inwestora w procesie decyzyjnym. Najmniej odpowiednia do tego celu jest liniowa dyskryminacja Fishera.

Najpoważniejszą wadą liniowej dyskryminacji Fishera jest krępujące założenie dotyczące rozkładu cech. Ponieważ zakłada się, że predyktory muszą mieć rozkład normalny w klasach, aż 70% spośród potencjalnych zmiennych objaśniających nie miało szans zaistnienia w modelu. Ponadto w rozważanym przypadku rozkłady zmiennej objaśnianej w modelu dyskryminacyjnym w poszczególnych klasach w zbyt dużym stopniu nachodziły na siebie, co jest jednoznaczne z wysokim prawdopodobieństwem popełnienia przez inwestora błędu podczas oceny, czy dany oferent wykona przedmiot zamówienia publicznego wysokiej jakości. Zarówno prawdopodobieństwo, że oferta, która w rzeczywistości zrealizowana dałaby zadowalający efekt końcowy, zostanie odrzucona, jak i szansa, że przyjęcie oferty okaże się błędem, są w otrzymanym modelu wyższe niż 20%. Ryzyko jest zbyt duże, aby przy wyborze oferenta można się było kierować parametrycznym modelem dyskryminacyjnym. Analiza dyskryminacyjna Fishera daje najlepsze rezultaty, jeżeli roz-

kłady zmiennej objaśnianej w klasach znacznie się różnią od siebie. Jako najważniejszą zaletę metody parametrycznej dyskryminacji należy wymienić łatwość interpretacji – każda oferta charakteryzowana jest za pomocą jednej wartości zmiennej Z , na podstawie której odbywa się klasyfikacja.

Więcej możliwości, jeśli chodzi o zastosowanie do oceny jakości wykonania zamówień publicznych, stwarza model logitowy. Jego najistotniejsze zalety to możliwość zastosowania jako predyktorów zmiennych o charakterze zarówno jakościowym, jak i ilościowym oraz brak założeń co do postaci rozkładu zmiennych objaśniających w modelu.

Niekorzystne z punktu widzenia możliwości skutecznego zastosowania modelu logitowego do wspomaganiania inwestora w procesie decyzyjnym jest to, że jest to model prawdopodobieństwa – kwestią do rozważenia pozostaje, kiedy należy uznać, że prawdopodobieństwo to jest na tyle wysokie, aby spodziewana jakość wykonania zamówienia publicznego została określona jako zadowalająca. Ponadto szukane są liniowe zależności pomiędzy zmiennymi objaśniającymi a zmienną objaśnianą, co powoduje wykluczenie z modelu zmiennych, od których jakość wykonania przedmiotu przetargu zależy nieliniowo.

Niedogodności charakterystyczne dla modeli wymienionych wcześniej nie występują w przypadku użycia nieparametrycznej metody dyskryminacyjnej do oceny, czy oferent wywiąże się ze swoich zobowiązań wobec inwestora w sposób zadowalający. Warto zastosować metodę drzew klasyfikacyjnych, ponieważ:

1. Nie ma założeń co do postaci rozkładu cech, można więc stosować predyktory o charakterze dowolnym.
2. Nie bada się zależności liniowej pomiędzy zmiennymi objaśniającymi a jakością, a także korelacji pomiędzy predyktorami, a jedynie siłę dyskryminacyjną danych zmiennych.
3. Model nie nastręcza trudności interpretacyjnych – jest przedstawiony w postaci rysunku.
4. Ze względu na charakter zmiennej objaśnianej. Jakość wykonania zamówienia publicznego jest reprezentowana przez zmienną jakościową, a przy tym trudno jest znaleźć zmienne, których wpływ na nią byłby bardzo znaczny.

Literatura

- [1] Breiman L., Friedman J., Olshen R., Stone C., *Classification and Regression Trees*, CRC Press, London 1984.
- [2] Cremilleux B., Fournier D., *A Quality Index for Decision Tree Pruning*, vol. 15, 2002, s. 37-43.
- [3] Dobson A.J., *An Introduction to Generalized Linear Models*, Chapman and Hall, London 1997.
- [4] Fisher R., *The Use of Multiple Measurements in Taxonomic Problems*, [w:] *Contributions to Mathematical Statistic*, John Wiley, New York 1950.

- [5] Gatnar E., *Nieparametryczna metoda dyskryminacji i regresji*, PWN, Warszawa 2001.
- [6] Gruszczyński M., *Scoring logitowy w praktyce bankowej a zagadnienie koincydencji*, „Bank i Kredyt” 1999, nr 5, s. 57-63.
- [7] Jiang J., Tsenkova R., Ozaki Y., *Principal Discriminant Variate Method for Classification of Multicollinear Data: Principle and Applications*, „Analytical sciences” 2001, vol. 17, s. 471-474.
- [8] Kurzyński M., *Rozpoznawanie obiektów. Metody statystyczne*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 1997.
- [9] Landgrebe D., Safavian S.R., *A Survey of Decision Tree Classifier Methodology*, IEEE Transactions on System, „Man and Cybernetics” 1991, vol. 21, nr 3, s. 660-674.
- [10] Lewis R.J., *An Introduction to Classification and Regression Tree (CART) Analysis*, Annual Meeting of the Society for Academic Emergency Medicine, San Francisco 2000.
- [11] Mejer D., *Analiza dyskryminacyjna*, „Bank” 2000, nr 6, s. 38-44.
- [12] Panasiuk i in., *Prawo zamówień publicznych z komentarzem*, Oficyna Wydawnicza Branta, Warszawa 2004.
- [13] Pieróg J., *Prawo zamówień publicznych: komentarz*, C.H. Beck, Warszawa 2004.
- [14] Rao R.C., Toutenburg H., *Linear Models: Least Squares and Alternatives*, Springer-Verlag, New York 1995.
- [15] Siarka P., *Zastosowanie metod statystycznych w budowie modeli credit-scoringowych*, AE, Wrocław 2003.
- [16] Stanisław A., *Analiza dyskryminacyjna*, „Medycyna Praktyczna” 2002, nr 06.
- [17] Ustawa z dnia 29 stycznia 2004 r., *Prawo zamówień publicznych* (DzU nr 19, poz. 177).
- [18] Yang J., Yang J., Zhang D., *What's Wrong with Fisher Criterion?*, „Pattern Recognition” 2002, vol. 35, s. 2665-2668.

THE APPLICATION OF SELECTED QUANTITATIVE METHODS TO ASSESS COMPETITIVE TENDERING EXECUTION QUALITY

Summary

The problem of the competitive tendering execution quality decreasing caused by an excessive reduction of the offered price was investigated. The author proposes the application of quantitative methods to assess. *Ex post* quality concerning road building and to forecast competitive tendering execution quality assessment. Binomial logit model, Fisher's linear discriminant analysis with Bayesian classification algorithm and nonparametric discriminant method (CART algorithm) were applied to assess the quality. The best results were obtained by using classification tree. It was shown that Fisher's discriminant analysis and logit model can't be used to assess competitive tendering execution quality. That is because the majority of predictors has irregular classes distribution and because the dependence between exogenous variate and endogenous variate is nonlinear.