

dr inż. Monika Górka-Stańczyk^{1*)}

ORCID: 0000-0002-5985-2078:

dr inż. Joanna Sagan²⁾

ORCID: 0000-0003-3116-0448

Sensitivity analysis of input variables in an ANN model for predicting curtain wall costs

Analiza wrażliwości zmiennych modelu SSN prognozowania kosztów ścian osłonowych

DOI: 10.15199/33.2025.12.07

Abstract. Assess the importance of input variables in an artificial neural network (ANN) model designed to predict the costs of curtain walls. The analysis was carried out on the basis of 209 contract documents of public utility buildings located in central and southern Poland. Out of 28 initially identified factors, 24 variables describing the technical parameters of the buildings and the types of facade materials were selected for the construction of the ANN model. The global sensitivity analysis of the model revealed that the most critical cost-determining factor for facade systems is the facade area. Due to the low significance levels of other variables, input variable selection was conducted, showing that a reduced model with 16 variables retained a quality comparable to that of the full 24-variable model. In addition, a simulation was carried out to assess the impact of the most significant variables on the SSN model. The results confirm that the SSN responds appropriately to changes in the input variables and further serves as an effective tool for predicting the costs of façade systems.

Keywords: facade systems; sensitivity analysis; artificial neural network (ANN); cost prediction.

Streszczenie. Oceniono znaczenie zmiennych wejściowych w modelu sztucznej sieci neuronowej (SSN) prognozującej koszty ścian osłonowych. Analizę przeprowadzono na podstawie 209 dokumentacji kontraktowych budynków użyteczności publicznej zlokalizowanych w centralnej i południowej Polsce. Spośród 28 zidentyfikowanych czynników, po selekcji wykorzystano 24 zmienne opisujące parametry techniczne obiektów i rodzaje materiałów elewacyjnych do budowy modelu sztucznej sieci neuronowej. Globalna analiza wrażliwości modelu SSN wykazała, że kluczowym czynnikiem determinującym koszty systemów fasadowych jest powierzchnia elewacji. Ze względu na niski poziom istotności pozostałych zmiennych przeprowadzono selekcję zmiennych wejściowych modelu sztucznej sieci neuronowej, gdzie w przypadku 16 zmiennych wejściowych jakość modelu pozostała na porównywalnym poziomie jak w przypadku 24 zmiennych. Ponadto wykonano symulację wpływu najistotniejszych zmiennych na model SSN. Badania potwierdzają, że SSN prawidłowo reaguje na zmiany zmiennych wejściowych i stanowi skuteczne narzędzie prognozowania kosztów systemów elewacyjnych.

Słowa kluczowe: systemy elewacyjne; analiza wrażliwości; model SSN; predykcja kosztów.

Façades play a fundamental role in shaping the aesthetic and functional performance of contemporary buildings. They define the visual identity of a structure, imparting a distinctive architectural character and serving as a recognizable element within the urban environment. The rapid advancement of construction technologies, together with the introduction of innovative materials, has elevated the importance of curtain wall design, both in technical terms and within the broader architectural context [1, 2]. Contemporary curtain wall systems are multifunctional structural assemblies that integrate usability, aesthetic, energy-efficient, and environmental requirements. When properly designed, they enhance user comfort, reduce energy losses, improve the acoustic performance of interior spaces, and contribute to the overall prestige of the building [3, 4].

The execution of a construction investment requires maintaining a balance among three key factors: time, cost, and quality [5]. Effective management of these parameters enables the investor to achieve the intended project objectives while minimizing technical and financial risks [6]. Moreover, modifications introduced during the design or construction

elewacje pełnią kluczową rolę w budowaniu estetyki i funkcjonalności współczesnych obiektów. Kształtują wizualny charakter budynku, nadają mu indywidualny styl i stają się znakiem rozpoznawczym w przestrzeni miejskiej. Dynamiczny rozwój technologii budowlanych oraz pojawienie się innowacyjnych materiałów sprawiają, że projektowanie ścian osłonowych nabiera coraz większego znaczenia, zarówno w aspekcie technicznym, jak i architektonicznym [1, 2]. Współczesne ściany osłonowe są konstrukcjami o wielofunkcyjnym charakterze, łączącymi wymagania użytkowe, estetyczne, energooszczędne i ekologiczne. Odpowiednio zaprojektowane wpływają na komfort użytkowników, ograniczają straty energii, poprawiają akustykę pomieszczeń, a także podnoszą prestiż budynku [3, 4].

Proces realizacji inwestycji budowlanej wymaga zachowania równowagi pomiędzy trzema kluczowymi wartościami: czasem, kosztem i jakością [5]. Poprawne zarządzanie tymi parametrami pozwala inwestorowi osiągnąć zakładane cele przy minimalizacji ryzyka technicznego i finansowego [6]. Co więcej, zmiany na etapie projektowania lub wykonawstwa wpływają na przebieg harmonogramu oraz koszty, dlatego niezbędne staje się precyzyjne planowanie oraz nadzór nad

¹⁾ Politechnika Krakowska, Wydział Inżynierii Lądowej

²⁾ AGH w Krakowie, Wydział Inżynierii Lądowej i Gospodarki Zasobami

^{*)} Correspondence address: monika.gorka@pk.edu.pl

stages affect both the schedule and overall expenditures, making precise planning and continuous supervision of the implementation process essential [7]. Every construction project is inherently associated with costs, and their proper planning and control are critical determinants of project success [8, 9]. In the case of curtain wall systems, investor decision-making becomes particularly demanding. A properly conducted cost analysis is crucial at both the design and execution stages, as it allows for the establishment of an accurate project budget. Cost estimation for curtain wall systems encompasses a wide range of factors, including material prices, structural system selection, installation technologies, and labour time requirements [10]. For these reasons, the search for new methods and models of cost estimation – particularly those employing artificial intelligence – has become increasingly important.

The significance of the input variables in the proposed artificial neural network (ANN) model for forecasting curtain wall costs was evaluated. The study included a global sensitivity analysis of the model based on the degree of importance of the factors that exert the greatest influence on façade system costs. In addition, a variability analysis of the model was carried out to assess its response to changes in the most significant input variables.

Research subject

The traditional classification of external walls includes single-, double-, and triple-layer constructions. The analysis focused on the solutions most commonly used in public utility buildings, namely glass-metal curtain walls and ventilated façades systems. The classification of curtain wall systems is presented in figure 1.

Aluminium plays a dominant role in glass-metal façade systems. Aluminium profiles are characterized by high strength combined with low weight, corrosion resistance, flexibility in shaping cross-section geometry, and excellent thermal insulation performance. Moreover, their production is associated with reduced CO₂ emissions, and the material itself is fully recyclable. For this reason, the study focused on façade systems in which the structural framework consists of aluminium profiles, while various types of glass serve as the infill.

Considering the type of system used, aluminium façades are classified into three main groups [11]: mullion-transom systems, structural systems, and semi-structural systems.

The second solution analysed in the study is the ventilated façade. Its construction comprises a substructure (supporting grid), a thermal insulation layer, an exterior cladding, and mechanical fasteners.

procesem realizacji [7]. Każde przedsięwzięcie budowlane jest nierozdzielnie związane z kosztami, a ich właściwe planowanie i kontrola determinują powodzenie całego projektu [8, 9]. W przypadku ścian osłonowych decyzje inwestorów są szczególnie wymagające. Prawdłowo przeprowadzona analiza kosztowa ma istotne znaczenie zarówno na etapie projektowania, jak i wykonawstwa. Umożliwia ona ustalenie budżetu przedsięwzięcia. W przypadku ścian osłonowych, szacowanie kosztów obejmuje szeroki zakres czynników: od cen materiałów i systemów konstrukcyjnych, przez czas i technologię montażu [10]. Z tego względu istotne staje się poszukiwanie nowych metod i modeli szacowania kosztów z wykorzystaniem np. sztucznej inteligencji.

Oceniono istotność zmiennych wejściowych zaproponowanego modelu sztucznej sieci neuronowej prognozowania kosztów ścian osłonowych. W badaniu przeprowadzono globalną analizę wrażliwości modelu w zależności od stopnia istotności czynników, które w największym stopniu wpływają na koszty systemów fasadowych. Dodatkowo wykonano analizę zmienności modelu, w zależności od zmiany najistotniejszych zmiennych wejściowych.

Przedmiot badań

Tradycyjny podział ścian zewnętrznych obejmuje konstrukcje jedno-, dwu- lub trójwarstwowe. Skoncentrowano się na rozwiązaniach najczęściej stosowanych w obiektach użyteczności publicznej, czyli metalowo-szklanych oraz wentylowanych ścianach osłonowych. Podział ścian osłonowych przedstawia rysunek 1.




Fig. 1. Classification of curtain walls [11]

Rys. 1. Podział ścian osłonowych [11]

Dominującą rolę w elewacjach szklano-metalowych odgrywa aluminium. Profile aluminiowe charakteryzują się dużą wytrzymałością przy niewielkiej masie, odpornością na korozję, możliwością dowolnego kształtowania geometrii przekrojów, a także bardzo dobrymi parametrami izolacyjności termicznej. Ponadto ich produkcja wiąże się z obniżoną emisją CO₂, a sam materiał w pełni podlega procesowi recyklingu. Z tego względu w badaniach skupiono się na systemach fasadowych, w których konstrukcję stanowi szkielet aluminiowy, natomiast wypełnienie szkło różnego rodzaju.

Biorąc pod uwagę rodzaj zastosowanego systemu, fasady aluminiowe dzieli się na trzy główne grupy [11]: słupowo-ryglowe; strukturalne; semistrukturalne.

Drugim analizowanym rozwiązaniem są elewacje wentylowane. Ich konstrukcja obejmuje: podkonstrukcję (ruszt), warstwę termoizolacyjną, okładzinę elewacyjną oraz łączniki mechaniczne.

Research methodology

ANN Model. The first stage of the research involved identifying the factors influencing the cost of curtain wall systems during the conceptual design phase, based on the availability of fundamental structural data. This identification was carried out through a review of the relevant literature as well as an analysis of 209 contract documentation sets. A detailed description of the factors is provided in [12]. The initial database consisted of 28 variables influencing the cost of façade systems. Based on the Spearman rank correlation analysis, four variables were excluded:

- type of façade under analysis – simple (X_{10});
- type of aluminium–glass façade – with specified fire resistance (X_{15});
- type of glazing – transparent insulating glass unit (X_{18});
- type of window and door joinery – fire-rated doors (X_{26}).

These variables showed either no correlation with the dependent variable (Y) or a strong correlation with other independent variables. Table 1 presents the input variables used in the proposed artificial neural network model along with their corresponding symbols.

The next stage of the analysis involved developing the ANN model. A unidirectional, multilayer perceptron (MLP) network was selected, with the BFGS algorithm used for training. The dataset was divided into 70% for training and 30% for validation and testing. The minimum number of neurons in the hidden layer was set to 6, and the maximum to 20. A fourfold random sampling strategy was applied for selecting the training set. In each sampling iteration, 50 networks were trained, and the five networks with the best training and testing performance were retained. As

Metodyka badań

Model SSN. Pierwszym etapem przeprowadzonych badań była identyfikacja czynników wpływających na koszt realizacji systemów fasadowych, na etapie przygotowania koncepcji projektowej, przy znajomości podstawowych danych konstrukcyjnych. Dokonano jej na podstawie studium literatury przedmiotu, a także analizy 209 dokumentacji kontraktowych. Dokładany opis czynników przedstawiono

w [12]. Początkowa baza danych składała się z 28 zmiennych kształtujących koszty systemów elewacyjnych. Na podstawie przeprowadzonej analizy korelacji rang Spearmana wykluczono cztery zmienne:

- rodzaj analizowanej elewacji – prosta (X_{10});
- rodzaj fasady aluminiowo-szklanej – o danej odporności ogniowej (X_{15});
- rodzaj zastosowanego szkła – przeźierne zespolone (X_{18});
- rodzaj stolarki otworowej – drzwi ogniowe (X_{26}).

Zmienne te charakteryzowały się brakiem korelacji z zmienną zależną (Y) lub silną korelacją z pozostałymi zmiennymi niezależnymi. W tabeli 1 zestawiono zmienne wejściowe wykorzystane w zaproponowanym modelu sztucznej sieci neuronowej wraz z odpowiadającymi im symbolami.

Kolejny etap analizy to budowa modelu SSN. Wybrano sieć jednokierunkową, wielowarstwową MLP, gdzie algorytm uczący to BFGS. Przyjęto rozkład zmiennych w stosunku 70% (zbiór uczący) i 30% (zbiór walidacyjny i testowy). Minimalna liczba neuronów w warstwie ukrytej została określona jako 6, a maksymalna – 20. Przyjęto strategię losowania zbioru uczącego czterokrotnie. W każdym losowaniu uczono 50 sieci i zapisywano 5 o najlepszej jakości uczenia i testowania. W efekcie wytypowano sieć o strukturze MLP 24-2-1 i funkcjach ak-

Table 1. Set of input variables of the ANN model
Tabela 1. Zbiór zmiennych wejściowych modelu SSN

Variable / Zmienne wejściowe	Symbol / Oznaczenie
Location / Lokalizacja	X_1
Type of public utility building / Rodzaj budynku użyteczności publicznej	X_2
Building form (shape) / Bryła budynku	X_3
Building height / Wysokość budynku	X_4
Building length / Długość budynku	X_5
Building width / Szerokość budynku	X_6
Number of storeys / Liczba kondygnacji	X_7
Area of the analysed façade / Powierzchnia analizowanej elewacji	X_8
Complexity level of façade execution / Poziom skomplikowania wykonania elewacji	X_9
Type of façade analysed – curved / Rodzaj analizowanej elewacji – łukowa	X_{11}
Type of façade analysed – inclined / Rodzaj analizowanej elewacji – pochyła	X_{12}
Type of aluminium–glass façade – mullion–transom system / Rodzaj fasady aluminiowo-szklanej – słupowo-ryglowa	X_{13}
Type of aluminium–glass façade – semi-structural system / Rodzaj fasady aluminiowo-szklanej – półstrukturalna	X_{14}
Type of glazing – fire-resistant glass / Rodzaj zastosowanego szkła – ogniowe	X_{16}
Type of glazing – opaque (non-transparent) glass / Rodzaj zastosowanego szkła – nieprzeźierne	X_{17}
Type of ventilated façade cladding – composite panel / Rodzaj okładziny elewacji wentylowanej – płyta kompozytowa	X_{19}
Type of ventilated façade cladding – sintered quartz panel / Rodzaj okładziny elewacji wentylowanej – spieki kwarcowe	X_{20}
Type of ventilated façade cladding – HPL panel / Rodzaj okładziny elewacji wentylowanej – płyta HPL	X_{21}
Type of ventilated façade cladding – timber cladding / Rodzaj okładziny elewacji wentylowanej – okładzina drewniana	X_{22}
Type of ventilated façade cladding – fibre-cement panel / Rodzaj okładziny elewacji wentylowanej – płyta włókno-cementowa	X_{23}
Type of door joinery – hinged doors / Rodzaj stolarki otworowej – drzwi rozwierne	X_{24}
Type of door joinery – sliding doors / Rodzaj stolarki otworowej – drzwi przesuwne	X_{25}
Type of window joinery – tilt-and-turn windows (RU) / Rodzaj stolarki otworowej – okna RU	X_{27}
Type of window joinery – structurally bonded windows / Rodzaj stolarki otworowej – okna klejone strukturalnie	X_{28}

a result, a network with an MLP 24-2-1 architecture was identified, employing a logistic activation function in the hidden layer and a hyperbolic tangent function in the output layer. The Mean Absolute Percentage Error (MAPE) for the selected model was 10.91% for the training set and 11.53% for the test set. Additionally, the coefficient of determination R^2 was calculated at 0.97387 for the training set and 0.947726 for the test set. The minimum relative error in the test set for the MLP 24-2-1 network was 0%, while the maximum was 43%.

Analysis of results

To assess the relevance and usefulness of the input variables in the artificial neural network model, a sensitivity analysis was performed, enabling an evaluation of the influence of individual input variables (X_j) on the predicted value of the output variable (Y). The analysis examined the extent to which changes in input values produce fluctuations in the model's output. By conducting a global sensitivity analysis using the STATISTICA software, the variables were ranked according to their impact on the prediction, and those that play a key role in ensuring the reliability of the model's forecasts were identified (table 2).

The sensitivity analysis indicates that the most significant variable in the ANN model is X_8 – the area of the analysed façade. Due to the very low sensitivity of the output variable (Y) to the remaining independent variables (X_j), an attempt was made to perform input variable selection for the ANN model. For this purpose, a forward stepwise selection method was applied. The results are presented in figure 2.

tywacji: funkcja logistyczna w warstwie ukrytej oraz funkcja tangens hiperboliczny w warstwie wyjścia. Wyznaczono błąd prognozy MAPE (ang. *Mean Absolute Percentage Error*) wynoszący 10,91% w przypadku zbioru uczącego oraz 11,53% w przypadku testowego. Dodatkowo obliczono współczynnik determinacji R^2 , który wyniósł 0,97387 w przypadku

zbioru uczącego, a dla zbioru testowego 0,947726. Minimalny błąd względny zbioru testowego sieci MLP 24-2-1 to 0%, a maksymalny 43%.

Analiza wyników

W celu określenia znaczenia i użyteczności zmiennych wejściowych w modelu sztucznej sieci neuronowej przeprowadzono **analizę wrażliwości modelu** umożliwiającą ocenę wpływu poszczególnych zmiennych wejściowych (X_j) na wartość prognozowaną zmiennej wyjściowej (Y). Badano, w jakim stopniu zmiana wartości danych wejściowych powoduje wahania wyniku modelu. Dzięki globalnej wrażliwości modelu przeprowadzonej za pomocą programu STATISTICA uporządkowano zmienne pod względem ich wpływu na prognozę oraz wskazano te, które mają charakter kluczowy z punktu widzenia wiarygodności predykcji (tabela 2).

Z przeprowadzonej analizy wrażliwości wynika, że najistotniejszą zmienną w przypadku modelu SSN jest zmienna X_8 – powierzchnia analizowanej elewacji. Ze względu na bardzo małą wrażliwość zmiennej Y na pozostałe zmienne niezależne (X_j), podjęto próbę selekcji zmiennych wejściowych w modelu SSN. W tym celu wykorzystano metodę selekcji krokowej „w przód”. Wyniki przedstawiono na rysunku 2.

Wykonana analiza wrażliwości modelu umożliwi-

Table 2. Global Sensitivity Analysis for the ANN Model

Tabela 2. Analiza globalnej wrażliwości w przypadku modelu SSN

	Input variables (X_j) / Zmienne wejściowe (X_j)	Degree of sensitivity of the output variable Y / Stopień wrażliwości zmiennej wyjściowej Y
X_8	area of the analysed façade / powierzchnia analizowanej elewacji	56.978
X_4	building height / wysokość budynku	2.571
X_{11}	type of façade analysed – curved / rodzaj analizowanej elewacji – łukowa	2.520
X_7	number of storeys / liczba kondygnacji	1.662
X_{16}	type of glazing – fire-resistant glass / rodzaj zastosowanego szkła – ognioowe	1.601
X_{25}	type of door joinery – sliding doors / rodzaj stolarki otworowej – drzwi przesuwne	1.496
X_{22}	type of ventilated façade cladding – timber cladding / rodzaj okładziny elewacji wentylowanej – okładzina drewniana	1.388
X_9	complexity level of façade execution / poziom skomplikowania wykonania elewacji	1.367
X_{19}	type of ventilated façade cladding – composite panel / rodzaj okładziny elewacji wentylowanej – płyta kompozytowa	1.266
X_{12}	type of façade analysed – inclined / rodzaj analizowanej elewacji – pochyła	1.178
X_{20}	type of ventilated façade cladding – sintered quartz panel / rodzaj okładziny elewacji wentylowanej – spieki kwarcowe	1.141
X_{24}	type of door joinery – hinged doors / rodzaj stolarki otworowej – drzwi rozwierne	1.129
X_6	building width / szerokość budynku	1.103
X_3	building form (shape) / bryła budynku	1.096
X_{13}	type of aluminium–glass façade – mullion–transom system / rodzaj fasady aluminiowo-szklanej – słupowo-ryglowa	1.063
X_{21}	type of ventilated façade cladding – HPL panel / rodzaj okładziny elewacji wentylowanej – płyta HPL	1.060
X_{17}	type of glazing – opaque glass / rodzaj zastosowanego szkła – nieprzeziernie	1.052
X_5	building length / długość budynku	1.049
X_1	location / lokalizacja	1.046
X_{23}	type of ventilated façade cladding – fibre-cement panel / rodzaj okładziny elewacji wentylowanej – płyta włókno-cement	1.028
X_{28}	type of window joinery – structurally bonded windows / rodzaj stolarki otworowej – okna klejone strukturalnie	1.019
X_{14}	type of aluminium–glass façade – semi-structural system / rodzaj fasady aluminiowo-szklanej – półstrukturalna	1.017
X_{27}	type of window joinery – tilt-and-turn windows (RU) / rodzaj stolarki otworowej – okna RU	1.006
X_2	type of public utility building / rodzaj budynku użyteczności publicznej	1.002

The conducted sensitivity analysis enabled the selection of individual input variables, reducing the set from 24 to 16 of the most significant variables. After introducing the reduced set of 16 variables, the model's training error decreased from 22.55% to 10.92%, which is comparable to the error obtained for the neural network model using all 24 variables (10.91%). The first non-significant variable identified was X_{17} – type of glazing (opaque).

Additionally, a sensitivity simulation of the ANN model was performed with respect to changes in the input variable values. In the first step, the model's response to modifications of the most significant variable – X_8 , the area of the analysed façade – was examined. In the second step, a simulation was conducted for the three most influential input variables: X_8 – area of the analysed façade; X_4 – building height; X_{11} – type of façade analysed (curved). The measurable parameters were increased and decreased by 10% relative to their baseline values, while all other variables were kept constant. For variable X_{11} , depending on possible configurations, the following coding was adopted: “occurs = 1” and “does not occur = 0”. For a randomly selected case, the predicted façade construction cost and the percentage deviation from the baseline value were determined. Furthermore, basic descriptive statistics were calculated: the arithmetic mean (m), standard deviation (s), and coefficient of variation (V), which, as a relative measure of variability, enables comparison of results when the analysed quantities are of different magnitudes. The results are presented in tables 3 and 4.

Based on the conducted simulation, it can be concluded that the model correctly reflects the response to changes in the input variable values. In the analysed combinations that included the curved façade variable X_{11} , a higher percentage increase in costs was observed compared to the baseline values. This outcome is fully justified, as the construction of such façades requires the use of curved glass, the production of which generates higher financial expenditures.

The coefficient of variation V , calculated for the modification of the key variable, reached 8%, while for the simultaneous modification of the three most significant variables it amounted to 12%.




Fig. 2. Training Error Value of the ANN Model as a Function of the Number of Input Variables

Rys. 2. Wartość błędu uczenia modelu SSN w zależności od liczby zmiennych wejściowych

ła selekcję poszczególnych zmiennych wejściowych, ograniczając zbiór 24 zmiennych do 16 najistotniejszych. Po wprowadzeniu 16 zmiennych błąd uczenia modelu zmalał z 22,55% do 10,92% i jest porównywalny do błędu, jaki uzyskuje model sieci neuronowych w przypadku wprowadzenia 24 zmiennych (10,91%). Pierwszą nieistotną zmienną modelu była zmienna X_{17} – rodzaj zastosowanego szkła (nieprzeierne).

Dodatkowo wykonano symulację wrażliwości modelu SSN w odniesieniu do zmiany wartości zmiennych wejściowych. W pierwszym kroku poddano analizie reakcję modelu na modyfikację najistotniejszej zmiennej – powierzchni analizowanej elewacji X_8 , a w drugim kroku przeprowadzono symulację zmiany modelu w odniesieniu do trzech najistotniejszych zmiennych wejściowych: X_8 – powierzchnia analizowanej elewacji; X_4 – wysokość budynku; X_{11} – rodzaj analizowanej elewacji – łukowa. Parametry mierzalne zostały zwiększone oraz zmniejszone o 10% względem wartości bazowej, przy jednoczesnym utrzymaniu pozostałych zmiennych na niezmiennym poziomie. Z kolei w przypadku zmiennej X_{11} – w zależności od możliwych kombinacji przyjęto: „wystąpi = 1”, „nie wystąpi = 0”. Dla losowo wybranego przypadku określono prognozowany koszt wykonania elewacji oraz procentową różnicę w odniesieniu do wartości wyjściowej. Obliczono również podstawowe statystyki opisowe: średnią arytmetyczną (m), odchylenie standardowe (s) oraz współczynnik zmienności (V), który jako miara względna zmienności, pozwala porównywać wyniki, gdy wielkości poddane analizie są różnego rzędu. Wyniki przedstawiono w tabelach 3 oraz 4.

Na podstawie przeprowadzonej symulacji można stwierdzić, że model prawidłowo odwzorowuje reakcję na zmiany wartości zmiennych wejściowych. W analizowanych kombinacjach, w których uwzględniono elewację łukową X_{11} , odnotowano większy procentowy wzrost kosztów w porównaniu z wartościami bazowymi. Jest to zjawisko całkowicie uzasadnione, gdyż realizacja tego typu elewacji wymaga zastosowania szkła giętego, którego produkcja generuje większe nakłady finansowe. Współczynnik zmienności V , obliczony przy zmianie kluczowej zmiennej, osiągnął 8%, z kolei w przypadku zmiany trzech najistotniejszych zmiennych – 12%.

Table 3. Variability of the output variable Y of the ANN model depending on the change in the most significant input variable X_8
Tabela 3. Zmienność zmiennej wyjściowej Y modelu SSN w zależności od zmiany najistotniejszej zmiennej wejściowej X_8

Variable X_8 / Zmienna X_8	Area of the analysed façade [m ²] / Powierzchnia analizowanej elewacji [m ²]	Façade cost according to the ANN model [mln PLN] / Koszt elewacji wg modelu SSN [mln zł]	Cost change [%] / Zmiana kosztu [%]	m	s	V [%]
n/c / bz.	5103.25	5.698	0			
+10%	5613.58	6.175	8	5.70	0.47	8
-10%	4592.93	5.232	-9			

Summary

The conducted research confirms that the use of an artificial neural network for forecasting curtain wall costs constitutes an effective and valuable tool supporting project budget planning. For the training set, the coefficient of determination R^2 reached 0.97387, and for the test set 0.947726, indicating that the ANN model explains the variability of the dependent variable Y (façade system costs) very well. Moreover, the MAPE value of 11.53% for the test set demonstrates a satisfactory level of predictive accuracy for cost estimation at the conceptual design stage. It should be noted that the ANN model may exhibit certain limitations, such as the risk of overfitting, non-uniform relationships between variables, lack of identifiable data structures, subjective variable assessment, or an insufficient number of observations in the dataset.

The sensitivity analysis indicates that the key factor influencing curtain wall costs is their surface area (X_8). The sensitivity level of the output variable reached 56.978, while the remaining variables exhibited significantly lower impact (below 2.571). The stepwise selection of input variables allowed for reducing the number of factors from 24 to 16 without a noticeable decline in model performance. The conducted simulation of the influence of the most significant input variables confirmed the model's appropriate response to changes in input parameters.

Table 4. Variability of the output variable Y of the ANN model depending on the changes in input variables X_8, X_4, X_{11}
Tabela 4. Zmienność zmiennej wyjściowej Y modelu SSN w zależności od zmiany zmiennych wejściowych X_8, X_4, X_{11}

Combination / Kombinacja	X_8 [%]	X_4 [%]	X_{11}	Façade cost according to the ANN model [mln PLN] / Koszt elewacji wg modelu SSN [mln zł]	Change [%] / Zmiana [%]
1.1	bz	bz	0	5.698	0
1.2	+10	bz	0	6.175	8
1.3	+10	+10	0	6.234	9
1.4	+10	+10	1	7.566	25
1.5	+10	bz	1	7.481	24
1.6	bz	+10	0	5.749	1
1.7	bz	+10	1	6.975	18
1.8	bz	bz	1	6.881	17
1.9	-10	+10	0	5.282	-8
1.10	-10	+10	1	6.327	10
1.11	-10	-10	0	5.181	-10
1.12	-10	-10	1	6.125	7
1.13	-10	bz	0	5.232	-9
1.14	-10	bz	1	6.226	8
1.15	bz	-10	0	5.648	-1
1.16	bz	-10	1	6.786	16
1.17	+10	-10	0	6.119	7
1.18	+10	-10	1	7.394	23
Arithmetic mean / Średnia arytmetyczna			m	6.282	
Standard deviation / Odchylenie standardowe			s	0.760	
Coefficient of variation / Współczynnik zmienności			V	12%	

Podsumowanie

Przeprowadzone badania potwierdzają, że zastosowanie sztucznej sieci neuronowej do prognozowania kosztów ścian osłonowych stanowi skuteczne i wartościowe narzędzie wspierające planowanie budżetu przedsięwzięcia. W przypadku zbioru uczącego współczynnik determinacji R^2 wyniósł 0,97387, a w przypadku zbioru testowego 0,947726, co wskazuje, że model SSN bardzo dobrze wyjaśnia zmienność zmiennej zależnej Y (koszty systemów fasadowych). Ponadto błąd MAPE na poziomie 11,53% dla zbioru testowego świadczy o zadowalającej jakości predykcji modelu szacowania kosztów ścian osłonowych na etapie przygotowania koncepcji projektowej. Należy podkreślić, że model sztucznej sieci neuronowej może mieć pewne ograniczenia związane np.: z ryzykiem nadmiernego dopasowania, brakiem jednorodnych zależności pomiędzy zmiennymi, brakiem identyfikowalnych struktur danych, subiektywną oceną zmiennych, czy zbyt małą liczbą danych w zbudowanej bazie.

Przeprowadzona analiza wrażliwości wskazuje, że kluczowym czynnikiem wpływającym na poziom kosztów ścian osłonowych jest ich powierzchnia X_8 . Stopień wrażliwości zmiennej wyjściowej kształtował się na poziomie 56,978, podczas gdy pozostałe zmienne charakteryzują się istotnie mniejszą siłą oddziaływania (poniżej 2,571). Selekcja krokowa zmiennych wejściowych pozwoliła na ograniczenie liczby czynników z 24 do 16, bez wyraźnej utraty jakości modelu. Przeprowadzona symulacja wpływu najistotniejszych zmiennych wejściowych potwierdziła poprawność reakcji modelu na zmianę parametrów wejściowych. ►

Received: 10.07.2025

Revised: 19.08.2025

Published: 23.12.2025

Artykuł wpłynął do redakcji: 10.07.2025 r.

Otrzymano poprawiony po recenzjach: 19.08.2025 r.

Opublikowano: 23.12.2025 r.

Literature

- [1] Saeedi M, Mohammad R, Kavian P. Study the Effects of Constructions New Techniques and Technologies on Time, Cost and Quality of Construction Projects from the Perspective of Construction Management. *Journal of civil Engineering and Materials Application*. 2017; <https://doi.org/10.15412/J.JCEMA.12010204>.
- [2] Górka M. Use of aluminium and glass facades in urban architecture. *Budownictwo i Architektura*. 2019; 18.3: 29-40.
- [3] Zhangabay N, Tursunkululy T, Ibraimova U, Abdikerova U. Energy-Efficient Adaptive Dynamic Building Facades: A Review of Their Energy Efficiency and Operating Loads. *Applied Sciences*. 2024; <https://doi.org/10.3390/app142310979>.
- [4] Besir AB, Cuce E. Green roofs and facades: A comprehensive review. *Renewable and Sustainable Energy Reviews*. 2018; <https://doi.org/10.1016/j.rser.2017.09.106>.
- [5] Caglayan S, Ozorhon B. Determining building information modeling effectiveness. *Automation in Construction* 2023; <https://doi.org/10.1016/j.autcon.2023.104861>
- [6] Wieczorek D, Plebankiewicz E, Zima K. Model estimation of the whole life cost of a building with respect to risk factors. *Technological and Economic Development of Economy*. 2019; <https://doi.org/10.3846/tede.2019.7455>.
- [7] Kardiani R, Kurniyaningrum E, Yuwono BE, Widiarso T. House of Risk Approach in Determining Delay Risk Factors. *IAIC Transactions on Sustainable Digital Innovation (ITSDI)*. 2025; <https://doi.org/10.34306/itsdi.v6i2.690>.
- [8] Nia SB, Taheri M, Jamalpour R. Achieving Realistic Cost Estimates in Building Construction Projects: A Reliability Assessment of Pre-Construction Stage Cost Estimates. *International Journal of Construction Engineering and Management*. 2023; <https://doi.org/10.5923/j.ijcem.20231203.02>.
- [9] Leśniak A, Zima K. Cost calculation of construction projects including sustainability factors using the Case Based Reasoning (CBR) method. *Sustainability*. 2018; <https://doi.org/10.3390/su10051608>.
- [10] Leśniak A, Górka M. Analysis of the cost structure of aluminum and glass facades. In *Advances and Trends in Engineering Sciences and Technologies III: Proceedings of the 3rd International Conference on Engineering Sciences and Technologies (ESaT 2018)*, CRC Press. 2019; 445.
- [11] Urbańska-Galewska E, Kowalski D. Lekka obudowa. Część 4. Układy konstrukcyjne. *Builder*. 2016; 20(12): 106-110.
- [12] Leśniak A, Górka M, Wieczorek D. Identification of factors shaping tender prices for lightweight. *Scientific Review Engineering and Environmental Sciences*. 2019; <https://doi.org/10.22630/PNIKS.2019.28.2.16>.