

Badania nad prognozowaniem wytrzymałości betonu w oparciu o mechanizm uwagi i sieć rezydualną

Research on concrete strength prediction based on attention mechanism and residual network

Haiwei Lin¹, Hangqi Zhang², Haikuan Wu^{3,*}, Yichen Miao^{4,*}

¹Dehong Normal University, Dehong Prefecture, Yunnan Province, 678400, China.

²China University of Mining & Technology-Beijing, Beijing 100083, China

³School of Emergency Management, Xihua University, Chengdu 610039, Sichuan Province, China.

⁴Faculty of Civil Engineering and Mechanics, Kunming University of Science and Technology, Kunming 650500, Yunnan Province, China.

*Corresponding authors: H. Wu, e-mail: hkwu@mail.xhu.edu.cn, Y. Miao, e-mail: miao_yichen@kust.edu.cn

Streszczenie

Dokładne przewidywanie wytrzymałości betonu na ściskanie ma kluczowe znaczenie dla kontroli jakości i oceny bezpieczeństwa konstrukcji w inżynierii lądowej. Jednak tradycyjne metody uczenia maszynowego często mają trudności z uchwyceniem złożonych interakcji nieliniowych i silnych korelacji cech charakterystycznych dla receptur mieszanek betonowych, co ogranicza ich dokładność prognostyczną i zdolność uogólniania. Aby sprostać tym wyzwaniom, w niniejszym badaniu zaproponowano model głębokiego uczenia [AM-ResNet], łączący mechanizmy uwagi z sieciami resztkowymi. Architektura resztkowa skutecznie łagodzi problem zanikającego gradientu w sieciach głębokich, podczas gdy mechanizm uwagi zwiększa zdolność do identyfikacji kluczowych czynników wpływających poprzez dynamiczne przypisywanie wag cech. W eksperymentach wykorzystano standardowy zbiór danych dotyczących wytrzymałości betonu na ściskanie pochodzący z repozytorium UCI Machine Learning Repository, zawierający 1030 próbek i 8 zmiennych wejściowych. W ramach badania przeprowadzono kompleksową, wielowymiarową analizę porównawczą modeli regresji wektorów nośnych [SVR], lasu losowego [ang. Random Forest] oraz sieci neuronowej z propagacją wsteczną. Proponowany model AM-ResNet osiągnął współczynnik determinacji [R^2] wynoszący 0,790, średni błąd kwadratowy [RMSE] wynoszący 3,2 MPa oraz średni procentowy błąd kwadratowy [RMSPE] wynoszący 8,9%. Ponad 92% błędów prognozowania mieściło się w przedziale ± 10 MPa, co spełnia typowe inżynierskie standardy kontroli jakości. Przy poziomie szumu wejściowego poniżej 20% model AM-ResNet nadal utrzymuje wartość R^2 na poziomie 0,674,

Summary

Accurately predicting the compressive strength of concrete is crucial for quality control and structural safety assessment in civil engineering. However, traditional machine learning methods often struggle to capture the complex nonlinear interactions and strong feature correlations inherent in concrete mix design, thereby limiting their predictive accuracy and generalization ability. To address these challenges, this study proposes a deep learning model [AM-ResNet] that combines attention mechanisms with residual networks. The residual architecture effectively mitigates the vanishing gradient problem in deep networks, while the attention mechanism enhances the ability to identify key influencing factors by dynamically assigning feature weights. The experiments utilized a standard concrete compressive strength dataset from the UCI Machine Learning Repository, which contains 1,030 samples and 8 input variables. The study conducted a comprehensive, multi-dimensional comparative analysis of Support Vector Regression [SVR], Random Forest, and Backpropagation Neural Network models. The proposed AM-ResNet model achieved a coefficient of determination [R^2] of 0.790, a root mean square error [RMSE] of 3.21 MPa, and a root mean square percentage error [RMSPE] of 8.9%. Over 92% of the prediction errors fell within the ± 10 MPa range, meeting typical engineering quality control standards. Under 20% input noise, AM-ResNet still maintains an R^2 value of 0.674, with a performance decline of only 14.7%, significantly outperforming baseline models. Using only 10% of the training samples, its R^2 value reaches 0.621, demonstrating exceptional data efficiency. Five-fold cross-validation confirmed its stability and

przy spadku wydajności wynoszącym zaledwie 14,7%, co znacznie przewyższa wyniki modeli bazowych. Wykorzystując jedynie 10% próbek szkoleniowych, jego wartość R^2 osiąga 0,621, co świadczy o wyjątkowej efektywności wykorzystania danych. Pięciokrotna walidacja krzyżowa potwierdziła jego stabilność i wykazała najniższą wariancję [$\sigma = 0,021$]. Proponowana struktura AM-ResNet zapewnia solidne, dokładne i interpretowalne rozwiązanie do prognozowania wytrzymałości betonu, posiadające ogromny potencjał do zastosowań w inteligentnej kontroli jakości i projektowaniu materiałów w dziedzinie inżynierii lądowej.

Słowa kluczowe: prognozowanie wytrzymałości betonu, mechanizm uwagi, sieć rezydualna, uczenie głębokie, zdolność uogólniania

1. Wprowadzenie

Wraz z postępującą urbanizacją beton stał się kluczowym materiałem w budownictwie i infrastrukturze, a jego jakość ma bezpośredni wpływ na bezpieczeństwo i trwałość obiektów inżynierskich (1, 2). Wytrzymałość betonu jest kluczowym wskaźnikiem służącym do oceny jego jakości, a dokładne przewidywanie wytrzymałości ma kluczowe znaczenie dla projektowania inżynierskiego i kontroli jakości. Jednak na wytrzymałość betonu wpływa wiele czynników, w tym rodzaj cementu, skład kruszywa, proporcje mieszanki i warunki dojrzewania, co zwiększa złożoność i utrudnia przewidywanie wytrzymałości (3). Konwencjonalne podejścia do przewidywania wytrzymałości betonu opierają się głównie na badaniach eksperymentalnych i modelach statystycznych, takich jak analiza regresji i sieci neuronowe (4-6). Metody te często napotykać jednak ograniczenia w przypadku złożonych zależności nieliniowych i cech wielowymiarowych. W ostatnich latach, wraz z szybkim rozwojem technik głębokiego uczenia się – w szczególności dzięki pomysłnemu zastosowaniu mechanizmów uwagi i sieci resztkowych [ResNet] w wizji komputerowej i przetwarzaniu języka naturalnego – coraz więcej badań wprowadza te zaawansowane metody do prognozowania wytrzymałości betonu (7, 8).

Wczesne badania dotyczące prognozowania wytrzymałości betonu opierały się głównie na metodach eksperymentalnych i tradycyjnych modelach statystycznych, takich jak regresja liniowa, wielowymiarowa regresja nieliniowa oraz modele uczenia maszynowego oparte na regresji wektorów nośnych [SVR] (9, 10). Metody te sprawdzają się dobrze w przypadku stosunkowo prostych zależności między danymi; jednak w obliczu wysoce nieliniowych interakcji cech i złożonych rozkładów danych często wykazują niską dokładność prognozowania i słabą zdolność uogólniania (11). Następnie pojawiły się modele uczenia maszynowego, takie jak drzewa decyzyjne, lasy losowe i sieci neuronowe – w szczególności sieci neuronowe z propagacją wsteczną [BP] – które znalazły szerokie zastosowanie w prognozowaniu wytrzymałości betonu. Chociaż modele te lepiej radzą sobie z uchwyceniem nieliniowych zależności w danych, ich wydajność w praktycznych zastosowaniach pozostaje ograniczona przez architekturę sieci

demonstrated the lowest variance [$\sigma = 0.021$]. The proposed AM-ResNet framework provides a robust, accurate, and interpretable solution for concrete strength prediction, holding great potential for applications in intelligent quality control and material design within the civil engineering field.

Keywords: concrete strength prediction, attention mechanism, residual network, deep learning, generalization ability

1. Introduction

With the acceleration of urbanization, concrete has become a critical material in construction and infrastructure, and its quality directly affects the safety and durability of engineering structures (1, 2). Concrete strength is a key indicator for evaluating its quality, and accurate prediction of strength is crucial for engineering design and quality control. However, concrete strength is influenced by multiple factors, including cement type, aggregate composition, mix proportions, and curing conditions, which add complexity and challenges to strength prediction (3). Conventional approaches to concrete strength prediction primarily rely on experimental testing and statistical models, such as regression analysis and neural networks (4-6). However, these methods often encounter limitations when dealing with complex nonlinear relationships and high-dimensional features. In recent years, with the rapid advancement of deep learning techniques-particularly the successful application of attention mechanisms and residual networks [ResNet] in computer vision and natural language processing-an increasing number of studies have introduced these advanced methods into concrete strength prediction. (7, 8).

Early studies on concrete strength prediction primarily relied on experimental approaches and traditional statistical models, such as linear regression, multivariate nonlinear regression, and machine learning models based on support vector regression [SVR] (9, 10). These methods perform well when dealing with relatively simple data relationships; however, they often exhibit low prediction accuracy and poor generalization ability when confronted with highly nonlinear feature interactions and complex data distributions (11). Subsequently, machine learning models such as decision trees, random forests, and neural networks-particularly back-propagation [BP] neural networks-emerged and were widely applied to concrete strength prediction. Although these models are better at capturing nonlinear relationships within the data, their performance in practical applications remains limited by network architecture and training algorithms, often leading to instability and insufficient prediction accuracy (12). Sun et al. (13) reported that, compared with traditional empirical models, advanced machine learning

i algorytmy uczenia, co często prowadzi do niestabilności i niewystarczającej dokładności prognozowania (12). Sun i in. (13) stwierdzili, że w porównaniu z tradycyjnymi modelami empirycznymi zaawansowane metody uczenia maszynowego, takie jak XGBoost, mogą znacznie poprawić dokładność prognozowania wytrzymałości betonu na ściskanie w różnych warunkach dojrzewania, ujawniając jednocześnie kluczowe czynniki wpływające, takie jak czas dojrzewania, wilgotność i temperatura. Ponadto Sah i in. (14) stwierdzili, że spośród modeli takich jak sztuczne sieci neuronowe [ANN], wielokrotna regresja liniowa, maszyny wektorów nośnych oraz drzewa regresyjne, to właśnie ANN wykazały najlepszą skuteczność zarówno pod względem dokładności, jak i wydajności w prognozowaniu wytrzymałości betonu na ściskanie.

W ostatnich latach, wraz z szybkim rozwojem technik głębokiego uczenia, konwolucyjne sieci neuronowe [CNN] i głębokie sieci neuronowe [DNN] są coraz częściej wykorzystywane w dziedzinie prognozowania wytrzymałości betonu ze względu na ich dużą zdolność do dopasowywania nieliniowego (15). Ahmad i in. (16) zbadali wykorzystanie technik uczenia maszynowego typu ensemble do prognozowania wytrzymałości na ściskanie betonu wysokowydajnego [HPC] poprzez analizę wydajności maszyn gradientowego wzmocnienia [GBM], lasów losowych [RF] oraz głębokich sieci neuronowych [DNN]. Jednak ograniczenia tych tradycyjnych modeli głębokiego uczenia się w zakresie uchwycenia zależności dalekiego zasięgu oraz zapobiegania zanikowi gradientu ograniczają ich dokładność prognozowania i wydajność uogólniania (16). Aby rozwiązać te problemy, naukowcy podjęli próbę wprowadzenia do tej dziedziny mechanizmów uwagi i sieci resztkowych [ResNet] (17). Mechanizm uwagi odniósł znaczący sukces w przetwarzaniu języka naturalnego [NLP] i wizji komputerowej [CV] poprzez adaptacyjne przypisywanie wag, co zwiększa interpretowalność cech i poprawia wydajność prognozowania (18). Sieci rezydujące [ResNets], poprzez wprowadzenie połączeń pomijających, skutecznie łagodzą problem zanikania gradientu podczas uczenia głębokich sieci i zwiększają zdolność uczenia się głębokich reprezentacji cech (19). Chociaż w niektórych badaniach zaczęto analizować wykorzystanie mechanizmów uwagi lub sieci resztkowych osobno do prognozowania wytrzymałości betonu, prace dotyczące połączenia tych dwóch elementów są wciąż stosunkowo nieliczne. Ponadto dotychczasowe badania nie poruszały jeszcze dogłębnie kluczowych kwestii, takich jak identyfikacja istotności cech, radzenie sobie z nierównowagą danych oraz poprawa zdolności uogólniania modeli (9, 20). W związku z tym skuteczna integracja mechanizmów uwagi z sieciami resztkowymi oraz dogłębna analiza ich skuteczności w prognozowaniu wytrzymałości betonu stały się pilną kwestią wymagającą rozwiązania.

W odróżnieniu od dotychczasowych badań, w których sieci uwagowe i rezydujące stosowano oddzielnie, w niniejszym badaniu oba mechanizmy zintegrowano w jednolitej strukturze, zoptymalizowanej specjalnie pod kątem prognozowania wytrzymałości betonu. Opracowano niestandardowy blok uwagowo-rezydujący, a jego parametry dostosowano w celu poprawy interpretowalności cech oraz wydajności obliczeniowej. W szczególności najpierw wykorzystano strukturę sieci rezydującej, aby sprostać wyzwaniom

methods such as XGBoost can significantly improve the accuracy of concrete compressive strength prediction under different curing conditions, while also revealing key influencing factors such as curing time, humidity, and temperature. In addition, Sah et al. (14) found that among models such as artificial neural networks [ANN], multiple linear regression, support vector machines, and regression trees, ANN exhibited the best performance in terms of both accuracy and efficiency for predicting concrete compressive strength.

In recent years, with the rapid development of deep learning techniques, convolutional neural networks [CNNs] and deep neural networks [DNNs] have been increasingly introduced into the field of concrete strength prediction due to their strong nonlinear fitting capability (15). Ahmad et al. (16) investigated the use of ensemble machine learning techniques for predicting the compressive strength of high-performance concrete [HPC] by analyzing the performance of gradient boosting machines [GBM], random forests [RF], and deep neural networks [DNN]. However, the limitations of these traditional deep learning models in capturing long-range dependencies and preventing gradient vanishing constrain their prediction accuracy and generalization performance (16). To address these issues, researchers have attempted to introduce attention mechanisms and residual networks [ResNet] into this field (17). The attention mechanism has achieved remarkable success in natural language processing [NLP] and computer vision [CV] by adaptively assigning weights, thereby enhancing feature interpretability and improving prediction performance (18). Residual networks [ResNets], by introducing skip connections, effectively alleviate the gradient vanishing problem in deep network training and enhance the capability of learning deep feature representations (19). Although some studies have begun to explore the use of attention mechanisms or residual networks individually for concrete strength prediction, research on combining the two remains relatively scarce. Moreover, existing work has not yet thoroughly addressed key issues such as feature importance identification, handling of data imbalance, and enhancement of model generalization performance (9, 20). Therefore, effectively integrating attention mechanisms with residual networks and thoroughly investigating their performance in concrete strength prediction has become an urgent issue to be addressed.

Unlike existing studies that apply attention or residual networks separately, this study integrates both mechanisms into a unified framework specifically optimized for concrete strength prediction. A custom attention-residual block was designed, and its parameters were tuned to improve feature interpretability and computational efficiency. Specifically, a residual network framework is first employed to address the challenges of training deep networks; subsequently, an attention mechanism is introduced to dynamically assign different weights to input features. Finally, the proposed model is validated on a standard concrete dataset to evaluate its predictive performance and practical applicability.

Furthermore, the originality of this study lies in the unified integration of attention mechanisms and residual learning specifically tailored for concrete strength prediction. While previous works have

związany z uczeniem głębokich sieci, następnie wprowadzono mechanizm uwagi w celu dynamicznego przypisywania różnych wag do cech wejściowych. Na koniec proponowany model jest weryfikowany na standardowym zbiorze danych dotyczących betonu w celu oceny jego zdolności prognostycznych i praktycznej przydatności.

Ponadto oryginalność niniejszego badania polega na spójnym połączeniu mechanizmów uwagi i uczenia resztkowego, dostosowanych specjalnie do prognozowania wytrzymałości betonu. Chociaż w dotychczasowych pracach techniki te stosowano niezależnie, ich połączone wykorzystanie w dziedzinie charakteryzującej się wysoce nieliniowym zachowaniem materiału i silnymi współzależnościami cech pozostaje wciąż słabo zbadane. Proponowana architektura nie tylko umożliwia głębokie, hierarchiczne wyodrębnianie cech, ale także adaptacyjnie podkreśla najbardziej wpływowe parametry, rozwiązując w ten sposób długotrwałe wyzwania związane z nadmiarowością cech, maskowaniem słabych korelacji i niewystarczającą interpretowalnością w poprzednich modelach. Podejście to oferuje zarówno innowację metodologiczną, jak i praktyczne znaczenie inżynierskie, zapewniając bardziej solidne, uogólnialne i interpretowalne ramy prognozowania dla projektowania materiałów i oceny bezpieczeństwa konstrukcji.

2. Metodologia

2.1. Zbiór danych i przetwarzanie wstępne

Zbiór danych wykorzystany w niniejszym badaniu to standardowy zbiór danych dotyczących wytrzymałości betonu na ściskanie, pozyskany z repozytorium UCI Machine Learning Repository. Zbiór ten jest szeroko stosowany w dziedzinie analizy regresji wytrzymałości betonu i cieszy się dużym uznaniem ze względu na swoją reprezentatywność naukową oraz wiarygodność. Zbiór danych składa się z 1030 próbek z eksperymentów dotyczących mieszanek betonowych, z których każda zawiera osiem zmiennych wejściowych - cement, żużel wielopieczowy, popiół lotny, wodę, superplastyfikator, kruszywo gruboziarniste, kruszywo drobnoziarniste i wiek - a także jedną zmienną wyjściową, a mianowicie wytrzymałość betonu na ściskanie [MPa].

2.1.1. Eksploracyjna analiza danych [EDA]

W celu uzyskania głębszego wglądu w rozkład danych oraz wpływ poszczególnych zmiennych na wytrzymałość betonu przeprowadzono wizualną analizę eksploracyjną. Na rysunkach 1[a]–1[h] umieszczono wykresy punktowe przedstawiające zależność wytrzymałości betonu od poszczególnych zmiennych wejściowych. Szczegółowa analiza przedstawia się następująco:

[1] Czas dojrzewania [rys. 1[a]]:

Dane skupiają się głównie na 15, 28 i 56 dniach, przy czym największą gęstość obserwuje się w 28 dniu, co odzwierciedla kluczową rolę standardowego czasu dojrzewania w określaniu wytrzymałości betonu.

applied these two techniques independently, their combined use in a domain characterized by highly nonlinear material behavior and strong feature interdependencies remains underexplored. The proposed architecture not only enables deep hierarchical feature extraction but also adaptively emphasizes the most influential parameters, thereby addressing long-standing challenges in feature redundancy, weak correlation masking, and insufficient interpretability in prior models. This approach offers both methodological innovation and practical engineering significance, providing a more robust, generalizable, and interpretable prediction framework for material design and structural safety assessment.

2. Methodology

2.1. Dataset and preprocessing

The dataset used in this study is the standard Concrete Compressive Strength dataset obtained from the UCI Machine Learning Repository. This dataset has been widely used in the field of concrete strength regression analysis and is highly recognized for its academic representativeness and reliability. The dataset consists of 1,030 samples of concrete mix experiments, each containing eight input variables-cement, blast furnace slag, fly ash, water, superplasticizer, coarse aggregate, fine aggregate, and age-as well as one output variable, namely the concrete compressive strength [MPa].

2.1.1. Exploratory Data Analysis [EDA]

To gain deeper insights into the data distribution and the influence of each variable on concrete strength, a visual exploratory analysis was conducted. Figures 1[a]-1[h] present scatter plots of concrete strength against each input variable. The detailed analysis is as follows:

[1] Age [Figure 1[a]]:

The data are mainly concentrated at 15, 28, and 56 days, with the highest density observed at 28 days, reflecting the critical role of the standard curing age in determining concrete strength.

[2] Superplasticizer [Figure 1[b]]:

The dosage is generally low, with only a few data points showing high levels. Its effect on enhancing concrete strength appears to be limited.

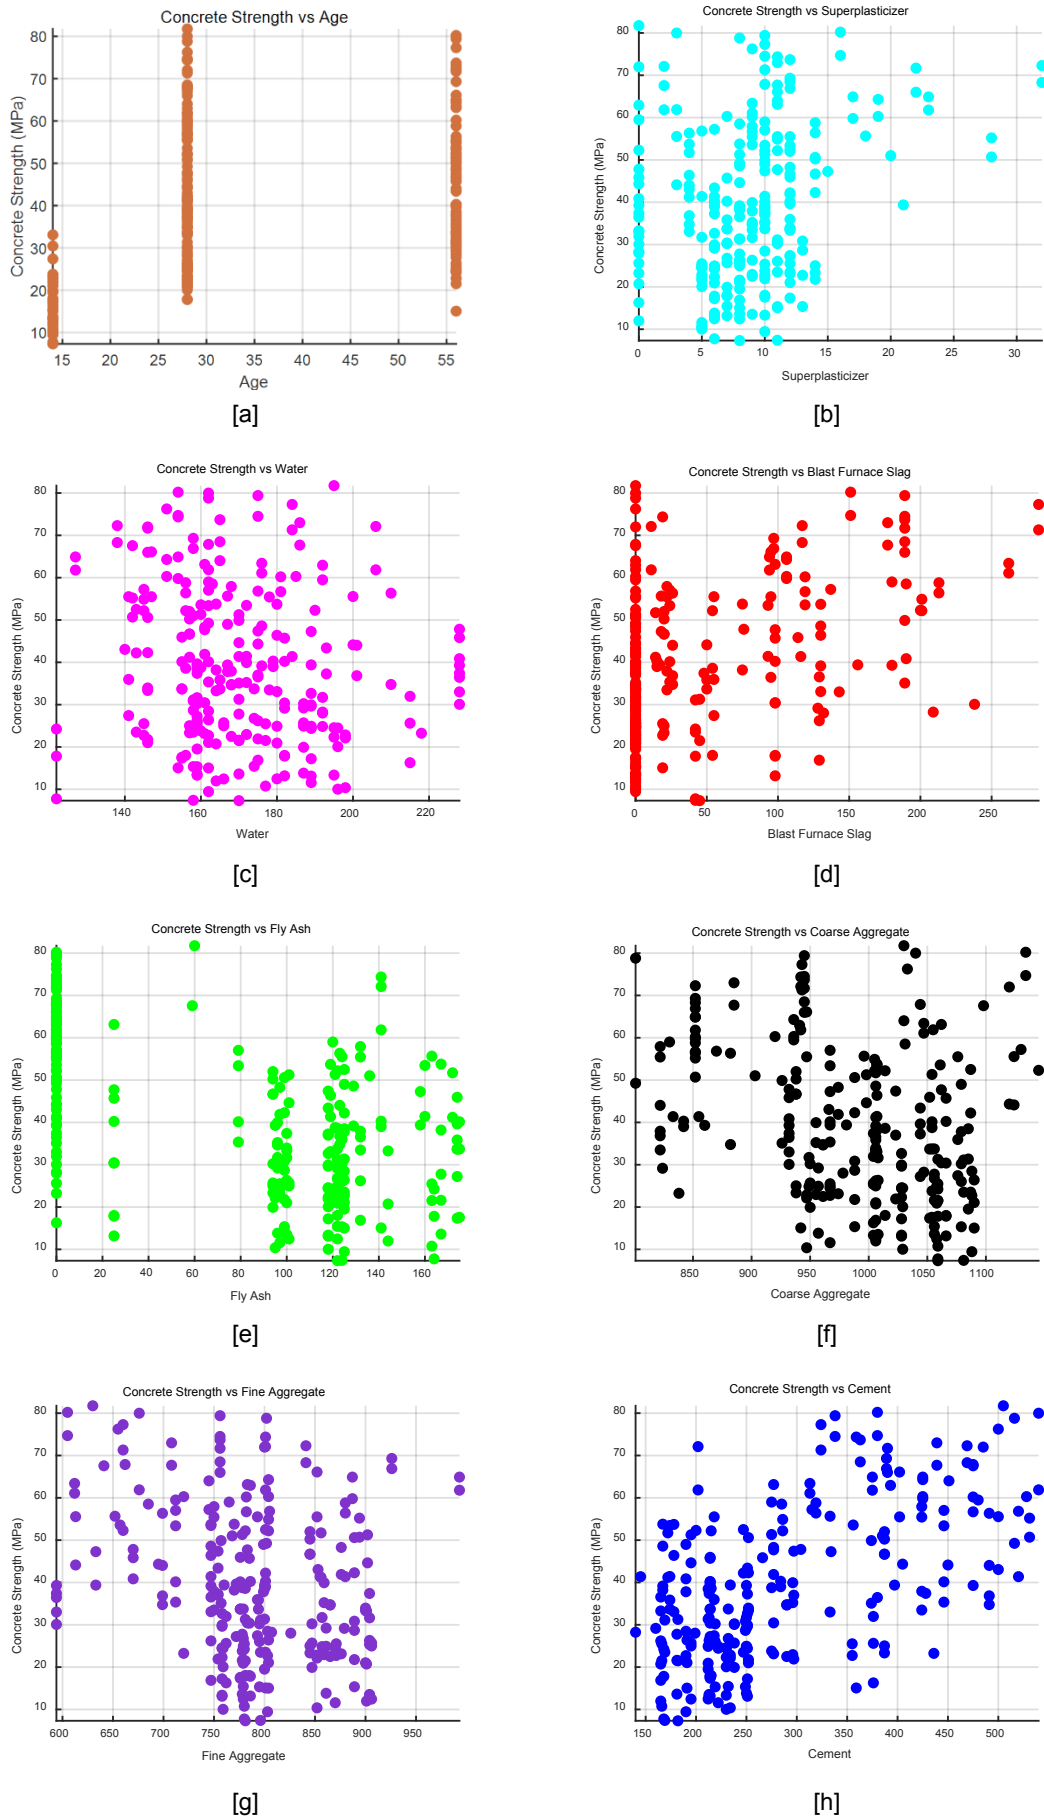
[3] Water Content [Figure 1[c]]:

The data points exhibit a relatively uniform distribution without a clear linear correlation, suggesting a complex relationship between water content and concrete strength.

[4] Blast Furnace Slag [Figure 1[d]]:

The data are mainly concentrated in the low replacement range, with only a few data points at higher levels. The increase in slag content shows a nonlinear relationship with concrete strength.

[5] Fly Ash [Figure 1[e]]:



Rys. 1. Wykres punktowy przedstawiający zależność między wytrzymałością betonu a innymi parametrami [a – wiek; b – superplastyfikator; c – woda; d – żużel wielkopiecowy; e – popiół lotny; f – kruszywo gruboziarniste; g – kruszywo drobnoziarniste; h – cement].

Fig. 1. Scatter plot of concrete strength and other parameters [a-age; b-superplasticizer; c-water; d-blast furnace slag; e-fly ash; f-coarse aggregate; g-fine aggregate; h-cement].

[2] Superplastyfikator [rys. 1[b]]:

Udział jest ogólnie niski, a tylko kilka punktów danych wskazuje na wysokie poziomy. Jego wpływ na zwiększenie wytrzymałości betonu wydaje się być ograniczony.

[3] Zawartość wody [rys. 1[c]]:

Punkty danych wykazują stosunkowo równomierny rozkład bez wyraźnej korelacji liniowej, co sugeruje złożoną zależność między zawartością wody a wytrzymałością betonu.

[4] Żużel wielkopiecowy [rys. 1[d]]:

Dane skupiają się głównie w zakresie niskiego zastąpienia, a tylko kilka punktów danych dotyczy wyższych poziomów. Wzrost zawartości żużla wykazuje nieliniową zależność z wytrzymałością betonu.

[5] Popiół lotny [rys. 1[e]]:

Udział skupia się głównie na poziomie 0 oraz w przedziale 100–160. Wzrost zawartości popiołu lotnego ma zazwyczaj negatywny wpływ na wytrzymałość betonu.

[6] Kruszywo gruboziarniste [rys. 1[f]] i kruszywo drobnoziarniste [rys. 1[g]]:

Punkty danych są szeroko rozłożone, ale stosunkowo rozproszone, co wskazuje na słabą korelację z wytrzymałością betonu; sugeruje to, że wpływ rodzaju i udziału kruszywa na wytrzymałość jest stosunkowo złożony.

[7] Zawartość cementu [rys. 1[h]]:

Obserwuje się wyraźną dodatnią korelację, co wskazuje, że wyższa zawartość cementu generalnie prowadzi do wzrostu wytrzymałości betonu.

2.1.2. Procedura wstępnego przetwarzania danych

W celu dalszej ilościowej analizy korelacji między poszczególnymi cechami a wytrzymałością betonu obliczono macierz współczynników korelacji Pearsona dla zmiennych wejściowych i wyjściowych, jak pokazano na rys. 2. Wyniki analizy wskazują, że:

Zawartość cementu [0,5899], żużel [0,4426] i wiek [0,3766] wykazują istotną dodatnią korelację z wytrzymałością betonu, przy czym zawartość cementu jest czynnikiem o największym znaczeniu.

Popiół lotny wykazuje silną ujemną korelację z wytrzymałością betonu [-0,531], co wskazuje, że wzrost zawartości popiołu lotnego może zmniejszyć wytrzymałość betonu.

Kruszywo gruboziarniste [-0,3078] i kruszywo drobnoziarniste [-0,2655] wykazują stosunkowo słabą korelację z wytrzymałością betonu.

Zawartość wody wykazuje niewielką ujemną korelację z wytrzymałością betonu [-0,1457].

Na podstawie powyższej analizy wstępnie zidentyfikowano zawartość cementu, żużel i wiek jako główne czynniki prognostyczne, co

The dosage is mainly concentrated at 0 and within the 100–160 range. An increase in fly ash content tends to exhibit a negative effect on concrete strength.

[6] Coarse Aggregate [Figure 1[f]] and Fine Aggregate [Figure 1[g]]:

The data points are widely distributed but relatively scattered, showing a weak correlation with concrete strength, which suggests that the influence of aggregate type and dosage on strength is relatively complex.

[7] Cement Content [Figure 1[h]]:

A clear positive correlation is observed, indicating that higher cement content generally leads to an increase in concrete strength.

2.1.2. Data preprocessing procedure

To further quantitatively analyze the correlation between each feature and concrete strength, the Pearson correlation coefficient matrix of the input and output variables was computed, as shown in Figure 2. The analysis results indicate that:

Cement content [0.5899], slag [0.4426], and age [0.3766] exhibit significant positive correlations with concrete strength, with cement content being the most prominent factor.

Fly ash shows a strong negative correlation with concrete strength [-0.531], indicating that an increase in fly ash content may reduce concrete strength.

Coarse aggregate [-0.3078] and fine aggregate [-0.2655] exhibit relatively weak correlations with concrete strength.

Water content exhibits a slight negative correlation with concrete strength [-0.1457].

Based on the above analysis, cement content, slag, and age were preliminarily identified as the primary predictive factors, providing a scientific basis for feature selection in the modeling process.

2.1.3. Data preprocessing steps

To ensure the accuracy and generalization ability of the predictive model, the dataset was preprocessed as follows:

Missing and Outlier Analysis: No missing values were found in the dataset. Outliers were examined using boxplots [not shown]. Considering the practical experimental conditions, extreme values were retained to preserve the completeness of the dataset and enhance model generalization.

Feature Normalization: The Min-Max normalization method was applied to scale all input variables to the [0, 1] range (21, 22). This preprocessing step reduces the impact of dimensional differences among features and improves the convergence speed of the model during training.

Data Splitting: The dataset was randomly divided into a training set [80 %] and a testing set [20 %] to objectively evaluate the model's performance.

stanowi naukową podstawę do wyboru cech w procesie modelowania.

2.1.3. Etapy wstępnego przetwarzania danych

Aby zapewnić dokładność i zdolność uogólniania modelu predykcyjnego, zbiór danych został wstępnie przetworzony w następujący sposób:

Analiza braków i wartości odstających: w zbiorze danych nie stwierdzono żadnych brakujących wartości. Wartości odstające zbadano za pomocą wykresów pudełkowych [nie przedstawiono]. Biorąc pod uwagę praktyczne warunki eksperymentalne, wartości skrajne zostały zachowane w celu zachowania kompletności zbioru danych i poprawy zdolności uogólniania modelu.

Normalizacja cech: zastosowano metodę normalizacji Min-Max w celu skalowania wszystkich zmiennych wejściowych do zakresu [0, 1] (21, 22). Ten etap przetwarzania wstępnie zmniejsza wpływ różnic wymiarowych między cechami i poprawia szybkość zbieżności modelu podczas uczenia.

Podział danych: Zbiór danych został losowo podzielony na zbiór szkoleniowy [80%] i zbiór testowy [20%] w celu obiektywnej oceny wydajności modelu.

Podsumowując, procedura wstępnego przetwarzania danych zapewniła naukową ważność i spójność zbioru danych, tworząc solidną podstawę dla wydajnego szkolenia modelu i dokładnych prognoz.

2.2. Architektura i implementacja modelu


2.2.1. Model sieci Attention-Residual Network [AM-ResNet]

[1] Mechanizm uwagi

Mechanizm uwagi czerpie inspirację z ludzkiego systemu uwagi wzrokowej, który dynamicznie przypisuje wagi różnym częściom danych wejściowych w oparciu o ich znaczenie (23, 24). Został on szeroko przyjęty w dziedzinie głębokiego uczenia się, szczególnie w przetwarzaniu języka naturalnego [NLP] i wizji komputerowej, gdzie wykazał się niezwykłą skutecznością. W prognozowaniu wytrzymałości betonu mechanizm uwagi umożliwia modelowi lepszą identyfikację względnego znaczenia różnych cech. W przypadku wielu czynników wpływających na beton nie wszystkie zmienne wejściowe mają równy wpływ na prognozę. Dzięki włączeniu mechanizmu uwagi model może nauczyć się, które cechy są najważniejsze, poprawiając w ten sposób dokładność prognozowania.

Mechanizm uwagi realizowany jest w następujących etapach:

1. Waga danych wejściowych: dane wejściowe otrzymują przypisane wagi, przy czym cechy o większym znaczeniu otrzymują wyższe oceny uwagi.
2. Adaptacyjna regulacja: model adaptacyjnie dostosowuje wagi w zależności od kontekstu, wzmacniając kluczowe informacje i tłumiąc cechy o mniejszym znaczeniu.



Rys. 2. Mapa ciepła macierzy współczynników korelacji Pearsona dla zmiennych wejściowych i wyjściowych.

Fig. 2. Pearson correlation coefficient matrix heat map of input variables and output variables.

In summary, the data preprocessing procedure ensured the scientific validity and consistency of the dataset, laying a solid foundation for efficient model training and accurate prediction.

2.2. Model architecture and implementation

2.2.1. Attention-Residual Network [AM-ResNet] model

[1] Attention Mechanism

The attention mechanism is inspired by the human visual attention system, which dynamically allocates weights to different parts of the input based on their importance (23, 24). It has been widely adopted in the field of deep learning, particularly in natural language processing [NLP] and computer vision, where it has demonstrated remarkable effectiveness. In concrete strength prediction, the attention mechanism enables the model to better identify the relative importance of different features. When dealing with the multiple influencing factors of concrete, not all input variables contribute equally to the prediction. By incorporating the attention mechanism, the model can learn which features are most critical, thereby improving prediction accuracy.

Specifically, the attention mechanism is implemented through the following steps:

1. Weighted Input: The input data are assigned weights, with more important features receiving higher attention scores.
2. Adaptive Adjustment: The model adaptively adjusts the weights based on different contexts, enhancing critical information while suppressing less relevant features.
3. Dynamic Computation: Through weighted summation, the model dynamically selects and processes the most relevant information from the input.

3. Obliczenia dynamiczne: poprzez sumowanie ważne model dynamicznie wybiera i przetwarza najbardziej istotne informacje z danych wejściowych.

[2] Sieć resztkowa [ResNet]

ResNet to architektura głębokiej sieci neuronowej zaproponowana przez Microsoft Research, która w nowatorski sposób wprowadza połączenia pomijające [ang. skip connections] w celu złagodzenia problemu zanikania gradientu podczas uczenia głębokich sieci (25, 26). Wraz ze wzrostem głębokości tradycyjnych sieci neuronowych często pojawiają się problemy związane z zanikaniem lub eksplozją gradientu, co utrudnia skuteczne uczenie. Aby rozwiązać ten problem, ResNet wykorzystuje połączenia resztkowe [pomijające] na każdej warstwie, umożliwiając informacjom ominięcie niektórych warstw i bezpośrednie przekazanie do warstw głębszych. Taka konstrukcja przyspiesza uczenie i poprawia wydajność modelu. Główną ideą połączeń resztkowych jest umożliwienie każdej warstwie uczenia się resztki, czyli różnicy między danymi wejściowymi a pożądanym wynikiem, zamiast bezpośredniego odwzorowania. Takie podejście pozwala sieci łatwiej uczyć się przydatnych cech i poprawia stabilność uczenia wraz ze wzrostem głębokości sieci.

Podstawowym elementem składowym sieci ResNet jest blok rezydualny, który zazwyczaj składa się z dwóch warstw konwulucyjnych. Połączenie typu skip dodaje się poprzez bezpośrednie zsumowanie danych wejściowych z wynikami za pomocą sumowania element po elemencie. Formułę matematyczną (27) przedstawiono poniżej:

$$y = F(x, \{W_i\}) + x \quad (1)$$

gdzie, x oznacza dane wejściowe, $F(x, \{W_i\})$ reprezentuje dane wyjściowe obliczone za pomocą warstw konwulucyjnych i funkcji aktywacji, a y jest ostatecznym wynikiem.

[3] Integracja mechanizmu uwagi i sieci resztkowej

Integracja mechanizmu uwagi z siecią resztkową pozwala modelowi wykorzystać mocne strony obu komponentów. W zadaniu prognozowania wytrzymałości betonu najpierw wykorzystuje się sieć resztkową do wyodrębnienia złożonych cech nieliniowych, a następnie stosuje się mechanizm uwagi w celu przypisania adaptacyjnych wag do tych cech. Umożliwia to modelowi skuteczniejsze skupienie się na cechach zawierających najwięcej informacji, poprawiając w ten sposób dokładność prognozowania.

Dzięki połączeniu tych dwóch podejść model jest zdolny do: 1) Głębokiego uczenia się cech: sieć rezydualna umożliwia modelowi wyodrębnianie cech głębokiego poziomu, jednocześnie skutecznie unikając trudności szkoleniowych, które pojawiają się wraz ze wzrostem głębokości sieci. 2) Dynamicznego ważenia: mechanizm uwagi pozwala sieci dynamicznie wybierać cechy istotne dla zadania prognozowania, jednocześnie tłumiąc zbędne informacje.

Ogólny przebieg pracy modelu prognozowania wytrzymałości betonu, opartego na połączeniu mechanizmu uwagi i sieci resztkowej, przedstawiono na rys. 3.

[2] Residual Network [ResNet]

The ResNet is a deep neural network architecture proposed by Microsoft Research, which innovatively introduces skip connections to alleviate the gradient vanishing problem in training deep networks (25, 26). As the depth of traditional neural networks increases, they often suffer from gradient vanishing or exploding problems, which hinder effective training. To address this issue, ResNet incorporates residual [skip] connections at each layer, allowing information to bypass certain layers and be directly transmitted to deeper layers. This design accelerates training and enhances model performance. The core idea of residual connections is to enable each layer to learn the residual—that is, the difference between the input and the desired output—rather than the direct mapping. This approach allows the network to more easily learn useful features and improves training stability as the network depth increases.

The core building block of ResNet is the residual block, which typically consists of two convolutional layers. A skip connection is added by summing the input directly with the output through an element-wise addition. The mathematical formulation (27) is as follows:

$$y = F(x, \{W_i\}) + x \quad (1)$$

where, x denotes the input, $F(x, \{W_i\})$ represents the output computed through convolutional layers and activation functions, and y is the final output.

[3] Integration of Attention Mechanism and Residual Network

Integrating the attention mechanism with the residual network allows the model to leverage the strengths of both components. In the task of concrete strength prediction, the residual network is first employed to extract complex nonlinear features, after which the attention mechanism is applied to assign adaptive weights to these features. This enables the model to focus more effectively on the most informative features, thereby improving prediction accuracy.

By combining these two approaches, the model is able to: 1) Deep Feature Learning: The residual network enables the model to extract deep-level features while effectively avoiding training difficulties that arise as the network depth increases. 2) Dynamic Weighting: The attention mechanism allows the network to dynamically select features relevant to the prediction task while suppressing redundant information.

The overall workflow of the concrete strength prediction model based on the integration of the attention mechanism and residual network is illustrated in Fig. 3.

In this workflow, the input data are first preprocessed, including data cleaning, feature selection, and normalization. Subsequently, the residual network extracts deep features through multiple residual blocks, and the attention mechanism assigns weights to these features based on their relative importance.

Finally, the weighted features are used to predict concrete strength, and the final prediction results are generated. In contrast to stan-

W tym schemacie postępowania dane wejściowe są najpierw poddawane przetwarzaniu wstępnemu, obejmującemu czyszczenie danych, wybór cech oraz normalizację. Następnie sieć rezydualna wyodrębnia cechy głębokie za pośrednictwem wielu bloków rezydualnych, a mechanizm uwagi przypisuje tym cechom wagi w oparciu o ich względną istotność.

Na koniec cechy z uwzględnieniem wag są wykorzystywane do prognozowania wytrzymałości betonu, co pozwala uzyskać ostateczne wyniki prognozy. W przeciwieństwie do standardowych architektur ResNet, po każdym bloku rezydualnym włączyliśmy podmoduł uwagi kanałowej, umożliwiający adaptacyjną rekaliibrację map cech. Taka konstrukcja poprawia czułość na kluczowe cechy składu mieszanki, takie jak cement i stosunek wody do cementu. Ta struktura uczenia głębokiego, która integruje mechanizmy uwagi i sieci rezydualne, umożliwia skuteczniejsze radzenie sobie ze złożonością i nieliniowością w prognozowaniu wytrzymałości betonu, zwiększając w ten sposób zarówno dokładność prognoz, jak i odporność modelu.

2.2.2. Model regresji wektorów nośnych [SVR]

Maszyna wektorów nośnych [SVM] to powszechnie stosowana metoda uczenia nadzorowanego, znana ze swojej wysokiej skuteczności zarówno w zadaniach klasyfikacyjnych, jak i regresyjnych (28). SVM tworzy hiperpłaszczyznę, która maksymalizuje margines między klasami w celu przeprowadzenia klasyfikacji lub regresji. W zadaniu prognozowania wytrzymałości betonu SVM może być stosowana jako model regresji [regresja wektorów nośnych, SVR] w celu oszacowania wytrzymałości betonu. Wykazała ona wysoką wydajność, szczególnie w przypadku małych rozmiarów próbek, danych wielowymiarowych i relacji nieliniowych.

W ramach maszyny wektorów nośnych [SVM] problemy regresji są rozwiązywane przy użyciu regresji wektorów nośnych [SVR]. Celem SVR jest zidentyfikowanie optymalnej hiperpłaszczyzny regresji, tak aby błędy prognozowania dla większości punktów danych mieściły się w z góry określonym marginesie tolerancji, zazwyczaj oznaczanym jako ϵ . W szczególności SVR ma na celu zminimalizowanie złożoności funkcji regresji przy jednoczesnym ograniczeniu wielkości błędów prognozowania, osiągając w ten sposób optymalną wydajność prognozowania.

Celem optymalizacji SVR jest znalezienie optymalnego modelu regresji poprzez zminimalizowanie następującej funkcji celu:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2)$$

Z zastrzeżeniem następujących ograniczeń:

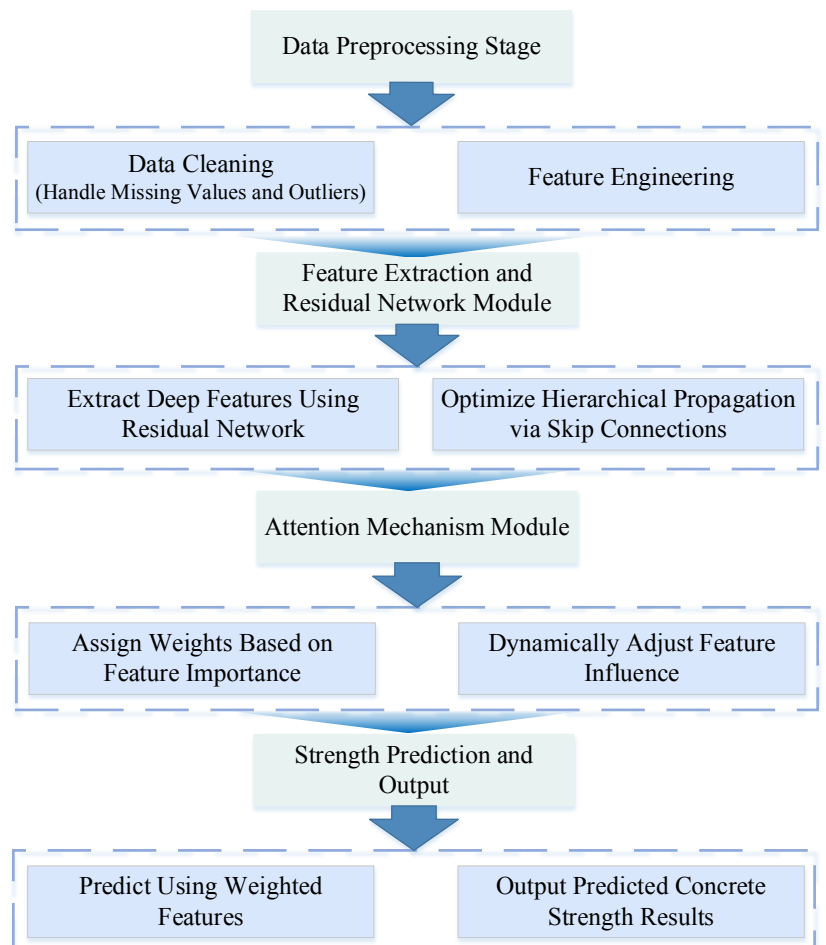
$$|f(x_i) - y_i| \leq \epsilon \quad (3)$$

standard ResNet architectures, we incorporated a channel attention submodule after each residual block, allowing adaptive recalibration of feature maps. This design improves sensitivity to critical mix composition features such as cement and water-cement ratio. This deep learning framework, which integrates attention mechanisms and residual networks, enables more effective handling of the complexity and nonlinearity in concrete strength prediction, thereby enhancing both prediction accuracy and model robustness.

2.2.2. Support Vector Regression [SVR] model

Support Vector Machine [SVM] is a widely used supervised learning method, known for its strong performance in both classification and regression tasks (28). The SVM constructs a hyperplane that maximizes the margin between classes to perform classification or regression. In the task of concrete strength prediction, SVM can be applied as a regression model [Support Vector Regression, SVR] to estimate concrete strength. It has demonstrated strong performance, particularly when dealing with small sample sizes, high-dimensional data, and nonlinear relationships.

Under the framework of Support Vector Machine [SVM], regression problems are addressed using Support Vector Regression [SVR]. The goal of SVR is to identify an optimal regression hyperplane such that the prediction errors for most data points fall within a



Rys. 3. Schemat blokowy modelu prognozowania wytrzymałości betonu opartego na mechanizmie uwagi i sieci rezydualnej.

Fig. 3. Flowchart of Concrete Strength Prediction Model Based on Attention Mechanism and Residual Network.

gdzie $f(x_i)$ oznacza wartość przewidywaną, y_i – wartość rzeczywistą, ε – tolerancję błędu, a , w i b – parametry hiperpłaszczyzny.

W prognozowaniu wytrzymałości betonu model SVM modeluje zależności między składem surowców, proporcjami mieszanki, warunkami dojrzewania i innymi cechami w celu oszacowania końcowej wytrzymałości betonu. Uwzględniając złożone nieliniowe interakcje między tymi cechami, SVR pomaga utrzymać wysoką dokładność prognozowania nawet przy ograniczonej ilości danych próbnych. Schemat prognozowania z wykorzystaniem regresji wektorów nośnych [SVR] do prognozowania wytrzymałości betonu przedstawiono na rys. 4.

W tym schemacie postępowania dane wejściowe są najpierw poddawane wstępnej obróbce w kilku etapach, obejmujących uzupełnianie brakujących wartości, wykrywanie wartości odstających, dobór cech oraz standaryzację. Następnie wybierana jest odpowiednia funkcja jądra - na przykład funkcja radialna [RBF] - a hiperparametry, takie jak parametr karny C i tolerancja błędu ε , są dostrajane za pomocą walidacji krzyżowej. Następnie model regresji wektorów nośnych [SVR] jest trenowany przy użyciu zbioru danych szkoleniowych, a parametry modelu są optymalizowane w celu uzyskania modelu regresji o najlepszej wydajności. Na koniec wytrenowany model SVR jest wykorzystywany do tworzenia prognoz na danych testowych i generowania ostatecznych wyników prognoz wytrzymałości betonu.

Dzięki temu procesowi SVM może skutecznie modelować złożone dane nieliniowe, zapewniając w ten sposób dokładne prognozy wytrzymałości betonu.

2.2.3. Model lasu losowego [RF]

Las losowy [RF, z ang. Random Forest] to metoda uczenia zbiorowego szeroko stosowana w zadaniach takich jak klasyfikacja, regresja i selekcja cech (29). Las losowy zwiększa stabilność i dokładność modelu poprzez tworzenie wielu drzew decyzyjnych i agregowanie ich prognoz. Ze względu na duże możliwości w zakresie selekcji cech oraz wysoką wydajność uogólniania, las losowy znalazł szerokie zastosowanie w różnych dziedzinach, w tym w prognozowaniu wytrzymałości betonu.

Las losowy to algorytm oparty na koncepcji uczenia zbiorowego, który dokonuje prognoz poprzez tworzenie wielu drzew decyzyjnych. Każde drzewo decyzyjne jest trenowane na losowo wybranym podzbiórze danych, a podczas procesu podziału cech dla każdego drzewa wybierany jest również losowy podzbiór cech. Na koniec las losowy generuje ostateczną prognozę poprzez agregację wyników wszystkich drzew decyzyjnych – stosując głosowanie większościowe w przypadku zadań klasyfikacyjnych lub uśrednianie w przypadku zadań regresyjnych.

W prognozowaniu wytrzymałości betonu model lasu losowego skutecznie uwzględnia złożone relacje nieliniowe poprzez przetwarzanie cech wielowymiarowych, takich jak skład surowców, proporcje mieszanki i warunki dojrzewania. Dzięki swojej wydajności w przetwarzaniu danych wielowymiarowych, las losowy doskonale

predefined tolerance margin, typically denoted as ε . Specifically, SVR aims to minimize the complexity of the regression function while constraining the magnitude of the prediction errors, thereby achieving optimal predictive performance.

The optimization objective of SVR is to find the optimal regression model by minimizing the following objective function:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2)$$

Subject to the following constraints:

$$|f(x_i) - y_i| \leq \varepsilon \quad (3)$$

where, $f(x_i)$ is the predicted value, y_i is the actual value, ε is the error tolerance, and w and b are the parameters of the hyperplane.

In concrete strength prediction, SVM models the relationships between raw material composition, mix proportions, curing conditions, and other features to estimate the final concrete strength. By capturing the complex nonlinear interactions among these features, SVR helps maintain high prediction accuracy even with limited sample data. The prediction workflow of using Support Vector Regression [SVR] for concrete strength prediction is illustrated in Fig. 4.

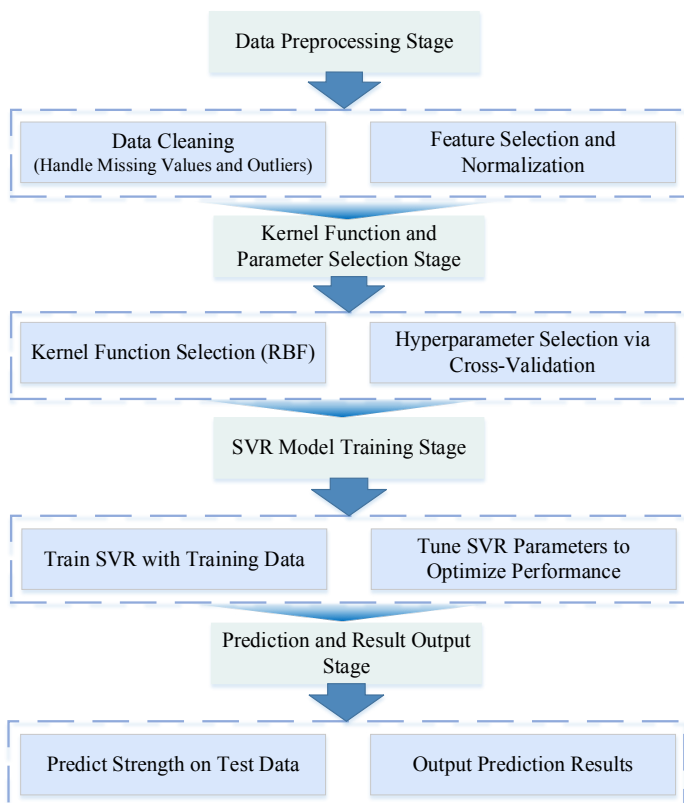
In this workflow, the input data are first preprocessed through several steps, including missing value handling, outlier detection, feature selection, and standardization. Next, an appropriate kernel function-such as the radial basis function [RBF]-is selected, and hyperparameters such as the penalty parameter C and the error tolerance ε are tuned using cross-validation. Then, the Support Vector Regression [SVR] model is trained using the training dataset, and the model parameters are optimized to obtain the best-performing regression model. Finally, the trained SVR model is used to make predictions on the testing data, and the final concrete strength prediction results are generated.

Through this workflow, SVM can efficiently model complex nonlinear data, thereby providing accurate predictions of concrete strength.

2.2.3. Random Forest [RF] Model

Random Forest [RF] is an ensemble learning method widely used in tasks such as classification, regression, and feature selection (29). Random Forest improves model stability and accuracy by constructing multiple decision trees and aggregating their predictions. Due to its strong feature selection capability and high generalization performance, Random Forest has been widely applied in various fields, including concrete strength prediction.

Random Forest is an algorithm based on the concept of ensemble learning, which makes predictions by constructing multiple decision trees. Each decision tree is trained on a randomly selected subset of the data, and during the feature-splitting process, a random subset of features is also chosen for each tree. Finally, Random Forest generates the final prediction by aggregating the outputs



Rys. 4. Schemat blokowy modelu prognozowania wytrzymałości betonu opartego na regresji wektorów nośnych [SVR].

Fig. 4. Flowchart for Concrete Strength Prediction Model Based on Support Vector Regression [SVR].

nadaje się do modelowania skomplikowanych interakcji między wieloma czynnikami wpływającymi na wytrzymałość betonu.

Zalety wykorzystania algorytmu lasu losowego do prognozowania wytrzymałości betonu obejmują: [1] Odporność na nadmierne dopasowanie: dzięki agregacji prognoz wielu drzew decyzyjnych algorytm lasu losowego zmniejsza ryzyko nadmiernego dopasowania, które może wystąpić w przypadku pojedynczego drzewa decyzyjnego. [2] Automatyczny dobór cech: podczas każdego podziału algorytm automatycznie wybiera najbardziej istotne cechy, ograniczając w ten sposób potrzebę ręcznego opracowywania cech. [3] Wysoka zdolność uogólniania: lasu losowego zachowuje wysoką wydajność uogólniania podczas pracy ze złożonymi zbiorami danych, skutecznie unikając nadmiernego dopasowania do danych szkoleniowych. Przebieg procesu prognozowania wytrzymałości betonu przy użyciu algorytmu lasu losowego przedstawiono na rys. 5.

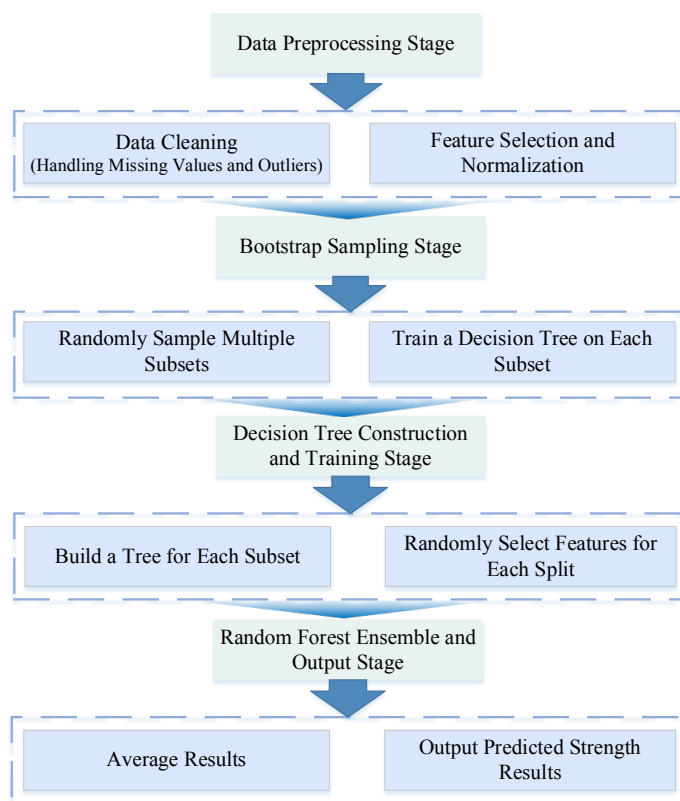
W tym schemacie postępowania dane wejściowe są najpierw poddawane wstępnej obróbce, obejmującej takie etapy jak czyszczenie danych, wybór cech i standaryzacja. Następnie z oryginalnego zbioru danych losowo pobieranych jest wiele podzbiorów przy użyciu metody bootstrap, a każdy podzbiór służy do wyszkolenia osobnego drzewa decyzyjnego. Dzięki temu schematowi postępowania algorytm lasu losowego może skutecznie przetwarzać dane wielowymiarowe i złożone w zakresie prognozowania wytrzymałości betonu, zapewniając stabilne i dokładne wyniki prognoz.

of all decision trees-using majority voting for classification tasks or averaging for regression tasks.

In concrete strength prediction, the Random Forest model effectively captures complex nonlinear relationships by processing multidimensional features such as raw material composition, mix proportions, and curing conditions. Owing to its efficiency in handling high-dimensional data, Random Forest is well-suited for modeling the intricate interactions among multiple factors influencing concrete strength.

The advantages of using Random Forest in concrete strength prediction include: [1] Resistance to Overfitting: by aggregating the predictions of multiple decision trees, Random Forest reduces the risk of overfitting that may occur with a single decision tree. [2] Automatic Feature Selection: during each split, Random Forest automatically selects the most relevant features, thereby reducing the need for manual feature engineering. [3] High Generalization Ability: random Forest maintains strong generalization performance when dealing with complex datasets, effectively avoiding overfitting to the training data. The prediction workflow of using Random Forest for concrete strength prediction is illustrated in Fig. 5.

In this workflow, the input data are first preprocessed through steps such as data cleaning, feature selection, and standardization. Then, multiple subsets are randomly sampled from the original dataset using bootstrap sampling, and each subset is used to train an individual decision tree. Through this workflow, Random Forest can efficiently handle high-dimensional and complex data



Rys. 5. Schemat blokowy modelu prognozowania wytrzymałości betonu opartego na algorytmie Random Forest [RF].

Fig. 5. Flowchart of Concrete Strength Prediction Model Based on Random Forest [RF].

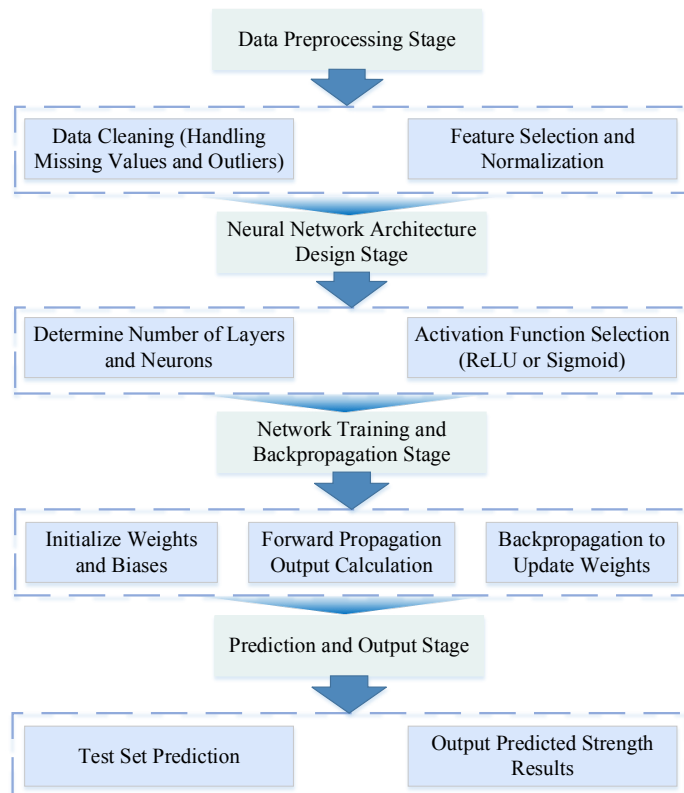
2.2.4. Model sieci neuronowej z propagacją wsteczną [BP-NN]

Sieć neuronowa z propagacją wsteczną [BP, z ang. Backpropagation Neural Network] jest siecią neuronową typu feedforward opartą na algorytmie wstecznej propagacji błędu (30). Składa się z warstwy wejściowej, jednej lub więcej warstw ukrytych oraz warstwy wyjściowej i dostosowuje wagi oraz przesunięcia w sieci za pomocą algorytmu propagacji wstecznej w celu wykonywania zadań prognozowania. Sieć neuronowa BP jest typowym algorytmem uczenia nadzorowanego, szeroko stosowanym w zadaniach takich jak klasyfikacja i regresja. W szczególności w przypadku prognozowania wytrzymałości betonu jest ona w stanie uchwycić złożone zależności nieliniowe i zapewnić dokładne prognozy.

Sieć neuronowa BP doskonale nadaje się do analizy zależności nieliniowych w prognozowaniu wytrzymałości betonu. Wykorzystując jako dane wejściowe wielowymiarowe cechy - takie jak skład betonu i warunki dojrzewania - sieć prognozuje końcową wytrzymałość betonu. Jej wielowarstwowa struktura umożliwia wydobycie złożonych interakcji między cechami, co pozwala zwiększyć dokładność prognoz.

Procedura korzystania z sieci neuronowej BP jest następująca:

1. Przygotowanie danych: zbierz i uporządkuj istotne cechy betonu, takie jak skład surowców i warunki dojrzewania.
2. Projektowanie sieci: zdefiniuj architekturę sieci, w tym liczbę warstw i neuronów w warstwach wejściowej, ukrytej i wyjściowej.



Rys. 6. Schemat blokowy modelu prognozowania wytrzymałości betonu opartego na sieci neuronowej z propagacją wsteczną [BP-NN].

Fig. 6. Flowchart of Concrete Strength Prediction Model Based on Backpropagation Neural Network [BP-NN].

in concrete strength prediction, providing stable and accurate prediction results.

2.2.4. Backpropagation Neural Network [BP-NN] Model

The BackPropagation Neural Network [BP Neural Network] is a feedforward neural network based on the error backpropagation algorithm (30). It consists of an input layer, one or more hidden layers, and an output layer, and adjusts the weights and biases within the network using the backpropagation algorithm to perform prediction tasks. BP Neural Network is a typical supervised learning algorithm that is widely used in tasks such as classification and regression. In particular, for concrete strength prediction, it is capable of capturing complex nonlinear relationships and providing accurate predictions.

BP Neural Network is well-suited for handling nonlinear relationships in concrete strength prediction. By taking multidimensional features—such as concrete composition and curing conditions—as input, the network predicts the final concrete strength. Its multilayer structure enables the extraction of complex interactions among features, thereby improving prediction accuracy.

The procedure for using the BP Neural Network is as follows:

1. Data Preparation: Collect and organize relevant concrete features, such as raw material composition and curing conditions.
2. Network Design: Define the network architecture, including the number of layers and neurons in the input, hidden, and output layers.
3. Training Process: Adjust the network weights using the backpropagation algorithm to minimize prediction error.
4. Prediction Output: Validate the trained model on the testing set and generate predicted values for concrete strength. The prediction workflow of the BP Neural Network for concrete strength prediction is illustrated in Figure 6.

In this workflow, the input data are first preprocessed, including handling of missing values, outlier detection, feature selection, and standardization. Next, the structure of the neural network is designed by specifying the number of neurons in the input, hidden, and output layers, and selecting appropriate activation functions. Then, the network is trained using the backpropagation algorithm, adjusting the weights and biases iteratively until convergence is achieved. Finally, the trained network is used to make predictions on the test data and output the final concrete strength prediction results.

3. Results and Discussion

3.1. Results of AM-ResNet Model

Fig. 7 illustrates the variation of the loss function during the training process. In the early stages of training, the loss decreases significantly, indicating that the model rapidly learns the main features of the data. As training progresses, the loss curve gradually stabilizes,

3. Proces uczenia: dostosuj wagi sieci za pomocą algorytmu wstecznej propagacji błędów, aby zminimalizować błąd prognozy.

4. Wynik prognozy: Zweryfikuj wytrenowany model na zbiorze testowym i wygeneruj wartości prognozowane dla wytrzymałości betonu. Przebieg procesu prognozowania wytrzymałości betonu przez sieć neuronową BP przedstawiono na rys. 6.


W tym schemacie postępowania dane wejściowe są najpierw poddawane przetwarzaniu wstępnemu, obejmującemu obsługę brakujących wartości, wykrywanie wartości odstających, dobór cech oraz standaryzację. Następnie projektowana jest struktura sieci neuronowej poprzez określenie liczby neuronów w warstwach wejściowej, ukrytej i wyjściowej oraz wybór odpowiednich funkcji aktywacji. Następnie sieć jest trenowana przy użyciu algorytmu wstecznej propagacji błędów, w ramach którego wagi i przesunięcia są dostosowywane iteracyjnie aż do osiągnięcia zbieżności. Na koniec wytrenowana sieć służy do generowania prognoz na danych testowych i generowania ostatecznych wyników prognoz wytrzymałości betonu.

3. Wyniki i dyskusja

3.1. Wyniki modelu AM-ResNet

Rys. 7 ilustruje zmiany funkcji straty podczas procesu uczenia. We wczesnych etapach uczenia strata znacznie maleje, co wskazuje, że model szybko uczy się głównych cech danych. W miarę postępu uczenia krzywa straty stopniowo się stabilizuje, a strata walidacyjna wykazuje trend podobny do straty szkoleniowej, co wskazuje, że model nie wykazuje znaczącego nadmiernego dopasowania. Wahania błędu szkoleniowego mogą być związane z procesem optymalizacji wokół lokalnych minimów; jednak ogólna zbieżność jest stabilna, co potwierdza solidność architektury sieci i skuteczność procesu szkolenia.

Rys. 8 przedstawia wyniki oceny istotności poszczególnych cech wejściowych w odniesieniu do wyników prognoz modelu. Warto zauważyć, że mapa istotności cech zasadniczo różni się od mapy cieplnej przedstawionej na rys. 2. Mapa istotności cech odzwierciedla przede wszystkim wpływ poszczególnych cech modelu na wyniki prognoz i nie uwzględnia relacji między cechami, podczas gdy mapa cieplna odzwierciedla głównie korelację między próbkami. Podsumowując, znaczenie cech koncentruje się na wpływie poszczególnych cech, podczas gdy mapy cieplne skupiają się na wzajemnych relacjach między cechami/próbkami. Wyraźna obserwacja pokazuje, że cecha 7 i cecha 2 mają największy wpływ na prognozowanie wytrzymałości. Wskazuje to, że model skutecznie identyfikuje kluczowe czynniki wpływające, podkreślając zaletę mechanizmu uwagi w selekcji cech. Pozornie słaba korelacja między zawartością wody na rysunku 2 a jej dużą istotnością na rys. 8 może być wyjaśniona pośrednią nieliniową interakcją między wodą a stosunkiem wody do cementu, którą AM-ResNet skutecznie wychwytuje poprzez mechanizm uwagi. Pozostałe cechy wykazują stosunkowo mniejszą ważność, ale nadal wnoszą pomocniczy wkład w ogólną wydajność modelu.



Rys. 7. Przebieg krzywej straty w trakcie uczenia się w poszczególnych epokach.


Fig. 7. Training progress of loss curve with epoch.

and the validation loss follows a trend similar to the training loss, indicating that the model does not exhibit significant overfitting. The fluctuations in training error may be related to the optimization process around local minima; however, the overall convergence is stable, confirming the robustness of the network architecture and the effectiveness of the training process.

Fig. 8 shows the importance scores of each input feature with respect to the model's prediction results. It is worth noting that the feature importance map is fundamentally different from the heatmap in Figure 2. The feature importance map mainly reflects the contribution of each feature in the model to the prediction results, and does not involve the relationship between features, while the heatmap mainly reflects the correlation between samples. In summary, feature importance focuses on the influence of individual features, while heatmaps focus on the interrelationships between features/samples. A clear observation reveals that Feature 7 and Feature 2 make the most significant contributions to strength prediction. This indicates that the model effectively identifies key influencing factors, highlighting the advantage of the attention mechanism in feature selection. The seemingly weak correlation between water content in Figure 2 and its high feature importance in Figure 8 can be explained by the indirect nonlinear interaction between water and the water-cement ratio, which the AM-ResNet effectively captures through the attention mechanism. The remaining features exhibit relatively lower importance but still provide auxiliary contributions to the overall performance of the model.

Figure 9 presents a scatter plot of the actual measured strength versus the predicted strength by the model. Most data points are distributed near the fitted regression line, with a correlation coefficient R^2 of 0.75, indicating good predictive accuracy of the model. This result confirms the effectiveness of the deep learning framework that integrates residual networks and attention mechanisms in capturing the complex nonlinear relationships inherent in concrete strength prediction.

Fig. 10 shows the frequency distribution of prediction errors, which



Rys. 8. Znaczenie cech betonu [składników] [Cechy 1–8: cement, żużel, popiół lotny, woda, superplastyfikator, kruszywo gruboziarniste, kruszywo drobnoziarniste i wiek].


Fig. 8. Feature importance of concrete [Feature 1-8: cement, slag, fly ash, water, superplasticizer, coarse aggregate, fine aggregate, and age].

Na rys. 9 przedstawiono wykres punktowy przedstawiający rzeczywistą zmierzoną wytrzymałość w funkcji wytrzymałości przewidywanej przez model. Większość punktów danych skupia się w pobliżu dopasowanej linii regresji, a współczynnik korelacji R^2 wynosi 0,75, co wskazuje na dobrą dokładność prognostyczną modelu. Wynik ten potwierdza skuteczność struktury opartej na głębokim uczeniu, łączącej sieci resztkowe i mechanizmy uwagi, w uchwyceniu złożonych zależności nieliniowych charakterystycznych dla prognozowania wytrzymałości betonu.

Na rysunku 10 przedstawiono rozkład częstotliwości błędów prognoz, które skupiają się głównie w przedziale od -5 MPa do +5 MPa, co wskazuje, że większość prognoz modelu jest dokładna i stabilna. Choć w skrajnych obszarach błędów [błędy przekraczające ± 15 MPa] zaobserwowano kilka wartości odstających, ogólny rozkład błędów wykazuje dobrą symetrię i skupienie, co potwierdza solidność modelu w praktycznych zastosowaniach inżynierskich.

Ogólnie rzecz biorąc, wykres na rys. 10 wskazuje, że błędy prognozowania modelu skupiają się głównie w wąskim przedziale, co świadczy o wysokiej ogólnej dokładności. Niektóre prognozy nadal wykazują jednak zauważalne odchylenia – zwłaszcza w warunkach ekstremalnych – co sugeruje, że konieczna może być dalsza optymalizacja modelu w celu zmniejszenia tych większych błędów.

Podsumowując, trend strat na rys. 7, znaczenie cech na rysunku 8, wyniki prognoz na rys. 9 oraz rozkład błędów na rys. 10 pokazują, że model działa dobrze podczas szkolenia i może skutecznie przeprowadzać prognozowanie i klasyfikację w praktycznych zastosowaniach.




Rys. 9. Rzeczywista i przewidywana wytrzymałość betonu.

Fig. 9. Actual and predicted strength of concrete.

are primarily concentrated within the range of -5 MPa to +5 MPa, indicating that the majority of the model's predictions are accurate and stable. Although a few outliers are observed in the extreme error regions [errors exceeding ± 15 MPa], the overall error distribution exhibits good symmetry and concentration, supporting the robustness of the model for practical engineering applications.

Overall, the Fig. 10 indicates that the model's prediction errors are mainly concentrated within a small range, reflecting high overall accuracy. However, some predictions still exhibit noticeable deviations-particularly under extreme conditions-suggesting that further model optimization may be necessary to reduce these larger errors.

Taken together, the loss trend in Figure 7, feature importance in



Rys. 10. Rozkład błędu prognozy dla betonu.

Fig. 10. Prediction error distribution of concrete.

3.2. Wyniki modelu SVR

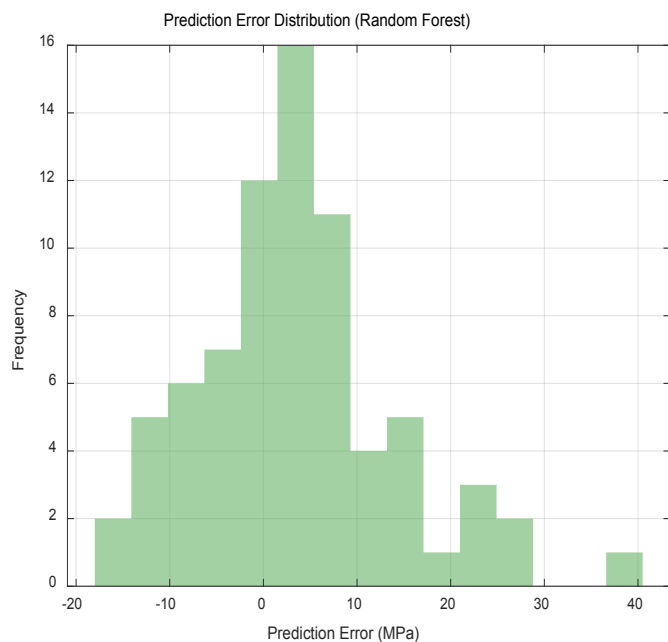
Rys. 11 ilustruje rozkład błędów modelu Support Vector Machine [SVM]. Choć błędy skupiają się w pobliżu zera, wykazują one większe wahania w porównaniu z modelem opartym na uwadze. Ponadto niektóre wartości odstające przekraczają ± 20 MPa, co podkreśla ograniczenia modelu SVM w radzeniu sobie ze złożonymi zależnościami nieliniowymi.

Na rys. 12 przedstawiono wykres punktowy porównujący rzeczywistą wytrzymałość betonu z wartościami przewidywanymi na podstawie modelu SVM, ilustrujący zależność między wartościami przewidywanymi a rzeczywistymi. Choć większość punktów danych znajduje się w pobliżu linii regresji, ogólny współczynnik korelacji $R^2 = 0,620$ wskazuje, że choć istnieje pewna zależność liniowa, dokładność prognostyczna modelu jest stosunkowo ograniczona. Sugeruje to, że model SVM może zapewnić umiarkowany poziom prognozowania, ale większe odchylenia w niektórych punktach danych wskazują, że w bardziej złożonych warunkach może być konieczna dalsza optymalizacja.

Podsumowując, oba wykresy wskazują, że choć model SVM wykazuje pewną zdolność prognostyczną, a rozkład jego błędów jest stosunkowo skupiony, nadal istnieje pole do poprawy – zwłaszcza w zakresie zmniejszenia błędów prognozowania i zwiększenia ogólnej dokładności.


3.3. Wyniki modelu RF

Rys. 13 ilustruje rozkład błędów prognozowania modelu Random Forest. Większość błędów skupia się wokół wartości 0 MPa, co wskazuje, że większość prognoz jest stosunkowo dokładna. Obserwuje się jednak pewne większe błędy, szczególnie w przypadkach niedoszacowania lub przeszacowania. Rozkład błędów jest stosunkowo nierównomierny, z istotnymi odchyleniami dodatnimi



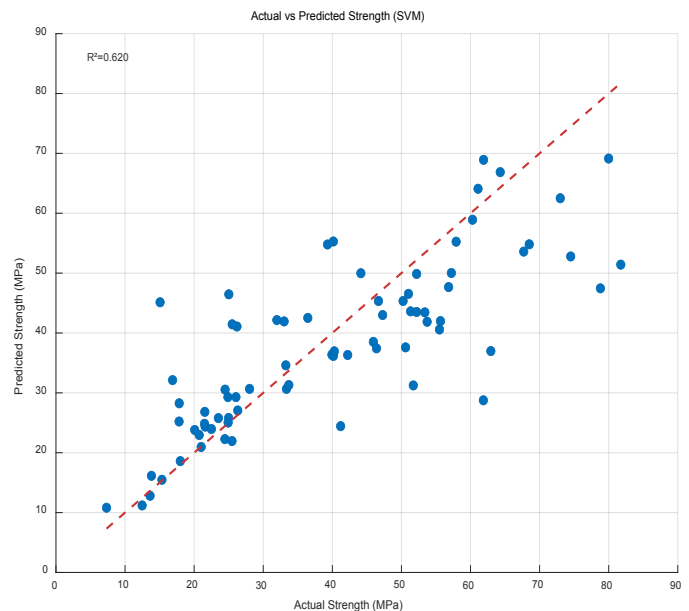
Rys. 13. Rozkład błędów prognozy w modelu lasu losowego.

Fig. 13. Prediction error distribution of the random forest model.



Rys. 11. Rozkład błędów prognozy modelu SVM.

Fig. 11. Prediction error distribution of the SVM model.



Rys. 12. Porównanie rzeczywistej i przewidywanej wytrzymałości betonu przy użyciu modelu SVM.

Fig. 12. Comparison of actual and predicted concrete strength using SVM model.

Figure 8, prediction results in Figure 9, and error distribution in Figure 10 all demonstrate that the model performs well during training and can effectively carry out prediction and classification in practical applications.

3.2. Results of SVR model

Fig. 11 illustrates the error distribution of the Support Vector Machine [SVM] model. While the errors are concentrated near zero, they exhibit greater fluctuation compared to the attention-based model. Moreover, some outliers exceed ± 20 MPa, highlighting the limitations of the SVM model in handling complex nonlinear

i ujemnymi, co wskazuje, że model wykazuje pewne odchylenia w niektórych prognozach.

Rys. 14 przedstawia zależność między rzeczywistą a przewidywaną wytrzymałością betonu. Punkty danych wykazują ogólną tendencję liniową, a dopasowana linia regresji daje wartość R^2 wynoszącą 0,586, co wskazuje na umiarkowany poziom korelacji między wartościami przewidywanymi a rzeczywistymi. Wartość R^2 sugeruje jednak również, że dopasowanie modelu nie jest optymalne i pozostaje znaczny margines błędu. W szczególności dokładność prognoz ma tendencję do spadku w zakresie wyższych wartości wytrzymałości.

Podsumowując, choć model Random Forest wykazuje pewną skuteczność w prognozowaniu wytrzymałości betonu, nadal występują znaczne błędy prognozowania – zwłaszcza w zakresie wartości skrajnych. Istnieje znaczna możliwość poprawy, a w celu zwiększenia dokładności prognoz konieczne mogą być dalsze dostosowania lub optymalizacja.

3.4. Wyniki modelu BP-NN

Na rys. 15 przedstawiono rozkład błędów prognozowania modelu sieci neuronowej BP. Ogólnie rzecz biorąc, błędy skupiają się wokół wartości 0 MPa, co wskazuje, że większość prognoz jest stosunkowo dokładna. Jednak zakres błędów jest stosunkowo szeroki, zwłaszcza w przypadkach dużych odchyień dodatnich i ujemnych, co sugeruje, że model może generować znaczne odchylenia prognoz w określonych warunkach – szczególnie w przypadku wartości skrajnych. Niemniej jednak rozkład błędów jest w przybliżeniu symetryczny, co wskazuje na spójną wydajność modelu w różnych zakresach wytrzymałości.

Rys. 16 przedstawia zależność między rzeczywistą a przewidywaną wytrzymałością betonu. Dopasowana linia regresji daje wartość R^2 wynoszącą 0,565, co wskazuje na pewien poziom korelacji między prognozami sieci neuronowej BP a rzeczywistą wytrzymałością, choć korelacja ta jest stosunkowo słaba. Choć punkty danych zasadniczo przebiegają wzdłuż linii regresji, niektóre wartości prognozowane znacznie odbiegają od wartości rzeczywistych, szczególnie w zakresie wysokich wytrzymałości. Wynik ten sugeruje, że chociaż model oferuje stosunkowo dokładne prognozy w zakresie niskiej i średniej wytrzymałości, jego dokładność prognostyczna maleje przy wyższych poziomach wytrzymałości, co wskazuje na znaczny potencjał do poprawy.

Podsumowując, chociaż model sieci neuronowej BP wykazuje pewien poziom dokładności w prognozowaniu wytrzymałości betonu, charakteryzuje się stosunkowo dużymi błędami prognozowania i słabą wydajnością dopasowania w zakresie wysokiej wytrzymałości. Zaleca się dalszą optymalizację w celu zwiększenia dokładności prognozowania.

3.5. Analiza porównawcza wydajności

W celu kompleksowej oceny wydajności proponowanego modelu AM-ResNet w niniejszym rozdziale przeprowadzono systematyczną analizę porównawczą modelu AM-ResNet z trzema modelami

relationships.

Fig. 12 displays a scatter plot of the actual versus predicted concrete strength using the SVM model, illustrating the relationship between the predicted and true values. Although most data points lie near the regression line, the overall correlation coefficient of $R^2=0.620$ indicates that, while a certain linear relationship exists, the model's predictive accuracy is relatively limited. This suggests that the SVM model can provide a moderate level of prediction, but larger deviations in some data points imply that further optimization may be needed under more complex conditions.

Taken together, these two figures indicate that although the SVM model possesses a certain predictive capability and its error distribution is relatively concentrated, there remains room for improvement-particularly in reducing prediction errors and enhancing overall accuracy.

3.3. Results of RF model

Fig. 13 illustrates the prediction error distribution of the Random Forest model. Most errors are concentrated around 0 MPa, indicating that the majority of predictions are relatively accurate. However, some larger errors are observed, particularly in cases of underestimation or overestimation. The error distribution is relatively uneven, with substantial positive and negative deviations, indicating that the model exhibits certain biases in some predictions.

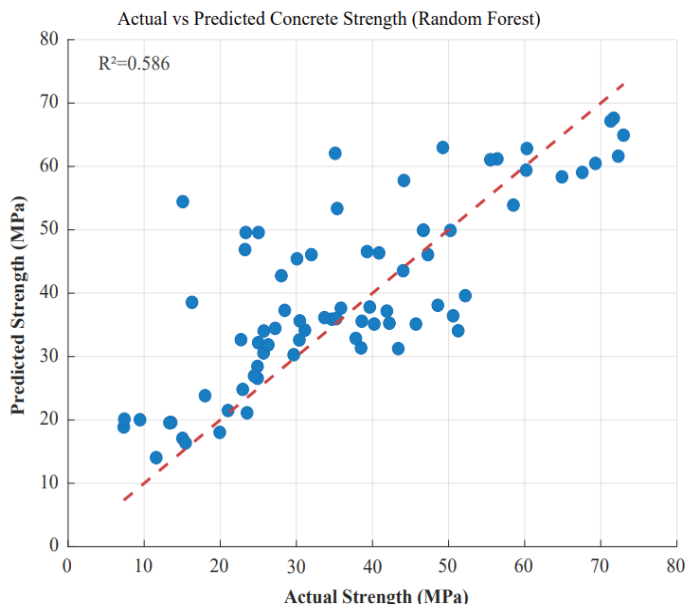
Fig. 14 illustrates the relationship between the actual and predicted concrete strength. The data points exhibit an overall linear trend, and the fitted regression line yields an R^2 value of 0.586, indicating a moderate level of correlation between the predicted and actual values. However, the R^2 value also suggests that the model's fit is not optimal, with a considerable amount of error remaining. In particular, the prediction accuracy tends to decrease in the higher strength range.

In summary, although the Random Forest model demonstrates a certain level of effectiveness in predicting concrete strength, considerable prediction errors still exist-particularly in the range of extreme values. There remains significant room for improvement, and further adjustment or optimization may be necessary to enhance prediction accuracy.

3.4. Results of BP-NN model

Fig. 15 presents the prediction error distribution of the BP Neural Network model. Overall, the errors are concentrated around 0 MPa, indicating that most of the predictions are relatively accurate. However, the error range is relatively wide, especially in cases of large positive and negative deviations, suggesting that the model may produce significant prediction bias under certain conditions-particularly for extreme values. Nevertheless, the error distribution is approximately symmetric, indicating consistent model performance across different strength ranges.

Fig. 16 illustrates the relationship between actual and predicted concrete strength. The fitted regression line yields an R^2 value

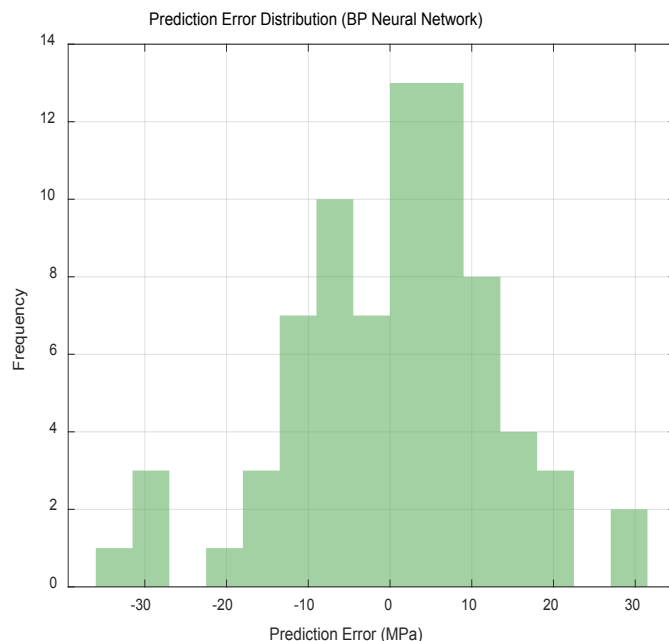


Rys. 14. Porównanie rzeczywistej i przewidywanej wytrzymałości betonu przy użyciu modelu typu lasu losowego.

Fig. 14. Comparison of actual and predicted concrete strength using random forest model.

bazowymi - regresją wektorów nośnych [SVR], lasem losowym [RF] oraz siecią neuronową z propagacją wsteczną [BP-NN] – w wielu wymiarach. Wymiary oceny obejmują: wydajność wieloparametrową, wydajność w różnych przedziałach wytrzymałości, stabilność walidacji krzyżowej, rozkład reszt, efektywność uczenia, wrażliwość na szum oraz wydajność przy różnych rozmiarach zbiorów szkoleniowych. Porównanie wydajności wieloparametrowej przedstawiono na rys. 17. Model AM-ResNet osiągnął najwyższą wartość R^2 [0,790], co wskazuje, że może wyjaśnić 79% wariacji wytrzymałości betonu. Co ważniejsze, jego MAE wyniosło 3,21 MPa, a MAPE 8,9%, co wskazuje, że średni błąd prognozy mieści się w dopuszczalnych tolerancjach inżynierskich. W porównaniu z modelem SVR, który osiągnął drugi najlepszy wynik, AM-ResNet zmniejszył RMSE o 33,8% i MAPE o 34,1%, osiągając znaczną poprawę dokładności prognozowania.

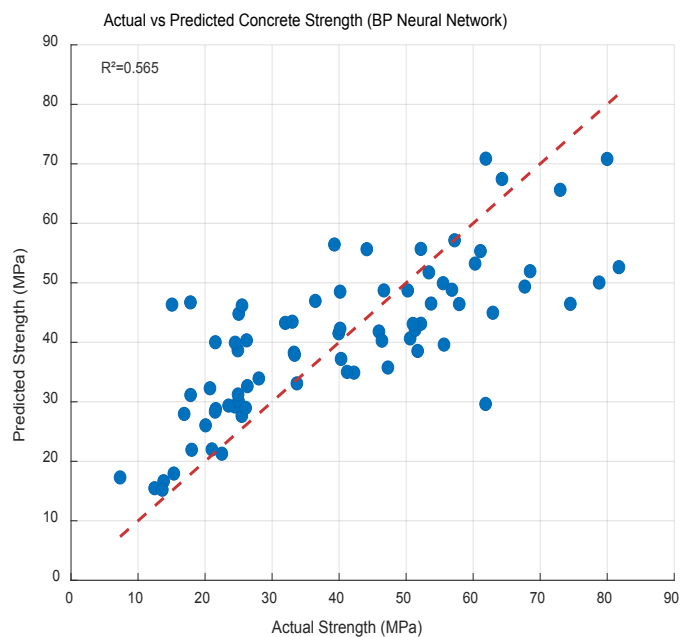
206 próbek z zestawu testowego podzielono na trzy przedziały w oparciu o ich rzeczywistą wytrzymałość na ściskanie: niska wytrzymałość [<30 MPa, 48 próbek], średnia wytrzymałość [$30-60$ MPa, 112 próbek] oraz wysoka wytrzymałość [>60 MPa, 46 próbek]. Wartości R^2 i RMSE zostały ponownie obliczone dla każdego przedziału w celu oceny wydajności modelu w różnych zakresach wytrzymałości [rysunek 18]. Wszystkie modele wykazały najwyższą dokładność prognozowania w przedziale średniej wytrzymałości, który stanowi również większość zbioru danych. Warto zauważyć, że model AM-ResNet osiągnął szczególnie dobre wyniki w zakresie wysokiej wytrzymałości [>60 MPa], z RMSE wynoszącym 5,23 MPa, w porównaniu z 7,45 MPa dla modelu SVR – co stanowi poprawę o 29,8%. Wskazuje to, że architektura oparta na sieciach rekurencyjnych z mechanizmem uwagi [attention-residual] jest bardziej skuteczna w uchwyceniu złożonych relacji nieliniowych występujących w recepturach mieszanek betonu o wysokiej wytrzymałości.



Rys. 15. Rozkład błędów prognozy w modelu sieci neuronowej typu BP.

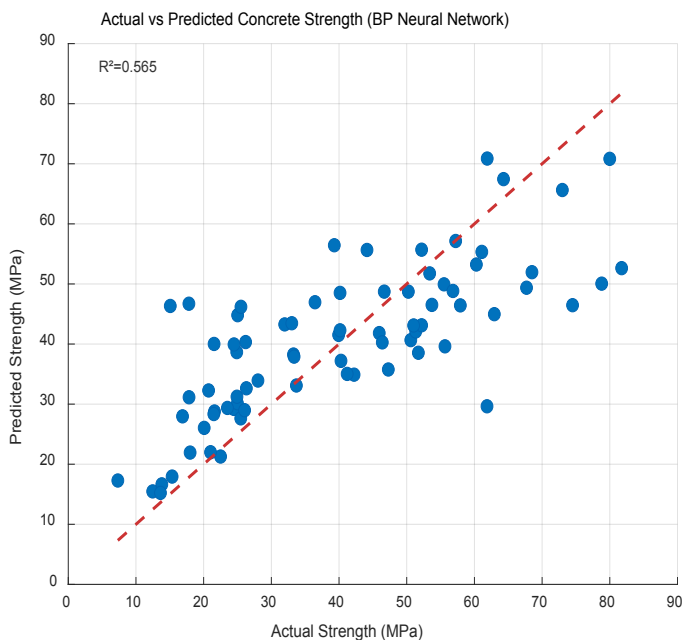
Fig. 15. Prediction error distribution of the bp neural network model.

of 0.565, indicating a certain level of correlation between the BP Neural Network's predictions and the actual strength, though the correlation is relatively weak. Although the data points generally follow the regression line, some predicted values deviate noticeably from the actual values, particularly in the high-strength range. This result suggests that while the model offers relatively accurate predictions in the low-to-medium strength range, its predictive accuracy diminishes at higher strength levels, indicating substantial room for improvement.



Rys. 16. Porównanie rzeczywistej i przewidywanej wytrzymałości betonu przy użyciu modelu sieci neuronowej BP.

Fig. 16. Comparison of actual and predicted concrete strength using bp neural network model.



Rys. 16. Porównanie rzeczywistej i przewidywanej wytrzymałości betonu przy użyciu modelu sieci neuronowej BP.

Fig. 16. Comparison of actual and predicted concrete strength using bp neural network model.

W ramach pięciokrotnej walidacji krzyżowej zbiorów danych został losowo podzielony na pięć podzbiorów o równej wielkości [około 206 próbek na każdy podzbiór]. W każdym podzbiórze cztery podzbiory wykorzystano do szkolenia, a jeden do walidacji; proces ten powtórzono pięć razy, aby zapewnić, że każdy podzbiór został wykorzystany jako zbiór walidacyjny dokładnie raz. Zebrano wartości R^2 ze wszystkich podzbiorów i obliczono ich średnią oraz odchylenie standardowe [rys. 19]. Mniejsze odchylenie standardowe wskazuje, że model jest mniej wrażliwy na różne podziały danych i wykazuje większą stabilność. Analiza wykazuje, że model AM-ResNet nie tylko osiągnął najwyższą średnią R^2 , ale także miał najmniejsze odchylenie standardowe [0,021], co wskazuje, że zachowuje stabilną wydajność w różnych podziałach na trening i walidację. Natomiast model BP-NN wykazał największą zmienność [$\sigma = 0,063$], co sugeruje, że jest on bardziej wrażliwy na inicjalizację i podział danych. Niska wariancja modelu AM-ResNet świadczy o jego niezawodności w praktycznych zastosowaniach inżynierskich, nawet gdy dane szkoleniowe mogą się różnić.

Odchylenie oblicza się jako różnicę między wartością przewidywaną a wartością rzeczywistą. Dla każdego modelu zliczyliśmy liczbę próbek, dla których bezwzględne odchylenie mieściło się w przedziałach progowych ± 5 MPa i ± 10 MPa, a następnie obliczyliśmy odsetek tych próbek w stosunku do całkowitej liczby próbek w zbiorze testowym [206] [rys. 20]. Wskaźnik ten w intuicyjny sposób odzwierciedla stopień, w jakim prognozy modelu spełniają inżynierskie wymagania dotyczące dokładności. Analiza wykazuje, że prawie 80% wartości przewidywanych przez AM-ResNet mieści się w przedziale ± 5 MPa od wartości rzeczywistych, a ponad 92% mieści się w przedziale ± 10 MPa. Ten poziom dokładności spełnia typowe inżynierskie wymagania kontroli jakości dotyczące badań wytrzymałości betonu. AM-ResNet charakteryzuje się znacznie

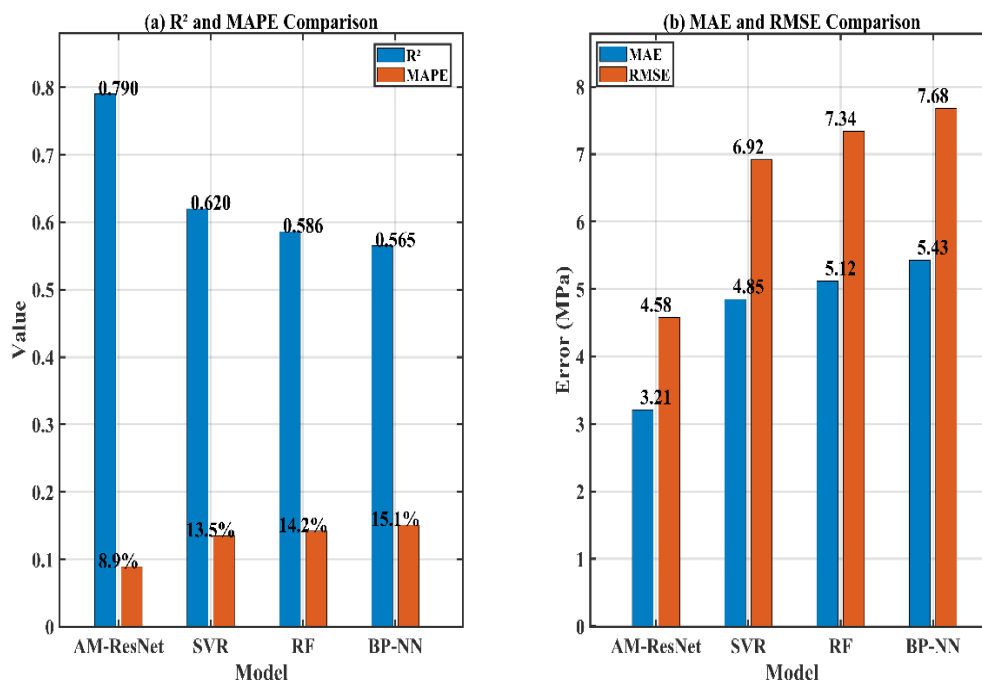
In summary, although the BP Neural Network model demonstrates a certain level of accuracy in predicting concrete strength, it exhibits relatively large prediction errors and poor fitting performance in the high-strength range. Further optimization is recommended to enhance its predictive accuracy.

3.5. Comparative performance analysis

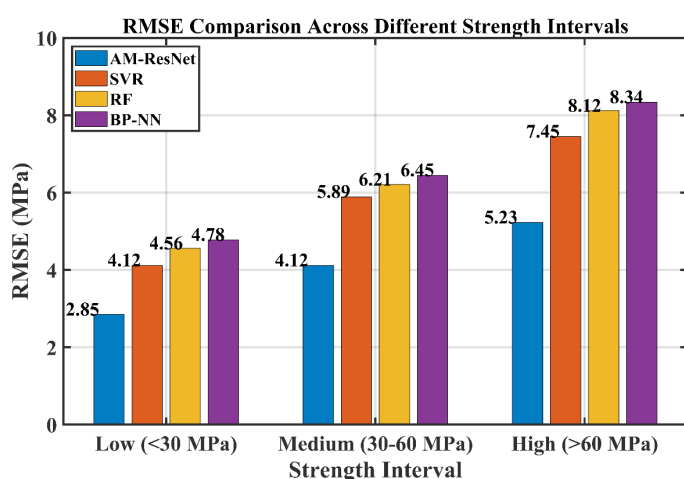
To comprehensively evaluate the performance of the proposed AM-ResNet model, this section conducts a systematic comparative analysis of AM-ResNet against three baseline models - Support Vector Regression [SVR], Random Forest [RF], and Backpropagation Neural Network [BP-NN]-across multiple dimensions. The evaluation dimensions include: multi-metric performance, performance across different strength intervals, cross-validation stability, residual distribution, training efficiency, noise sensitivity, and performance under different training set sizes. The multi-metric performance comparison is shown in Figure 17. The AM-ResNet model achieved the highest R^2 value [0.790], indicating that it can explain 79 % of the variance in concrete strength. More importantly, its MAE was 3.21 MPa and MAPE was 8.9 %, indicating that the average prediction error falls within acceptable engineering tolerances. Compared to the second-best performing SVR model, AM-ResNet reduced RMSE by 33.8 % and MAPE by 34.1 %, achieving a significant improvement in prediction accuracy.

The 206 samples in the test set were divided into three intervals based on their actual compressive strength: low strength [<30 MPa, 48 samples], medium strength [30–60 MPa, 112 samples], and high strength [>60 MPa, 46 samples]. R^2 and RMSE were recalculated for each interval to evaluate the model's performance across different strength ranges [Figure 18]. All models demonstrated the highest prediction accuracy in the medium-strength interval, which also constitutes the majority of the dataset. Notably, AM-ResNet performed particularly well in the high-strength range [>60 MPa], with an RMSE of 5.23 MPa, compared to 7.45 MPa for SVR-a 29.8 % improvement. This indicates that the attention-residual architecture is more effective at capturing the complex nonlinear relationships present in high-strength concrete mix designs.

Using five-fold cross-validation, the dataset was randomly divided into five subsets of equal size [approximately 206 samples per fold]. In each fold, four subsets were used for training and one subset for validation; this process was repeated five times to ensure that each subset was used as the validation set exactly once. The R^2 values from all folds were collected, and their mean and standard deviation were calculated [Fig. 19]. A smaller standard deviation indicates that the model is less sensitive to different data partitions and exhibits better stability. Analysis reveals that AM-ResNet not only achieved the highest mean R^2 but also had the smallest standard deviation [0.021], indicating that it maintains stable performance across different training-validation splits. In contrast, BP-NN exhibited the highest variability [$\sigma = 0.063$], suggesting that it is more sensitive to initialization and data partitioning. The low variance of AM-ResNet demonstrates its reliability in practical engineering applications, even when training data may vary.



Rys. 17. Porównanie wyników dla wielu wskaźników.
 Fig. 17. Performance comparison of multiple indicators.



Rys. 18. Skuteczność prognozowania dla różnych przedziałów intensywności.
 Fig. 18. Prediction performance under different intensity intervals.

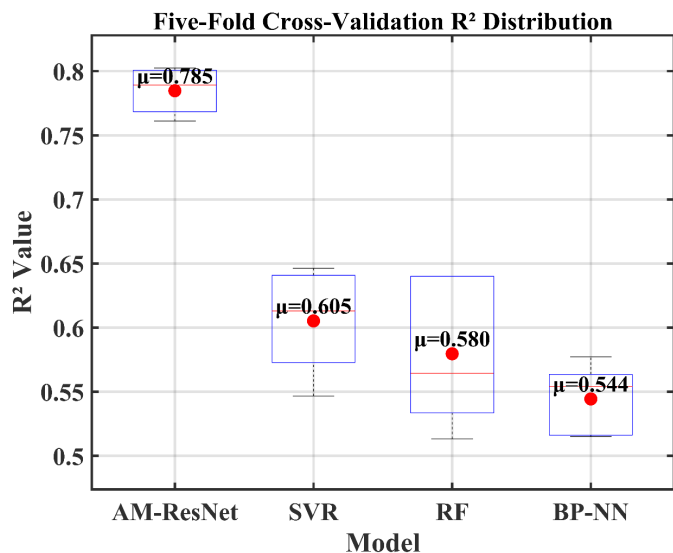
wyższym odsetkiem próbek mieszczących się w wąskim przedziale błędów, co dodatkowo potwierdza praktyczną wartość modelu dla zastosowań inżynierskich.

Wszystkie modele zostały wytrenowane na tej samej platformie sprzętowej [karta graficzna NVIDIA RTX 3080, procesor Intel i7-12700K], a całkowity czas [w sekundach] od rozpoczęcia treningu do zakończenia wszystkich 500 epok treningowych został zarejestrowany. W przypadku AM-ResNet i BP-NN liczbę epok szkoleniowych wymaganych do ustabilizowania funkcji straty określono poprzez monitorowanie straty walidacyjnej; zbieżność uznano za osiągniętą, gdy strata walidacyjna zmniejszyła się o mniej niż 0,001 przez 10 kolejnych epok. SVR i RF są metodami nieiteracyjnymi i nie obejmują koncepcji zbieżności opartej na epokach [rys. 21]. Chociaż czas szkolenia dla AM-ResNet jest o około 30% dłuższy

The residual is calculated as the predicted value minus the actual value. We counted the number of samples for which the absolute residual fell within the ± 5 MPa and ± 10 MPa threshold ranges for each model, and calculated the proportion of these samples relative to the total number of samples in the test set [206] [Fig. 20]. This metric intuitively reflects the extent to which the model's predictions meet engineering accuracy requirements. Analysis reveals that nearly 80 % of AM-ResNet's predicted values fall within ± 5 MPa of the actual values, and over 92 % fall within ± 10 MPa. This level of accuracy satisfies typical engineering quality control requirements for concrete strength testing. AM-ResNet has a significantly higher proportion of samples within the small error range, further confirming the model's practical value for engineering applications.

All models were trained on the same hardware platform [NVIDIA RTX 3080 GPU, Intel i7-12700K CPU], and the total time [in seconds] from the start of training to the completion of all 500 training epochs was recorded. For AM-ResNet and BP-NN, the number of training epochs required for the loss function to stabilize was determined by monitoring the validation loss; convergence was deemed achieved when the validation loss decreased by less than 0.001 for 10 consecutive epochs. SVR and RF are non-iterative methods and do not involve the concept of epoch-based convergence [Fig. 21]. Although the training time for AM-ResNet is approximately 30 % longer than that of BP-NN, its training curve converges smoothly without significant oscillations. The additional computational cost is offset by a significant improvement in prediction accuracy, as demonstrated by the aforementioned metrics. This trade-off between computational efficiency and prediction performance is advantageous for applications where accuracy is a priority.

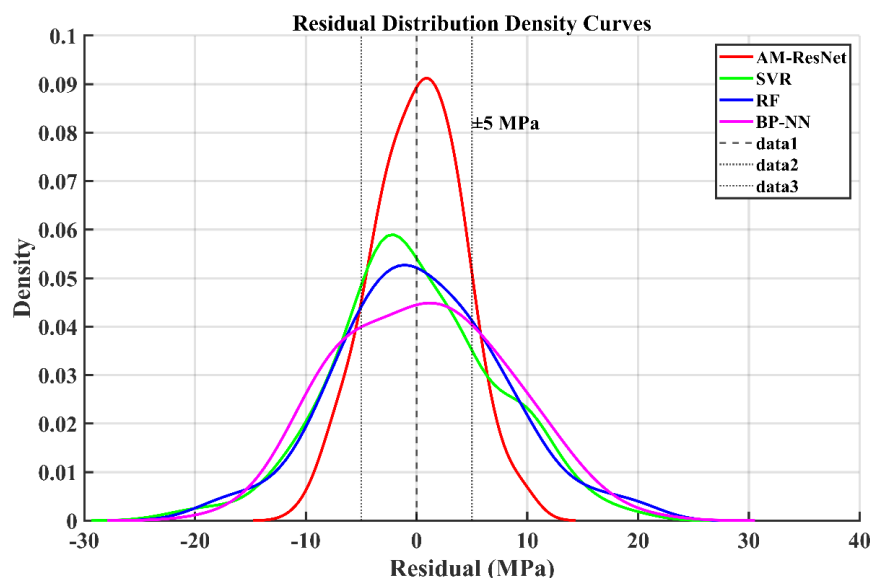
To evaluate the robustness of each model to noise in the input data, Gaussian noise of varying degrees was added to the features in



Rys. 19. Analiza stabilności metodą walidacji krzyżowej.

Fig. 19. Cross validation stability analysis.

niż dla BP-NN, jego krzywa szkolenia zbiega się płynnie bez



Rys. 20. Analiza rozkładu reszt.

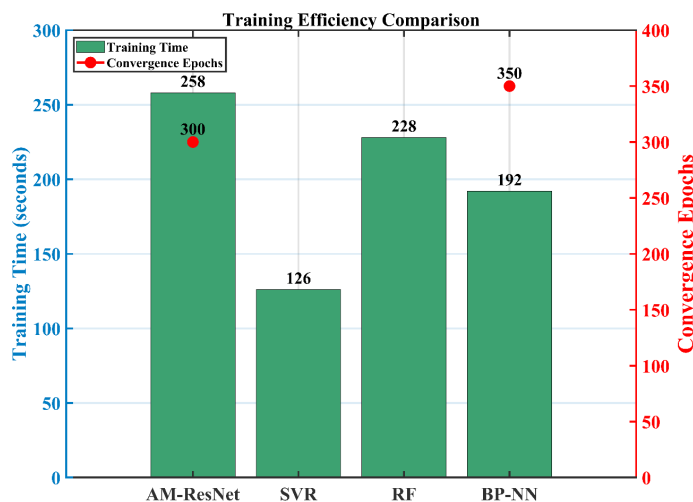
Fig. 20. Residual distribution analysis.

znaczących oscylacji. Dodatkowy koszt obliczeniowy jest równoważony przez znaczną poprawę dokładności prognozowania, co pokazują wyżej wymienione wskaźniki. Ten kompromis między wydajnością obliczeniową a wydajnością prognozowania jest korzystny w zastosowaniach, w których priorytetem jest dokładność.

Aby ocenić odporność każdego modelu na zakłócenia w danych wejściowych, do cech w zbiorze testowym dodano szum Gaussa o różnym natężeniu. Konkretna procedura wygląda następująco: dla każdej cechy wejściowej obliczono pierwotne odchylenie standardowe σ_f , a następnie dodano szum Gaussa o odchyleniach standardowych wynoszących $0\% \times \sigma_f$, $5\% \times \sigma_f$, $10\% \times \sigma_f$, $15\% \times \sigma_f$ i $20\% \times \sigma_f$ w celu wygenerowania próbek testowych z zakłóceniami szumowymi. Prognozy przeprowadzono ponownie dla każdego

the test set. The specific procedure is as follows: For each input feature, the original standard deviation of was calculated, and then Gaussian noise with standard deviations of $0\% \times \sigma_f$, $5\% \times \sigma_f$, $10\% \times \sigma_f$, $15\% \times \sigma_f$, and $20\% \times \sigma_f$ was added to generate noise-corrupted test samples. Predictions were re-run at each noise level, the R^2 values were calculated, and the decline in R^2 relative to the noise-free condition was recorded. To eliminate the randomness of a single noise addition, the noise addition process was repeated 10 times, and the average was taken as the final result [Figure 22]. As the noise level increased, the predictive performance of all models declined to varying degrees. AM-ResNet maintains the highest R^2 values at all noise levels and exhibits the smallest performance decline. At a 20 % noise level, AM-ResNet's R^2 remains at 0.674, while BP-NN has dropped to 0.372. This indicates that AM-ResNet possesses stronger resistance to noise interference, primarily due to the stability of feature extraction provided by the residual structure and the ability of the attention mechanism to focus on key information. In practical engineering applications, data acquisition often involves measurement errors and noise; this characteristic of AM-ResNet makes it more practical.

To evaluate the learning capabilities and data efficiency of each model under small-sample conditions, training samples were drawn from the full dataset at different proportions. The specific procedure is as follows: We randomly sampled 10 % [approximately 82 samples], 30 % [approximately 247 samples], 50 % [approximately 412 samples], 70 % [approximately 577 samples], and 100 % [824 samples] of the original training set [824 samples] to create new training sets. Each model was retrained on the corresponding training set and evaluated on the same test set [206 samples], with R^2 and RMSE recorded. To eliminate random sampling bias, each proportion was repeated 10 times, with training samples randomly resampled each time; the 10-fold

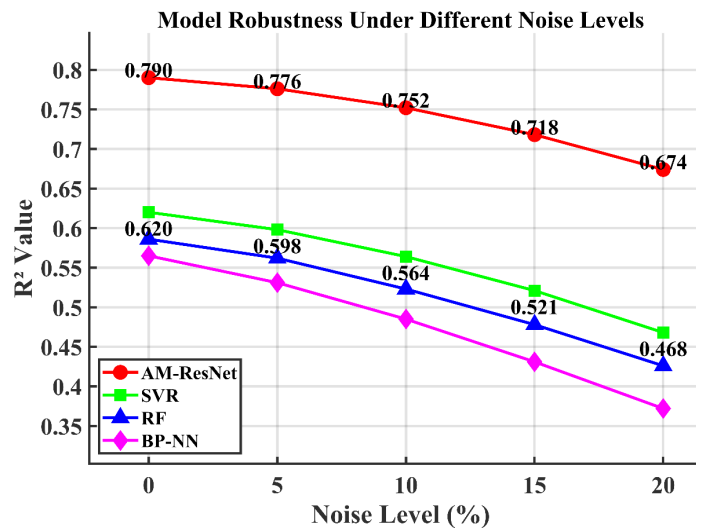


Rys. 21. Analiza efektywności uczenia i zbieżności.

Fig. 21. Analysis of Training Efficiency and Convergence.

poziomu szumu, obliczono wartości R^2 i odnotowano spadek R^2 w stosunku do stanu bez szumu. Aby wyeliminować losowość pojedynczego dodania szumu, proces dodawania szumu powtórzono 10 razy, a średnią przyjęto jako wynik końcowy [rys. 22]. Wraz ze wzrostem poziomu szumu wydajność prognostyczna wszystkich modeli spadła w różnym stopniu. AM-ResNet utrzymuje najwyższe wartości R^2 przy wszystkich poziomach szumu i wykazuje najmniejszy spadek wydajności. Przy poziomie szumu wynoszącym 20% wartość R^2 dla AM-ResNet pozostaje na poziomie 0,674, podczas gdy dla BP-NN spadła do 0,372. Wskazuje to, że AM-ResNet charakteryzuje się większą odpornością na zakłócenia szumowe, głównie dzięki stabilności ekstrakcji cech zapewnianej przez strukturę resztkową oraz zdolności mechanizmu uwagi do skupiania się na kluczowych informacjach. W praktycznych zastosowaniach inżynierskich pozyskiwanie danych często wiąże się z błędami pomiarowymi i szumami; ta cecha AM-ResNet sprawia, że jest on bardziej praktyczny.

Aby ocenić zdolności uczenia się i efektywność przetwarzania danych każdego modelu w warunkach małej próbki, z pełnego zbioru danych pobrano próbki szkoleniowe w różnych proporcjach. Konkretna procedura wygląda następująco: losowo pobraliśmy 10% [około 82 próbek], 30% [około 247 próbek], 50% [około 412 próbek], 70% [około 577 próbek] i 100% [824 próbek] z oryginalnego zestawu szkoleniowego [824 próbek], aby stworzyć nowe zestawy szkoleniowe. Każdy model został ponownie przeszkolony na odpowiednim zbiorze szkoleniowym i oceniony na tym samym zbiorze testowym [206 próbek], przy czym odnotowano wartości R^2 i RMSE. Aby wyeliminować błąd losowego doboru próby, każdy udział został powtórzony 10 razy, przy czym próbki szkoleniowe były za każdym razem losowo ponownie dobierane; jako wynik końcowy przyjęto 10-krotną średnią każdej miary [rysunek 23]. Analiza wykazała, że model AM-ResNet utrzymał optymalną wydajność prognozowania we wszystkich proporcjach zbioru szkoleniowego. Co istotne, nawet przy wykorzystaniu zaledwie 10% próbek szkoleniowych [około 82 próbek] model AM-ResNet osiągnął współczynnik R^2 na poziomie 0,621 oraz RMSE wynoszące 6,52 MPa - poziomy wydajności zbliżone do tych osiągniętych przez modele SVR i RF przy wykorzystaniu 50% próbek szkoleniowych. Wskazuje to, że model AM-ResNet charakteryzuje się wyższą efektywnością wykorzystania danych i może skutecznie uczyć się na ograniczonej liczbie próbek. Wraz ze wzrostem liczby próbek szkoleniowych wydajność wszystkich modeli wykazuje tendencję wzrostową. AM-ResNet wykazuje najbardziej znaczącą poprawę na swojej krzywej uczenia się: przy wzroście liczby próbek szkoleniowych z 10% do 100% współczynnik R^2 wzrósł o 27,2%, podczas gdy modele SVR, RF i BP-NN poprawiły się odpowiednio o 27,8%, 29,6% i 32,0%. Choć marginesy poprawy są podobne, AM-ResNet utrzymuje wyraźną przewagę w zakresie wydajności bezwzględnej na każdym etapie. Jego przewaga jest szczególnie wyraźna, gdy próbek szkoleniowych jest niewiele. Gdy próbki szkoleniowe stanowią zaledwie 10%, R^2 modelu AM-ResNet jest o 28,0% wyższy niż w przypadku SVR, o 37,4% wyższy niż w przypadku RF i o 45,1% wyższy niż w przypadku BP-NN. Wynika to ze skutecznego wyodrębniania cech przez sieć resztkową oraz

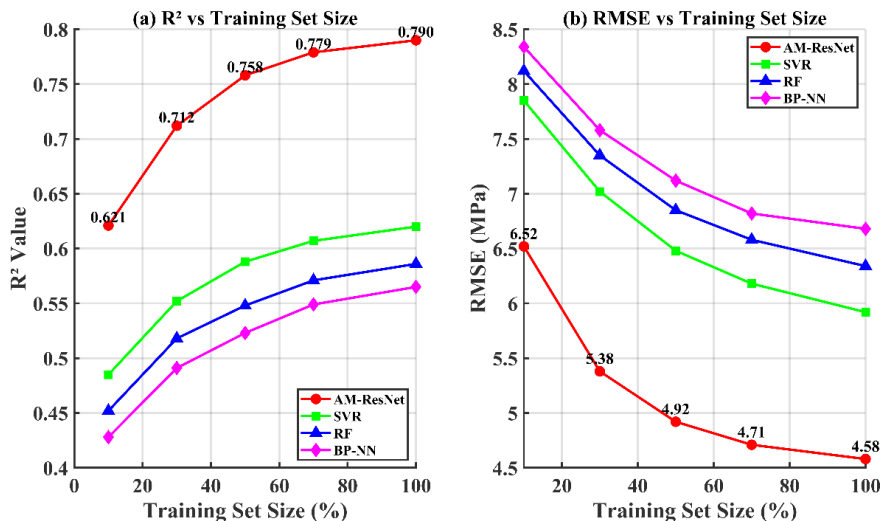


Rys. 22. Analiza wrażliwości na zakłócenia.

Fig. 22. Noise sensitivity analysis.

average of each metric was taken as the final result [Figure 23]. Analysis revealed that AM-ResNet maintained optimal prediction performance across all training set proportions. Notably, even when using only 10 % of the training samples [approximately 82 samples], AM-ResNet achieved an R^2 of 0.621 and an RMSE of 6.52 MPa-performance levels approaching those of SVR and RF when using 50 % of the training samples. This indicates that AM-ResNet exhibits higher data utilization efficiency and can learn effectively with limited samples. As the number of training samples increases, the performance of all models shows an upward trend. AM-ResNet exhibits the most significant improvement on its learning curve: from 10 % to 100 % training samples, R^2 increased by 27.2 %, while SVR, RF, and BP-NN improved by 27.8 %, 29.6 %, and 32.0 %, respectively. Although the improvement margins are similar, AM-ResNet maintains a clear lead in absolute performance at every stage. Its advantage is particularly pronounced when training samples are scarce. When training samples account for only 10 %, AM-ResNet's R^2 is 28.0 % higher than SVR's, 37.4 % higher than RF's, and 45.1 % higher than BP-NN's. This is attributed to the effective feature extraction of the residual network and the key information focusing provided by the attention mechanism, enabling the model to capture core patterns even with limited data. In practical engineering applications, acquiring large amounts of high-quality concrete strength test data is often costly and time-consuming. AM-ResNet's excellent performance under low-data conditions means that prediction models meeting engineering accuracy requirements can be trained with fewer test data, significantly reducing data collection costs and time.

To visually illustrate the overall performance of each model across multiple evaluation dimensions, the scores of each model on different metrics are normalized [Fig. 24]. The normalization method used is minimum-maximum normalization, which maps the values of each metric to the interval [0,1]. The specific formula is as follows: for positive metrics [where higher values are better], the normalized score = [actual value - minimum value] / [maximum value - minimum value]; for negative metrics [where lower values are better],



Rys. 23. Analiza wydajności przy różnych rozmiarach zbiorów szkoleniowych.

Fig. 23. Performance analysis under different training set sizes.

skupiania się na kluczowych informacjach zapewnianego przez mechanizm uwagi, co pozwala modelowi uchwycić podstawowe wzorce nawet przy ograniczonych danych. W praktycznych zastosowaniach inżynierskich pozyskanie dużych ilości wysokiej jakości danych z badań wytrzymałości betonu jest często kosztowne i czasochłonne. Doskonała wydajność AM-ResNet w warunkach ograniczonej ilości danych oznacza, że modele prognostyczne spełniające inżynierskie wymagania dotyczące dokładności mogą być trenowane przy użyciu mniejszej ilości danych testowych, co znacznie zmniejsza koszty i czas gromadzenia danych.

Aby wizualnie przedstawić ogólną wydajność każdego modelu w wielu wymiarach oceny, wyniki poszczególnych modeli dla różnych wskaźników zostały znormalizowane [rys. 24]. Zastosowano metodę normalizacji minimalno-maksymalnej, która odwzorowuje wartości każdego wskaźnika na przedział [0,1]. Konkretny wzór jest następujący: dla wskaźników dodatnich [gdzie wyższe wartości są lepsze] znormalizowany wynik = [wartość rzeczywista – wartość minimalna] / [wartość maksymalna - wartość minimalna]; dla wskaźników ujemnych [gdzie niższe wartości są lepsze] wartości są najpierw przeliczane na ich odwrotności, aby przekształcić je w wskaźniki dodatnie przed normalizacją. Kompleksowy wykres radarowy wydajności pokazuje, że AM-ResNet osiąga najlepsze wyniki w pięciu wymiarach: R², RMSE, odporność na szumy, wydajność na małych zbiorach danych oraz stabilność walidacji krzyżowej, podczas gdy pozostaje nieco w tyle pod względem wydajności szkolenia. Wynik ten potwierdza znaczące zalety AM-ResNet w zakresie dokładności prognozowania, odporności i stabilności. Chociaż czas szkolenia jest nieco dłuższy, kompromis ten jest akceptowalny w przypadku zadań inżynierskich związanych z prognozowaniem, które wymagają wysokiej dokładności.


the values are first converted to their reciprocals to transform them into positive metrics before normalization. The comprehensive performance radar chart shows that AM-ResNet performs best across five dimensions: R², RMSE, noise robustness, performance on small datasets, and cross-validation stability, while lagging slightly in training efficiency. This result confirms AM-ResNet's significant advantages in prediction accuracy, robustness, and stability. Although training time is slightly longer, this trade-off is acceptable for engineering prediction tasks that demand high accuracy.

4. Conclusion

This study proposes a deep learning framework that integrates an attention mechanism with a residual network [AM-ResNet] for concrete compressive strength prediction. The proposed model effectively addresses the limitations of conventional methods in capturing complex nonlinear interactions and feature correlations.

Experimental results demonstrate that AM-ResNet achieves superior prediction accuracy with an R² of 0.790, MAE of 3.21 MPa, and MAPE of 8.9%. Over 92% of prediction errors fall within ±10 MPa, meeting typical engineering quality control requirements. Compared to baseline models including SVR, RF, and BP-NN, AM-ResNet reduces RMSE by 33.8% and MAPE by 34.1%, with particularly pronounced advantages in high-strength concrete prediction.

The model exhibits strong robustness and data efficiency. Under 20% input noise, the R² remains at 0.674 with only a 14.7% degradation, substantially outperforming BP-NN [34.2% degra-



Rys. 24. Kompleksowa analiza wydajności.

Fig. 24. Comprehensive performance analysis.

4. Wnioski

W niniejszym artykule zaproponowano framework uczenia głębokiego, łączący mechanizm uwagi z siecią rezydualną [AM-ResNet], służący do prognozowania wytrzymałości betonu na ściskanie. Proponowany model skutecznie eliminuje ograniczenia metod konwencjonalnych w zakresie uwzględniania złożonych interakcji nieliniowych i korelacji cech.

Wyniki eksperymentalne pokazują, że AM-ResNet osiąga doskonałą dokładność prognozowania z R^2 wynoszącym 0,790, MAE wynoszącym 3,21 MPa i MAPE wynoszącym 8,9%. Ponad 92% błędów prognozowania mieści się w przedziale ± 10 MPa, co spełnia typowe wymagania inżynierskie w zakresie kontroli jakości. W porównaniu z modelami bazowymi, w tym SVR, RF i BP-NN, AM-ResNet zmniejsza RMSE o 33,8% i MAPE o 34,1%, wykazując szczególnie wyraźne zalety w prognozowaniu betonu o wysokiej wytrzymałości.

Model wykazuje dużą odporność i efektywność wykorzystania danych. Przy 20% szumu wejściowego współczynnik R^2 utrzymuje się na poziomie 0,674 z jedynie 14,7% spadkiem, znacznie przewyższając model BP-NN [34,2% spadek]. Przy zaledwie 10% próbek szkoleniowych model AM-ResNet osiąga współczynnik R^2 wynoszący 0,621, porównywalny z modelami bazowymi szkolonymi na 50% danych. Pięciokrotna walidacja krzyżowa potwierdza jego stabilność przy najniższej wariancji [$\sigma = 0,021$].

Proponowana struktura AM-ResNet stanowi solidne, dokładne i interpretowalne rozwiązanie do prognozowania wytrzymałości betonu. Jej doskonała wydajność w warunkach zakłóceń i ograniczonej ilości danych, w połączeniu z wysoką zdolnością uogólniania, sprawia, że jest to obiecujące narzędzie do inteligentnej kontroli jakości i projektowania materiałów w zastosowaniach inżynierii lądowej. W przyszłości planowane jest rozszerzenie modelu na inne właściwości betonu, takie jak trwałość i mrozoodporność, oraz uwzględnienie heterogenicznych danych z wielu źródeł w celu dalszego zwiększenia jego praktycznej użyteczności.

Finansowanie

Wsparcie finansowe otrzymano w ramach projektu inauguracyjnego Centrum Badań Inżynierskich w Syczuanie ds. Wykorzystania Osadów Komunalnych jako Materiałów Budowlanych [Sichuan College of Architectural Technology], nr SESBM202403.

Wkład autorów

Wszyscy autorzy w równym stopniu przyczynili się do powstania pracy; autorzy przeczytali również i zatwierdzili ostateczną wersję manuskryptu.

Dostępność danych

Zbiory danych wygenerowane i/lub analizowane w trakcie niniejszego badania są dostępne u autora korespondencyjnego na uzasadniony wniosek.

With only 10 % of training samples, AM-ResNet achieves an R^2 of 0.621, comparable to baseline models trained on 50 % of the data. Five-fold cross-validation confirms its stability with the lowest variance [$\sigma = 0.021$].

The proposed AM-ResNet framework offers a robust, accurate, and interpretable solution for concrete strength prediction. Its superior performance under noise and limited data conditions, combined with strong generalization capability, positions it as a promising tool for intelligent quality control and material design in civil engineering applications. Future work will extend the model to other concrete properties such as durability and frost resistance, and incorporate multi-source heterogeneous data to further enhance its practical applicability.

Funding

The financial support was received from the Opening Project of Sichuan Engineering Research Center for Resource Utilization of Municipal Sludge for Building Materials [Sichuan College of Architectural Technology], No. SESBM202403.

Author Contribution

All authors have contributed equally to the work, authors also read and approved the final manuscript.

Data availability

The datasets generated during and/or analyzed during the current study are available from the corresponding author on reasonable request.

Conflict of interest

The authors declare that they have no potential conflict of interest in relation to the study in this paper. The authors have no relevant financial or non-financial interests to disclose.

Konflikt interesów

Autorzy oświadczają, że nie mają żadnego potencjalnego konfliktu interesów w odniesieniu do badania opisanego w niniejszym artykule. Autorzy nie mają żadnych istotnych interesów finansowych ani niefinansowych, które należałoby ujawnić.

Literatura / References

1. H. Wu, et al., Research of the workability, mechanical and hydration mechanism of coal gangue-construction solid waste backfilling materials. *Constr. Build. Mater.* **408**, 133833 (2023). <https://doi.org/10.1016/j.conbuildmat.2023.133833>
2. H. Wu, et al., Research on pore distribution and creep properties of recycled plastic concrete. *Constr. Build. Mater.* **485**, 141947 (2025). <https://doi.org/10.1016/j.conbuildmat.2025.141947>
3. M. Amar, Comparative use of different AI methods for the prediction of concrete compressive strength. *Cleaner Mater.* **15**, 100299 (2025). <https://doi.org/10.1016/j.clema.2025.100299>
4. W. Ben Chaabene, M. Flah, M.L. Nehdi, Machine learning prediction of mechanical properties of concrete: Critical review. *Constr. Build. Mater.* **260**, 119889 (2020). <https://doi.org/10.1016/j.conbuildmat.2020.119889>
5. W. Zhang, D. Liu, K. Cao, Prediction of concrete compressive strength using support vector machine regression and non-destructive testing. *Case Stud. Constr. Mater.* **21**, e03416 (2024). <https://doi.org/10.1016/j.cscm.2024.e03416>
6. S. Kumar, et al., Prediction of compressive strength of high-volume fly ash self-compacting concrete with silica fume using machine learning techniques. *Constr. Build. Mater.* **438**, 136933 (2024). <https://doi.org/10.1016/j.conbuildmat.2024.136933>
7. Y. Jiang, et al., Prediction of time-dependent concrete mechanical properties based on advanced deep learning models considering complex variables. *Case Stud. Constr. Mater.* **21**, e03629 (2024). <https://doi.org/10.1016/j.cscm.2024.e03629>
8. R.V. Muthurathinam, et al., Optimizing concrete compressive strength prediction with a deep forest model: an advanced machine learning approach. *Matéria (Rio J.)* **29**(4) (2024). <https://doi.org/10.1590/1517-7076-rmat-2024-0569>
9. Q. Lv, et al., Machine learning-based optimization of concrete strength using interpretable models. *Mater. Today Commun.* **47**, 112872 (2025). <https://doi.org/10.1016/j.mtcomm.2025.112872>
10. W. Wang, et al., Prediction of Compressive Strength of Concrete Specimens Based on Interpretable Machine Learning. *Materials* **17**(15), 17153661 (2024). <https://doi.org/10.3390/ma17153661>
11. N.-H. Nguyen, et al., Heuristic algorithm-based semi-empirical formulas for estimating the compressive strength of the normal and high performance concrete. *Constr. Build. Mater.* **304**, 124467 (2021). <https://doi.org/10.1016/j.conbuildmat.2021.124467>
12. S. Zheng, T. Hu, Y. Yu, Interpretable Machine Learning-Based Prediction Model for Concrete Cover Separation of FRP-Strengthened RC Beams. *Materials* **17**(9), 17091957 (2024). <https://doi.org/10.3390/ma17091957>
13. B. Sun, et al., Prediction of compressive strength of concrete under various curing conditions: a comparison of machine learning models and empirical mathematical models. *Innov. Infrastruct. Solut.* **9**(7), 262 (2024). <https://doi.org/10.1007/s41062-024-01467-9>
14. A.K. Sah, Y.M. Hong, Performance Comparison of Machine Learning Models for Concrete Compressive Strength Prediction. *Materials* **17**(9), 17092075 (2024). <https://doi.org/10.3390/ma17092075>
15. M. Hosseinzadeh, et al., Concrete strength and durability prediction through deep learning and artificial neural networks. *Front. Struct. Civ. Eng.* **18**(10), 1540–1555 (2024). <https://doi.org/10.1007/s11709-024-1124-9>
16. F. Ahmad, et al., Machine learning-based Graphical User Interface for predicting high-performance concrete compressive strength: Comparative analysis of Gradient Boosting Machine, Random Forest, and Deep Neural Network Models. *Front. Struct. Civ. Eng.* **19**(7), 1075–1090 (2025). <https://doi.org/10.1007/s11709-025-1201-8>
17. R. Wang, et al., Structural damage identification by using physics-guided residual neural networks. *Eng. Struct.* **318**, 118703 (2024). <https://doi.org/10.1016/j.engstruct.2024.118703>
18. Y. Sun, Z. Gu, S.B. Yang, Probing vision and language models for construction waste material recognition. *Autom. Constr.* **166**, 105629 (2024). <https://doi.org/10.1016/j.autcon.2024.105629>
19. H. Li, et al., The local information extraction BFRC compressive strength prediction method via one-dimensional convolutional residual network. *Mater. Today Commun.* **39**, 108834 (2024). <https://doi.org/10.1016/j.mtcomm.2024.108834>
20. V.S. Aswal, B.K. Singh, R. Maheshwari, Machine learning-based model for prediction of concrete strength. *Multiscale Multidiscip. Model. Exp. Des.* **8**(1), 48 (2025). <https://doi.org/10.1007/s41939-024-00609-x>
21. K. Cao-Van, et al., Prediction of heart failure using voting ensemble learning models and novel data normalization techniques. *Eng. Appl. Artif. Intell.* **154** (2025). <https://doi.org/10.2139/ssrn.5022046>
22. M. Shantal, Z. Othman, A. Abu Bakar, Missing data imputation using correlation coefficient and min-max normalization weighting. *Intell. Data Anal.* **29**(2), 372–384 (2025). <https://doi.org/10.3233/IDA-230140>
23. H.X. Wu, et al., Facial expression recognition algorithm based on multi-attention mechanism. *Int. J. Innov. Comput. Inf. Control* **19**(4), 1239–1250 (2023). <http://doi.org/10.24507/ijic.19.04.1239>
24. A.D. Raha, et al., Corrections to “Attention to Monkeypox: An Interpretable Monkeypox Detection Technique Using Attention Mechanism”. *IEEE Access* **12**, 118937–118937 (2024). <http://doi.org/10.1109/access.2024.3448708>
25. G. Prashal, P. Sumathi, N.P. Padhy, Synchrosqueezed Transform Based Multicondense Residual Network for Ultra-Short-Term Solar Power Forecasting. *IEEE Trans. Ind. Inform.* **21**(2), 1489–1498 (2025). <https://doi.org/10.1109/TII.2024.3485693>
26. A. Noorzadegan, et al., Stable weight updating: A key to reliable PDE solutions using deep learning. *Eng. Anal. Bound. Elem.* **168**, 106439 (2024). <https://doi.org/10.1016/j.enganabound.2025.106439>
27. M.A. Abbas, et al., Residual mechanical properties of high strength concrete BBR9 subjected to dynamic uniaxial compressive loading. *Cem. Concr. Res.* **180**, 16 (2024). <https://doi.org/10.1016/j.cemconres.2024.107488>
28. A.H. Shadiani, M.A. Shoorehdeli, Online Learning Approach Based on Recursive Formulation for Twin Support Vector Machine and Sparse Pinball Twin Support Vector Machine. *Neural Process. Lett.* **55**(4), 5143–5165 (2023). <https://doi.org/10.1007/s11063-022-11084-1>
29. B. Liu, R. Mazumder, Randomization Can Reduce Both Bias and Variance: A Case Study in Random Forests. *J. Mach. Learn. Res.* **26**, 1–49 (2025). <https://jmlr.org/papers/v26/24-0255.html>
30. W. Cho, et al., FastLRNR and Sparse Physics Informed Back-propagation. *Results Appl. Math.* **25** (2025). <https://doi.org/10.1016/j.rinam.2025.100547>