

Prognozowanie wytrzymałości na ściskanie betonu natryskowego przy zastosowaniu inteligentnych metod obliczeniowych: sztucznej sieci neuronowej i regresji wektorów wspierających

Prediction of shotcrete compressive strength using Intelligent Methods; Neural Network and Support Vector Regression

Słowa kluczowe: beton natryskowy, wytrzymałość na ściskanie, pył krzemionkowy, sztuczna sieć neuronowa, regresja wektorów wspierających

Keywords: Shotcrete, Compressive Strength, Micro-Silica, Neural Network, Support Vector Regression

1. Wstęp

Beton natryskowy jest mieszaniną cementu, kruszywa, domieszk i wody. Mieszanina ta jest pneumatycznie natryskiwana na powierzchnię z dużą szybkością, metodą suchą lub mokrą (1). Beton natryskowy jest szeroko stosowany w inżynierii lądowej, a także górniczej (2), jako obudowa podziemnego wyrobiska. Dla przykładu ma szereg zastosowań w zakresie drążenia tuneli, robotach ziemnych, naprawie konstrukcji, stabilizacji skarpy (3). Wytrzymałość na ściskanie betonu natryskowego jest jedną z jego najważniejszych mechanicznych właściwości. Niektóre właściwości: stosunek cement – woda, ilość kruszywa drobnego i grubego i domieszki wpływają na jego wytrzymałość. Z powodu dużej liczby takich czynników wydaje się trudnym prognozowanie wytrzymałości betonu natryskowego. Skład mieszanki betonowej i reakcje między składnikami określają właściwości materiału kompozytowego, takiego jak beton lub beton natryskowy (4). Opracowano różne modele matematyczne do prognozowania wytrzymałości betonu. Modelowanie takie było rozwijane przy użyciu głównie danych laboratoryjnych. Różne metody poczynając od regresji liniowej i wielorakiej (5–8) do metod sztucznej inteligencji, takich jak logika rozmyta lub sieci neuronowe były stosowane z wynikiem pozytywnym (9 – 14) w modelowaniu. Obecnie inteligentne metody obliczeniowe mają szczególne znaczenie w prognozowaniu właściwości materiałów. Możliwości sieci neuronowych w poszukiwaniu złożonych korelacji między zmiennymi zamieniły je w dogodne narzędzie modelowania właściwości lub procesu na podstawie posiadanych danych (15). Jeśli prognozowanie wytrzymałości jest traktowane jako odwzorowanie parametrów wpływających na 28 – dniową wytrzymałość betonu natryskianego, to możliwym będzie opracowanie modelu odwzorowania przy zastosowaniu wielowarstwowej, jednokierunkowej sieci neuronowej [MFNN] zamiast modelu regresyjnego. Badania nad sieciami neuronowymi

1. Introduction

Shotcrete is a mixture of cement, aggregates, admixtures and water. This substance is pneumatically sprayed on a surface of rock at a high speed through a wet or dry method (1). As the support of underground excavations, shotcrete is widely used in civil and mining engineering fields (2). It has, for example, wide applications in tunneling, well digging, repairing of structures and slope stabilization (3). Compressive strength of shotcrete is one of its most important mechanical properties. Some parameters like cement-water ratio, amount of fine and coarse aggregates – fine versus coarse and admixtures, all which affect its strength. Due to the large number of such parameters, it seems difficult to predict shotcrete strength. Mix design and reactions between constituents determine the behavior of composite materials, like concrete or shotcrete (4). Different mathematical models have been suggested to predict concrete behavior. Such modeling is mainly developed using laboratory data. Different methods, from linear/multivariable regressions (5–8) to artificial intelligence methods, like fuzzy logic or neural networks, have been successfully used in this field (9–14). Today, intelligent methods have a particular role in predicting behavior of materials. The capability of neural networks in defining complex correlations between variables has turned them into a strong tool for data modeling (15). If strength prediction is regarded as map of the parameters influencing the 28-day compressive strength of shotcrete, it will be possible to develop a mapping model using Multilayered Feed-Forward Neural Networks, MFNNs, instead of regression model. The study on neural networks has been inspired by biological neural networks and has been based on modeling the biological behavior of neural cells. In an artificial neural network, processing elements, i.e. neurons, simulate the performance of neural cells of human brain with billions of related neurons. These neurons are the essential elements of the central nervous system and determine any requested response. MFNN

mi były inspirowane działaniem biologicznych sieci neuronowych i wykorzystywały modelowanie działania naturalnych neuronów. W sztucznych sieciach neuronowych element przetwarzania, czyli neurony, naśladują działanie komórek nerwowych ludzkiego mózgu z bilionami powiązanych neuronów. Neurony są niezbędnymi składnikami centralnego układu nerwowego i określają dowolną żądaną odpowiedź. MFNN jest typowym modelem sztucznej sieci neuronowej, który jest wykorzystywany prawie we wszystkich obszarach naukowych (16). Wykonano już szereg badań modelowych w zakresie wytrzymałości różnych betonów z użyciem tego właśnie modelu. Oztas i in. (9) opracowali model do prognozowania opadu betonu i 28 dniowej wytrzymałości betonu na ściskanie z użyciem sieci neuronowych. Zastosowali czterowarstwową sieć neuronową z dwoma ukrytymi warstwami, która wyliczała wytrzymałość betonu z dużą dokładnością, zarówno dla danych uczących jak i dla danych testowych. Na podstawie uzyskanych wyników Autorzy pracy (9) stwierdzili, że jako narzędzie dające się zastosować do prognozowania wytrzymałości betonu na ściskanie oraz konstancji betonu, sieci neuronowe zapewniają dużą dokładność prognozowania. Sobhani i in. (17) porównali różne metody regresji, sieci neuronowej i logiki rozmytej w prognozowaniu wytrzymałości samozagęszczającej się mieszanki betonowej po 28 dniach. Autorzy pracy (17) stwierdzili dużą efektywność obliczeniową metod z wykorzystaniem sztucznych sieci neuronowych i logiki rozmytej, w porównaniu z metodą analizy regresji. Elsanadedy i in. (18) rozwinięli modele prognostyczne dla wytrzymałości betonu zbrojonego z włóknami polimerowymi. Zastosowali sieć neuronową z czterema warstwami ukrytymi i badali wpływ różnych czynników stosując analizę wrażliwości [SA]. W wyniku badań stwierdzili, że sieci neuronowe są lepszym narzędziem prognostycznym w porównaniu z charakterystykami zastępczymi uzyskanymi, metodą regresji.

Maszyna wektorów nośnych [SVM] jest nadzorowaną metodą uczenia, wykorzystywaną w analizie danych do klasyfikacji [SVC] i regresji [SVR]. SVR została niedawno zastosowana do prognozowania w różnych obszarach. Jest to inna metoda inteligencji obliczeniowej powiązana z siecią neuronową, zasadniczo oparta na teorii uczenia statystycznego, zaproponowanej przez Vapinka (19). Opublikowano także kilka prac przy zastosowaniu tej metody do prognozowania właściwości betonu. Chou i Tsai (20) prowadzili badania wytrzymałości betonu na ściskanie stosując SVR. Zastosowali zarówno klasyfikację hierarchiczną jak i metody regresji do prognozowania wytrzymałości i wykazali dobrą efektywność metody SVR w prognozowaniu wytrzymałości. Sobhani i in. (21) zastosowali zarówno sieci neuronowe oraz metodę SVR do prognozowania wytrzymałości samozagęszczającej się mieszanki betonowej i wykazali, że oba modele można użyć do prognozowania wytrzymałości betonu z wysoką dokładnością i dużą jakością generalizacji. Stwierdzili, że metoda SVR zapewnia lepszą efektywność w porównaniu z sieciami neuronowymi w warunkach niekompletnych danych. Shi i Dong (22) prognozowali wytrzymałość betonu stosując SVR. Porównali wyniki uzyskane metodą SVR z wynikami otrzymanymi przy stosowaniu sieci neuronowych i wykazali większą dokładność wyników uzyskanych metodą SVR. Ponadto wykazali, że obie metody mogą być uznane za właściwe

model is a typical model of neural networks which is employed almost in all scientific fields (16). It is possible to find a large number of studies carried out to predict the strength of different concretes using this method. Oztas et al. (9) designed a neural network model to predict the slump and the 28-day compressive strength of high strength concretes. They introduced a 4-layered neural network with two hidden layers, which showed concrete strength, for both training and test data, with a high accuracy. Regarding the obtained results, they argued that as an applicable tool, neural networks have a high potential for predicting the compressive strength and slump of concretes. Sobhani et al. (17) compared different regression, neural network and fuzzy methods to predict the 28-day strength of self-compacting concretes. They reported high capability of neural networks and fuzzy methods compared with typical regression methods. Elsanadedy et al. (18) developed prediction models for the strength of reinforced concretes with polymer fibers. They used a four-hidden layered network and investigated the influence of different parameters using sensitivity analysis, SA, and eventually concluded that neural networks are more appropriate tools than regression equations. Support Vector Machine [SVM], is a supervised learning method employed for data analysis to classify [SVC] and regression [SVR]. SVR has been recently used for prediction in different fields. It is another technique in computational intelligence associated with neural network and is essentially based on static learning theory proposed by Vapink (19). There are also several studies conducted using this method to predict concrete behavior. Chou and Tsai (20) conducted studies on concrete compressive strength using SVR. They used hierarchy classification as well as regression methods to predict the strength and showed the proper performance of SVR in predicting the strength. Sobhani et al. (21) used both neural network and SVR to predict self-compacting concrete strength and showed that both models can predict the compressive strength of the concretes with a high accuracy and a high generalization quality. They stated that SVR shows a better performance than neural network in incomplete data conditions. Shi and Dong (22) predicted cement strength using SVR. They compared SVR results with that of neural network and showed that SVR obtained more accurate results compared with neural network. They, however, showed that both models can be regarded as an acceptable alternative method for practical tests. Yuvataj et al. (23) used SVR-based model and predicted the joint properties in high strength concrete [HSC] and ultra-high strength concrete [UHSC] beams. They suggested that SVR is consistent with empirical methods in predicting the properties of the beams joints. Although, the different data mining techniques were used for predicting compressive strength of concrete include artificial neural network, support vector machine. In the case of shotcrete, however, the progress of research has been limited. Properties of hardened shotcrete are different from conventional cast concrete in many aspects: such as the aggregate size; porosity; sensitivity to temperature and humidity; air voids content (24).

This study aims to conduct a research to compare SVR and back-propagation artificial neural network in order to investigate their characteristics and potentials in predicting the 28-day strength of

do zastosowań praktycznych. Yuvataj i in. (23) zastosowali model oparty na SVR i prognozowali właściwości fugi z betonu o wysokiej wytrzymałości [BWW] i belek z betonu o bardzo wysokiej wytrzymałości [UHSC]. Sugerują, że wyniki prognozowania właściwości łączek belek według metody SVR są zgodne z wynikami uzyskanymi doświadczalnie. Pomimo, że różne techniki eksploracji danych były stosowane do prognozowania wytrzymałości betonu na ściskanie, włączając sztuczne sieci neuronowe i maszynę wektorów nośnych to jednak w przypadku betonu natryskowego postęp badań był ograniczony. Właściwości stwardniałego betonu natryskowego różnią się od właściwości konwencjonalnego betonu układanego, a mianowicie: uziarnieniem kruszywa, porowatością, oddziaływaniami temperatury i wilgotności, zawartość banieczek powietrza (24).

Niniejsza praca ma na celu porównanie SVR oraz sztucznej sieci neuronowej z wsteczną propagacją błędu, w celu zbadania ich właściwości i możliwości prognozowania wytrzymałości betonu natryskowego, po 28 dniach. Dane uczące i testowe obu modeli zostały ustalone na podstawie wyników badań odporności na ściskanie, uzyskanych na próbkach betonu natryskowego. Dotychczas zbadano 59 próbek, o różnym składzie mieszanki betonowej. Danymi wejściowymi są: ilość cementu (c), woda (w), kruszywo drobne, pył krzemionkowy, stosunek w/c . Danymi wyjściowymi są wytrzymałości betonu po 28 dniach. Metodą prób i błędów badano różne struktury i rozmieszczenia sztucznych neuronów w celu otrzymania właściwej sieci neuronowej.

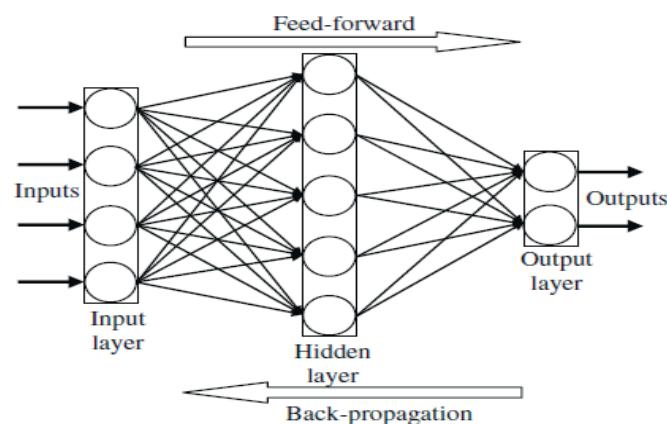
2. Sieci neuronowe

Sztuczna sieć neuronowa jest strukturą matematyczną przetwarzającą informację, mającą wspólne właściwości przetwarzania z biologiczną siecią neuronową. Sieci neuronowe są bardziej przydatne w procesach słabo zdefiniowanych lub w procesach, o działaniu których nie wszystko jest wiadome. Inną właściwością tych modeli, odróżniającą ich od innych metod obliczeniowych i algorytmów, jest ich mała wrażliwość na błędy danych wejściowych. W tym systemie złożone działania są wykonywane przez ścisłą, równoległą strukturę, w której raczej duża liczba prostych jednostek obliczeniowych niż pojedyncza jednostka, przeprowadza wszystkie czynności. Dlatego błąd lub niewłaściwy wynik pojedynczego neuronu nie ma dużego wpływu na inne jednostki obliczeniowe. Sieci jednokierunkowe są najbardziej znanyimi i szeroko stosowanymi modelami. W sieci jednokierunkowej neurony [jednostki obliczeniowe] są zorganizowane w warstwy i każdy neuron jest połączony ze wszystkimi neuronami następnej warstwy. Rysunek 1 pokazuje schemat struktury sieci jednokierunkowej. Z pośród różnych algorytmów algorytm optymalizacyjny Levenberga–Marquardta jest najczęściej używany jako algorytm treningu, z powodu jego szybkiej zbieżności i odporności na błędy w danych (25). Więcej szczegółów dotyczących sztucznych sieci neuronowych można znaleźć w pracach (26 - 28).

shotcretes. Training and test data of both models were extracted from the results of unconfined compression tests [UCS], carried out on the shotcrete specimens. To this end, 59 specimens with different mix designs were tested. Input parameters were: amount of cement, water, fine-coarse aggregates, micro-silica and water-cement [w/c] ratio and the output was the 28-day strength of concrete. To obtain a proper neural network, different structures and layouts were used by try and error and finally the optimal structure was obtained.

2. Neural networks

Artificial neural network is an information processing system which has common performance characteristics with biological neural networks. Neural networks are more effective in processes with no accurate definition or a particular understanding of them. Another characteristic of the models, differentiating them from other methods and algorithms, is that they are low sensitivity to input errors. In this system, complex activities are performed through a strict parallel structure in which a large number of simple computational units- rather than a single unit- perform all activities. Therefore, the error and incorrect result of a neuron will have no significant effect on other computational units. Feed-Forward networks are the most recognized models widely used in most applications. In feed-forward networks, neurons are arranged in layers with every neuron connected to all neurons of next layer. Fig. 1 shows a schematic view of a feed-forward network. Among the various algorithms available, Levenberg–Marquardt algorithm is the most commonly used training algorithm due to its speed and robustness (25). More details about the ANN and its mathematics are given in Beale and Jackson (26), as well as Fausett (27) papers.



Rys. 1. Struktura sieci jednokierunkowej wielowarstwowej z wsteczną propagacją sygnału (28)

Fig. 1. Architecture of a feed-forward network (28).

3. Support Vector Regression (SVR) theory

Support Vector Machine [SVM], developed by Vapnik (29), is a supervised learning method that was initially proposed for classification tasks, i.e., to model discrete labeled output. The

3. Teoria regresji wektorów wspierających

Maszyna wektorów wspierających [nośnych] opracowana przez Vapnika (29) jest metodą uczenia nadzorowanego – czyli z nauczycielem, początkowo proponowaną do rozwiązywania zadań klasyfikacyjnych, to znaczy do modelowania etykietowanych dyskretnych sygnałów wyjściowych. Metody klasyfikacji wykorzystujące maszyny wektorów wspierających oparte są na zasadzie optymalnego rozdzielenia klas, w celu znalezienia hiperpłaszczyzny przecinającą przestrzeń, w której występują oba znane pozytywne, a także negatywne przypadki, co schematycznie pokazano na rysunku 2. Zastosowanie SVM do zagadnień regresji stało się możliwe po wprowadzeniu ϵ – niewrażliwej funkcji straty. Regresja wektorów wspierających (SVR) jest modyfikacją metody SVM, w której liniowy model jest budowany w nowej wielowymiarowej przestrzeni wektorów cech. W regresji wektorów wspierających dane wejściowe są pierwsze mapowane do wielowymiarowej przestrzeni wektorów cech przez nieliniowe mapowanie, w celu rozwiązania problemu liniowej regresji w tej przestrzeni cech. Mapowanie to może być przeprowadzone przy użyciu funkcji jądra. W ostatnich latach SVR stała się popularnym narzędziem do rozwiązywania nieliniowych zagadnień regresji z ograniczoną bazą danych. Dalsze szczegóły metody podają Cortes i Vapnik (30).

4. Materiały i skład mieszanki

W przeprowadzonych badaniach użyto 59 mieszanek betonowych pokazanych w Tablicy 1. Pył krzemionkowy zastosowano we wszystkich próbkach w celu zwiększenia wytrzymałości betonu natryskowego. Kruszywo łamane grube o uziarnieniu 4,75-9,5 mm, a także drobne kruszywo naturalne o uziarnieniu 0-4,75mm, jak piasek, dodawano do każdej projektowanej mieszanki betonowej.

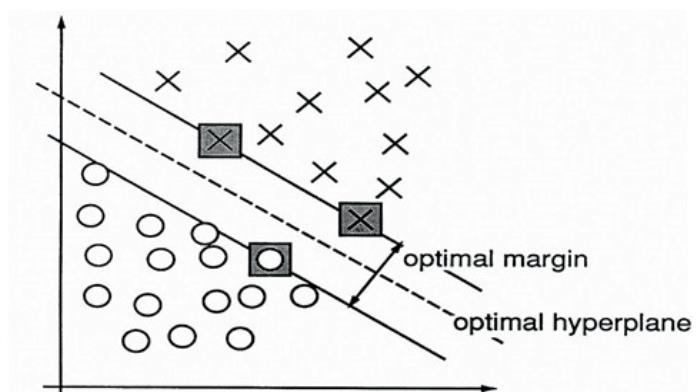
5. Przygotowanie próbek mieszanek betonu natryskowego

Próbki betonu natryskowego zostały przygotowane według specyfikacji zawartej w ACI 506-2-91, artykuł TS 7.5.3. Mieszanki betonowe przygotowywano przy stałej konsystencji. Wszystkie doświadczenia i pobieranie próbek zostały wykonane zgodnie z normą ASTM C1140. Należy zaznaczyć, że wszystkie składniki mieszanki ważono, a wszystkie doświadczenia prowadzono w tych samych warunkach.

6. Modele i wyniki

6.1. Modelowanie za pomocą sztucznej sieci neuronowej

Stosownie do wyżej omówionych właściwości sieci neuronowej w niniejszym artykule zawarto dane uczące, weryfikujące i testowe 59 próbek, z których 45 (75%) stosowano do uczenia i weryfikacji sieci, a 14 (25%) użyto po treningu sieci, w celu wyboru jej właściwej struktury. Tablica 2 pokazuje zakresy danych.



Rys. 2. Przykład problemu rozdziału w przestrzeni dwuwymiarowej. Wektory wspierające, oznaczone przez szare kwadraty, określają najszerszą granicę dyskryminacji między dwiema klasami (30).

Fig. 2. An example of a separable problem in a 2 dimensional space. The support vectors, marked with grey squares, define the margin of largest separation between the two classes (30).

support vector machines based classification methods are based on the principle of optimal separation of classes to find the best hyper-plane that bisects a space in which both known positive and negative instances are presented [Fig. 2]. After the introduction of the ϵ -insensitive loss function, it was possible to apply SVM to regression problems. Support vector regression [SVR] is a modification of SVM in which a linear model is constructed in the new higher dimensional feature space. In Support Vector Regression, the input data is first mapped into a higher dimensional feature space by nonlinear mapping to solve a linear regression problem in this feature space. This mapping can be done using a kernel function. During recent years, SVR has become a popular tool for solving nonlinear regression problems with limited database. Further details in this respect can be found in (30).

4. Materials and mix design

A total of 59 mix designs of shotcrete were used in this study. Table 1 summarizes them. Micro-silica was applied to all specimens in order to enhance the strength of shotcretes. Crushed coarse aggregate stone with a particle size of 4.75-9.5 mm as well as natural fine aggregates = sand with a particle size of 0-4.75 mm were added to all mixtures.

5. Preparing specimens

Mix designs of shotcretes were prepared as per ACI 506-2-91 clause TS 7.5.3. The considered mix was prepared by keeping the slump constant. All tests and sampling operations were carried out in accordance with ASTM C1140. It should be mentioned that all amounts were measured by mass and all tests had the same practical parameters.

Tablica 1 / Table 1

PRÓBKI MIESZANEK BETONU NATRYSKOWEGO

MIX DESIGN USED IN THE SAMPLES

Próbka Sample No	Dane uczące i weryfikujące oraz testowe Training/Testing data	Cement (kg)	Woda Water (kg)	Kruszywo drobne F.A. (kg)	Kruszywo grube C.A. (kg)	Pył krzemionkowy Micro SiO ₂ (kg)	W/C	(MPa)
1	Test	570	200	1150	480	0	0.35	46.48
2	Train	542	225	1150	480	28	0.41	47.27
3	Train	513	238	1140	480	55	0.46	39.91
4	Train	485	243	1140	475	81	0.5	47.95
5	Train	470	184	1200	520	0	0.39	43.05
6	Test	470	200	1190	490	24	0.42	43.35
7	Test	470	206	1170	480	46	0.44	48.05
8	Train	470	225	1150	470	68	0.48	47.27
9	Train	520	210	1098	470	52	0.4	46.48
10	Train	520	210	1095	455	52	0.4	53.45
11	Train	520	227	1080	445	52	0.44	43.15
12	Train	520	200	1070	440	54	0.38	46.48
13	Train	520	185	1145	490	0	0.36	43.44
14	Train	470	200	1145	488	47	0.43	41.48
15	Test	520	217	1090	450	53	0.42	50.80
16	Train	300	244	1363	418	50	0.82	31.38
17	Train	350	247	1313	418	50	0.7	37.36
18	Train	400	221	1263	418	50	0.55	51.09
19	Train	450	231	1213	418	50	0.51	50.21
20	Train	400	216	1320	430	0	0.54	32.75
21	Train	400	188	1320	430	0	0.47	35.30
22	Train	400	204	1320	430	40	0.51	42.95
23	Train	400	212	1320	430	40	0.53	45.01
24	Train	380	224	1320	430	0	0.59	27.16
25	Train	380	209	1320	430	20	0.55	28.24
26	Train	380	197	1320	430	20	0.52	29.62
27	Train	380	175	1320	430	20	0.46	31.68
28	Train	370	211	1320	430	0	0.57	31.48
29	Train	370	189	1320	430	30	0.51	32.85
30	Test	370	181	1320	430	30	0.49	33.44
31	Train	370	174	1320	430	30	0.47	36.58
32	Train	360	198	1320	430	0	0.55	30.79
33	Test	360	191	1320	430	40	0.53	31.97
34	Train	360	194	1320	430	40	0.51	34.91
35	Train	360	169	1320	430	40	0.47	36.09
36	Train	390	222	770	428	0	0.57	33.64
37	Test	390	242	770	428	50	0.62	35.70
38	Test	390	195	770	428	50	0.5	40.11
39	Train	390	179	770	428	50	0.46	40.89
40	Test	390	164	770	428	50	0.42	42.56
41	Train	390	207	770	428	50	0.53	35.30
42	Train	390	195	770	428	50	0.5	37.76
43	Train	390	183	770	428	50	0.47	40.11
44	Train	365	219	800	428	0	0.6	30.89
45	Train	365	234	800	428	50	0.64	32.75
46	Test	365	190	800	428	50	0.52	33.44
47	Train	365	179	800	428	50	0.49	35.99
48	Train	365	164	800	428	50	0.45	40.01
49	Train	365	200	800	428	50	0.55	29.42

Dalszy ciąg Tablicy 1 / Sequel of Table 1

50	Train	365	190	800	428	50	0.52	33.24
51	Test	365	175	800	428	50	0.48	38.74
52	Train	320	185	825	555	0	0.58	28.93
53	Test	320	160	825	555	0	0.5	35.11
54	Train	320	150	825	555	0	0.47	44.03
55	Train	320	141	825	555	0	0.44	46.39
56	Train	290	168	825	555	30	0.58	33.15
57	Test	290	159	825	555	30	0.55	37.85
58	Train	290	145	825	555	30	0.5	41.58
59	Train	290	130	825	555	30	0.45	53.64

Tablica 2 / Table 2

ZAKRESY ZMIENNOŚCI SKŁADNIKÓW MIESZANKI BETONU NATRYSKOWEGO I STOSUNKU W/C ORAZ WYTRZYMAŁOŚCI NA ŚCISKANIE

RANGE OF PARAMETERS

Attribute Składnik oraz stosunek W/C i wytrzymałość na ściskanie	Minimum	Average/Średnia	Maximum
Cement / Cement(kg)	290	400	570
Water / Woda (kg)	130	196.96	130
Fine Aggregate / Kruszywo drobne (kg)	770	1058.39	1363
Coarse Aggregate / Kruszywogrube (kg)	418	456.83	555
Micro-Silica / Pył krzemionkowy (kg)	0	33.59	81
Water-Cement Ratio / Stosunek woda - cement	0.35	0.5	0.82
Shotcrete Compressive Strength / Wytrzymałość na ściskanie (MPa)	27.16	39.00	53.64

Jednokierunkową, wielowarstwową sieć neuronową z algorytmem wstępnej propagacji błędu użyto do budowy modelu. Na rysunku 4 pokazano schemat struktury sieci neuronowej, opracowanej w wyniku badań. Sieć składa się z jednej warstwy ukrytej z sigmoidalną funkcją aktywacji i warstwy wyjściowej składającej się z jednego neuronu z liniową funkcją transferu – pure-line. Dane wejściowe zawierają ilość cementu, wody, kruszywa drobnego i grubego oraz pyłu krzemionkowego, a także stosunek w/c. Dane wyjściowe zawierają wytrzymałość na ściskanie betonu natryskowego po 28 dniach. Liczba neuronów w warstwie ukrytej dobrana została metodą prób i błędów, biorąc pod uwagę najlepszą wydajność sieci. Ustalono liczbę neuronów w warstwie ukrytej równą 11. W tablicy 3 zamieszczono ogólne właściwości zastosowanej sieci. Sieć modelowano stosując program MATLAB. Na rysunku 5 pokazano porównawczą krzywą rzeczywistej wytrzymałości na ściskanie wobec wartości prognozowanej. Zgodnie z tą krzywą liniowa funkcja regresji została zaproponowana do opisu korelacji wartości rzeczywistych naprężenia ściskającego wobec wartości prognozowanych. W przypadku otrzymanej liniowej funkcji korelacji współczynnik korelacji liniowej wynosi 0,9344 co świadczy o bardzo wysokiej korelacji danych, uzyskanych za pomocą zaproponowanej sieci neuronowej.

6.2. Modelowanie z zastosowaniem SVR

Te same dane w liczbie 45 oraz 14 co w przypadku modelowania wytrzymałości na ściskanie betonu natryskowego przy wykorzystaniu ANN zastosowano do modelowania wytrzymałości na ściskanie

6. Models and results

6.1. Neural network modeling

According to above discussions, this paper contains 59 training and test data, 45 [75%] of which are used for network training and 14 [25%] of which are used for network testing. Table 2 shows the range of the employed data. Feed-Forward network with back-propagation algorithm was used to build the model. Fig. 4 shows a schematic view of the built network. It consists of one hidden layer, containing sigmoid neurons, and one linear output layer [pure-line]. Network inputs include the amount of cement, water, fine + coarse aggregates, micro-silica and water to cement (w/c) ratio. Network output is the 28-day strength of shotcretes. The number of neurons in the hidden layer was obtained through try and error process and considering the best performance of the network. A total number of neurons were considered 11 in the hidden layer of the network. Table 3 summarizes the general properties of the applied network. The network was modeled by MATLAB. Fig. 5 shows the comparative curve of network performance and laboratory data. According to the curve, linear function was used to relate real values to predicted ones. In this curve, correlation coefficient is 0.9344 implying the proper performance of the network.

6.2. SVR modeling

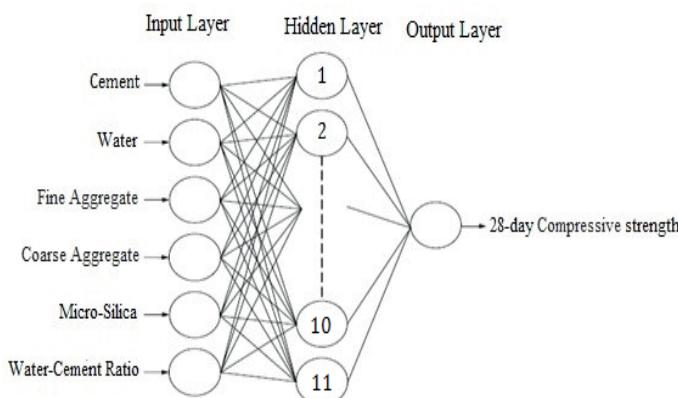
As mentioned in neural network modeling, the same 45 and 14 data are used for training and testing the model. The model inputs

Tablica 3 / Table 3

OGÓLNE WŁAŚCIWOŚCI SIECI

GENERAL PROPERTIES OF THE NETWORK

Network Sieć	Learning algorithm Algorytm uczenia	The number of neurons in each layer Liczba neuronów w każdej warstwie			Activation function Funkcja aktywacji		Error function Funkcja błędu
		input wejściowa	hidden ukryta	output wyjściowa	hidden	output	
Feed-forward backpropagation Jednokierunkowa wielowarstwowa z wsteczną propagacją sygnału (błędu)	Levenberg- Marquardt	1	22	6	Purelin	TANSIG	Mean square error Średni błąd kwadratowy



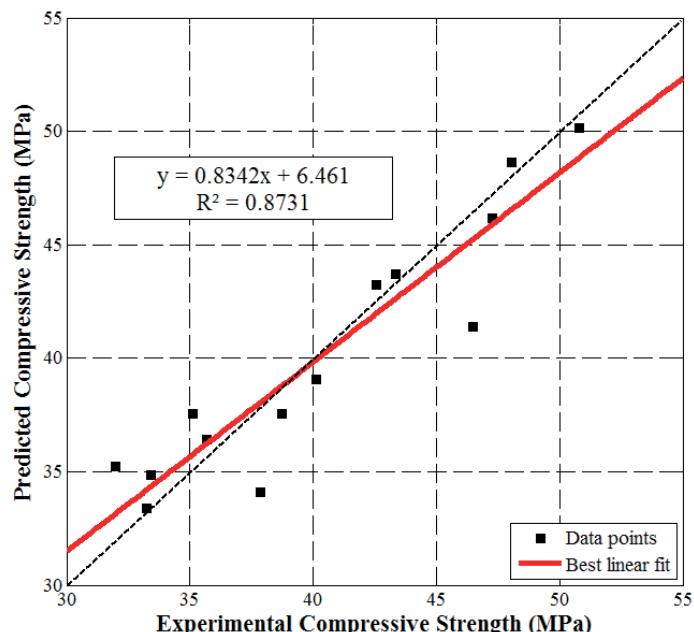
Rys. 4. Schematyczny obraz utworzonej sieci

Fig. 4. Schematic view of the built network

betonu natryskowego przy użyciu SVR. Dane wejściowe zawierają ilość cementu, wody, kruszywa drobnego i grubego oraz pyłu krzemionkowego, a także stosunek w/c. Dane wyjściowe obejmują wytrzymałość na ściskanie betonu natryskowego po 28 dniach. Radialną funkcję bazową jądra [RBF] zastosowano w modelowaniu metodą SVR. Program MATLAB [kody LS-SVM] użyto do budowy modelu. W oprogramowaniu LIBSVM parametry uczenia zawierające czynnik karzący C oraz odchylenie – szerokość RBF funkcji jądra g wyznaczono przez skanowanie danych, połączone ze sprawdzeniem krzyżowym. Wartości tych dwóch parametrów mają duży wpływ na wydajność uczenia i generalizację metody SVR (31). Na rysunku 6 pokazano liniową zależność między wartościami z pomiaru i z prognozowania. Uzyskany współczynnik korelacji liniowej 0,929 wskazuje na silną korelację między analizowanymi zmiennymi losowymi.

6.3. Porównanie wyników otrzymanych za pomocą obu modeli

Jak wyżej pokazano oba modele dają dobre wyniki w prognozowaniu wytrzymałości na ściskanie betonu natryskowego, zdolności do uczenia się przy zastosowaniu dostępnych próbek oraz zdolności do generalizacji działania. Stosując współczynnik korelacji R, średni bezwzględny błąd procentowy MAPE i pierwiastek błędu średniokwadratowego RMSE porównano oba modele. Statystyki zdefiniowane są równaniami [1], [2] i [3]. Porównanie wskaźników MAPE, RMSE i współczynnika korelacji R prognozowania



Rys. 5. Rzeczywista wytrzymałość na ściskanie wobec wartości prognozowanej przy wykorzystaniu modelu ANN

Fig. 5. Actual Compressive strength versus predicted Compressive strengths (in MPa) by ANN model

include the amount of cement, water, fine-coarse aggregates, micro-silica and water-cement ratio, while the output is the 28-day strength of shotcretes. Radial basis Kernel function, [RBF], was used in SVR modeling. MATLAB [LS-SVM codes] was used to develop the model. In LIBSVM software, learning parameters including the penalty factor C and the deviation – width of the RBF kernel function g were determined via a grid searching method coupled with cross-validation. The values of these two parameters highly affect the training and generalization capability of the SVR (31). Fig. 6 shows the linear relationship between the measured values and those predicted by the model. The obtained correlation coefficient, [0.929], implies that real values and predicted ones are close to each other.

6.3. Comparison of the results of both models

As mentioned above, both models showed a proper performance in predicting shotcrete strength, trainability via available samples and generalizability of behaviors. Using correlation coefficient, R,

jednoosiowej wytrzymałości na ściskanie (UCS) są zamieszczone w Tablicy 4. Dalszą analizę błędów predykcji można przeprowadzić w oparciu o wyniki pomiarów i obliczeń zawarte w tablicy 5, pokazującą błąd względny [RE] każdego modelu, we wszystkich czternastu przypadkach próbek testowych. Błąd względny obliczano stosując równanie [4].

$$R = \frac{\sum_{i=1}^N (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (T_i - \bar{T})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad [1]$$

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - P_i|}{T_i} \times 100 \quad [2]$$

$$RMSE(\%) = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - P_i)^2} \quad [3]$$

$$RE(\%) = \frac{P_i - T_i}{T_i} \times 100 \quad [4]$$

gdzie: \bar{P}_i , \bar{T}_i i N są wartościami zmierzonymi/ oczekiwanyymi, wartościami prognozowanymi, średnią z wartości oczekiwanych, średnią z wartości prognozowanych i liczbą próbek. Teoretycznie model prognostyczny jest oceniany jako doskonały, gdy MAPE, RMSE i RE są bliskie zera, podczas gdy współczynnik korelacji R jest bliski jedności (32). Dodatnie i ujemne wartości RE wskazują na przeszacowanie i niedoszacowanie wartości prognozowanych. Jednak z danych zwartych w Tablicy 4 wynika, że wydajności prognozowania przy stosowaniu ANN są nieco lepsze, w porównaniu z SVR. Jak widać z tablicy 5 obie metody prognozowania mają akceptowalną wydajność prognozowania. Maksymalne i minimalne błędy względne prognozowania przy zastosowaniu ANN wyniosły 10,92% oraz 0,47%. W przypadku SVR wynoszą one odpowiednio 11,75% i 0,20%. W przypadku betonu natryskowego jego jakość zależy od umiejętności operatorów, w przeciwieństwie do betonu układanego. A więc błąd modelowania jest akceptowalny i można stwierdzić, że obie inteligentne metody obliczeniowe można uznać za alternatywę kosztownych i czasochłonnych metod testowania.

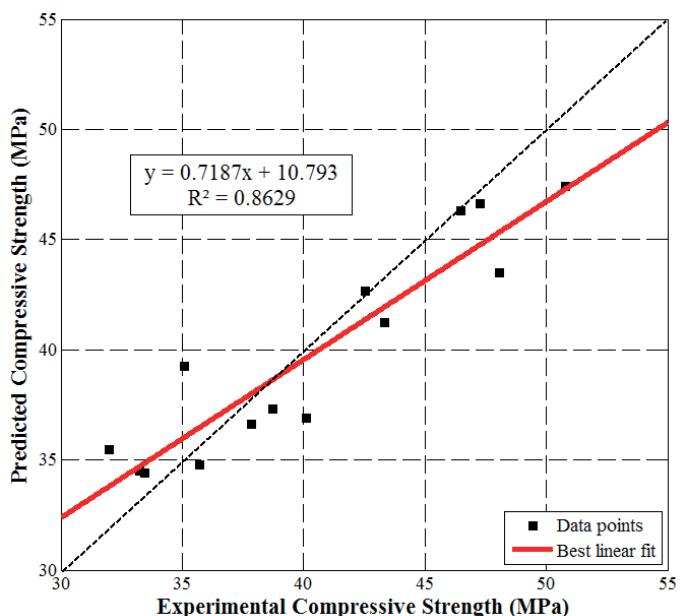
Ponadto do porównania wydajności różnych metod sporządzono wykresy pokazane na rysunku 7. Jeżeli istnieje doskonała korelacja pomiędzy wynikami obliczeniowymi i wynikami doświadczalnymi, to wszystkie punkty będą leżały na linii prostej nachylonej na wykresie pod kątem 45°. Marginesy klasyfikatora liniowego +10% i -10% są także pokazane na rysunku 7, w celu zobrazowania jakości prognozy. Rozkład błędu prognozowanego analizowanych modeli, wyrażonego za pomocą procentowej różnicy między wynikami obliczeń i doświadczeń, jest pokazany w tablicy 6.

Tablica 4 / Table 4

STATISTICAL PERFORMANCE OF MODELS

WARTOŚCI WYBRANYCH STATYSTYK MODELI

	NN	SVR
R	0.9344	0.929
MAPE (%)	4.1299	4.9965
RMSE	2.1434	2.4494



Rys. 6 . Rzeczywista wytrzymałość na ściskanie wobec wartości prognozowanej przy użyciu SVR

Fig. 6. Actual Compressive strength versus predicted Compressive strengths (in MPa) by SVR Model

and the Mean Absolute Percentage Error, MAPE, and Root Mean Square Error, RMSE, the above methods are compared with each other. The statistical parameters are derived from equations [1], [2] and [3]. The comparison of MAPE, RMSE indices and correlation coefficient [R] for predicting UCS can be seen in Table 4. Further analysis of the prediction errors can be obtained by examining Table 5, showing a summary statistics for the relative error (RE) of each model is reported for 14 testing samples. The relative error was calculated from the testing data using equation [4].

$$R = \frac{\sum_{i=1}^N (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (T_i - \bar{T})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad [1]$$

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - P_i|}{T_i} \times 100 \quad [2]$$

$$RMSE(\%) = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - P_i)^2} \quad [3]$$

$$RE(\%) = \frac{P_i - T_i}{T_i} \times 100 \quad [4]$$

where: \bar{P}_i , \bar{T}_i and N are target/measured values, predicted values, mean of target values, mean of predicted values and total number of input data. Theoretically, a predictive model is accepted as excellent when MAPE, RMSE and RE are the closest to zero, whereas for R are the closest to unity (32). Positive and negative signs for RE are indications of, respectively, overestimation and underestimation of the predicted value.

According to the table 4, these indices revealed that prediction performances of the ANN model are slightly higher than SVR, however, as seen in this Table, both models have acceptable

Tablica 5 / Table 5

OCENA WYNIKÓW PREDYKCJI WYKONANEJ PRZY ZASTOSOWANIU ANN I SVM DLA DANYCH TESTOWYCH

EVALUATION OF THE PREDICTED VALUES OBTAINED BY SVM AND ANN MODELS FOR TESTING RECORDS

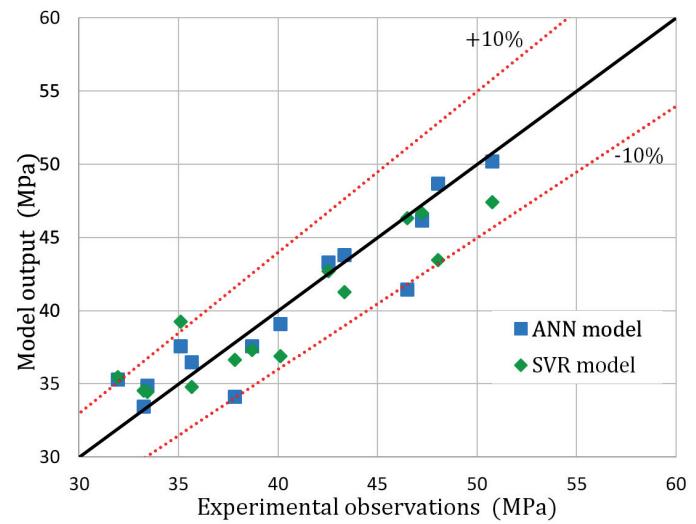
Sample Próbka No	Measured value Wartość zmierzona	ANN			SVR		
		Predicted value Wartość prognozy	Error Błąd	Relative error Błąd względny	Predicted value Wartość prognozy	Error Błąd	Relative error Błąd względny
1	46.48	41.41	-5.08	-10.92	46.30	-0.18	-0.39
6	43.35	43.73	0.38	0.88	41.25	-2.10	-4.84
7	48.05	48.61	0.56	1.16	43.47	-4.58	-9.54
14	50.80	50.12	-0.67	-1.33	47.39	-3.41	-6.71
19	47.27	46.16	-1.10	-2.33	46.61	-0.66	-1.40
30	33.44	34.86	1.42	4.24	34.41	0.97	2.89
33	31.97	35.24	3.27	10.22	35.48	3.51	10.98
37	35.70	36.42	0.73	2.04	34.78	-0.92	-2.57
38	40.11	39.05	-1.06	-2.64	36.91	-3.20	-7.99
40	42.56	43.24	0.68	1.60	42.64	0.08	0.20
46	33.24	33.40	0.16	0.47	34.51	1.26	3.79
51	38.74	37.56	-1.17	-3.03	37.31	-1.42	-3.67
53	35.11	37.57	2.47	7.02	39.23	4.13	11.75
57	37.85	34.09	-3.76	-9.94	36.63	-1.23	-3.24

Zarówno z rysunku 7 jak i z tablicy 6 wynika skuteczność proponowanych modeli do prognozowania wytrzymałości na ściskanie, osiągnięta za pomocą zastosowanego zbioru danych, gdyż większość punktów leży wewnątrz $\pm 10\%$ marginesu doskonałej zgodności. Właściwie ponad 85% wyników obliczeniowych otrzymanych przy zastosowaniu obu modeli znajduje się wewnątrz $\pm 10\%$ zakresu wyników doświadczalnych.

Na podstawie wartości wszystkich przytoczonych wyżej statystyk można stwierdzić, że oba proponowane modele są odpowiednie i prognożują wartości wytrzymałości na ściskanie bardzo bliskie wartościom doświadczalnym. Biorąc pod uwagę właściwości inteligentnych metod obliczeniowych należy zauważyć, że jakakolwiek zmiana w warunkach lub materiałach może mieć negatywny wpływ na wydajność sieci. Ponadto można dowieść, że w procesie uczenia takich modeli im większa jest liczba danych

prediction performance. As seen in Table 5, for the ANN method, the max and min absolute errors found were 10.92% and 0.47%, respectively. For the SVR method, the max and min absolute errors found were 11.75% and 0.20%, respectively. Unlike concrete, working with shotcrete depends on operators' skill. So, modeling error is acceptable and it can be argued that both intelligent methods can be regarded as a suitable alternative for costly and time-consuming test methods.

Moreover, to compare the performance of different approaches, graphs between actual and predicted strength are plotted in Fig. 7. If there is perfect agreement between the model and experimental results, all the points will lie along the 45 line. Error lines of $\pm 10\%$



Rys. 7. Porównanie wartości prognozowanych wytrzymałości na ściskanie wobec danych doświadczalnych dla proponowanych modeli prognozowania.

Fig. 7. Comparison of predicted values of compressive strength versus experimental data for proposed models.

Tablica 6 / Table 6

ROZKŁAD BŁĘDÓW RÓŻNYCH MODELI WYTRZYMAŁOŚCI NA ŚCIASKANIE WZGLĘDEM WYNIKÓW DOŚWIADCZALNYCH.

DISTRIBUTION OF ERRORS FOR DIFFERENT STRENGTH MODELS RELATIVE TO EXPERIMENTAL VALUES

Range of error Zakres błędu (%)	Percentage of testing data in the range for models	
	Procent danych testowych w zakresie błędu dla modeli (%)	
	ANN	SVR
± 1	14.3	14.3
± 5	64.3	71.4
± 10	85.7	85.7
± 15	100	100

i im większe ich rozproszenie, tym bliższe rzeczywistych będą wartości prognozowane.

7. Wnioski

W artykule pokazano zastosowanie sztucznych sieci neuronowych oraz regresji wektorów wspierających do prognozowania wytrzymałości na ściskanie betonu natryskowego. W modelu z zastosowaniem sieci neuronowych wprowadzono sieć jednokierunkową, z algorytmem wstępnej propagacji sygnału. Sieć ta zawierała jedną ukrytą warstwę składającą się z 11 neuronów. Model SVR zbudowano przy wykorzystaniu jądra RBF. Oba modele uczone wykorzystując pewną liczbę danych wejściowych i wyjściowych, otrzymanych z badań laboratoryjnych. Następnie prognozowano wytrzymałość na ściskanie betonu natryskowego po 28 dniach zakładając tylko dane wejściowe. Wartości prognozowane okazały się bardzo bliskie wartościom doświadczalnym. Na podstawie zbiorów danych testowych obliczono wartości R, MAPE i RMSE wynoszące odpowiednio 0,9344, 4,13 and 2,14 dla ANN. Natomiast dla modelu SVR wartości te wynosiły odpowiednio 0,929, 5,00 i 2,45. Równocześnie więcej niż 85% prognozowanych wartości znalazło się wewnątrz $\pm 10\%$ zakresu błędu danych uzyskanych doświadczalnie. Otrzymane wyniki pokazują, że obie inteligentne metody obliczeniowe mogą być stosowane z dużą dokładnością do prognozowania wytrzymałości na ściskanie. Stąd wytrzymałość na ściskanie betonu natryskowego po 28 dniach można prognozować w krótkim czasie z niewielkim błędem, przy wykorzystaniu modeli ANN i SVR. Zatem można dojść do wniosku, że te inteligentne metody obliczeniowe są wiernymi metodami modelowania, o wysokim stopniu dokładności i stabilności, w zakresie prognozowania właściwości materiałów.

Literatura / References

1. S. Prusek, M. Rotkegel, Ł. Małecki, Laboratory tests and numerical modelling of strength-deformation parameters of a shotcrete lining. *Engineering Structures* **75**, 353-362 (2014).
2. D.-G. Kim, G.-P. Lee, G.-J. Bae, Compressive and adhesive strengths of shotcrete deteriorated by hazardous components in the groundwater. *Tunnelling and Underground Space Technology* **21**, 323 (2006).
3. A. Hubáček, J. Brožovský, R. Hela, Comparison of Properties of Shotcrete Tested Using Destructive and Non-destructive Methods. *Procedia Engineering* **65**, 63-68 (2013).
4. F. Khademi, M. Akbari, S. M. Jamal, M. Nikoo, Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete. *Frontiers of Structural and Civil Engineering* **11**, 90-99 (2017).
5. S. Tsivilis, G. Parissakis, A mathematical model for the prediction of cement strength. *Cement and Concrete Research* **25**, 9-14 (1995).
6. M. F. M. Zain, S. M. Abd, Multiple regression model for compressive strength prediction of high performance concrete. *Journal of applied sciences* **9**, 155-160 (2009).
7. U. Atici, Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network. *Expert Systems with Applications* **38**, 9609-9618 (2011).

and -10% are also plotted to visualize the prediction performances. The error distribution of the models, in terms of the percentage difference between simulated and experimental results, is summarized in Table 6.

From both Fig. 7 and Table 6, results suggest the effectiveness of proposed models in predicting compressive strength with this dataset as most of the points are lying within $\pm 10\%$ of the line of perfect agreement. Actually, more than 85% of the simulated results are within $\pm 10\%$ of the experimental values for both models.

All of the statistical values demonstrate that both proposed ANN and SVR models are suitable and predict the compressive strength values very close to experimental values. However, it should be noted that considering the characteristics of intelligent methods, any change in conditions or materials can negatively affect the performance of the networks. Also, it is arguable that in the process of training such models, the larger the number of data and the higher the data dispersion, the closer to reality the model will be.

7. Conclusion

This paper used neural network and SVR intelligent methods to predict the 28-day compressive strength of shotcretes. Feed-Forward network with back-propagation algorithm was used in neural network model. This network had a hidden layer with 11 neurons. SVR model was built using RBF Kernel. Both models were trained using a number of laboratory data as input and output data. Then, only giving the input data, the 28-day compressive strength of shotcretes was predicted by the models. The predicted values were very close to test results. Based on testing datasets, the R, MAPE, and RMSE values were obtained as 0.9344, 4.13 and 2.14 for the ANN, respectively, whereas these values were obtained as 0.929, 5, and 2.45 for SVR model. On the other hand, more than 85% of the simulated results were within $\pm 10\%$ of the experimental values for proposed models. The obtained results reveal that both intelligent methods can predict compressive strength with a high level of accuracy. Therefore, the 28-day compressive strength of shotcretes could be predicted at a short time and with a low error using ANN and SVR models. Consequently, it may conclude that these intelligent methods are reliable modeling techniques for predicting material properties with a highly acceptable degree of accuracy and robustness.

8. F. Khademi, S. M. Jamal, Estimating the compressive strength of concrete using multiple linear regression and adaptive neuro-fuzzy inference system. *International Journal of Structural Engineering* **8**, 20-31 (2017).
9. A. Öztaş *et al.*, Predicting the compressive strength and slump of high strength concrete using neural network. *Construction and Building Materials* **20**, 769-775 (2006).
10. A. Nazari, Computer-aided prediction of physical and mechanical properties of high strength concrete containing Fe₂O₃ nanoparticles. *Cement Wapno Beton* **79**, 265-285 (2012).
11. S. Kostić, D. Vasović, Prediction model for compressive strength of basic concrete mixture using artificial neural networks. *Neural Comput & Applic* **26**, 1005-1024 (2015).
12. T. K. Erdem, G. Tayfur, Ö. Kirca, Experimental and modeling study of strength of high strength concrete containing binary and ternary binders. *Cement Wapno Beton* **78**, 224-237 (2011).
13. E. Ozgan, Artificial neural network based modelling of the Marshall Stability of asphalt concrete. *Expert Systems with Applications* **38**, 6025-6030 (2011).
14. F. F. Martins, A. Camões, Prediction of compressive strength of concrete containing fly ash using data mining techniques. *Cement Wapno Beton* **80**, 39-51 (2013).
15. E. Akbari *et al.*, Analytical modeling and simulation of I-V characteristics in carbon nanotube based gas sensors using ANN and SVR methods. *Chemometrics and Intelligent Laboratory Systems* **137**, 173-180 (2014).
16. H.-G. Ni, J.-Z. Wang, Prediction of compressive strength of concrete by neural networks. *Cement and Concrete Research* **30**, 1245-1250 (2000).
17. J. Sobhani, M. Najimi, A. R. Pourkhorshidi, T. Parhizkar, Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models. *Construction and Building Materials* **24**, 709-718 (2010).
18. H. M. Elsanadedy, Y. A. Al-Salloum, H. Abbas, S. H. Alsayed, Prediction of strength parameters of FRP-confined concrete. *Composites Part B: Engineering* **43**, 228-239 (2012).
19. V. N. Vapnik, An overview of statistical learning theory. *IEEE transactions on neural networks* **10**, 988-999 (1999).
20. J.-S. Chou, C.-F. Tsai, Concrete compressive strength analysis using a combined classification and regression technique. *Automation in Construction* **24**, 52-60 (2012).
21. J. Sobhani, M. Khanzadi, A. Movahedian, Support vector machine for prediction of the compressive strength of no-slump concrete. *Computers and Concrete* **11**, 337-350 (2013).
22. S. Xu-chao, D. Yi-feng, Support vector machine applied to prediction strength of cement. In: *2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce (AIMSEC)*, 1585-1588, IEEE, 2011.
23. P. Yuvaraj, A. Ramachandra Murthy, N. R. Iyer, S. K. Sekar, P. Samui, Support vector regression based models to predict fracture characteristics of high strength and ultra high strength concrete beams. *Engineering Fracture Mechanics* **98**, 29-43 (2013).
24. H. Kalhori, R. Bagherpour, Application of carbonate precipitating bacteria for improving properties and repairing cracks of shotcrete. *Construction and Building Materials* **148**, 249-260 (2017).
25. S. Chithra, S. R. R. S. Kumar, K. Chinnaraju, F. Alfin Ashmita, A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. *Construction and Building Materials*, **114**, 528-535 (2016).
26. R. Beale, T. Jackson, *Neural Computing - An Introduction*. CRC Press, 1990.
27. L. V. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice-Hall international editions, 1994.
28. M. Saridemir, Predicting the compressive strength of mortars containing metakaolin by artificial neural networks and fuzzy logic, *Advances in Engineering Software*, **40**, 920-927 (2009).
29. V. N. Vapnik, *Statistical learning theory*. John Wiley and Sons, New York, 1998.
30. C. Cortes, V. Vapnik, Support-vector networks. *Mach Learn*, **20**, 273-297 (1995).
31. C.-C. Chang, C.-J. Lin, LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, **2**, 27 (2011).
32. E. Ghasemi, H. Kalhori, R. Bagherpour, A new hybrid ANFIS-PSO model for prediction of peak particle velocity due to bench blasting., *Engineering with Computers*, **32**, 607-614 (2016).