

Ali Nazari

Department of Materials Science, Saveh Branch, Islamic Azad University, Saveh, Iran

Wspomagane komputerowo prognozowanie fizycznych właściwości betonu o wysokiej wytrzymałości, zawierającego nano-cząstki Fe_2O_3

Computer-aided prediction of physical and mechanical properties of high strength concrete containing Fe_2O_3 nanoparticles

1. Wprowadzenie

Wytrzymałość jest najważniejszą właściwością fizyczną betonu, którą mierzy się zwykle po normowym czasie dojrzewania. Wytrzymałość betonu zależy od szeregu czynników, a mianowicie składników betonu, wieku, stosunku w/c i wielu innych. Struktura porowatości określa właściwości transportowe zaczynu cementowego, to jest przepuszczalność i migrację jonów. Przepuszczalność zaczynu cementowego jest podstawową właściwością z punktu widzenia trwałości betonu: przedstawia ona łatwość, z którą woda lub inne ciecze mogą migrować przez beton, transportując tą drogą składniki agresywne. Ogromne znaczenie mają badania ilościowej zależności przepuszczalności od struktury porów. Począwszy od doświadczeń aż do symulacji numerycznej struktury porów i przepuszczalności kompozytów opartych na cemencie można dojść do lepszego poznania zjawisk transportowych, którym towarzyszą mechanizmy niszczenia betonu (1).

Konwencjonalne metody przewidywania różnych właściwości betonu są zwykle oparte albo na ich zależności od stosunku w/c albo na koncepcji okresu dojrzewania tego kompozytu. W ostatnich dwóch dekadach popularne stały się różne metody modelowania oparte na sieciach neuronowych (SN) i są one stosowane przez licznych badaczy do szerokiego zakresu zastosowań inżynierskich. SN mają budowę warstwową i mogą rozwiązywać trudne zagadnienia dzięki wzajemnemu prostych elementów liczących ze sztucznymi neuronami.

1. Introduction

Strength assessment of concrete is a main and probably the most important mechanical property, which is usually measured after a standard curing time. Concrete strength is influenced by lots of factors like concrete ingredients, age, ratio of water to cementitious materials, etc. The pore structure determines the transport properties of cement paste, such as permeability and ion migration. Permeability of cement paste is a fundamental property in view of the durability of concrete: it represents the ease with which water or other fluids can move through concrete, thereby transporting aggressive agents. It is therefore of utmost importance to investigate the quantitative relationships between the pore structure and the permeability. Through experimental studies and then numerical simulations of the pore structure and the permeability of cement-based materials, a better understanding of transport phenomena and associated degradation mechanisms will hopefully be reached (1).

Conventional methods of predicting various properties of concrete are generally based on either water to cement ratio rule or maturity concept of concrete (2). Over the last two decades, a different modeling method based on neural networks (NNs) has become popular and used by many researchers for a wide range of engineering applications. NNs are a family of massively parallel architectures that solve difficult problems via the cooperation of

W zasadzie elementy procesowe są analogiczne do neuronów mózgu, które składają się z wielu prostych elementów liczących, ułożonych w szeregu warstwach (3). Właściwości betonu można obliczyć stosując modele oparte na SN. Stosowanie tych modeli w doświadczeniach numerycznych pozwala na wygodną ocenę wpływu każdej zmiennej na skład mieszanki (4-6). Oprócz sztucznych sieci neuronowych (SSN) zaczęto wprowadzać ostatnio algorytmy genetyczne w celu opisanie właściwości eksploatacyjnych betonu w formie wzorów (7, 8).

Algorytmy genetyczne (AG) mają wiele zalet w porównaniu do klasycznych metod regresyjnych. Metody regresyjne często opierają się na z góry przyjętych funkcjach, których analizy regresyjne są przeprowadzane później. Z drugiej strony w przypadku zastosowania AG nie ma z góry przyjętej funkcji, którą się ocenia. W tym sensie AG mają przewagę nad analizą regresji i sieciami neuronowymi. Udowodniono, że AG jest skutecznym narzędziem w modelowaniu i opisywaniu za pomocą wzorów wyników doświadczalnych obejmujących wielowariantowe parametry, w przypadku których nie ma opracowanych modeli analitycznych (7, 8).

Celem niniejszych badań jest przewidywanie wytrzymałości na zginanie i wchłanianie wody w przypadku szeregu rodzajów betonu bez i z dodatkiem nanocząstek Fe_2O_3 za pomocą SSN i AG. Zbiór obejmujący wyniki 144 pomiarów wytrzymałości na zginanie i 144 oznaczeń wchłaniania wody obejmujących 16 betonów o różnym składzie, został oceniony za pomocą różnych modeli. Otrzymane wyniki porównano z doświadczalnymi w celu oceny możliwości programów zastosowanych do przewidywania właściwości betonu.

2. Materiały i metody

2.1. Materiały

Przygotowano w laboratorium dwie serie betonów. Pierwsza obejmowała wibrowane betony (WB) złożone z rzecznoego piasku i bazaltu jako kruszywa, a druga była betonem samozagęszczającym się (BSZ), z kruszywem wapiennym. Zastosowano następujące


highly interconnected but simple computing elements (or artificial neurons). Basically, the processing elements of a neural network are analogous to the neurons in the brain, which consist of many simple computational elements arranged in several layers (3). The concrete properties could be calculated using the models built with NNs. It is convenient to use these models for numerical experiments to review the effects of each variable on the mix proportions (4-6). Besides ANNs, genetic programming (GP) has begun to arise for the explicit formulation of the properties and the performances of concrete recently (7, 8). Genetic programming offers many advantages as compared to classical regression techniques. Regression techniques are often based on predefined functions where regression analyses of these functions are later performed. On the other hand, in the case of GP approach, there is no predefined function to be considered. In this sense, GP can be accepted to be superior to regression techniques and neural networks. GP has proven to be an effective tool to model and obtain explicit formulations of experimental studies including multivariate parameters where there are no existing analytical models (7, 8).

The aim of this study is to predict flexural strength and percentage of water absorption of several types of concrete with and without Fe_2O_3 nanoparticles by ANNs and GP. Totally 144 flexural strength and 144 percentages of water absorption data from 16 different concrete mixtures were collected, trained and tested by means of different models. The obtained results have been compared by experimental ones to evaluate the software power for predicting the properties of concrete.

2. Experimental procedure


2.1. Materials

Two series of concrete were made in the laboratory. The first was normally vibrated concrete (NVC) series with ordinary river sand as fine aggregates and the second self compacting concrete (SCC) series with limestone aggregates. The utilized materials are as below:



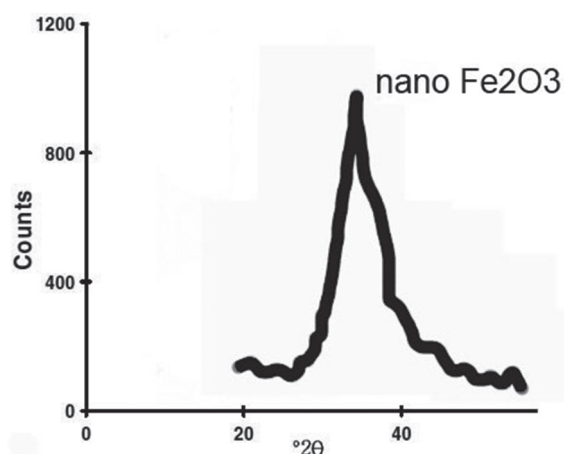
Rys. 1. Krzywa ziarnowa cement portlandzkiego

Fig. 1. Particles distribution pattern of ordinary Portland cement



Rys. 2. Obraz nanocząstek Fe₂O₃ pod elektronowym mikroskopem skaningowym

Fig. 2. SEM micrograph of Fe₂O₃ nanoparticles



Rys. 3. Dyfraktogram nanocząstek Fe₂O₃

Fig. 3. XRD analysis of Fe₂O₃ nanoparticles

Tablica 1 / Table 1

CHEMICAL OF PORTLAND CEMENT, MASS %

SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	SO ₃	Na ₂ O	K ₂ O	Strata prażenia Loss on ignition
21.89	5.3	3.34	53.27	6.45	3.67	0.18	0.98	3.21

Tablica 2 / Table 2

THE PROPERTIES OF NANO- Fe₂O₃

Diameter, nm	Specific surface area, m ² /g	Density, g/cm ³	Fe ₂ O ₃ , %
15 ± 3	155 ± 12	< 0.13	>99.9

materiały: przemysłowy cement portlandzki zgodny z normą ASTM C150 (9). Jego skład chemiczny podano w tablicy 1, a krzywą ziarnową pokazano na rysunku 1.

Nanocząstki Fe₂O₃ zostały dostarczone przez Suzhou Fuer Import & Export Trade Co. Ltd., średni wymiar cząstek wynosił 15 nm a powierzchnia Blaine'a 45 m²/g. Ich właściwości podano w tablicy 2, obraz z elektronowego mikroskopu skaningowego na rysunku 2, a wycinek rentgenogramu na rysunku 3. W przypadku betonów WB jako kruszywo drobne stosowano piasek rzeczny złożony z ziarn mniejszych od 0,5 mm, o module rozdrobnienia 2,25 i gęstości 2,58 g/cm³. Kruszywo grube stanowił kruszony bazalt o maksymalnym ziarnie 15 mm i gęstości 2,96 g/cm³.

Beton samozagęszczający się przygotowano z kruszonego wapienia i kruszywa otoczkowego 4/12 i dwóch rodzajów piasku: grubego 0/4, stosowanego jako kruszywo drobne oraz drobnego 0/2, z bardzo dużą zawartością małych cząstek (ich wymiar < 0,063 mm) wynoszącą 19,2%, których główną funkcją było wprowadzenie większej objętości miążkiego materiału w celu poprawy stabilności świeżego betonu. Domieszkę stanowił polikarboksylan z dodatkiem kondensatu polietylenowego, jako dodatek przeciwpieniący (Glenium C303). W tablicy 3 podano niektóre właściwości fizyczne i chemiczne stosowanej domieszki polikarboksylanowej.

Ordinary Portland Cement (OPC) conforming to ASTM C150 (9) standard was used as received. The chemical and physical properties of this cement are shown in Table 1. The particle size distribution pattern of the used OPC has been presented in Fig. 1.

Fe₂O₃ nanoparticles with average particle size of 15 nm and 45 m²/g Blaine fineness producing from Suzhou Fuer Import & Export Trade Co., Ltd was used as received. The properties of Fe₂O₃ nanoparticles are shown in Table 2. Scanning electron micrographs (SEM) and powder X-ray diffraction (XRD) diagrams of Fe₂O₃ nanoparticles are shown in Figs. 2 and 3.

Locally available natural sand with particles smaller than 0.5 mm and fineness modulus of 2.25 and specific gravity of 2.58 g/cm³ was used as fine aggregate for NVC series concrete. Crushed basalt stored in the laboratory with maximum size of 15 mm and specific gravity of 2.96 g/cm³ was used as coarse aggregate in NVC series concrete.

Tablica 3 / Table 3

PHYSICAL AND CHEMICAL CHARACTERISTICS OF THE POLYCARBOXYLATE ADMIXTURE

Appearance	Yellow-brown liquid
% solid residue	Approximately 36%
pH	5.2-5.3
Specific gravity (kg/l)	Approximately 1.06
Rotational Viscosity (MPa)	79.30
% C	52.25
ppm Na ⁺	9150
ppm K ⁺	158

2.2. Skład betonów

Przygotowano 6 serii mieszanek (Tablica 4). Mieszanki CO były próbkami kontrolnymi. Przygotowano je z naturalnych kruszyw, cementu i wody. Betony CO dojrzewały w wodzie (W) oraz w wodzie wapiennej (WW) i były oznaczone odpowiednio CO-W i CO-WW. Mieszanki serii N zawierały różny dodatek nanocząstek Fe_2O_3 . Zastępowały on cement w ilości 0,5; 1,0; 1,5 i 2,0% mas. Beton serii N także dojrzewał w wodzie i w wodzie wapiennej; próbki były oznaczone odpowiednio N-W i N-WW.

CO-BSZ przygotowano z cementu, kruszywa drobnego i ultra-drobnego wapienia, którego udział wynosił 19,2% mas. oraz domieszki polikarboksyłanowej, w ilości 0,4% mas. w stosunku do cementu. Seria N-BSZ zawierała różny odsetek nanocząstek Fe_2O_3 , które zastępowały cement w ilości od 1 do 5% mas. oraz zawierała 0,4% mas. tej samej domieszki. Stosunek wody do cementu był we wszystkich betonach taki sam i wynosił 0,40. Także zawartość spoiwa była taka sama i wynosiła 450 kg/m³. Skład wszystkich mieszanek podano w tablicy 4.

2.3. Metody

Do badań betonów w serii WB przygotowano beleczki o wymiarach 200 x 50 x 50 mm, a mieszanki umieszczano w formach, w dwóch warstwach, każdą z nich zagęszczając na stoliku wstrząsowym przez 10 s. Serię mieszanek BSZ przygotowano bez zagęszczania. Formy z mieszanką przykrywano folią polipropylenową i przechowywano w wilgotnej komorze przez 24 h. Następnie próbki rozformowywano i podzielono na dwie partie, z których jedna dojrzewała w wodzie, a druga w wodzie wapiennej, obie w temperaturze 20°C.

Wytrzymałość na zginanie oznaczano zgodnie z normą ASTM Tablica 4 / Table 4

COMPOSITION OF CONCRETE*

Sample designation	Fe_2O_3 nanoparticles, %	PC content, % of water	Quantities, kg/m ³			
			Cement	Fe_2O_3 nanoparticles	Fine aggregate, kg/m ³	Coarse aggregate, kg/m ³
C0-W	0	0	450.00	0.00	492	1148
N1-W	0.5	0	447.75	2.25	492	1148
N2-W	1.0	0	445.50	4.50	492	1148
N3-W	1.5	0	443.25	6.75	492	1148
N4-W	2.0	0	441.00	9.00	492	1148
C0-LW	0	0	450.00	0.00	492	1148
N1-LW	0.5	0	447.75	2.25	492	1148
N2-LW	1.0	0	445.50	4.50	492	1148
N3-LW	1.5	0	443.25	6.75	492	1148
N4-LW	2.0	0	441.00	9.00	492	1148
C0-SCC1	0	1.0	450	0	456	1092
N1-SCC1	1	1.0	445.5	4.5	456	1092
N2-SCC1	2	1.0	441.0	9.0	456	1092
N3-SCC1	3	1.0	437.5	13.5	456	1092
N4-SCC1	4	1.0	432.0	18.0	456	1092
N5-SCC1	5	1.0	427.5	22.5	456	1092

*Remark: constant water to binder [cement + nano- Fe_2O_3] ratio equal 0.40

Crushed limestone aggregates were used to produce self-compacting concretes, with gravel 4/12 and two types of sand: one coarse 0/4, for fine aggregates and the other fine 0/2, with a very high fines content (particle size < 0.063 mm) of 19.2%, the main function of which was to provide a greater volume of fine materials to improve the stability of the fresh concrete. A polycarboxylate with a polyethylene condensate defoamed based admixture (Glenium C303 SCC) was used. Table 3 shows some of the physical and chemical properties of polycarboxylate admixture used in this study.

2.2. Mixture proportions

Totally 6 series of mixtures were prepared and tested experimentally (Table 4). C0 series mixtures were prepared as control specimens. The control concretes were made of natural aggregates, cement and water. C0 series concretes were cured in water (W) and saturated limewater (LW) and designated as C0-W and C0-LW series, respectively. N series were prepared with different contents of Fe_2O_3 nanoparticles. The mixtures were prepared by the cement replacement of 0.5, 1.0, 1.5 and 2.0 mass percent. N series concretes were also cured in water (W) and saturated limewater (LW) and designated as N-W and N-LW series, respectively. C0-SCC series mixtures were prepared from cement, fine and ultra-fine crushed limestone aggregates with 19.2% by mass of ultra-fine ones and 0.4 mass percent of polycarboxylate admixture in relation to cement. N-SCC series were prepared with different contents of Fe_2O_3 nanoparticles. The mixtures were prepared with the cement replacement by Fe_2O_3 nanoparticles from 1 to 5 mass percent and 0.4 mass percent polycarboxylate admixture. The water to binder ratio for all mixtures was set at 0.40. The binder content of all mixtures was 450 kg/m³. The proportions of the mixtures are presented in Table 4.

C293 (10), przy czym próbki WB zginano po 7, 28 i 90 dniach, a BSZ po 2, 28 i 90 dniach.

Pomiary przepuszczalności wykonuje się różnymi metodami. W tej pracy wybrano nasiąkliwość wodą do oceny przepuszczalności próbek. Do tych pomiarów zastosowano metodę opisaną w normie ASTM C642 (11), zastosowaną po określonych czasach dojrzewania.

3. Wyniki doświadczeń

Wyniki pomiarów wytrzymałości na zginanie podano w tablicy 5. Wynika z nich, że wytrzymałość ta wzrasta z dodatkiem nano-Fe₂O₃ aż do 1%, w przypadku próbek serii NCV (oznaczonych N-W). Natomiast dodatek 2% nano-Fe₂O₃ zmniejsza wytrzymałość do poziomu bliskiego próbce kontrolnej. Korzystny wpływ nano-Fe₂O₃ może być spowodowany poprawą struktury porów w betonie, tak jak to zostało wykazane w jednej z wcześniejszych prac (12). Nano-cząstki Fe mogą także odgrywać rolę zarodków heterogenicznych w odniesieniu do fazy C-S-H. Powoduje to przyspieszenie hydratacji cementu i szybszy wzrost wytrzymałości.

Nano-Fe₂O₃ mogą bowiem powodować wypełnienie porów kapilarnych i zwiększenie zwięzłości mikrostruktury betonu.

Natomiast w przypadku próbek przechowywanych w wodzie wapiennej także dodatek 2% masowych nanocząstek Fe₂O₃ powoduje wzrost wytrzymałości na zginanie. Wyjaśnienie przyczyn pozytywnego wpływu dojrzewania próbek betonu w wodzie wapiennej wymaga dalszych badań. Nie można jednak wykluczyć, że ten korzystny wpływ wiąże się z ograniczeniem karbonatyzacji próbek betonu w wodzie wapiennej pod wpływem CO₂ z powietrza. W tablicy 7 pokazano także wyniki badań nasiąkliwości wody w obu seriach próbek betonu, CO i N. Wyniki te wskazują na podobny wpływ nano-Fe₂O₃ jak na wytrzymałość na zginanie.

W tablicy 7 podano wytrzymałość na zginanie próbek CO-BSZ i N-BSZ po 2, 7 i 28 dniach dojrzewania. Wyniki te pokazują, że wytrzymałość na zginanie wzrasta z dodatkiem nano-cząstek Fe₂O₃ zastępujących cement, aż do 4% masowych (seria N4-BSZ). Przy większym dodatku wytrzymałość maleje, jednak nawet dodatek

Tablica 5 / Table 5

WARTOŚCI PARAMETRÓW UŻYTYCH W MODELU SIECI NEURONOWEJ
THE VALUES OF PARAMETERS USED IN NEURAL NETWORK MODEL

Parametry / Parameters	Sieć neuronowa ANN
Liczba neuronów w warstwie wejściowej / umber of input layer units	8
Liczba warstw ukrytych / Number of hidden layer	2
Liczba neuronów w pierwszej warstwie ukrytej / Number of first hidden layer units	10
Liczba neuronów w drugiej warstwie ukrytej / Number of second hidden layer units	8
Liczba neuronów w warstwie wyjściowej / Number of output layer units	1
Współczynnik momentum / Momentum rate	0.88
Współczynnik uczenia się / Learning rate	0.70
Błąd po uczeniu się / Error after learning	0.000050
Cykl uczenia się / Learning cycle	30.000

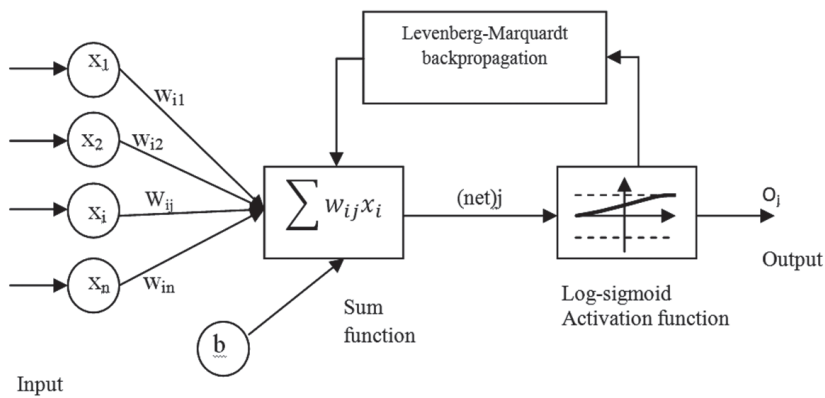
2.3. Test procedure

For NVC series concrete, bars 200 mm × 50 mm × 50 mm were cast and compacted in two layers on a jointing table, where each layer was vibrated for 10 s. SCC series mixtures were prepared without vibration. The moulds were covered with polyethylene sheets and moistened for 24 h. Then the specimens were demolded and cured in water and saturated limewater at a temperature of 20°C prior to test days. Flexural tests were carried out according to the ASTM C 293 (10) standard. After the specified curing period was over (7, 28 and 90 days for NVC series and 2, 28 and 90 days for SCC series), the concrete cubes were subjected to flexural test by using universal testing machine. For each period three samples were tested. Water permeability tests are performed with several methods. In this work, percentage of water absorption has been selected to evaluate the water permeability of the specimens. Water absorption of samples were measured as per ASTM C 642 (11), after specified curing time. For each period three samples were tested.

3. Experimental results

The flexural strength results of the specimens are shown in Table 5. The results show that the flexural strength increases with nano-Fe₂O₃ particles addition up to 1.0% in N-CV (designed N-W) series. It is shown that 2.0% Fe₂O₃ nanoparticles decreases the flexural strength to the level which is near to the control concrete. The effectiveness of nano-Fe₂O₃ can be caused by improving of the pore structure of concrete as it was shown in our earlier work (12). As a consequence, the rate of strength increase is faster. Also nano-Fe₂O₃ particles can increase the packing density of cement matrix, causing the reduction of larger pores. On the other hand, for the specimens cured in limewater, the flexural strength is increasing for 2.0 % mass of Fe₂O₃ nanoparticles addition. The influence of this curing condition must be taken into consideration, especially the eliminating the negative effect of carbonation of cement matrix by CO₂ from the air. The explanation of these advantageous effect of lime water curing needs further studies. Table 7 also shows the percentage of water absorption in C0 and N series concrete. The results indicate similar correlation with flexural strength.

Table 7 also shows the flexural strength of C0-SCC and N-SCC specimens after 2, 7 and 28 days of curing. The results show that the flexural strength increases with the addition of Fe₂O₃ nanoparticles up to 4.0 mass percent replacements (N4-SCC series) and then it decreases, although even the addition of 5.0 percent Fe₂O₃ nanoparticles produces specimens with much higher flexural strength with respect to C0-SCC and N-SCC specimens



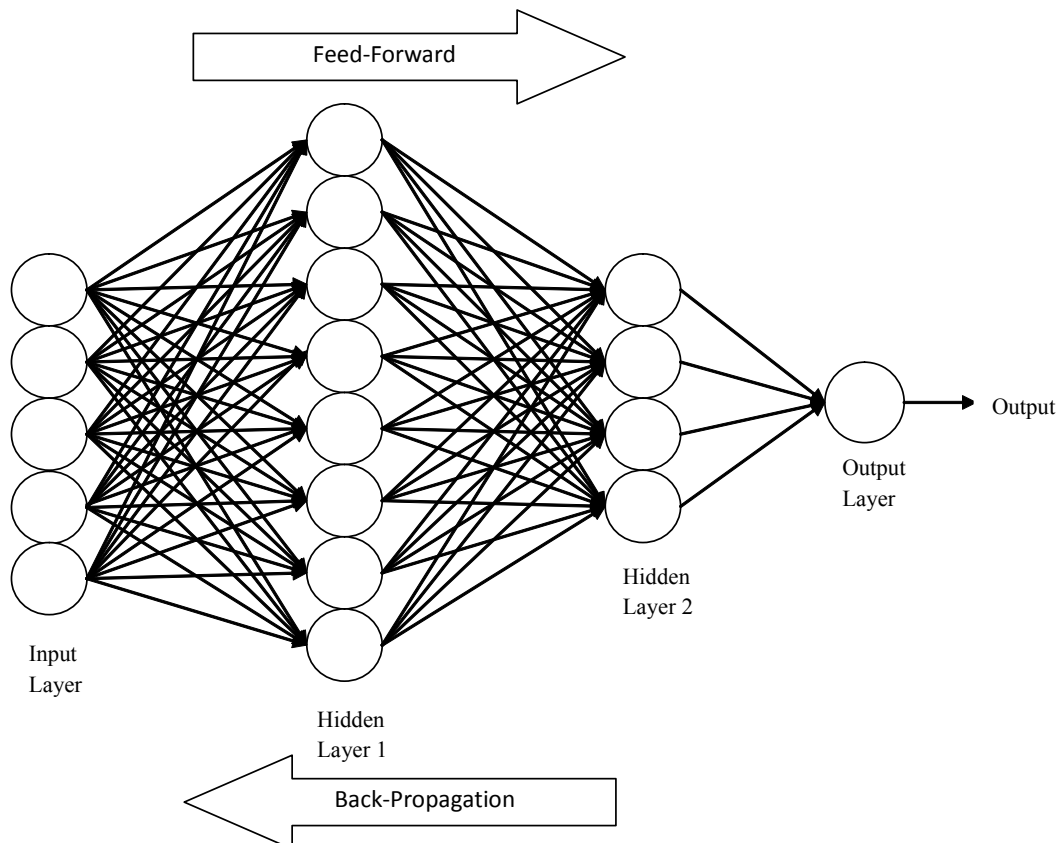
Rys. 4. Architektura stosowanej sieci neuronowej
 Fig. 4. Architecture of applied neural network

5,0% nano-Fe₂O₃ zapewnia próbkom większą wytrzymałość na zginanie, w porównaniu do próbek CO-BSZ i N-BSZ z dodatkiem 1,0; 2,0 i 3,0% nano-Fe₂O₃. W tabelicy 5 podano także nasiąkliwość próbek betonowych serii CO-BSZ i N-BSZ. Wyniki pokazują podobny korzystny wpływ nanocząstek jak w przypadku wytrzymałości na zginanie. Wpływ ten można wyjaśniać przez poprawę struktury porowatości i zarodnikującą rolę nano-Fe₂O₃ co już podano wcześniej (12). Utworzona w wyniku tego wpływu bardziej jednorodna i zbita mikrostruktura betonu powoduje wzrost wytrzymałości na zginanie i mniejszą nasiąkliwość wody. Przekroczenie korzystnego dodatku nano-Fe₂O₃ powoduje pogorszenie właściwości betonu, prawdopodobnie w wyniku nadmiernego zwiększenia zawartości cementu.

with 1.0, 2.0 and 3.0 percent of Fe₂O₃ nanoparticles. Table 5 also shows the percentage of water absorption in CO-SCC and N-SCC series concrete. The results indicate improvement of nanoparticles addition similar to flexural strength. The mechanism that the nanoparticles improve the strength and resistance to water permeability of concrete specimens can be explained by positive change of pore and their nucleation role on cement hydration, mentioned in earlier paper (12). This makes the cement matrix more homogeneous and compact. Consequently, the strength and resistance to water permeability of concrete is improved evidently (13). On the whole, the addition of nanoparticles of Fe₂O₃ improves the strength and resistance to water permeability of concrete. On the one hand, nanoparticles can also act as a filler to enhance the density of concrete, which leads to the porosity of concrete reduction significantly.

4. Artificial Neural Networks

ANNs were developed to model the human brain (15). Even an ANN fairly simple and small in size when compared to the human brain, has some powerful characteristics in knowledge and information processing because of its similarity to the human brain. Therefore, an ANN can be a powerful tool for engineering applications (16). McCulloch and Pitts (17) defined artificial neu-



Rys. 5. Typowa architektura wielowarstwowej preceptronowej sieci neuronowej
 Fig. 5. A typical architecture of multilayer perceptron neural network

Można ogólnie stwierdzić, że dodatek nano-cząstek Fe_2O_3 poprawia wytrzymałość i przepuszczalność wody. Jest to z jednej strony spowodowane działaniem tego dodatku jako wypełniacza uszczelniającego mikrostrukturę betonu, a z drugiej jego roli jako hetero-zarodki, przyspieszające powstawanie fazy C-S-H.

4. Sieci neuronowe

Dziedzina naukowa sieci neuronowych powstała w celu modelowania transmisji i przetwarzania sygnałów w systemie nerwowym człowieka i zwierząt (15). Chociaż sieć neuronowa jest bardzo prosta i niewielka w swym rozmiarze w porównaniu z mózgiem ludzkim, jednak ma pewne korzystne właściwości przydatne w technologii poznania i przetwarzania informacji wynikające z jej podobieństwa do działania mózgu ludzkiego. Dlatego sieć neuronowa może być ważnym narzędziem w zastosowaniach inżynierskich (16). McCulloch i Pitts (17) pierwszy raz zdefiniowali sztuczne neurony i zbudowali model neuronu pokazany na rysunku 4. Sieć McCullocha i Pittsa (17) ukształtowała podstawę dla prawie wszystkich późniejszych modeli sieci neuronowej. Później Rosenblatt (18) obmyślił urządzenie nazywane perceptronem, którego działanie było imitacją działania mózgu ludzkiego. Perceptrony Rosenblatta (18) składają się z neuronów połączonych w pojedynczą warstwę, neuronów McCullocha i Pittsa (17). Rumelhardt i inni (19) wyprowadził algorytm umożliwiających uczenie sieci perceptronów, z utworzeniem neuronów (warstw) ukrytych. Ich algorytm uczenia jest nazywany algorytmem wstecznej propagacji błędów i jest obecnie najczęściej używanym algorytmem uczenia. Rysunek 5 pokazuje typową architekturę wielowarstwowej perceptronowej sieci neuronowej z warstwą wejścia, dwoma warstwami ukrytymi i jedną warstwą wyjścia. W wyniku tych badań, równoległe z rozwojem technologii komputerowych, wykorzystanie sieci neuronowych stało się bardziej efektywne po roku 1980 (20).

Sztuczny neuron jest złożony z pięciu głównych części: sygnałów wejściowych (danych), wag synaptycznych, funkcji sumacyj-

rons for the first time and developed a neuron model as in Fig. 4. McCulloch and Pitts' network (17) formed the basis for almost all later neural network models. Afterwards, Rosenblatt (18) devised a machine called the perceptron that operated much in the same way as the human mind. Rosenblatt's perceptrons (18) consist of "sensory" units connected to a single layer of McCulloch and Pitts (17) neurons. Rumelhardt et al. (19) derived a learning algorithm for perceptron networks with constituted hidden units. Their learning algorithm is called back-propagation and is now the most widely used learning algorithm. Fig. 5 is shown a typical architecture of a multilayer perceptron neural network with an input layer, two hidden layer and one output layer. As a result of these studies, together with the developments in computer technology, using ANN has become more efficient after 1980 (20).

As it can be seen from Fig. 4, an artificial neuron is composed of five main parts: inputs, weights, sum function, activation function and outputs. Inputs are information that enters the neuron from other neurons or from external world. Weights are values that express the outcome of an input set or another process element in the preceding layer on this process element. Sum function is a function that calculates the effect of inputs and weights completely on this process element. This function computes the net input that approaches to a neuron (21). The weighted sums of the input components (net)_{*j*} are calculated using Eq. [1] as follows:

$$(net)_j = \sum_{i=1}^n W_j x_i + b \quad [1]$$

where (net)_{*j*} is the weighted sum of the *j*th neuron for the input received from the preceding layer with *n* neurons, W_j is the weight between the *j*th neuron in the previous layer, x_i is the output of the *i*th neuron in the previous layer (20). b is a fix value as internal addition and Σ represents sum function. Activation function is a function that processes the net input obtained from sum function and determines the neuron output. In general for multilayer feed-forward models as the activation function sigmoid activation function is used. The output of the *j*th neuron (out)_{*j*} is computed using Eq. [2] with a sigmoid activation function as follows (22):

```

1. Initialize the weights and parameter  $\mu$  ( $\mu = 0.01$  is appropriate).
2. Compute the sum of the squared errors over all inputs  $F(w)$ 
    $F(w) = e^T e$  (3)
   Where  $w = [w_1, w_2, \dots, w_n]$  consists of all weights of the network,  $e$  is the error vector comprising the error for all the training examples.
3. Solve (5) to obtain the increment of weights  $\Delta w$ 
    $\Delta w = [J^T J + \mu I]^{-1} J^T e$  (4)
   Where  $J$  is the Jacobian matrix,  $\mu$  is the learning rate which is to be updated using the  $\beta$  depending on the outcome. In particular,  $\mu$  is multiplied by decay rate  $\beta$  ( $0 < \beta < 1$ ).
4. Using  $w + \Delta w$  as the trial  $w$ , and judge
   IF trial  $F(w) < F(w)$  in step 2 THEN
      $W = w + \Delta w$ 
      $\mu = \mu \cdot \beta$  ( $\beta = 0.1$ )
     go back to step 2
   ELSE
      $\mu = \mu / \beta$ 
     go back to step 4
   END IF

```

Rys. 6. Pseudokod dla algorytmu LMBP (27)

Fig. 6. Pseudo-code for LMBP algorithm (27)

nej, funkcji aktywacyjnej i sygnałów wyjściowych (wyników) co jest pokazane na rysunku 4. Sygnały wejściowe są informacjami, które wchodzą do neuronu od innych neuronów lub z zewnątrz. Wagi są wartościami, które wyrażają wynik działania zbioru sygnałów wejściowych, lub innego składnika procesu transmisji informacji z poprzedniej warstwy, na rozpatrywany składnik procesu transmisji. Funkcja sumacyjna oblicza całkowity wpływ wejść i wag na dany składnik procesu transmisji, wylicza argument funkcji aktywacji dochodzący do neuronu (21). Ważone sumy składników wejścia (net_j) są obliczane przy zastosowaniu równania [1]:

$$(net)_j = \sum_{i=1}^n W_{ij} x_i + b \quad [1]$$

gdzie: $(net)_j$ jest ważoną sumą j -tego neuronu dla wejścia otrzymanego od poprzedzającej warstwy z n neuronami, W_{ij} wagą między j -tym neuronem w poprzedniej warstwie, x_i wyjściem i -tego neuronu w warstwie poprzedniej (20). b jest stałym składnikiem i \sum jest symbolem funkcji sumacyjnej. Funkcja aktywacji przetwarza argument otrzymany z funkcji sumacyjnej i określa sygnał wyjścia z neuronu. W ogólności dla wielowarstwowych modeli sieci z jednokierunkowym przepływem sygnałów jako funkcji aktywacyjnej używa się funkcji sigmoidalnej. Wyjście j -tego neuronu (out_j) jest obliczane przy użyciu równania [2] zawierającego funkcję sigmoidalną (22):

$$O_j = f(net)_j = \frac{1}{1 + e^{-\alpha(net)_j}} \quad [2]$$

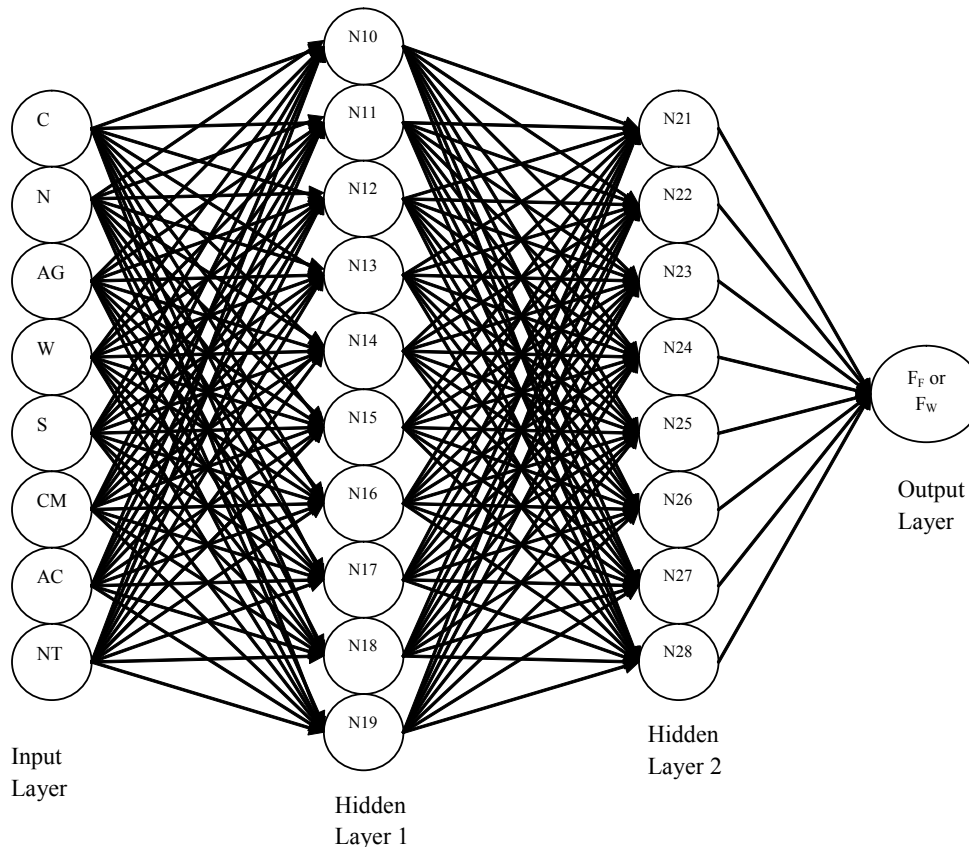
gdzie: α jest stałą stosowaną do kontroli kształtu funkcji aktywacji. Nieliniowość sigmoidalna uaktywnia się w każdej warstwie, za

$$O_j = f(net)_j = \frac{1}{1 + e^{-\alpha(net)_j}} \quad [2]$$

where α is constant used to control the slope of the semi-linear region. The sigmoid nonlinearity activates in every layer except in the input layer (20). The sigmoid activation function represented by Eq. [2] gives outputs in (0, 1). If it desired, the outputs of this function can be adjusted to (-1, 1) interval. As the sigmoid processor represents a continuous function it is particularly used in non-linear descriptions. Because its derivatives can be determined easily with regard to the parameters within $(net)_j$ variable (20). LMBP is often the fastest available back-propagation algorithm, and is highly recommended as a first-choice supervised algorithm, although it requires more memory than other algorithms. The standard LMBP training process can be described in the pseudocode of Fig. 6 (23).

4.1. Neural network model structure and parameters

ANN model is carried out in this research has eight neurons in the input layer and one neurons in the output layer as demonstrated in Fig. 7. The values for input layers were cement content (C), nanoparticle content (N), aggregate type (AG), water content (W), the amount of superplasticizer (S), the type of curing medium (CM), Age of curing (AC) and number of testing try (NT). The values for output layer were flexural strength (f_p) data in one set and percentage of water absorption (f_w) in the other set. Two hidden layer with ten and eight neurons were used in the architecture of multilayer neural network because of its minimum absolute percentage error values for training and testing sets. The neurons of neighboring



Rys. 7. Budowa warstwowa modelu sieci neuronowej

Fig. 7. The system used in the ANN model

wyjątkiem warstwy wejściowej (20). Sigmoidalna funkcja aktywacji pokazana równaniem [2] przyjmuje wartości (0, 1). Wartości tej funkcji mogą się mieścić w przedziale (-1, 1) wówczas, gdy funkcja ma postać funkcji sigmoidalnej bipolarnej. Funkcja sigmoidalna jest funkcją ciągłą i jest stosowana w nieliniowych sieciach neuronowych ze względu na łatwość obliczenia jej pochodnej, z uwzględnieniem parametrów występujących w zmiennej (net)_j (20).

LMBP (Levenberg Marquardt Back Propagation) jest często najszybszym algorytmem wstecznej propagacji błędów i jest wysoce rekomendowany jako metoda uczenia jednokierunkowych sieci wielowarstwowych, chociaż wymaga więcej pamięci niż inne algorytmy. Standardowy LMBP proces uczenia może być opisany w pseudokodzie pokazanym na rysunku 6 (23).

4.1. Budowa i parametry modelu sieci neuronowej

Model sieci neuronowej zastosowany w niniejszej pracy ma w warstwie wejściowej osiem neuronów i jeden neuron w warstwie wyjściowej, co jest pokazane na rysunku 7. Sygnałami do warstwy wejściowej były: zawartość cementu (C), zawartość nanocząstek (N), rodzaj kruszywa (AG), zawartość wody (W), ilość superplastyfikatora (S), rodzaj środowiska dojrzewania (CM), czas dojrzewania (AC) i liczba pokazów (NT). Sygnałami wyjściowymi były: zbiór wyników wytrzymałości na zginanie (f_r) i drugi zbiór wyników zawierający nasiąkliwość betonu (f_w). Dwie warstwy ukryte z dziesięcioma i ośmioma neuronami zastosowano w budowie wielowarstwowej sieci neuronowej ze względu na minimalizację wartości absolutnego błędów procentowego dla uczenia się i oceny efektywności pracy sieci neuronowej. Neurony sąsiadujące warstw są całkowicie wzajemnie związane poprzez wagi. W rezultacie neurony warstwy wyjściowej sieci generują prognozę wyniku.

W niniejszych badaniach algorytm wstecznej propagacji błędów został zastosowany w sieci z jednokierunkowym przepływem sygnałów i dwoma warstwami ukrytymi. Algorytm wstecznej propagacji błędów, jako jeden z najlepiej znanych algorytmów uczenia się dla wielowarstwowego perceptronu, jest metodą minimalizacji funkcji błędów dla danego wzoru uczenia się, w którym wagi są modyfikowane w krótkim czasie (23). Zastosowano nieliniową sigmoidalną funkcję aktywacji w warstwie ukrytej i na sygnałach wyjściowych warstwy wyjściowej. Określono wartości współczynnika momentum i uczenia się. Model był trenowany w kolejnych iteracjach. Nauczony model był badany z zastosowaniem wartości wejściowych, a prognozowane wyniki były bliskie wynikom doświadczalnym. Wartości parametrów użytych w modelu sieci neuronowej są zamieszczone w tabelicy 5. Decyzję o zakończeniu procesów uczenia się podejmuje się po stwierdzeniu następujących dwóch stanów końcowych:

- stan 1 (model: sieć neuronowa – I) oznacza, że uczenie się sieci neuronowej zostało zakończone, kiedy maksymalny ciąg uczenia się (epoka) osiągnął (1000),
- stan 2 (model: sieć neuronowa II) oznacza, że uczenie zakończyło się wówczas, gdy osiągnięto normę minimalnego błędów sieci.

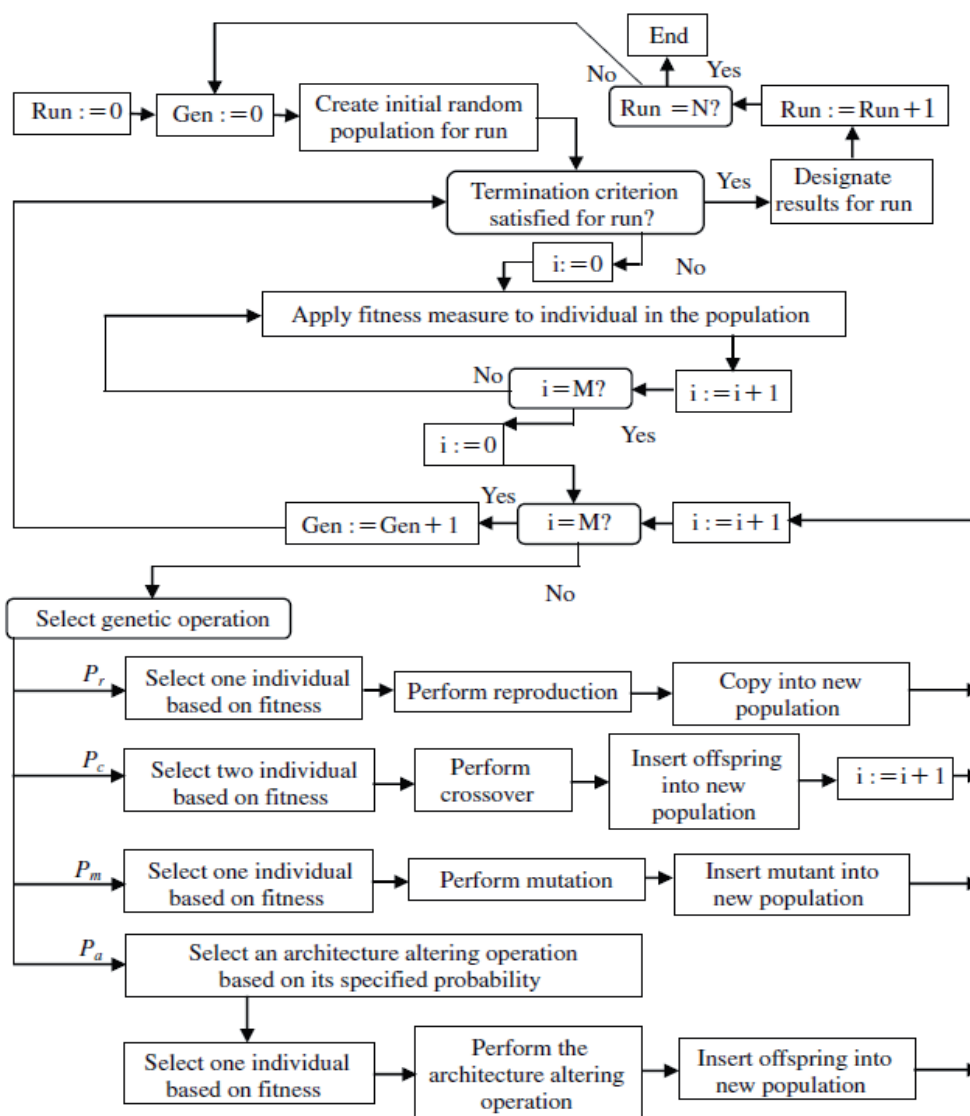
layers are completely interconnected by weights. Finally, the output layer neurons produce the network prediction as a result. In this study, the back-propagation training algorithm has been utilized in feed-forward two hidden layers. Back-propagation algorithm, as one of the most well-known training algorithms for the multilayer perceptron, is a gradient descent technique to minimize the error for a particular training pattern in which it adjust the weights by a small amount at a time (23). The non-linear sigmoid activation function was used in the hidden layer and the neuron outputs at the output layer. Momentum rate and learning rate values were determined and the model was trained through iterations. The trained model was only tested with the input values and the predicted results were close to experiment results. The values of parameters used in neural network model are given in Table 5. To make a decision on the completion of the training processes, two termination states are declared: state 1 (ANN-I model) means that the training of neural network was ended when the maximum epoch of process reached (1000) while state 2 (ANN-II model) means the training ended when minimum error norm of network gained.

5. Genetic programming

Genetic programming (GP) proposed by Koza (24) is an extension to Genetic Algorithms (GA). Koza (24) defines GP as a domain independent problem-solving approach in which computer programs are evolved to solve, or approximately solve, problems based on the Darwinian principle of reproduction and survival of the fittest and analogs of naturally occurring genetic operations such as crossover and mutation. GP reproduces computer programs to solve problems by executing the steps in Fig. 8. This figure is a flowchart showing the executional steps of a run of GP. The flowchart demonstrates the genetic operations in addition to the architecture changing operations. Also, this flowchart demonstrates a two offspring version of the crossover operation.

Gene expression programming (GEP) software which is used in this study is an extension to GEP that evolves computer programs of different sizes and shapes encoded in linear chromosomes of fixed length. The chromosomes are composed of multiple genes, each gene encoding a smaller sub-program. Furthermore, the structural and functional organization of the linear chromosomes allows the unconstrained operation of important genetic operators such as mutation, transposition, and recombination (25–37). The two main parameters GEP are the chromosomes and expression trees (ETs) (25–27). Two languages are utilized in GEP: the language of the genes and the language of ETs. A significant advantage of GEP is that it enables to infer exactly the phenotype given the sequence of a gene, and vice versa which is termed as Karva language.

For each problem, the type of linking function, as well as the number of genes and the length of each gene, are a priori chosen for each problem. While attempting to solve a problem, one can always start by using a single-gene chromosome and then proceed by increasing the length of the head. If it becomes very large, one can increase the number of genes and obviously choose a func-



Rys. 8. Arkusz przepływów w programowaniu genetycznym (28)

Fig. 8. Genetic programming flowchart (28)

5. Programowanie genetyczne

Programowanie genetyczne (PG) zaproponowane przez Kożę (24) jest rozszerzeniem algorytmów genetycznych (AG). Koza (24) definiuje PG jako dziedzinę niezależnego sposobu rozwiązywania zagadnień, w której używane są programy komputerowe do rozwiązywania lub przybliżonego rozwiązywania zagadnień, których podstawą jest darwinowska zasada doboru naturalnego, zgodnie z którą przeżywają najlepiej przystosowani i analogi naturalnie zachodzących operacji genetycznych takich jak krzyżowanie i mutacja. PG reprodukuje programy komputerowe do rozwiązywania problemów poprzez wykonanie kroków pokazanych na rysunku 8. Rysunek 8 jest arkuszem przepływów, przedstawiającym wykonywane kroki w postępowaniu PG. Arkusz przepływów uwidacznia operacje genetyczne w architekturze operacji losowych. Również arkusz przepływów pokazuje dwie wersje wyniku operacji krzyżowania.

Algorytm genetyczny genotypu/fenotypu (gene expression programming – GEP), który został użyty w niniejszych badaniach jest

tion to link the sub-ETs. One can start with addition for algebraic expressions or for Boolean expressions, but in some cases another linking function might be more appropriate (like multiplication or IF, for instance). The idea, of course, is to find a good solution, and GEP provides the means of finding one very efficiently (25).

5.1. Genetic expression programming structure and parameters

In this study, as seen in Figs. 9-12, the expression trees of two different GEP approach models namely GEP-I and GEP-II were constructed for flexural strength and percentage of water absorption. $d_0, d_1, d_2, d_3, d_4, d_5, d_6$ and d_7 in Figs. 9-12 represent C, N, AG, W, S, CM, AC and NT, respectively. In the GEP-I and GEP-II, as the number of genes used 3 and 4 genes (Sub-ETs), and as linking function used addition and multiplication, respectively. In training and testing of the GEP-I and GEP-II approach models constituted with two different Sub-ETs and linking function C, N, AG, W, S, CM, AC and NT as input data and f_F and f_W as independent output data. Among 144 experimental sets, 117 sets were randomly

rozszerzeniem GEP, rozwija programy komputerowe różnych rozmiarów i kształtów zakodowane w liniowych chromosomach o stałej długości. Chromosomy są złożone z wielokrotności genów, każdy gen szyfrując mniejszym podprogramem. Dalej strukturalna i funkcjonalna organizacja liniowych chromosomów pozwala na nieograniczone działanie ważnych operatorów genetycznych takich jak mutacja, krzyżowanie i rekombinacja (25 – 37). Dwoma głównymi parametrami GEP są chromosomy i drzewa wyrażenia (ETs) (25 – 27). W algorytmie GEP stosowane są dwa języki: język genów i język ETs. Ważną zaletą algorytmu GEP polega na tym, że umożliwia dokładne wnioskowanie genotypu danej sekwencji genów i na odwrót, co jest określane mianem języka Karva.

Dla każdego problemu rodzaj funkcji łączącej, a także liczba genów i długość każdego genu, są wybrane *a priori*. Podczas próby rozwiązania problemu można zawsze startować stosując chromo-


chosen as a training set for the GEP-I and GEP-II modeling and the remaining 27 sets were used as testing the generalization capacity of the proposed models.

For this problem, firstly, the fitness, f_i , of an individual program, i , is measured by:


$$f_i = \sum_{j=1}^{C_i} (M - |C_{(ij)} - T_j|) \quad [5]$$

where M is the range of selection, $C_{(ij)}$ is the value returned by the individual chromosome i for fitness case j (out of C_i fitness cases) and T_j is the target value for fitness case j . If $|C_{(ij)} - T_j|$ (the precision) is less than or equal to 0.01, then the precision is equal to zero, and $f_i = f_{max} = C_i M$. In this case, $M = 100$ was used, therefore, $f_{max} = 1000$. The advantage of this kind of fitness functions is that the system can find the optimal solution by itself (28, 29).


Sub-ET 1



Sub-ET 2



Sub-ET 3



Rys. 9. Drzewo wyrażenia z trzema genami dla wytrzymałości na zginanie w modelu GEP – I. C0 = 3,24, C1 = 11,32

Fig. 9. Expression tree with 3 gens for flexural strength in GEP-I model. C0 = 3.24 and C1 = 11.32

Tablica 6 / Table 6

PARAMETERS OF GEP APPROACH MODELS / PARAMETRY MODELU TYPU GEP

Określenie parametru / Parameter definition		GEP-I	GEP-II
P1	Zbiór funkcji / Function set	+, -, *, /, sqrt, x ³	+, -, *, /, sqrt, x ³
P2	Chromosomy / Chromosomes	30	40
P3	Rozmiar głowy / Head size	12	14
P4	Liczba genów / Number of genes	3	4
P5	Funkcja łącząca / Linking function	Addition	Multiplication
P6	Częstość mutacji / Mutation rate	0.044	0.044
P7	Częstość inwersji / Inversion rate	0.1	0.1
P8	Współczynnik rekombinacji jednopunktowej One-point recombination rate	0.3	0.3
P9	Współczynnik rekombinacji dwupunktowej Two-point recombination rate	0.3	0.3
P10	Współczynnik rekombinacji genu / Gene recombination rate	0.1	0.1
P11	Współczynnik krzyżowania genu / ene transposition rate	0.1	0.1

Tablica 7 / Table 7


TESTING DATA SETS FOR COMPARISON OF EXPERIMENTAL RESULTS WITH TESTING RESULTS PREDICTED FROM MODELS

Cement (Kg/m ³)	Nano- Fe ₂ O ₃ (Kg/m ³)	Aggregate type ^a	Water (Kg/m ³)	Superplasti- cizer (Kg/m ³)	Curing Medium ^b	Age of Curing	No. Test try	Flexural Strength (MPa)					Percentage of water absorption (%)				
								Exp.	ANN-I	ANN-II	GEP-I	GEP-II	Exp.	ANN-I	ANN-II	GEP-I	GEP-II
450	0	3	0	18	1	7	3	4.6	4.6	4.7	4.7	4.7	3.6	3.7	3.6	4.0	3.6
450	0	3	0	18	1	28	3	4.6	4.8	4.5	4.6	4.5	5.9	5.9	5.9	5.0	5.9
447.75	2.25	3	0	18	1	7	2	4.7	5.4	4.8	4.9	4.8	3.9	4.1	4.0	4.0	4.4
447.75	2.25	3	0	18	1	28	3	5.1	5.2	5.2	5.4	5.1	2.3	2.6	2.4	3.9	4.7
447.75	2.25	3	0	18	1	90	3	5.9	6.5	5.9	5.9	5.9	0.9	1.0	1.0	1.4	0.8
445.5	4.5	3	0	18	1	7	3	5.6	5.6	5.6	5.5	5.6	4.6	4.8	4.6	4.3	4.7
445.5	4.5	3	0	18	1	28	1	5.1	5.3	5.3	5.2	5.2	2.5	2.3	2.6	2.5	2.1
445.5	4.5	3	0	18	1	90	2	5.8	5.9	5.8	5.7	6.0	1.1	0.6	1.1	1.1	1.3
443.25	6.75	3	0	18	1	7	2	5.1	5.1	5.0	5.2	5.0	4.7	4.8	4.9	4.8	4.9
443.25	6.75	3	0	18	1	28	1	5.1	5.0	5.2	5.1	5.0	2.8	2.8	2.8	2.5	2.3
441	9	3	0	18	1	7	1	3.9	3.8	4.0	3.9	3.9	4.7	4.8	4.6	4.3	4.8
441	9	3	0	18	1	90	1	4.8	4.8	4.8	4.6	4.3	1.5	1.6	1.8	0.7	1.2
450	0	3	0	18	2	90	2	4.4	4.2	4.4	4.1	4.4	5.1	5.1	5.0	5.0	5.0
447.75	2.25	3	0	18	2	7	2	5.4	5.3	5.0	5.2	5.5	6.3	6.3	6.1	6.0	6.3
447.75	2.25	3	0	18	2	28	1	5.7	5.6	5.3	5.1	5.3	1.5	2.5	1.6	2.9	1.7
445.5	4.5	3	0	18	2	7	3	5.9	5.8	5.8	5.8	5.8	6.7	6.9	7.2	6.2	6.7
443.25	6.75	3	0	18	2	90	1	5.9	5.9	6.0	6.4	5.9	1.1	1.2	1.1	0.7	1.7
441	9	3	0	18	2	28	2	6.9	6.9	6.9	6.7	7.0	1.9	1.8	1.9	1.7	1.8
450	0	4	0.18	17.82	1	7	2	4.1	3.9	4.0	3.8	3.9	4.7	4.3	4.3	4.0	4.6
445.5	4.5	4	0.18	17.82	1	7	2	4.0	4.2	4.1	4.1	4.2	1.7	1.8	1.8	2.4	2.0
445.5	4.5	4	0.18	17.82	1	28	1	4.3	4.4	4.4	4.7	4.1	1.6	1.6	1.7	2.4	2.3
441	9	4	0.18	17.82	1	7	2	4.6	4.4	4.7	4.6	4.7	1.8	1.7	1.7	2.1	1.9
441	9	4	0.18	17.82	1	28	3	6.2	5.9	6.1	6.0	6.2	1.7	1.7	1.4	1.7	1.6
437.5	13.5	4	0.18	17.82	1	28	1	6.3	6.4	6.4	6.4	6.3	1.2	1.2	1.2	1.3	1.3
432	18	4	0.18	17.82	1	7	2	5.7	5.6	5.6	5.4	5.6	1.4	1.6	1.4	1.7	1.5
427.5	22.5	4	0.18	17.82	1	2	2	3.7	3.8	3.7	3.6	3.7	4.4	4.9	4.5	4.1	4.7
427.5	22.5	4	0.18	17.82	1	28	1	6.6	6.7	7.3	6.6	6.7	1.1	1.1	1.2	1.2	1.2


^a 3 denotes to natural sand aggregates and 4 denotes to limestone aggregates; 3 – piasek, 4 – wapień

^b 1 denotes to water curing medium and 2 denotes to saturated limewater curing medium; 1 – dojrzewanie w wodzie, 2 – w wodzie wapiennej


Sub-ET 1




Sub-ET 2



Sub-ET 3



Sub-ET 4



Rys. 10. Drzewo wyrażenia z czterema genami dla wytrzymałości na zginanie w modelu GEP – II. C0 = 2,20, C1 = 8,50

Fig. 10. Expression tree with 4 gens for flexural strength in GEP-II model. C0 = 2.20, c1 = 8.50

som z pojedynczym genem i wówczas postępować zwiększając długość głowy. Jeśli staje się ona bardzo duża wówczas można zwiększyć liczbę genów i oczywiście wybrać funkcję do połączenia kolejnych drzew wyrażań. Można startować z dodatkiem wyrażań algebraicznych lub wyrażań Boole'a, ale w pewnych przypadkach inna funkcja łącząca może być bardziej właściwa (np. mnożenie lub IF). Myślą przewodnią powyższego wyboru jest znalezienie dobrego rozwiązania, a wówczas GEP stanie się narzędziem działającym bardzo wydajnie (25).

Afterwards the set of terminals T and the set of functions F to create the chromosomes are preferred, namely, $T = \{C, N, AG, W, S, CM, AC, NT\}$ and four basic arithmetic operators (+, -, *, /) and some basic mathematical functions (Sqrt, x^3) were used.

Another major step is to choose the chromosomal tree, i.e., the length of the head and the number of genes. The GEP-I and GEP-II approach models initially used single gene and two lengths of heads, and increased the number of genes and heads, one after another during each run, and monitored the training and testing sets performance of each model. In this study, for the GEP-I and GEP-II approach models observed the number of genes 3 and 4, and length of heads 10 and 12, respectively. In addition, for the GEP-I and GEP-II approach models determined the linking function multiplication and addition, respectively.

Finally, a combination of all genetic operators (mutation, transposition and crossover) was utilized as set of genetic operators. Parameters of the training of the GEP-I and GEP-II approach models are given in Table 6. For the GEP-I and GEP-II approach models, chromosome 30 and 40 were observed to be the best of generation individuals predicting f_F and f_W . Explicit formulations based on the GEP-I and GEP-II approach models for f_F and f_W were obtained by:

$$f_F = f(C, N, AG, W, S, CM, AC, NT) \quad [6]$$

$$f_W = f(C, N, AG, W, S, CM, AC, NT) \quad [7]$$

Figs. 9 and 10 show the expression trees with 3 and 4 gens respectively for flexural strength prediction and Figs. 11 and 12 show the expression trees with 3 and 4 gens respectively for percentage of water absorption prediction. The related formulations could be obtained by the procedure shown in Fig. 13 (7).


6. Results

6.1. Artificial Neural network


In this study, the error arose during the training and testing in ANN-I and ANN-II models can be expressed as absolute fraction of variance (R^2) which are calculated by Eq. 8 (30):

$$R^2 = 1 - \left(\frac{\sum_i (t_i - o_i)^2}{\sum_i (o_i)^2} \right) \quad [8]$$


Sub-ET 1



Sub-ET 2



Sub-ET 3



Rys. 11. Drzewo wyrażenia z trzema genami dla procentowej zawartości zaabsorbowanej wody w modelu GEP – I. C0 = -1,75, C1 = 18,96

Fig. 11. Expression tree with 3 gens for percentage of water absorption in GEP-I model. C0 = -1.75, c1 = 18.96

5.1. Struktura i parametry algorytmu genetycznego genotypu/fenotypu GEP

W niniejszych badaniach, jak to jest pokazane na rysunkach 9 do 12, drzewa wyrażenia dwóch różnych typów modeli GEP, a mianowicie GEP – I i GEP – II zostały zbudowane dla wytrzymałości na zginanie i nasiąkliwości w %. d0, d1, d2, d3, d4, d5 d6 i d7 na rysunkach od 9 do 12 przedstawiają odpowiednio C, N, AG, W, S, CM, AC oraz NT. W modelach GEP – I i GEP – II zastosowano 3 i 4 geny (sub – ETs) i jako funkcje łączące zastosowano dodawanie i mnożenie. W uczeniu i testowaniu modeli typów GEP – I i GEP – II modele utworzono z dwóch różnych poddrzew wyrażań (sub – ETs) i funkcji łączącej C, N, AG, W, S, CM, AC oraz NT jako dane wejściowe oraz f_F i f_W , jako niezależne dane wyjściowe. Spośród 144 zestawów eksperymentalnych 117 zestawów było losowo wybranych jako zestaw uczący dla modelowania GEP – I i GEP – II, a pozostałe zostały użyte jako testujące uogólnioną po-

where t is the target value, o is the output value.

All of the results obtained from experimental studies and predicted by using the training and testing results of ANN I and ANN II models, for f_F are given in Figs. 14a and 14b, respectively and for f_W in Figs. 15a and 15b, respectively. The linear least square fit line, its equation and the R^2 values were shown in these figures for the training and testing data. Also, inputs values and experimental results with testing results obtained from ANN-I and ANN-II models were given in Table 7. As it is visible in Figs. 14 and 15 the values obtained from the training and testing in ANN-I and ANN-II models are very close to the experimental results. The result of testing phase in Figs. 14 and 15 shows that the ANN-I and ANN-II models are capable of generalizing between input and output variables with reasonably good predictions. The performance of the ANN-I and ANN-II models for f_F and f_W is shown in Figs. 14 and 15, respectively. The best values of R^2 are 96.41% and 97.67% for training set in the ANN-II model, respectively for flexural strength and percentage of water

jemność proponowanych modeli. Po pierwsze do rozwiązania zagadnienia uczenia dopasowanie f_i indywidualnego programu i jest mierzone za pomocą następującego równania:

$$f_i = \sum_{j=1}^{C_i} (M - |C_{(ij)} - T_j|) \quad [5]$$


gdzie: M jest zakresem selekcji, $C_{(ij)}$ wartością zwróconą przez indywidualny chromosom i dla przypadku dopasowania j (poza przypadkami dopasowania C_i) i T_j jest wartością celową dla przypadku dopasowania j . Jeśli $|C_{(ij)} - T_j|$ (dokładność) jest mniejsza lub równa 0,01, wówczas dokładność równa się zero i $f_i = f_{max} = C_i M$. W niniejszych badaniach zastosowano $M = 100$, dlatego $f_{max} = 1000$. Zaletą tego rodzaju funkcji dopasowania jest to, że system sam może znaleźć rozwiązanie optymalne (28, 29).

Następnie zbiór telomerów T i zbiór funkcji F wybiera się, aby utworzyć chromosomy. Mianowicie zostały wybrane: $T = \{C, N, AG, W, S, CM, AC, NT\}$ i cztery podstawowe operatory arytmetyczne (+, -, *, /) oraz niektóre funkcje elementarne (Sqrt, x^3).


Kolejnym ważnym krokiem jest wybór drzewa chromosomowego, czyli długości głowy i liczby genów. Typy modeli GEP – I i GEP – II początkowo używają pojedynczego genu i dwóch długości głów i wzrastającej kolejno liczby genów i głów podczas każdego przebiegu. Monitorują efektywność uczenia i testowania każdego modelu. W niniejszych badaniach modeli typu GEP – I i GEP – II zachowywano liczbę genów 3 i 4 oraz długość głów odpowiednio 10 i 12. Dodatkowo dla badanych typów modeli GEP – I i GEP – II określono funkcję łączącą mianowicie mnożenie i dodawanie.

Ostatecznie kombinacja wszystkich operacji genetycznych (mutacji, reprodukcji i krzyżowania) była użyta jako zbiór operatorów genetycznych. Parametry treningowe modeli typu GEP – I i GEP – II są zestawione w tablicy 6. Dla badanych modeli liczba


Sub-ET 1




Sub-ET 2



Sub-ET 3



Sub-ET 4



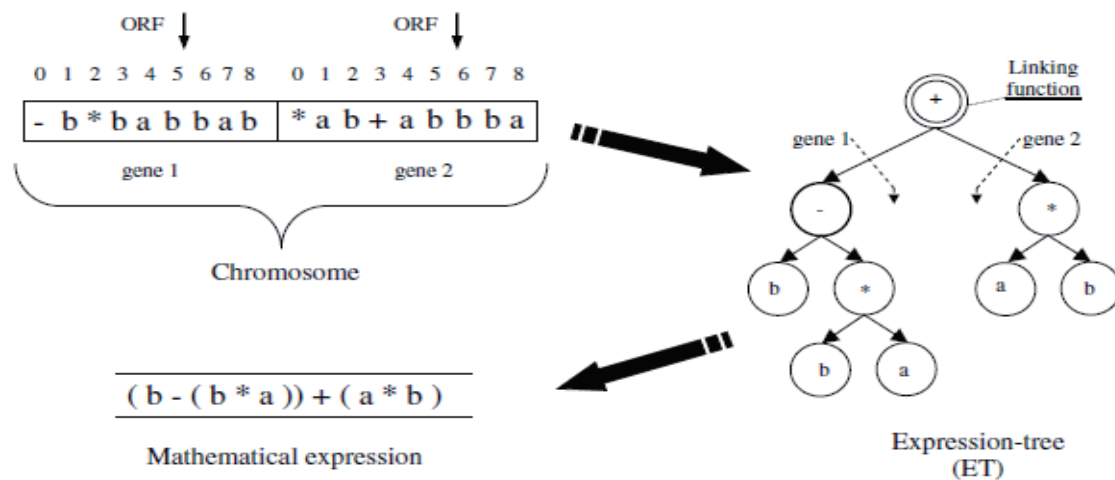
Rys. 12. Drzewo wyrażenia z czterema genami dla procentowej zawartości zaabsorbowanej wody w modelu GEP – II. $C_0 = 3,12$, $C_1 = 6,32$

Fig. 12. Expression tree with 4 gens for percentage of water absorption in GEP-II model. $C_0 = 3.12$, $c_1 = 6.32$

absorption. The minimum values of R^2 are 85.47% and 96.96% for testing set in the ANN-I model, respectively for flexural strength and percentage of water absorption. All of R^2 values show that the proposed ANN-I and ANN-II models are suitable and can predict f_r and f_w values for every age very close to the experimental values.

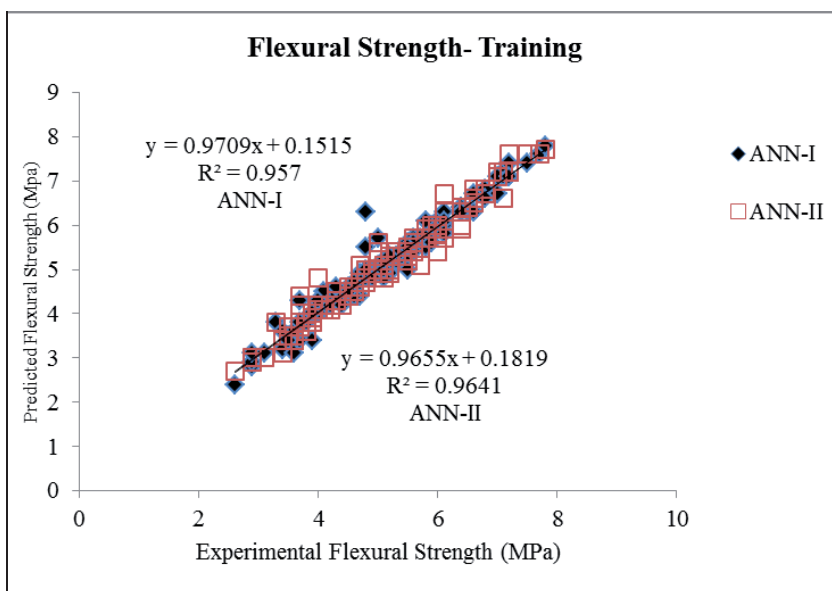
6.2. Genetic programming

Once again, in this study, the error arose during the training and testing in GEP-I and GEP-II models can be expressed as R^2 which

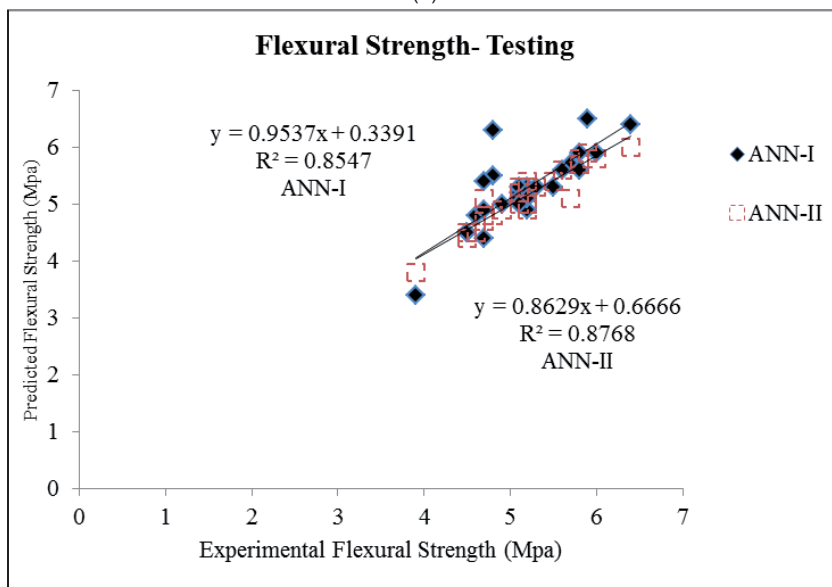


Rys. 13. Chromosom z dwoma genami i jego dekodowanie w GEP (7)

Fig. 13. Chromosome with two genes and its decoding in GEP (7)



(a)



(b)

Rys. 14. Korelacja zmierzonych i prognozowanych wytrzymałości na zginanie: a) ćwiczenie, b) pomiar; modele SN

Fig. 14. The correlation of the measured and predicted flexural strengths in a) training and b) testing phase for ANN models

are calculated by Eq. 8. All of the results obtained from experimental studies and predicted by using the training and testing results of GEP-I and GEP-II models, for f_f are given in Figs. 16a and 16b, respectively and for F_w in Figs. 17a and 17b, respectively. The linear least square fit line, its equation and the R^2 values were shown in these figures for the training and testing data. Also, inputs values and experimental results with testing results obtained from GEP-I and GEP-II models were given in Table 7. As it is visible in Figs. 16 and 17 the values obtained from the training and testing in GEP-I and GEP-II models are very close to the experimental results. The result of testing phase in Figs. 16 and 17 shows that the GEP-I and GEP-II models are capable of generalizing between input and output variables with reasonably good predictions. The performance of the GEP-I and GEP-II models for f_f and f_w is shown in Figs. 16 and 17, respectively. The best values of R^2 are 96.14% and 95.82% for training set in the GEP-II model, respectively for flexural strength and percentage of water absorption. The minimum values of R^2 are 86.52% and 85.55% for testing set in the GEP-I model, respectively for flexural strength and percentage of water absorption. All of the statistical values show that the proposed GEP-I and GEP-II models are suitable and can predict f_f and f_w values for every age very close to the experimental values.

7. Discussion

Artificial neural networks are capable of learning and generalizing from examples and experiences. This makes artificial neural networks a powerful tool for solving some of the complicat-

30 i 40 chromosomów była zachowana jako najlepsza generacja osobników prognozująca f_F i f_W . Obowiązywały precyzyjnie określone wzory dla modeli typu GEP – I i GEP – II:

$$f_F = f(C, N, AG, W, S, CM, AC, NT) \quad [6]$$

$$f_W = f(C, N, AG, W, S, CM, AC, NT) \quad [7]$$

Rysunki 9 i 10 pokazują drzewa wyrażenia odpowiednio z trzema i czterema genami dla prognozowania wytrzymałości na zginanie. Z kolei rysunki 11 i 12 przedstawiają drzewa wyrażenia z trzema i czterema genami dla prognozowania procentowej nasiąkliwości betonu. Stosowne wzory mogły obowiązywać dzięki procedurze pokazanej na rysunku 13 (7).

6. Wyniki

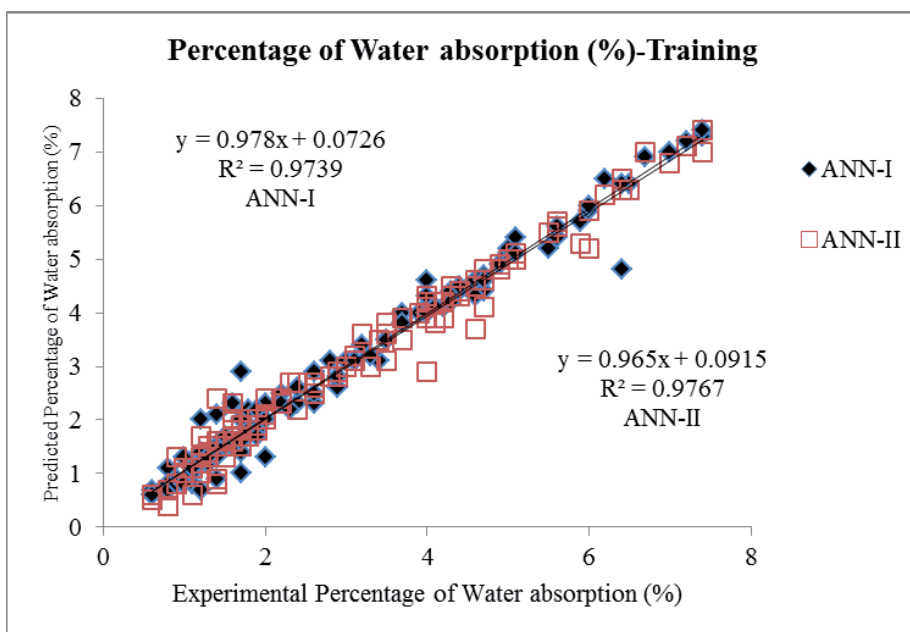
6.1. Sztuczne sieci neuronowe

W tej pracy powstał błąd w trakcie ćwiczenia i sprawdzania modeli Sn-I i SN-II, który można wyrazić jako absolutną frakcję wariancji R^2 , którą można wyliczyć z równania [8].


$$R^2 = 1 - \left(\frac{\sum_i (t_i - o_i)^2}{\sum_i (o_i)^2} \right) \quad [8]$$

gdzie: t – jest wartością docelową, o – jest wartością wyjściową.

Wszystkie wyniki otrzymane z badań doświadczalnych i prognozowania przy wykorzystaniu rezultatów ćwiczenia i sprawdzania modelu SN-I i SN-II, w przypadku f_F są podane odpowiednio na rysunkach 14a i 14b, a w przypadku f_W na rysunkach 15a i 15b. Metoda najmniejszych kwadratów odpowiada linii prostej, a jej równanie i wartość R^2 są pokazane na tych rysunkach jako dane do ćwiczenia i sprawdzania. Także wartości wejściowe i wyniki doświadczalne wraz z wynikami otrzymanymi przy wykorzystaniu modeli SN-I i SN-II są podane w tablicy 7. Jak widać na rysunkach 14 i 15 wartości otrzymane z ćwiczenia i sprawdzania modeli SN-I i SN-II są bardzo bliskie wynikom doświadczalnym. Wyniki z etapu ćwiczenia zamieszczone na rysunkach 14 i 15 pokazują, że modele SN-I i SN-II są zdolne do uogólniania zmiennych wejściowych i wyjściowych z wystarczająco dobrą prognozą. Właściwości modeli SN-I i SN-II dla prognozowania f_F i f_W są pokazane odpowiednio na rysunkach 14 i 15. Najlepsze wartości R^2 wynoszące 96,41 i 97,67 ze zbioru należącego do ćwiczeń modelu SN-II dotyczą odpowiednio wytrzymałości na zginanie i procentowej nasiąkliwości. Minimalne warto-



(a)



(b)

Rys. 15. Korelacja zmierzonych i prognozowanych nasiąkliwości wodą: a) ćwiczenie, b) pomiar; modele SN

Fig. 15. The correlation of the measured and predicted percentage of water absorption in a) training and b) testing phase for ANN models

ed civil engineering problems. In this study, using these beneficial properties of artificial neural networks in order to predict the flexural strength and percentage of water absorption values of concretes containing Fe_2O_3 nanoparticles without attempting any experiments were developed two different multilayer artificial neural network architectures namely ANN-I and ANN-II. In two models developed in ANN method, a multilayered feed forward neural network with a back propagation algorithm was used. The models were trained with input and output data. Using only the input data in trained models the flexural strength and percentage of water absorption values of concretes containing Fe_2O_3 nanoparticles were found. The flexural strength and percentage of water absorption values


ści R^2 wynoszące 85,47% i 96,96% wynikające ze zbioru sprawdzania modelu SN-I odnoszą się odpowiednio do wytrzymałości na zginanie i procentowej nasiąkliwości. Wszystkie wartości R^2 pokazują, że zaproponowane modele SN-I i SN-II pozwalają na prognozowanie wartości f_c i f_w dla każdego wieku próbek, prognozowane wartości są bardzo bliskie danym doświadczalnym.

6.2. Prognozowanie genetyczne


Jeszcze raz powstał w tej pracy błąd podczas ćwiczenia i sprawdzania modeli GEP-I i GEP-II, który może być wyrażony jako R^2 wyliczony z równania [8]. Wszystkie wyniki otrzymane doświadczalnie i prognozowane przez zastosowanie rezultatu z ćwiczenia i sprawdzania modeli GEP-I i GEP-II w przypadku f_c są pokazane na rysunku 16a i 16b, a dla f_w na rysunkach 17a i 17b. Metoda najmniejszych kwadratów daje linię prostą, a jej równanie i wartości R^2 odnoszące się do danych z ćwiczeń i sprawdzania są pokazane na tych rysunkach. Także wartości wejściowe i doświadczalne oraz rezultaty ze sprawdzania modeli GEP-I i GEP-II są podane w tabelicy 7. Jak to wynika z rysunków 16 i 17 wartości otrzymane z ćwiczenia i sprawdzania modeli GEP-I i GEP-II są bardzo bliskie wartościom doświadczalnym. Wyniki etapu sprawdzania naniesione na rysunkach 16 i 17 potwierdzają, że modele GEP-I i GEP-II mogą uogólniać zmienne wejściowe i wyjściowe ze stosunkowo dobrą dokładnością. Wyniki uzyskane z modeli GEP-I i GEP-II w przypadku f_c i f_w pokazano odpowiednio na rysunkach 16 i 17. Najlepsze wartości R^2 wynoszą 96,14% i 95,82% dla zbioru wyników z ćwiczenia modelu GEP-II, dotyczą odpowiednio wytrzymałości na zginanie i procentowej nasiąkliwości. Minimalne wartości R^2 wynoszą 86,52% i 85,55%, należą do zbioru ćwiczenia modelu GEP-I i dotyczą odpowiednio wytrzymałości na zginanie i procentowej nasiąkliwości. Wszystkie dane statystyczne wykazują, że zaproponowane modele GEP-I i GEP-II są przydatne do przewidywania wartości f_c i f_w i dla każdego wieku są bliskie wynikom doświadczalnym.

7. Dyskusja

Sieci neuronowe mogą uczyć się i uogólniać w oparciu o przykłady i doświadczenie. W związku z tym sieci neuronowe są doskonałym narzędziem do rozwiązywania niektórych skomplikowanych problemów inżynierskich. W tej pracy wykorzystując te właściwo-



(a)



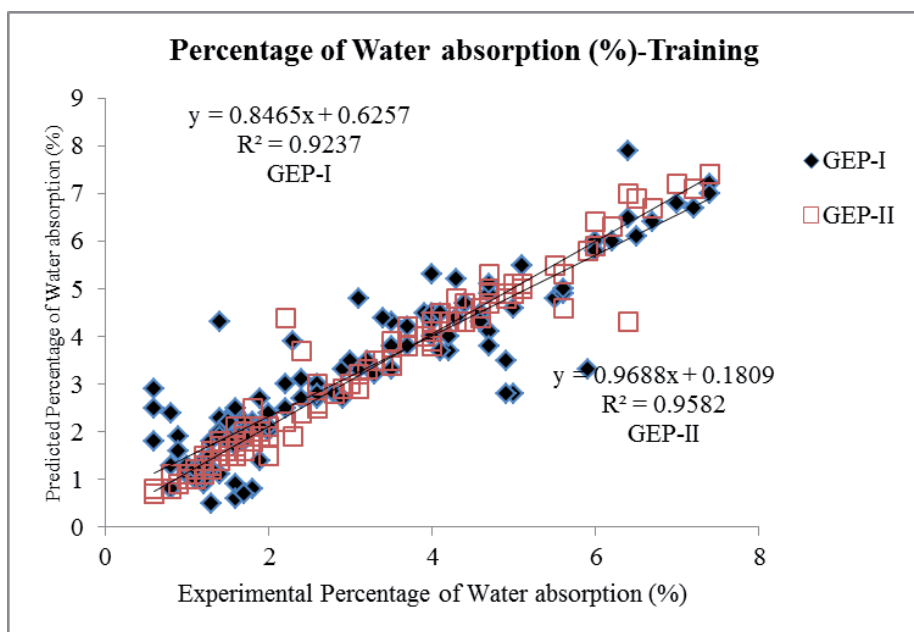
(b)

Rys. 16. Korelacja zmierzonych i prognozowanych wytrzymałości na zginanie modeli GEP: a) ćwiczenie, b) pomiar

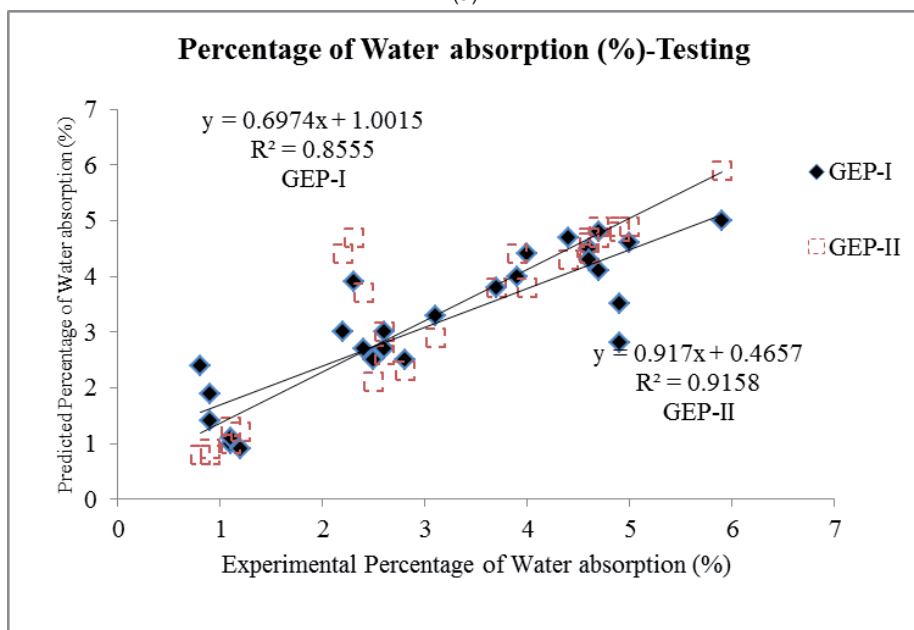
Fig. 16. The correlation of the measured and predicted flexural strengths in a) training and b) testing phase for GEP models

predicted from training and testing, for ANN-I and ANN-II models, are very close to the experimental results. Furthermore, according to the flexural strength and percentage of water absorption results predicted by using ANN-I and ANN-II models, the results of ANN-II model are closer to the experimental results. R^2 values that are calculated for comparing experimental results with ANN-I and ANN-II model results have shown this situation.

In addition, this study reports a new and efficient approach for the formulation of concrete containing Fe_2O_3 nanoparticles using GEP. Two different GEP-I and GEP-II approach models are proposed in order to predict flexural strength and percentage of water absorption values of concrete containing Fe_2O_3 nanoparticles. The proposed models are empirical and based on experimental results.



(a)



(b)

Rys. 17. Korelacja zmierzonych i prognozowanych nasiąkliwości wodą: a) ćwiczenie, b) pomiar; modele GEP

Fig. 17. The correlation of the measured and predicted percentage of water absorption in a) training and b) testing phase for GEP models

ści sieci neuronowych do prognozowania wytrzymałości na zginanie i nasiąkliwości betonów z dodatkiem nano-cząstek Fe_2O_3 , jeszcze przed rozpoczęciem doświadczeń, opracowano dwie różne wielowarstwowe sieci neuronowe SN-I i SN-II. W tych dwóch metodach zastosowano wielowarstwowe wprowadzanie sygnałów wejściowych i z algorytmem wstecznej propagacji. Proces uczenia tych modeli polegał na zastosowaniu danych wejściowych i wyjściowych. Stosując jedynie dane wejściowe w ćwiczonych modelach znaleziono wytrzymałość na zginanie oraz ilość pochłanianej wody w przypadku betonów zawierających nano-cząstki Fe_2O_3 .

Wytrzymałość na zginanie oraz nasiąkliwość prognozowane na podstawie ćwiczania sprawdzania modeli SN-I i SN-II bardzo nieznacznie różnią się od wyników doświadczalnych. Ponadto na pod-

The models developed in this study are used to be the number of genes 3 and 4, and the linking function addition and multiplication, respectively. All of the results obtained from the models show excellent agreement with experimental results. The statistical values of R^2 have shown this situation. Also, the proposed models are so simple that they can be used by anyone not necessarily familiar with GEP. Moreover, it is concluded that GEP is a good soft computing technique for use in concrete properties prediction. As a result, GEP may serve as a strong approach model and it may open a new area for the accurate and effective explicit formulation of many civil engineering problems. From the predicted results for flexural strength and percentage of water absorption, it is concluded that ANN models are more suitable for prediction the concrete properties. This conclusion is made on the R^2 values obtained from different applied models. However, application of GEP as a result of its simplicity is a relatively suitable approach for prediction the concrete properties.

8. Conclusions

1. Fe_2O_3 nanoparticles showed their positive influence on flexural strength and percentage water absorption up to 1.0 weight percent in N-W series concrete, up to 2.0 weight percent in N-LW series concrete and finally up to 4.0 weight percent in N-SCC series concrete. The deficiency in dispersion of nanoparticles more than the mentioned values causes the reduction of nanoparticles effects on improving flexural strength and percentage water absorption results.
2. ANN and GEP can be an alternative approach for the evaluation of the effect of cementitious material on the flexural strength and percentage water absorption. There is an optimum replacement ratio of Fe_2O_3 nanoparticles existed; this value can be predicted using ANN and GEP models.
3. ANN and GEP are efficient for predicting the flexural strength of Fe_2O_3 nanoparticles concrete. Comparison between ANN and GEP in terms of R^2 , showed that ANN provides better results than the GEP results.

Literatura / References

1. G. Ye, P. Lura, K. van Breugel, Modeling of water permeability in cementitious materials. *Mat. and Struct.*, **39**, 877 (2006).

stawie porównania otrzymanych wyników wytrzymałości na zginanie i nasiąkliwości z prognozowanymi przez modele SN-I i SN-II można stwierdzić, że ten ostatni daje wyniki bliższe doświadczalnych. Obliczony R^2 w celu porównania z modelem SN-I i SN-II, co potwierdziło te ustalenia.

Ponadto ta praca powoduje nowe i skuteczne podejście do stosowania sieci genetycznych w celu programowania doboru składu betonu z dodatkiem nano- Fe_2O_3 . Zastosowano dwa różne modele tych sieci GEP-I i GEP-II w celu prognozowania wytrzymałości na zginanie i poziomu nasiąkliwości betonów zawierających nano-cząstki Fe_2O_3 . Zaproponowane modele są empiryczne i opierają się na wynikach doświadczalnych. W modelach opracowanych w tej pracy zastosowano 3 i 4 geny jako funkcje łączące: dodawanie i mnożenie. Wszystkie wyniki otrzymane za pomocą tych modeli wykazały doskonałą zgodność z wynikami doświadczalnymi. Potwierdziły to także statystyczne wartości R^2 . Zaproponowane modele są proste i mogą być zastosowane przez każdego, niekoniecznie zaznajomionego z sieciami genetycznymi. Ponadto można stwierdzić, że GEP jest dobrą techniką obliczeniową do prognozowania właściwości betonu. W związku z tym GEP pozwala na opracowanie bardzo dobrych modeli, co daje możliwość dokładnego i skutecznego rozwiązywania wielu problemów inżynierskich.

Na podstawie prognozowanej wytrzymałości na zginanie i nasiąkliwości i uzyskanych wyników można stwierdzić, że modele oparte na sieciach neuronowych są bardziej przydatne do prognozowania właściwości betonu. ten wniosek opiera się na wartościach R^2 uzyskanych w przypadku różnych modeli. Jednak korzystanie z sieci genetycznych daje także proste i stosunkowo przydatne podejście do programowania właściwości betonu.

8. Wnioski

1. Nano-cząstki Fe_2O_3 wykazują korzystny wpływ na wytrzymałość na zginanie i nasiąkliwość w ilościach do 1% w przypadku wibrowanych betonów dojrzewających w wodzie i do 2% w przypadku betonów wibrowanych i dojrzewających w wodzie wapiennej oraz w końcu do 4% w przypadku betonów samozagęszczających się. Trudności w równomiernym rozproszczeniu nano-cząstek przy większym ich dodatku zmniejszają wpływ ich dodatku na obie podane właściwości betonu.
2. Sieci neuronowe genetyczne mogą stanowić wariantowe metody do prognozowania wpływu spoiwa na wytrzymałość na zginanie i nasiąkliwość betonu. Jak wspomniano, jest pewna optymalna zawartość Fe_2O_3 , którą można przewidzieć w oparciu o prognozy za pomocą modeli stosujących sieci neuronowe lub genetyczne.
3. Modele oparte na sieciach neuronowych i genetycznych są skutecznymi metodami do prognozowania wytrzymałości na zginanie betonu z dodatkiem nano- Fe_2O_3 . Porównanie modeli opartych na sieciach neuronowych lub genetycznych za pomocą R^2 wykazało, że te pierwsze dają lepsze dokładności.

2. N. Hong-Guang, W. Ji-Zong, Prediction of compressive strength of concrete by neural networks. *Cem. Concr. Res.*, **30**, 8, 1245 (2000).
3. M. Pala, O. Ozbay, A. Oztas, M. I. Yuce, Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks. *Constr. Build. Mat.*, **21**, 2, 384 (2005).
4. S. Akkurt, G. Tayfur, S. Can, Fuzzy logic model for prediction of cement compressive strength. *Cem. Concr. Res.*, **34**, 8, 1429 (2004).
5. A. Baykasoglu, T. Dereli, S. Tanis, Prediction of cement strength using soft computing techniques. *Cem. Concr. Res.*, **34**, 11, 2083 (2004).
6. S. Akkurt, S. Ozdemir, G. Tayfur, B. Akyol, The use of GA-ANNs in the modelling of compressive strength of cement mortar. *Cem. Concr. Res.*, **33**, 7, 973 (2003).
7. A. Cevik, M. Sonebi, Genetic programming based formulation for fresh and hardened properties of self-compacting concrete containing pulverised fuel ash. *Constr. Build. Mat.*, **23**, 7, 2614 (2009).
8. A. Cevik, M. Sonebi, Modelling the performance of self-compacting SIFCON of cement slurries using genetic programming technique. *Comput. Concr.*, **5**, 5, 475 (2008).
9. ASTM C150, Standard Specification for Portland Cement, annual book of ASTM standards, ASTM, Philadelphia, PA; 2001.
10. ASTM C39, Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens, ASTM, Philadelphia, PA; 2001.
11. ASTM C642, Standard Test Method for Density, Absorption, and Voids in Hardened Concrete, ASTM, Philadelphia, PA; 2001.
12. J. Y. Shih, T. P. Chang, T. C. Hsiao, Effect of nanosilica on characterization of Portland cement composite, *Cem. Concr. Res.*, **36**, 697 (2006).
13. A. Nazari, G. Khalaj, S. Riahi, M. J. Khalaj, The influence of Al_2O_3 nanoparticles on the properties of traditional concrete with ground granulated blastfurnace slag as binder. *Cement Wapno Beton*, **78**, 311 (2011).
14. H. Li, M. Zhang, J. Ou, Flexural fatigue performance of concrete containing nanoparticles for pavement, *Int. J. Fatigue*, **29**, 1292 (2007).
15. Q. Ye, The study and development of the nano-composite cement structure materials. *New building materials*, **1**, 4 (2001).
16. A. Mukherjee, S. N. Biswas, Artificial neural networks in prediction of mechanical behavior of concrete at high temperature. *Nucl. Eng. Design.*, **178**, 1, 1 (1997).
17. R. Ince, Prediction of fracture parameters of concrete by artificial neural networks. *Eng. Fract. Mech.*, **71**, 15, 2143 (2004).
18. W. S. McCulloch, W. Pitts. A logical calculus of the ideas immanent in neural nets. *Bull. Math. Biophys.*, **5**, 115, 37 (1943).
19. F. Rosenblatt, Principles of neuro dynamics: perceptrons and the theory of brain mechanisms. Washington, DC, Spartan Books 1962.
20. D. E. Rumelhart, G. E. Hinton, R. J. William, Learning internal representation by error propagation. In: Rumelhart DE, McClelland JL, editors. *Proceeding parallel distributed processing foundation*, vol. 1., Cambridge, MIT Press 1986.
21. S. W. Liu, J. H. Huang, J. C. Sung, C. C. Lee, Detection of cracks using neural networks and computational mechanics. *Comput. Meth. Appl. Mech. Eng.*, **191**, 25–26, 2831 (2002).
22. J. A. Anderson, Cognitive and psychological computation with neural models. *IEEE Trans. Syst. Man. Cybernetics*, V. SMC-13, **5**, 799 (1983).
23. J. J. Hopfield, Neural networks and physical systems with emergent collective computational abilities. *Proc. Nat. Acad. Sci.*, **79**, 2554 (1982).
24. A.A. Suratgar, M. B. Tavakoli, A. Hoseinabadi, Modified Levenberg–Marquardt method for neural networks training. *World Acad. Sci. Eng. Technol.*, **6**, 46 (2005).

25. J. R. Koza, Genetic programming: on the programming of computers by means of natural selection. Cambridge, MA, MIT Press 1992.
26. C. Ferreira, Gene expression programming in problem solving. In: Invited tutorial of the 6th online world conference on soft computing in industrial applications, 2001.
27. C. Ferreira, Gene expression programming: a new adaptive algorithm for solving problems. *Complex. Syst.*, **13**, 2, 87 (2001).
28. C. Ferreira, Gene expression programming: mathematical modeling by an artificial intelligence, 2002.
29. C. Ferreira, Gene expression programming in problem solving. In: 6th Online world conference on soft computing in industrial applications (invited tutorial), 2001.
30. O. N. Çiftci, S. Fadiloğlu, F. Goğuş, A. Guven, Genetic programming approach to predict a model acidolysis system. *Eng. Appl. Artif. Intell.*, **22**, 4–5, 759 (2009).
31. I. B. Topcu, M. Saridemir, Prediction of compressive strength of concrete containing fly ash using artificial neural network and fuzzy logic. *Comp. Mater. Sci.*, **41** 3, 305 (2008).