

Dariusz ALTERMAN\*

Instytut Podstawowych Problemów Techniki PAN

## METODY SZTUCZNEJ INTELIGENCJI W PRZEWIDYWANIU CECH BETONU NA PODSTAWIE ANALIZY STRUKTURY

**Streszczenie.** Referat poświęcony jest możliwościom automatycznego przewidywania cech betonu na podstawie charakterystyk jego struktury. Techniki Sztucznej Inteligencji (SI) zastosowano w celu odkrycia wiedzy zawartej w wynikach przeprowadzonych badań. Dwie nowe techniki SI wykorzystano w analizie wytrzymałości na ściskanie oraz mrozoodporności betonu.

## ARTIFICIAL INTELLIGENCE METHODS IN PREDICTING PROPERTIES OF CONCRETE FROM STRUCTURAL ANALYSIS

**Summary.** The paper is dedicated to possibilities of predicting properties of concrete from its structural characteristics. Selected techniques of Artificial Intelligence (AI) were applied to extract knowledge hidden in tests results. Two new AI techniques were used successfully in analysis of strength and frost resistance features of concrete.

### 1. Narzędzia automatycznej analizy danych oraz ich zastosowanie

Zastosowanie metod SI w opisywanym tu zakresie polega na wykorzystaniu dostępnych przykładów uzyskanych z doświadczeń w specjalnej procedurze automatycznego analizowania wyników eksperymentów. Jak dotąd, dość rzadko wykorzystuje się metody Sztucznej Inteligencji w dziedzinie nauki o materiałach betonowych. Obecnie podejmowane próby stosowania SI otwierają nadzieję na możliwość łączenia różnych metod w celu automatycznego znajdowania wiedzy ukrytej w bazach danych, a nawet powiązania jej z tradycyjnym ujęciem inżynierskim.

Rzeczywista baza danych może pochodzić z różnych źródeł i zawierać zarówno dane jakościowe, jak i ilościowe, informację niepełną, czasami wadliwą, często o ograniczonej wiarygodności. Zastosowanie metod SI może następować w dwóch podstawowych

---

\* Opiekun naukowy: Prof. dr hab. inż. Janusz Kasperkiewicz

kierunkach, rozpoznawania ilościowego i jakościowego. Pierwszej możliwości dostarczają sztuczne sieci neuronowe (SSN), [1, 2], które trenowane na bazie danych o znanych właściwościach pozwalają następnie przewidzieć ważne, a nieznane dla użytkownika cechy betonu. Jednak sztuczna sieć neuronowa posiada konstrukcję typu *black box* i służy jako narzędzie jedynie do przewidywania wartości nieznanymi cech. Wyniki takie są traktowane z pewną podejrzliwością przez ludzi, którzy przejawiają na ogół większe zaufanie do werbalnych opisów i możliwie obszernych pojęć, zwłaszcza prowadzących do formuł matematycznych.

Interesujące możliwości otwiera tutaj uczenie maszynowe (ML – *Machine Learning*) [3], dzięki któremu można tworzyć pewne pojęcia automatycznie, przez naukę z obserwacji cech przedmiotów. Jest to druga wzmiankowana powyżej alternatywa. W odróżnieniu od SSN programy ML są zdolne przetworzyć niedoskonałe dane pochodzące z rzeczywistych obserwacji. Najważniejszą zaletą jest to, że metody uczenia maszynowego można stosować w odniesieniu do danych jakościowych, w przeciwieństwie do metod SSN, które pozwalają analizować jedynie dane ilościowe. W rezultacie generowane są pewne reguły, pozwalające określić ważne cechy materiału, którego dotyczy baza danych.

Metody omówione powyżej można próbować łączyć [4]. W tekście ograniczono się do przedstawienia możliwości wykorzystania wybranych metod SI. Przeprowadzone eksperymenty zostały wykonane z pomocą procedur: *Fuzzy ARTMAP* (program SSN), [5], *aq19* i *See5* (dwa programy ML), [6, 7].

Wyniki pochodzą z bezpośrednich obserwacji struktury betonu na podstawie badania niektórych cech mechanicznych oraz analizy obrazu (IA – *Image Analysis*).

## 2. Baza danych

Baza danych, jaka jest tu rozważana – to uporządkowany zestaw informacji na temat: materiału, elementów jego struktury oraz eksploatacji materiału itd. Baza składa się z rekordów, a rekordy z atrybutów. Zawartością pól bazy danych, którą można wyobrazić sobie jako macierz złożoną z wierszy i kolumn, mogą być nie tylko liczby, ale także: charakterystyki jakościowe, nazwy, zmienne boolowskie, zmienne cykliczne, kategorie itd. Istotnymi elementami, od których zależy ewentualny sposób wyzyskania danej bazy, są: rozmiar, kompletność i wiarygodność.

Prosty eksperyment, realizowany przy założeniu braku synergistycznych efektów, mógł niekiedy zadowalać użytkownika, zawierając stosunkowo niewielką liczbę punktów doświadczalnych, odpowiadających poszczególnym rekordom. W skrajnej sytuacji, przyjmowanej niekiedy w prostych schematach planowania doświadczeń, liczba przypadków jest ograniczana do dwóch, np. minimalna i maksymalna zawartość powietrza w stwardniałym betonie. W pochodzących ze współcześnie realizowanych eksperymentach, zbiory danych liczby rekordów mogą iść w tysiące, co przy licznych atrybutach praktycznie uniemożliwia ich analizowanie na zasadzie przeglądu. Wyobraźnia i intuicja ludzka stosunkowo nieźle radzi sobie w przestrzeniach dwu – lub trójwymiarowych, gorzej jednak w przestrzeni wielowymiarowej. W wypadku danych wyłącznie numerycznych rozszerzenie pojęcia na wiele wymiarów jest oczywiste. Natomiast rozszerzenie, podczas gdy występują zmienne jakościowe, jest dalece nieoczywiste i jest to problem oczekujący na rozwiązanie.

W rezultacie przeprowadzonych eksperymentów w IPPT PAN zestawiono niewielką bazę danych dotyczącą badania mrozoodporności metodą Borås [8, 9].

Baza ta składa się z 16 rekordów. Struktura danych jest 6+2, co oznacza, że 6 atrybutów w każdym rekordzie dotyczy wejścia, a 2 wyjścia. Atrybuty wejściowe – to wyniki przeprowadzonych badań i w tym rozpatrywanym przypadku są nimi: gęstość betonu, zawartość powietrza w stwardniałym betonie, powierzchnia właściwa porów, współczynnik rozstawu porów, moduł sprężystości betonu oraz obecność pyłów krzemionkowych. Dwa atrybuty wyjściowe – to wytrzymałość 28-dniowa betonu na ściskanie oraz jego mrozoodporność. Inne wielkości, które niewątpliwie także wpływają na wytrzymałość i mrozoodporność betonu, nie były w tym doświadczeniu mierzone lub brane pod uwagę. Atrybut świadczący o zawartości pyłów krzemionkowych został uproszczony do zmiennej boolowskiej i ma dwie wartości yes lub no. Mrozoodporność została określona metodą Borås, przy czym przyjęto, że beton mrozoodporny to ten, którego ubytek masy przy powierzchniowym łuszczeniu po 56 cyklach zamarzania nie przekracza  $1\text{kg/m}^2$  i został zdefiniowany jako *non\_frost\_resistant*. Wartość drugiego atrybutu wyjściowego określono jako *frost\_resistant* i odpowiada betonowi niemrozoodpornemu. Struktura bazy danych jest wyjaśniona w tabeli 1.

Tabela 1

## Struktura bazy danych

Atrybut	Jednostki	Oznaczenie	Typ	Min	Max	Atrybuty nominalne		Uwagi
						Liczba przyp.	Lista wartości	
Gęstość	[kg/m <sup>3</sup> ]	density	con	1959	2504			
Zawartość powietrza	[%]	air	con	2.21	7.4			pomiar: IA
Powierzchnia właściwa porów	[1/mm]	spec_surf	con	9.08	44			pomiar: IA
Współczynnik rozstawu porów	[mm]	L	con	0.12	0.94			pomiar: IA
Moduł Younga	[GPa]	E	con	32.9	53.63			
Obecność pyłów krzemionkowych	[-]	SF	nom			2	yes, no	
Wytrzymałość na ściskanie	[MPa]	fc28	con	28.9	91.7			28-dniowa
Mrozoodporność	[-]	resistance	nom			2	yes, no	określona metodą Borås (po 56 dniach)

Całkowita, analizowana baza danych została przedstawiona w tabeli 2.

Tabela 2

## Całkowita baza danych zawierająca 16 rekordów

Lp.	Seria	$\rho$	A	$\alpha$	L	E	SF	fc	FR
		[kg/m <sup>3</sup> ]	[%]	[1/mm]	[mm]	[GPa]	[-]	[MPa]	[kg/m <sup>2</sup> ]
1	B20	2373	2.6	20.82	0.28	34.3	no	28.9	1.148
2	B30	2315	2.2	14.02	0.52	32.9	no	38.8	3.0935
3	B40	2422	1.5	28.67	0.94	52.9	no	49.4	1.0585
4	B30 IIIA	2388	3.8	9.08	0.62	46.4	no	53.3	7.2935
5	B50	2504	7.4	25	0.12	48.6	no	65.9	0.016
6	Beton I	2333	4.8	28	0.22		no	49.3	0.055
7	Beton II	2348	4.2				no	50.0	1.27
8	Beton III	2369	5.6				no	52.7	1.73
9	Beton IV	2351	5.6				no	57.2	1.21
10	Beton V	2359	4.4	44	0.20		no	53.1	1.82
11	S3/1	2475	2.21	22.96	0.3	53.6	yes	84.6	0.156
12	S3/2	2498	4.05	13.01	0.37	53.2	yes	91.7	0.1018
13	S3/3	1959	4	20.63	0.24	45.9	yes	79.3	0.12
14	S3/4	2391	3	17.24	0.33	47.1	yes	74.1	0.073
15	S3/5	2379	4.08	17.17	0.29	52.9	yes	88.3	0.054
16	S3/6	2453	5.11	16.47	0.28	51.9	yes	76.7	0.035

tutaj:  $\rho$  - gęstość betonu, A - zawartość powietrza,  $\alpha$  - powierzchnia właściwa porów,

L - współczynnik rozstawu porów, E - moduł Younga, SF - obecność pyłów

krzemionkowych, fc - wytrzymałość 28-dniowa betonu na ściskanie, FR - ubytek masy

określony metodą Borås po 56 cyklach zamrażania i odmrażania.

### 3. Eksperymenty na sztucznych sieciach neuronowych

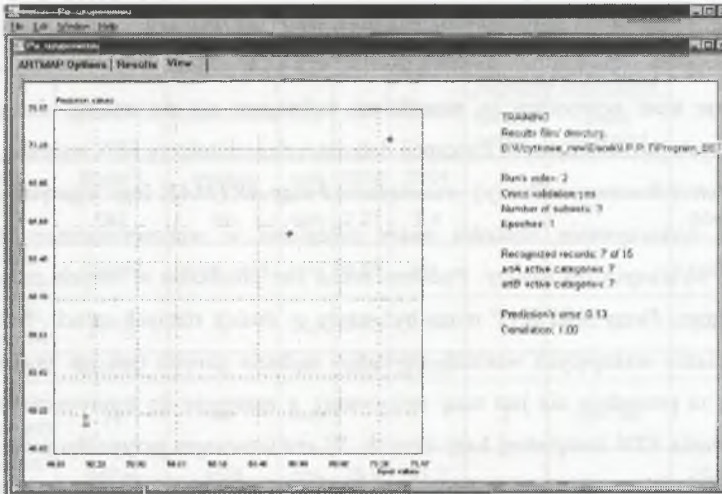
Sztuczne sieci neuronowe są narzędziem nadającym się do analizy danych czysto numerycznych. Spośród różnych koncepcji dotyczących architektury SSN wybrano sieci typu ART (*Adaptive Resonance Theory*) - rozwiązanie *Fuzzy ARTMAP*. Jego algorytm umożliwia efektywne wykorzystanie bliskości miary odległości w wielowymiarowej przestrzeni atrybutów wybranych do analizy. Podobna cecha jest nieobecna w innych rozwiązaniach SSN. Program *Fuzzy ARTMAP* może być użyty w dwóch różnych rolach. Służyć może do uzupełnienia brakujących wartości atrybutów w bazie danych (jak np. pustych miejsc w tabeli 2, ta procedura nie jest tutaj opisywana), a następnie do testowania dokładności przewidywania SSN kompletnej bazy danych. W analizowanym przypadku program został użyty do przewidywania wytrzymałości betonu na ściskanie przy uczeniu sieci neuronowej na przypadkowo wybranych 7 rekordach z bazy danych, wykorzystując procedurę cross-validation. Następnie przetestowano wytrenowaną sieć na 9 pozostałych rekordach. Struktura danych w tym przypadku była 6+1, przy czym jedyną zmienną wyjaśniającą był atrybut wytrzymałość na ściskanie betonu. Procedura okazała się być efektywna przy nastawieniu parametrów, tak jak pokazano w tabeli 3.

Tabela 3  
Wybrane parametry nastawienia programu  
*Fuzzy ARTMAP* [5]

Parametry:	Wartości:
- artA	
rho:	0.9999
- artB	
rho:	0.9992
- prediction	
rho:	0.99
epochs:	1
cross validation	yes

tutaj: rho – współczynnik dopasowania sieci

Wynik testowania na zbiorze uczącym z wykorzystaniem procedury cross-validation został przedstawiony na rysunku 1. Średni błąd przewidywania przy powyższych nastawieniach parametrów wynosił 0.13%, a współczynnik korelacji przewidywania danych wynosił około 100%, przy 7 z 15 rozpoznanych rekordach.



Rys. 1. Przykład ekranu wyników pokazujący predykcję wytrzymałości betonu na ściskanie, otrzymaną z wykorzystaniem programu Beton (*Fuzzy ARTMAP*). Wytrzymałość faktyczna na osi odciętych (w MPa), predykcja wytrzymałości na osi rzędnych

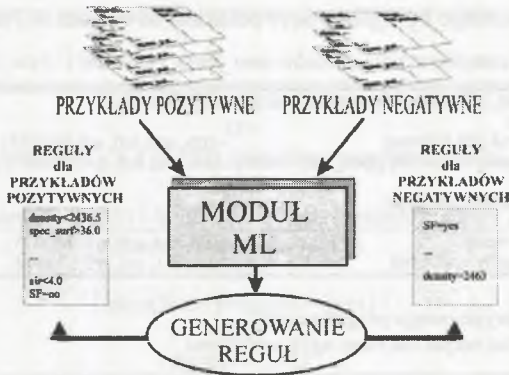
Fig. 1. Predictions of the strength of concrete, obtained by Beton program (*Fuzzy ARTMAP*). This is a copy of the program output screen. The actual strength values (in MPa) are on abscissa, the predictions – on the ordinates

#### 4. Eksperymenty z programami uczenia maszynowego (ML)

W systemach uczenia maszynowego (ML) program odgaduje zasadę przypisywaną do wyróżnionych kategorii rekordów w zależności od występowania w nich specyficznych kombinacji atrybutów. Przydział do kategorii tworzenie tzw. „gwiazdy” (*star*) zależy jest od nastawienia parametrów systemu. Analizowana baza danych musi być uprzednio przygotowana przez odpowiednie opisanie struktury.

W eksperymentach stosowano dwa odmienne programy *aq19* oraz *See5*, które generują reguły na podstawie przykładów. Cała rodzina programów (*aq15*, *aq18*, *aq19*) tworzy reguły, których wartość ocenić można na podstawie: liczby reguł, liczby warunków, prostoty warunków lub ich kombinacji.

Analizowana baza została podzielona na dwie klasy (przykłady pozytywne i negatywne, klas jednak może być więcej) i w ten sposób były generowane reguły oddzielnie dla każdej z klas, co objaśnia poniższy rysunek.



Rys. 2. Schemat generowania reguł przy pomocy programu aq19  
 Fig. 2. Functional scheme of rules generation by aq19

Programy uczenia maszynowego (ML) analizują dane nie tylko jako liczby, ale także w postaci klas i opisów tekstowych. Przetwarzanie danych przez programy *aq19* i *See5* polega na analizowaniu podzbiorów wszystkich rekordów według wybranego kryterium. W przedstawionym przykładzie z analizy struktury danych, wg tabeli 2, rekordy zostały podzielone jako mrozoodporne (*frost\_resistant*) i niemrozoodporne (*non\_frost\_resistant*).

Przykład skryptu zawierającego tylko minimum opisu wymaganego przez program *aq19* pokazano na rysunek 3.

Variables							SF-names								
#	type	size	cost	name			valuc name								
1	con	1	1	density.density			0 yes								
2	con	1	1	fc28.fc28			1 no								
3	con	1	1	air.air											
4	con	1	1	spec_surf.spec_surf											
5	con	1	1	L.L											
6	con	1	1	E.E											
7	nom	2	1	SF.SF											
non_frost_resistant-events								frost_resistant-events							
#	density	air	spec_surf	L	E	SF	fc28	#	density	air	spec_surf	L	E	SF	fc28
1	2373	2.6	20.82	0.28	34.3	no	28.9	5	2504	7.4	25	0.12	48.6	no	65.9
2	2315	2.2	14.02	0.52	32.9	no	38.8	6	2333	4.8	28	0.22	?	no	49.3
3	2422	1.5	28.67	0.94	52.9	no	49.4	11	2475	2.21	22.96	0.3	53.6	yes	84.6
4	2388	3.8	9.08	0.62	46.4	no	53.3	12	2498	4.05	13.01	0.37	53.2	yes	91.7
7	2348	4.2	?	?	?	no	50.0	13	1959	4	20.63	0.24	45.9	yes	79.3
8	2369	5.6	?	?	?	no	52.7	14	2391	3	17.24	0.33	47.1	yes	74.1
9	2351	5.6	?	?	?	no	57.2	15	2379	4.08	17.17	0.29	52.9	yes	88.3
10	2359	4.4	44	0.20	?	no	53.1	16	2453	5.11	16.47	0.28	51.9	yes	76.7

Rys. 3. Przykład minimalnego skryptu wejściowego do programu aq19  
 Fig. 3. Example of a minimal input script for aq19 predictions

Przykład pliku wyjściowego z programu aq19 pokazano na rysunek 4. Program wygenerował po dwie reguły (tzw. *complexes*) dla zbiorów *non\_frost\_resistant* i *frost\_resistant*.

```

non_frost_resistant-outhypo
# rule
1 [air<4.00] [SF=no] (t:6, u:4, n:0, q:0.866025)
2 [density<2436.50] [spec_surf>36.00] (t:4, u:2, n:0, q:0.707107)

frost_resistant-outhypo
# rule
1 [SF=yes] (t:6, u:4, n:0, q:0.866025)
2 [density>2463.00] (t:3, u:1, n:0, q:0.612372)

```

Rys. 4. Przykład pliku wyjściowego programu aq19

Fig. 4. An example of the output file from aq19 predictions

Reguła ta może zostać przetłumaczona jako:

<p><b>Beton nie jest mrozoodporny</b></p> <p><b>IF:</b>  <math>\lceil \text{air content} &lt; 4.0 \rceil \text{ AND } \lceil \text{silica fume presence} = \{\text{no}\} \rceil</math></p> <p><b>OR:</b>  <math>\lceil \text{density} &lt; 2436.5 \rceil \text{ AND } \lceil \text{specific surface} &gt; 36.0 \rceil</math></p>
<p><b>Beton jest mrozoodpony</b></p> <p><b>IF:</b>  <math>\lceil \text{silica fume presence} = \{\text{yes}\} \rceil</math></p> <p><b>OR:</b>  <math>\lceil \text{density} &gt; 2463 \rceil</math></p>

W ramce powyższej jednostkami dotyczącymi poszczególnych komponentów są:  $[\text{kg}/\text{m}^3]$  dla gęstości betonu,  $[\text{l}/\text{mm}]$  dla powierzchni właściwej porów oraz  $[\%]$  w przypadku zawartości porów. Moc predykcji reguł uzyskano na wysokim poziomie około: 87% (współczynnik  $q=0.866$ ).

Podobne reguły otrzymano przy użyciu programu *See5*, np.:

<p>Rule 4/2: (4.2, lift 1.4)</p> <p>SF = yes  -&gt; class frost_resistant [0.840]</p>	<p>Rule 2/3: (3.2, lift 1.6)</p> <p>density &gt; 2453  class frost_resistant [0.807]</p>
<p>Rule 4/3: (3.5, lift 2.0)</p> <p>air &lt;= 4.4  SF = no  -&gt; class non frost resistant [0.819]</p>	<p>Rule 2/1: (8.4/1.6, lift 1.5)</p> <p>density &lt;= 2453  SF = no  -&gt; class non frost resistant [0.754]</p>

Występujące powyżej wartości w nawiasach (np. 3.5 lub 8.4/1.6) stanowią ocenę jakości reguły, definiowaną na podstawie względnej częstotliwości występowania klasy w zbiorze treningowym.



Przedstawione powyżej reguły zostały przetłumaczone jak poprzednio:

<p><b>Beton nie jest mrozoodporny</b></p> <p><b>IF:</b>  <math>\lceil \text{air content} \leq 4.4 \rceil \text{ AND } \lceil \text{silica fume presence} = \{\text{no}\} \rceil</math></p> <p><b>OR:</b>  <math>\lceil \text{density} \leq 2453 \rceil \text{ AND } \lceil \text{silica fume presence} = \{\text{no}\} \rceil</math></p>
<p><b>Beton jest mrozoodporny</b></p> <p><b>IF:</b>  <math>\lceil \text{silica fume presence} = \{\text{yes}\} \rceil</math></p> <p><b>OR:</b>  <math>\lceil \text{density} &gt; 2453 \rceil</math></p>

Jednostkami w ramce są:  $[\text{kg}/\text{m}^3]$  dla gęstości oraz [%] dla zawartości porów.

Otrzymane rezultaty zweryfikowano pozytywnie przy pomocy funkcji filtracji w Excelu.

## 5. Wnioski

Eksperymenty zostały wykonane w odniesieniu do bardzo małej bazy danych. Naturalnie w ten sposób ważność wyników jest w znacznym stopniu ograniczona. Przykład ten pokazuje jednak, że techniki SI mogą być poprawnie stosowane przy analizie baz danych z dziedziny inżynierii materiałów do przewidywania ich cech użytkowych.

Zaproponowana procedura łączy różne programy - *Fuzzy ARTMAP*, *aq18* i *See5*, których wyniki uzupełniają się wzajemnie. Potwierdza to możliwość efektywnego trenowania systemów SI na podstawie przykładów i możliwość skutecznego przewidywania właściwości oraz zachowania się materiałów.

Stwierdzono, że wcześniejsze ograniczenia w odniesieniu do SSN, polegające na konieczności odrzucania rekordów z brakującymi wartościami atrybutów z różnych eksperymentów, mogą być skutecznie wyeliminowane przez użycie programów uczenia maszynowego.

Programy ML posiadają zdolność generowania zasad (reguł) nieznanych wcześniej użytkownikom baz danych.

## LITERATURA

1. Kasperkiewicz J.: Artificial neural networks in engineering materials design, Proceedings of the International Conference "Challenges to Civil and Mechanical Engineering in 2000 and beyond", June 2-5, 1997, Wrocław, vol.I, 103-126.
2. Waszczyszyn Z.: Zastosowanie sztucznych sieci neuronowych w inżynierii lądowej, XLI Konf. Nauk. KILW i KN PZITB, t.9 – Materiały pokonferencyjne, Kraków 1996, 251-288.
3. Cichosz P.: Systemy uczące się, WNT, Warszawa 2000, s. 894.
4. Kasperkiewicz J., Alterman D.: Artificial Neural Networks in predicting properties of brittle matrix composites, in *Brittle Matrix Composites*, A.M. Brandt, V.C. Li, I.H. Marshall, Cambridge and Warsaw 2000, 485-496.
5. Kasperkiewicz J., Racz J., Dubrawski A.: HPC strength prediction using artificial neural network, *Journal of Computing in Civil Engineering*, v.9, No.4, October 1995, 279-284.
6. Michalski R.S., Kaufman K.A.: The AQ19 system for machine learning and pattern discovery: a general description and user's guide, George Mason University, MLI 01-2, March 2001, s.39.
7. Quinlan J.R., *C4.5: Programs for machine learning*, Morgan Kaufmann Publishers, San Mateo, California 1993, s.302.
8. Brandt A.M., Józwiak-Niedźwiedzka D.: Uszkodzenia powierzchni betonowych spowodowane cyklicznym zamrażaniem i odmrażaniem, XLVII Konferencja Naukowa KILiW i KN PZITB, Krynica, wrzesień 2001, 277-284.
9. Józwiak-Niedźwiedzka D.: Scaling resistance of different concretes tested with Borås method, International Symposium on Non-Traditional Cement&Concrete, Brno, June 2002.

Recenzent: Dr hab. inż. Jerzy Skrzypczyk, prof. Politechniki Śląskiej

**Abstract**

The paper is dedicated to possibilities of predicting properties of concrete from its structural characteristics. Selected techniques of Artificial Intelligence (AI) were applied to extract knowledge hidden in tests results. Two new AI techniques were used successfully in analysis of strength and frost resistance features of concrete.