

Primljen / Received: 24.9.2020.

Ispravljen / Corrected: 31.1.2021.

Prihvaćen / Accepted: 3.3.2021.

Dostupno online / Available online: 10.7.2021.

Usporedba metoda umjetne inteligencije za predviđanje tlačne čvrstoće betona

Autor:

Doc.dr.sc. **Mehmet Timur Cihan**, dipl.ing.građ.

Sveučilište Tekirdağ Namık Kemal, Turska

Fakultet tehničkih znanosti

Odjel za građevinarstvo

mehmetcihan@nku.edu.tr

Autor za korespondenciju

Prethodno priopćenje

Mehmet Timur Cihan

Usporedba metoda umjetne inteligencije za predviđanje tlačne čvrstoće betona

Tlačna čvrstoća betona je značajan parametar u projektiranju betona. Točnim predviđanjem tlačne čvrstoće betona mogu se smanjiti troškovi i ostvariti uštede u vremenu. U ovom radu se na temelju šest raznih međunarodnih nizova podataka uspoređuje uspješnost predviđanja vrijednosti tlačne čvrstoće betona primjenom nekoliko metoda baziranih na umjetnoj inteligenciji (prilagodljivi neuroneizraziti sustav, algoritam slučajnih šuma, linearna regresija, klasifikacijsko i regresijsko stablo, regresija potpornih vektora, metoda najbližih susjeda i stroj za ekstremno učenje). Učinak tih metoda procjenjuje se pomoću koeficijenta korelacije, korijena srednje kvadratne pogreške, srednje apsolutne pogreške i srednje apsolutne postotne pogreške. Usporedni rezultati pokazuju da je prilagodljivi neuroneizraziti sustav uspješniji od ostalih u svim nizovima podataka.

Ključne riječi:

umjetna inteligencija, regresija, ANFIS, tlačna čvrstoća betona, međunarodni podaci

Research Paper

Mehmet Timur Cihan

Comparison of artificial intelligence methods for predicting compressive strength of concrete

Compressive strength of concrete is an important parameter in concrete design. Accurate prediction of compressive strength of concrete can lower costs and save time. Therefore, the compressive strength of concrete prediction performance of artificial intelligence methods (adaptive neuro fuzzy inference system, random forest, linear regression, classification and regression tree, support vector regression, k-nearest neighbour and extreme learning machine) are compared in this study using six different multinational datasets. The performance of these methods is evaluated using the correlation coefficient, root mean square error, mean absolute error, and mean absolute percentage error criteria. Comparative results show that the adaptive neuro fuzzy inference system (ANFIS) is more successful in all datasets.

Key words:

artificial intelligence, regression, ANFIS, concrete compressive strength, multinational data

1. Uvod

Zbog svojih brojnih prednosti, beton se danas u građevinarstvu koristi više od svih drugih materijala. Vrlo velika proizvodnja betona doprinosi potrošnji prirodnih resursa (pijeska, šljunka ili drobljenog kamena). Osim toga, emisije stakleničkih plinova rastu usporedo s porastom potrošnje cementa [1]. Zbog toga se u proizvodnji betona upotrebljavaju dodatni materijali kako bi se smanjila potrošnja cementa i prirodnih resursa.

Predviđanje mehaničkih svojstava građevnih materijala danas je značajno područje istraživanja u znanosti o materijalima i općenito u građevinarstvu. U praksi se beton klasificira prema tlačnoj čvrstoći. Zbog toga je točna procjena tlačne čvrstoće betona itekako važna. Beton se sastoji od različitih komponenata (agregat, cement, voda i dodatni materijali), a te su komponente nasumično raspoređene u cementnoj matrici. Zbog složene strukture cementne matrice, broj ovisnih varijabli koje djeluju na tlačnu čvrstoću betona prilično je velik pa je stoga stopa predviđivosti tlačne čvrstoće betona vrlo niska [2, 3]. Međutim, uz pomoć novih tehnologija, točnost predviđanja tlačne čvrstoće betona može se povećati, a za to se koriste razne metode umjetne inteligencije (eng. *Artificial Intelligence* - AI).

Posljednjih su godina izrađene brojne studije o predviđanju tlačne čvrstoće betona na temelju njegovih sastojaka [4-19] te primjenom varijabli koje se istovremeno mogu kontrolirati [20, 21].

Radi održive proizvodnje i troškova, danas se u proizvodnji betona upotrebljava velik broj podataka (dodatnih materijala), što otežava postizanje zahtijevanih svojstava betona. Zbog toga je važno odrediti mogućnosti primjene metoda AI kako bi se što preciznije predviđela tlačna čvrstoća betona u projektiranju betona koji sadrže dodatne materijale. Topçu i Saridemir [4] te Başıyigit i dr. [6] koristili su umjetne neuronske mreže i modele neizrazite logike za predviđanje tlačne čvrstoće betona s dodatkom letećeg pepela. Osim toga, Sandemir [5] je usporedio umjetne neuronske mreže i modele neizrazite logike u svrhu predviđanja tlačne čvrstoće morta s dodatkom metakaolina, i to nakon 3, 7, 28, 60 i 90 dana. Sandemir [7] je razvio dva modela primjenjujući pristup evolucijskog programiranja gena (eng. *gene expression programming* - GEP) za predviđanje tlačne čvrstoće betona s dodatkom pepela rižinih ljusaka pri starosti betona od 1, 3, 7, 14, 28, 56 i 90 dana. Gilan [22] je razvio model regresije potpornih vektora (eng. *support vector regression* - SVR) [23] i optimalizacije rojem čestica (eng. *particle swarm optimization* - PSO) [24, 25] za predviđanje tlačne čvrstoće, te je koristio rezultate brzog prodiranja klorida u analizi betona s dodatkom metakaolina. Atici [26] je primijenio višestruku regresijsku analizu i umjetnu neuronsku mrežu za predviđanje tlačne čvrstoće betona kojemu su dodane različite količine podataka (zgure iz visokih peći i letećeg pepela) tijekom različitih razdoblja njege (3, 7, 28, 90 i 180 dana).

Istraživanje problema optimalizacije betona visoke čvrstoće iznimno je značajno za industriju betona, pa se stoga ti problemi istražuju pomoću višeciljne optimalizacije bazirane na regresijskoj analizi, umjetnoj neuronskoj mreži (eng. *Artificial*

Neural Network - ANN) i evolucijskom programiranju gena (eng. *Gene Expression Programming* - GEP) [27]. Osim toga, za predviđanje modula elastičnosti normalnog betona i betona visoke čvrstoće koriste se i potporni vektorski stroj (eng. *Support Vector Machine* - SVM), algoritam neizrazite logike i umjetne neuronske mreže [28-30].

Metode umjetne inteligencije također se primjenjuju za određivanje svojstava (tlačne čvrstoće) samozbijajućeg betona. Zhang i dr. [10] predložili su model slučajnih šuma baziran na ticalnom pretražnom algoritmu (engl. *beetle antennae search* - BAS) kao sredstva koje omogućuje predviđanje tlačne čvrstoće lakog samozbijajućeg betona. Primjenom neuronskih mreža, Siddique i dr. [9] usporedili su podatke iz literature s eksperimentalnim podacima u svrhu predviđanja tlačne čvrstoće samozbijajućeg betona. Uz to, Ghafoori i dr. [31] usporedili su linearne-nelinearne regresije i neuronske mreže kako bi predviđeli brzu difuziju klorida u samozbijajućem betonu, a na bazi udjela pojedinačnih komponenata betona.

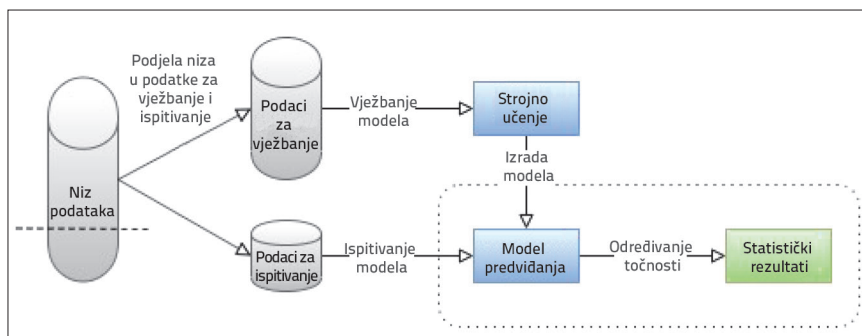
Sobhani i dr. [8] prikazali su primjenu pouzdanih modela ANN i ANFIS u predviđanju tlačne čvrstoće neslijegajućeg betona nakon 28 dana njege. Tsai [32] je predložio upotrebu modela hibridnog višeslojnog perceptrona kao sredstva za predviđanje čvrstoće betonskih uzoraka. Za predviđanje tlačne čvrstoće pri cijepanju te tlačne čvrstoće lakog betona pri visokim temperaturama, Tanyildizi i Çevik [33] koristili su genetsko programiranje (količina cementa: 400 i 500 kg/m³). Feng i dr. [11] predložili su novi pristup za predviđanje tlačne čvrstoće betona koji se temelji na algoritmu adaptivnog učenja.

U ovom se radu prikazuje uspješan općeniti model za predviđanje, koji se može primijeniti neovisno o vrsti niza podataka. Za te je potrebe korišteno šest raznih nizova podataka s raznim ulaznim varijablama te s raznim veličinama uzoraka. Jedan od tih nizova izradio je i autor ovog rada. Za predviđanje tlačne čvrstoće betona koristi se ANFIS, slučajne šume (RF), linearna regresija, klasifikacijsko i regresijsko stablo, regresija potpornih vektora, metoda najbližih susjeda i modeli za ekstremno učenje. Za ocjenu uspješnosti metoda umjetne inteligencije korištenih u ovom radu primjenjuje se korelacijski koeficijent (R), korijen srednje kvadratne pogreške (eng. *Root Mean Square Error* - RMSE), srednja apsolutna pogreška (MAE), srednja apsolutna postotna pogreška (eng. *Mean Absolute Percentage Error* - MAPE) i kriteriji vrijednosti p.

2. Metode i eksperimentalni postav

2.1. Modeli za predviđanje

Kod većine inženjerskih problema, varijable, koje zapravo i čine problem, ovisne su jedna o drugoj. Kada se jedna varijabla statički promijeni, ostale se varijable ne mijenjaju u jednakoj mjeri. Izuzetno je važno otkriti tu uzročnu vezu između varijabli. Regresijska analiza je izrada regresijske jednadžbe u svrhu predviđanja najtočnijega načina za procjenu vrijednosti varijable slučajnog odziva ovisne o vrijednosti neke druge ovisne varijable. U današnje se vrijeme sve više primjenjuju metode bazirane



Slika 1. Dijagram toka regresijske analize

na umjetnoj inteligenciji zato što su veličina nizova podataka, interakcija brojnih složenih varijabli, nelinearan odnos između ulaznih i izlaznih (ciljnih) varijabli te točnost predviđanja izlazne varijable. Regresijska analiza je podvrsta nadziranog učenja. U postupku nadziranog učenja algoritam se izučava pomoću niza podataka čiji ulazi odgovaraju izlaznim vrijednostima. Za ocjenu uspješnosti predviđanja izučavanog algoritma koristi se niz podataka za neovisno ispitivanje. Slika 1. prikazuje dijagram toka regresijske analize. Statistički proračuni i razrade modela provode se pomoću programskog jezika R [34].

2.1.1. Slučajna šuma (RF)

Metoda slučajnih šuma (eng. *Random Forest* - RF) je metoda grupnog učenja koja se koristi za klasifikaciju i regresiju. Prema toj metodi, mnoga se stabla odlučivanja kreiraju tijekom treniranja te se zatim u predviđanju koristi prosjek rezultata dobivenih pomoću tih stabala odlučivanja. Najznačajnija prednost metode slučajnih šuma je u tome što se njima dobiva rješenje problema pretjeranih prilagodbi u stablima odlučivanja. Ta metoda omogućuje jednostavno paralelno djelovanje jer je i sama jednostavna, a i otpornija je na ekstremne vrijednosti i buku. Ona je isto tako uspješnija od drugih metoda grupnog učenja [35, 36]. U ovom se radu u provođenju koristi paket *caret* [37] R.

2.1.2. Klasifikacijska i regresijska stabla odlučivanja (CART)

CART je algoritam stabla za donošenje odluka. On se koristi za rješavanje klasifikacijskih i regresijskih problema. Stablo za donošenje odluka služi za kreiranje modela stabla kojim se mogu ocijeniti vrijednosti izlaznih varijabli na temelju ulaznih varijabli iz niza podataka. U algoritmu *CART* koristi se Ginijev koeficijent kao kriterij podjele tipa binarne podjele, pri čemu se koriste kategorične ili kontinuirane varijable [38]. U ovom se radu u provođenju koristi paket *rpart* [39] R.

2.1.3. Regresija potpornih vektora (SVR)

U regresiji potpornih vektora, cilj je pronaći najvjerojatniju linearnu funkciju kojom se ocjenjuje grupa podataka u

prostoru s pogreškom epsilon (margina tolerancije). Ako se podaci mogu podijeliti linearno, podjela se može provesti izravno pomoću hiperravnine kojom se margina povećava do maksimuma. Ako se podaci ne mogu podijeliti linearno, oni se pripisuju prostoru više dimenzije pomoću jezgrene funkcije. Tako se određuju podaci za linearnu podjelu. Kao rezultat dobiva se funkcija $F(x)$ za pretvaranje ulaznih vrijednosti treniranja u izlazne

vrijednosti [23]. U ovom se radu u provođenju koristi ϵ 1071 R paket [40].

2.1.4. Algoritam k-najbližih susjeda (K-NN)

K-NN je algoritam utemeljen na uzorcima, a može se koristiti za rješavanje klasifikacijskih i regresijskih problema. Izračunavaju se udaljenosti između uzorka probnih podataka i svih uzoraka u nizu podataka za izučavanja kako bi se pronašao najbliži uzorak "k". Zatim se uprosječivanjem tih najbližih uzoraka izračunava izlazna varijabla [41]. U ovom se radu u provođenju koristi *FNN* R paket [42].

2.1.5. Strojevi za ekstremno učenje (ELM)

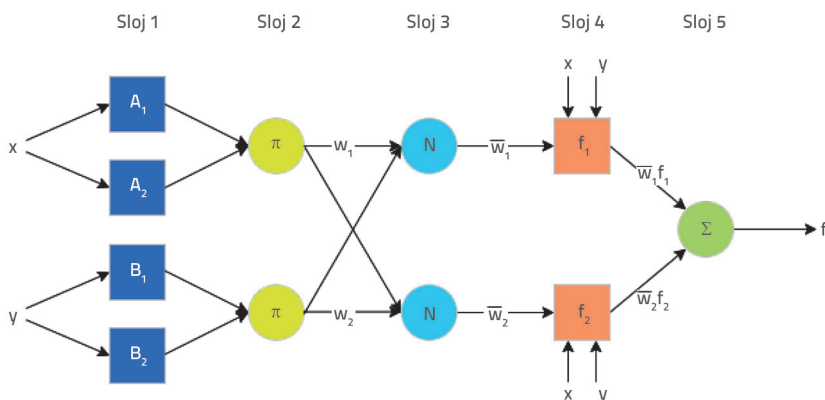
Strojevi za ekstremno učenje u osnovi su slični mrežama ANN s jednim skrivenim slojem. Princip rada strojeva ELM uglavnom je isti kao i onaj koji se koristi u mrežama ANN. U fazi obuke pomoću ELM-a ponderi i pristrane pogreške iz ulaznog sloja pripisuju se skrivenom sloju nasumce, a te se vrijednosti ne ažuriraju tijekom čitavog postupka [43]. Kao i kod umjetnih neuronskih mreža, i kod ELM-a je potrebna aktivacijska funkcija. Dostupne su brojne vrste takvih aktivacijskih funkcija, a može ih odabrati i sam korisnik [44]. U ovom se radu u provođenju koristi *elmNnrCp* R paket [45].

2.1.6. Linearna regresija (LR)

LR se koristi u brojnim istraživanjima zbog svoje jednostavnosti, djelotvornosti i učinkovitosti. Jednadžbom jednostruke regresije ($y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$) iskazuje se linearni odnos između neovisne varijable (x_1, x_2, \dots, x_n ulazna varijabla) i ovisne varijable (y , izlazna varijabla). Ovaj model u skladu je s ravnolinijskim modelima za određivanje odnosa između svake ulazne varijable i svake izlazne varijable [46]. U ovom se radu u provođenju koristi *stats* R paket [44].

2.1.7. Prilagodljivi neuroneizraziti sustav (ANFIS)

Metoda ANFIS temelji se na neizrazitom sustavu zaključivanja. ANFIS je model u kojem se koristi neizrazita logika i umjetne neuronske mreže. Ta metoda je djelotvoran model predviđanja,



Slika 2. Struktura ANFIS

a kategorizira se između neuroizrazitih sustava i postupaka strojnog učenja [48]. Algoritam za učenje ANFIS sastoji se od metode najmanjih kvadrata i algoritma povratnog prostiranja. Ulazni uzorci produciraju se u prvom koraku postupka učenja, a najbolji sekundarni parametri određuju se pomoću metoda najmanjih srednjih kvadrata. Ovdje se pretpostavlja da su primarni parametri konstantni. U drugom se koraku ulazni uzorci podvostručuju i zamjenjuju metodom gradijenta spuštavanja primarnih parametara, pri čemu se pretpostavlja da su sekundarni parametri konstantni. Zatim se taj postupak ponavlja [49-51]. U ovom se radu u provođenju koristi paket *frbs* R [52]. Struktura ANFIS prikazana je na slici 2.

U sloju 1 (sloj neizrazite pretvorbe), izlaz svakog čvora je funkcija pripadnosti kao što je Gausova, trokutasta, trapezoidna itd. U sloju 2 (sloj pravila), izlaz svakog čvora pravila množi se sa stupnjevim pripadnosti, a u proračunu se primjenjuje pravilo o snazi aktivacije. U sloju 3 (normalizacijski sloj), svi čvorovi koji dolaze iz sloja pravila prihvaćaju se kao ulazne vrijednosti te se izračunava normalizirana snaga aktivacije svakog pravila. Ponderirane vrijednosti pravila izračunavaju se u sloju 4 (sloj definiranja izrazite vrijednosti zaključka). Ukupan rezultati (a to je zbroj svih pravila) izračunava se u sloju 5 (sloj sumiranja). U tom se sloju nalazi samo jedan fiksni čvor [53].

2.2. Mjerenje učinkovitosti i validacijske metode

Različite strategije dijeljenja mogu se primijenjivati za potrebe uvježbavanje modela i ispitivanje njegove učinkovitosti [54, 55]. Valjanost uvježbanoga modela razlikuje se od valjanosti algoritma. Sposobnost generaliziranja modela ovisi o njegovoj učinkovitosti u pogledu neviđenih ispitanih vrijednosti. U ovom se radu niz podataka podijeljen primjenom pristupa 2/3 + 1/3. Nasumce odabrane dvijetrećine niza podataka koriste se za modeliranje uvježbavanja, a preostala trećina služi za učinkovitost uvježbanih modela. Modeli su provedeni deset puta te se nakon tih deset iteracija daju rasponi pogreške u predviđanju modela (tablica 4.). Kako bi se usporedile učinkovitosti svih modela, nakon toga se nizovi podataka nasumce dijele od iste točke primjenom pristupa ulaznih vrijednosti. Pokazatelji

učinkovitosti R , $RMSE$, MAE i $MAPE$ koriste se za validaciju učinkovitosti uvježbanih modela umjetne inteligencije na neviđenom nizu ispitanih vrijednosti (tablica 5.). Analize su provedene postupkom R programiranja [34].

- Korelacijski koeficijent (R): Vrijednost R označava stupanj linearne korelacije između registriranih (stvarnih/izmjerenih) i predviđenih vrijednosti tlačne čvrstoće. Vrijednost R varira od 0 do 1. Kako točnost predviđanja raste, tako raste i vrijednost R , tj. približava se vrijednosti 1. Vrijednost R može se prikazati kako slijedi:

$$R = \frac{\sum_i^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (1)$$

gdje je O registrirana vrijednost tlačne čvrstoće, \bar{O} je srednja registrirana vrijednost, P je predviđena tlačna čvrstoća prema razvijenom modelu umjetne inteligencije, a \bar{P} je srednja predviđena vrijednost.

Korijen srednje kvadratne pogreške ($RMSE$) označava standardno odstupanje razlike između registriranih i predviđenih vrijednosti tlačne čvrstoće. Poželjna je niža vrijednost $RMSE$. Ta se vrijednost izražava kako slijedi:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (P_i - O_i)^2} \quad (2)$$

Srednja apsolutna pogreška (MAE): Ovaj kriterij predstavlja prosječnu apsolutnu razliku između registrirane i predviđene tlačne čvrstoće. Niža vrijednost MAE označava bolju podudarnost modela. Ta se vrijednost označava kako slijedi:

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (3)$$

Srednja apsolutna postotna pogreška ($MAPE$): $MAPE$ je srednja apsolutna pogreška (registrirana vrijednost minus predviđena vrijednost) predviđenih vrijednosti tlačne čvrstoće. Niža vrijednost $MAPE$ označava bolju podudarnost modela. Ta se vrijednost označava kako slijedi:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{P_i - O_i}{O_i} \right| \quad (4)$$

2.3. Opis podataka

Točnost predviđanja modela ocijenjena je na temelju objavljenih međunarodnih nizova podataka [22, 56-58]. Kod svih nizova podataka, tlačna čvrstoća je izlazna varijabla, a ulazne varijable variraju u ovisnosti o konkretnim nizovima podataka. Statistički prikaz nizova podataka dan je u tablici 1.

Tablica 1. Statistički podaci o nizovima podataka

Opis	Kratica	Mjerna jedinica	Min.	Max.	Srednja vrijednost	Standardna devijacija	Smjer
Niz podataka 1: Turska (veličina uzorka: 104)							
Cement	<i>C</i>	kg/m ³	330	345	337,6	6,37	Ulaz
Tlačna čvrstoća cementa	<i>f_{cc}</i>	MPa	34,4	55,1	44,95	9,00	Ulaz
Superplastifikator	<i>SP</i>	kg/m ³	3,96	4,83	4,376	0,30	Ulaz
Voda	<i>W</i>	kg/m ³	142,8	217	180,2	18,22	Ulaz
Sitnozrnati agregat	<i>FA</i>	kg/m ³	827	1292	1078	135,72	Ulaz
Krupnozrnati agregat	<i>CA</i>	kg/m ³	543	1009	733,1	158,14	Ulaz
Tlačna čvrstoća betona	<i>f_c</i>	MPa	19,86	53,87	36,7	8,20	Izlaz
Niz podataka 2 [22]: Iran (veličina uzorka: 100)							
Cement	<i>C</i>	kg/m ³	320	400	358	24,62	Ulaz
Metakaolin	<i>M</i>	kg/m ³	0	80	42	24,62	Ulaz
Voda	<i>W</i>	kg/m ³	140	200	173,6	18,61	Ulaz
Krupnozrnati agregat	<i>CA</i>	kg/m ³	765	954	881,3	78,54	Ulaz
Sitnozrnati agregat	<i>FA</i>	kg/m ³	796	1017,5	884,7	95,83	Ulaz
Starost	<i>A</i>	dana	7	180	76,25	67,56	Ulaz
Tlačna čvrstoća betona	<i>f_c</i>	MPa	19	82,5	49,29	13,64	Izlaz
Niz podataka 3 [56]: Hong Kong (veličina uzorka: 144)							
Leteći pepeo	<i>FlyA</i>	%	0	55	25	19,11	Ulaz
Silikatna prašina	<i>SF</i>	%	0	5	1,88	2,43	Ulaz
Ukupan udio cementnog materijala	<i>TCM</i>	kg/m ³	400	500	436,7	45,13	Ulaz
Sitnozrnati agregat	<i>FA</i>	kg/m ³	536	724	639,2	54,71	Ulaz
Krupnozrnati agregat	<i>CA</i>	kg/m ³	1086	1157	1125	29,51	Ulaz
Voda	<i>W</i>	lit/m ³	150	205	171,7	24,00	Ulaz
Superplastifikator (dodatak za smanjenje udjela vode)	<i>HRWRA</i>	lit/m ³	0	13	4,89	4,04	Ulaz
Starost	<i>A</i>	dana	3	180	60,67	61,31	Ulaz
Tlačna čvrstoća betona	<i>f_c</i>	MPa	7,8	107,8	56,66	23,71	Izlaz
Niz podataka 4 [57]: Sjeverna Koreja (veličina uzorka: 324)							
Voda	<i>W</i>	kg/m ³	160	180	170	8,18	Ulaz
Cement	<i>C</i>	kg/m ³	284	600	417,8	77,03	Ulaz
Sitnozrnati agregat	<i>FA</i>	kg/m ³	552	951	767,7	85,45	Ulaz
Krupnozrnati agregat	<i>CA</i>	kg/m ³	845	989	898,5	43,82	Ulaz
Superplastifikator	<i>SP</i>	kg/m ³	0	2	1,03	0,55	Ulaz
Tlačna čvrstoća betona	<i>f_c</i>	MPa	37,5	73,6	51,93	9,45	Izlaz
Niz podataka 5 [58]: Južna Koreja (veličina uzorka: 104)							
Vodovezivni faktor	<i>W/B</i>	%	30	45	37,6	5,57	Ulaz
Voda	<i>W</i>	kg/m ³	160	180	170	8,24	Ulaz
Odnos sitnozrnatog agregata	<i>FAR</i>	%	37	53	46	3,64	Ulaz
Aerant	<i>AEA</i>	kg/m ³	0,04	0,08	0,05	8,30	Ulaz
Leteći pepeo	<i>FlyA</i>	%	0	20	10,1	0,01	Ulaz
Superplastifikator	<i>SP</i>	kg/m ³	1,89	8,5	4,48	2,30	Ulaz
Tlačna čvrstoća betona	<i>f_c</i>	MPa	38	74	52,68	9,43	Izlaz

Tablica 1. Statistički podaci o nizovima podataka - nastavak

Opis	Kratica	Mjerna jedinica	Min.	Max.	Srednja vrijednost	Standardna devijacija	Smjer
Niz podataka 6 [59]: Tajvan (veličina uzorka: 1030)							
Cement	C	kg/m ³	102	540	281,2	104,51	Ulaz
Zgura iz visokih peći	BFS	kg/m ³	0	359,4	73,9	86,28	Ulaz
Leteći pepeo	FlyA	kg/m ³	0	200	54,19	63,00	Ulaz
Voda	W	kg/m ³	121,8	247	181,6	21,36	Ulaz
Superplastifikator	SP	kg/m ³	0	32,2	6,2	5,97	Ulaz
Krupnozrnat agregat	CA	kg/m ³	801	1145	972,9	77,75	Ulaz
Sitnozrnat agregat	FA	kg/m ³	594	992,6	773,6	80,18	Ulaz
Starost	A	dani	1	365	45,66	63,17	Ulaz
Tlačna čvrstoća betona	f_c	MPa	2,33	82,6	35,82	16,71	Izlaz

Niz podataka 1 iskazan je kako bi se odredila predvidivost vrijednosti f_c i vrijednosti slijeganja, uzimajući u obzir ovisne varijable normalnog betona koje se mogu istovremeno kontrolirati. Izlazna varijabla u nizu podataka 1 preuzeta je iz literature [20, 21, 60]. Ulazne varijable u nizu podataka 1 odabrane su kao količine sastavnih materijala betonskih uzoraka proizvedenih u okviru doktorske disertacije [60]. Ti sastavni dijelovi betona do sada nisu niti objavljeni niti korišteni ni u kojim istraživanjima. U mješavinama normalnog betona, tri različite vrste cementa korištene su kao vezivni materijali, a superplastifikator je korišten kako bi se osigurala dostatna obradivost. U tablici 2 prikazana su svojstva vezivnih materija i superplastifikatora korištenog u nizu podataka 1. Varijable iz niza podataka 1 prikazane su u tablici 3. Prosjek od tri rezultata dobivenih ispitivanjem uzoraka korišten je za svaku posebnu točku projektirane mješavine u nizu podataka 1. Uzorci su njegovani u vodi zasićenoj vapnom pri temperaturi od 23 ± 2 °C u vremenu od 28 dana, nakon čega su ti uzorci ispitani.

Niz podataka 2 iskazan je kako bi se odredila predvidivost vrijednosti f_c isto kao i vrijednosti brzog prodora klorida za beton s dodatkom metakaolina i to pomoću hibridnog modela baziranog na regresiji potpornih vektora i optimalizaciji rojem čestica (PSO) [22]. Uz to, taj hibridni model uspoređen je s prilagodljivim neuroneizrazitim sustavom (ANFIS) [22]. U svim betonskim mješavinama korišten je portlandski cement ASTM C150 tipa 1 te metakaolin dobiven iz tri vrste kaolina [22].

Niz podataka 3 iskazan je kako bi se istražila čvrstoća, odnos tlačnog naprezanja i deformacije te ponašanje pri lomu betona i to zamjenom cementa s letećim pepelom i silikatnom prašinom u unaprijed određenim omjerima [46]. U svim betonskim mješavinama korišten je portlandski cement ASTM tipa 1, ASTM leteći pepeo klase F s niskim udjelom kalcija i silikatne prašine [56]. Kako bi se osigurala odgovarajuća obradivost, u mješavinama je korišten i visoko učinkoviti dodatak za smanjenje udjela vode na bazi naftalena (HRWRA) [56]. U analizi niza podataka 3 nije primjenjena nikakva metoda umjetne inteligencije, prema radu Lam i dr. [56].

Niz podataka 4 iskazan je kako bi se predvidjela vrijednost f_c betona visoke čvrstoće (HSC) primjenom metode ekstremnog učenja [57]. Osim toga, rezultati dobiveni metodom ekstremnog učenja uspoređeni su s rezultatima umjetne neuronske mreže (ANN) [57]. U mješavinama je korišten portlandski cement tipa 1 i superplastifikator na bazi polikarboksilata [57].

Niz podataka 5 iskazan je kako bi se umanjio broj probnih mješavina betona visoke učinkovitosti (betona u kojem tlačna čvrstoća varira od 40 do 80 MPa) i to primjenom genetskog algoritma [58]. U mješavinama je korišten portlandski cement ASTM tipa I, leteći pepeo klase F i naftalenski superplastifikator [58].

Niz podataka 6 iskazan je kako bi se predvidjela vrijednost f_c betona visoke učinkovitosti pomoću umjetnih neuronskih mreža (ANN) [59]. U mješavinama je korišten portlandski cement ASTM tipa I, leteći pepeo, praškasta zgura i superplastifikator s naftalen-formaldehidom i kopolimerom masnih kiselina [59].

Tablica 2. Svojstva vezivnih materijala i superplastifikatora u nizu podataka 1

Vezivni materijali i superplastifikator		Gustoća čestica [kg/m ³]	f_{cc} [MPa]	Specifična površina (Blaine) [m ² /kg]
Cement (C)	CEM V/A (S-P) 32,5 N	2990	34,40	416,0
	SDC 32,5 R	3160	44,75	339,0
	CEM I 42,5 R	3140	55,10	379,0
Superplastifikator (SP)		1100	-	-
f_{cc} - tlačna čvrstoća betonskog morta				

Tablica 3. Laboratorijski niz podataka 1

No	C [kg/m ³]	f _{cc} [MPa]	SP [kg/m ³]	W [kg/m ³]	FA [kg/m ³]	CA [kg/m ³]	f _c [MPa]
1	337,5	44,75	4,39	199,00	1162,92	585,83	38,76
2	337,5	44,75	4,39	159,70	1233,39	621,33	36,17
3	337,5	44,75	4,39	199,00	1162,92	585,83	38,12
4	337,5	44,75	4,39	159,70	1233,39	621,33	36,06
5	337,5	44,75	4,39	199,00	1162,92	585,83	38,45
6	337,5	44,75	4,39	159,70	1233,39	621,33	35,19
7	330	34,4	3,96	184,58	1152,54	620,60	28,59
8	330	34,4	3,96	168,66	1252,08	589,21	24,38
9	345	34,4	4,83	191,04	1183,06	556,74	30,44
10	345	34,4	4,83	172,14	1164,50	627,04	23,37
11	330	55,1	4,62	150,75	1292,34	608,16	42,47
12	330	55,1	4,62	208,96	1117,94	601,97	39,27
13	345	55,1	4,14	153,23	1207,19	650,02	39,05
14	345	55,1	4,14	217,91	1157,01	544,48	39,51
15	330	34,4	4,62	152,74	1227,89	661,17	28,49
16	330	34,4	4,62	208,46	1181,37	555,94	23,57
17	345	34,4	4,14	164,68	1262,91	594,31	27,56
18	345	34,4	4,14	217,91	1105,65	595,35	22,86
19	330	55,1	3,96	192,04	1211,48	570,11	42,48
20	330	55,1	3,96	169,65	1208,48	650,72	37,58
21	345	55,1	4,83	200,50	1133,46	610,32	42,19
22	345	55,1	4,83	182,59	1239,22	583,16	37,17
23	337,5	44,75	4,39	204,48	1146,71	577,67	37,84
24	337,5	44,75	4,41	204,48	1146,71	577,67	35,86
25	337,5	44,75	4,41	171,64	1225,45	617,33	32,59
26	337,5	44,75	4,41	204,48	1146,71	577,67	36,66
27	337,5	44,75	4,41	171,64	1225,45	617,33	35,26
28	337,5	44,75	4,41	171,64	1225,45	617,33	33,58
29	337,5	44,75	4,41	191,04	1155,31	582,00	37,00
30	337,5	44,75	4,42	164,68	1230,08	619,67	32,91
31	330	34,4	4,42	176,62	1148,01	618,16	28,94
32	330	34,4	4,42	173,13	1249,37	587,94	22,80
33	345	34,4	4,42	187,06	1173,25	552,12	29,34
34	345	34,4	4,42	178,11	1160,95	625,12	24,43
35	330	55,1	4,42	155,22	1288,96	606,57	42,17
36	330	55,1	4,42	193,03	1127,96	607,36	42,08
37	345	55,1	4,43	159,70	1202,66	647,59	38,62
38	345	55,1	4,43	202,99	1153,97	543,04	41,81
39	330	34,4	4,43	157,21	1224,98	659,60	26,38
40	330	34,4	4,43	193,53	1169,19	550,21	24,36
41	345	34,4	4,43	168,16	1260,20	593,03	27,44
42	345	34,4	4,43	201,49	1096,27	590,30	25,13
43	330	55,1	4,44	174,63	1210,13	569,47	43,25
44	330	55,1	4,44	173,63	1205,90	649,33	39,29

Tablica 3. Laboratorijski niz podataka 1 - nastavak

No	C [kg/m ³]	f _{cc} [MPa]	SP [kg/m ³]	W [kg/m ³]	FA [kg/m ³]	CA [kg/m ³]	f _c [MPa]
45	345	55,1	4,44	182,09	1135,40	611,37	44,19
46	345	55,1	4,44	186,07	1236,86	582,05	37,68
47	330	34,4	4,44	201,00	1122,14	604,23	26,56
48	337,5	34,4	4,44	213,93	1095,95	590,12	23,58
49	330	34,4	4,44	211,44	1130,83	569,67	23,44
50	335	34,4	4,45	197,51	1226,71	577,27	20,47
51	345	55,1	4,45	209,45	1209,11	569,00	31,85
52	345	55,1	4,39	192,54	1212,55	610,83	35,92
53	335	55,1	4,83	192,04	1247,68	587,14	35,13
54	340	55,1	4,02	190,05	1221,09	657,51	36,58
55	330	55,1	4,42	195,52	1167,55	588,17	39,97
56	345	34,4	3,96	205,47	1158,71	545,27	27,02
57	345	55,1	4,49	209,45	1106,94	596,04	39,79
58	345	34,4	4,83	209,45	1172,91	631,57	19,86
59	337,5	44,75	4,49	187,56	903,79	868,35	42,57
60	337,5	44,75	4,39	187,56	903,79	868,35	44,59
61	337,5	44,75	4,39	164,18	978,64	940,26	45,67
62	337,5	44,75	4,39	187,56	903,79	868,35	42,84
63	337,5	44,75	4,39	164,18	978,64	940,26	43,68
64	337,5	44,75	4,39	164,18	978,64	940,26	42,88
65	330	34,4	4,39	174,13	863,04	934,97	34,22
66	330	34,4	3,96	169,65	1025,19	873,31	29,63
67	345	34,4	3,96	183,08	949,97	809,23	32,31
68	345	34,4	4,83	174,63	889,31	963,42	29,19
69	330	55,1	4,83	152,74	1056,9	900,32	53,87
70	330	55,1	4,62	192,04	847,76	918,41	44,07
71	345	55,1	4,62	155,72	920,12	996,80	53,11
72	345	55,1	4,14	156,22	920,12	996,80	52,92
73	345	55,1	4,14	200,00	934,39	795,96	43,23
74	330	34,4	4,14	148,26	928,48	1005,85	33,46
75	330	34,4	4,62	189,55	946,75	806,49	29,33
76	345	34,4	4,62	159,20	1029,22	876,75	33,31
77	345	34,4	4,14	197,51	826,99	895,9	29,00
78	330	55,1	4,14	173,13	977,64	832,81	45,89
79	330	55,1	3,96	164,18	914,63	990,85	44,37
80	345	55,1	3,96	180,10	854,69	925,91	46,40
81	345	55,1	4,83	176,12	1010,96	861,18	47,37
82	337,5	44,75	4,83	165,17	978,39	940,02	42,92
83	337,5	44,75	4,39	187,06	903,79	868,35	44,01
84	337,5	44,75	4,39	187,06	903,79	868,35	42,09
85	337,5	44,75	4,39	165,17	978,39	940,02	42,55
86	337,5	44,75	4,39	165,17	978,39	940,02	41,75
87	337,5	44,75	4,39	187,06	903,79	868,35	42,62
88	330	34,4	4,39	173,63	863,52	935,48	33,10
89	330	34,4	3,96	168,16	1026,00	874,00	29,75

Tablica 3. Laboratorijski niz podataka 1 - nastavak

No	C [kg/m ³]	f _{cc} [MPa]	SP [kg/m ³]	W [kg/m ³]	FA [kg/m ³]	CA [kg/m ³]	f _c [MPa]
90	345	34,4	3,96	179,60	951,85	810,84	32,33
91	345	34,4	4,83	168,66	891,94	966,27	32,16
92	330	55,1	4,83	151,24	1057,7	901,00	51,57
93	330	55,1	4,62	181,59	852,78	923,84	47,62
94	345	55,1	4,62	154,23	921,07	997,83	48,18
95	345	55,1	4,14	189,55	940,30	801,00	46,41
96	330	34,4	4,14	142,79	931,34	1008,96	34,53
97	330	34,4	4,62	186,07	948,36	807,86	28,43
98	345	34,4	4,62	156,22	1031,1	878,35	33,09
99	345	34,4	4,14	196,02	827,94	896,94	29,06
100	330	55,1	4,14	175,62	976,30	831,66	48,60
101	330	55,1	3,96	162,19	983,55	837,84	50,22
102	330	55,1	3,96	163,18	915,10	991,36	43,65
103	345	55,1	3,96	170,15	859,46	931,08	51,11
104	345	55,1	4,83	175,12	1011,49	861,64	45,54

3. Rezultati i rasprava

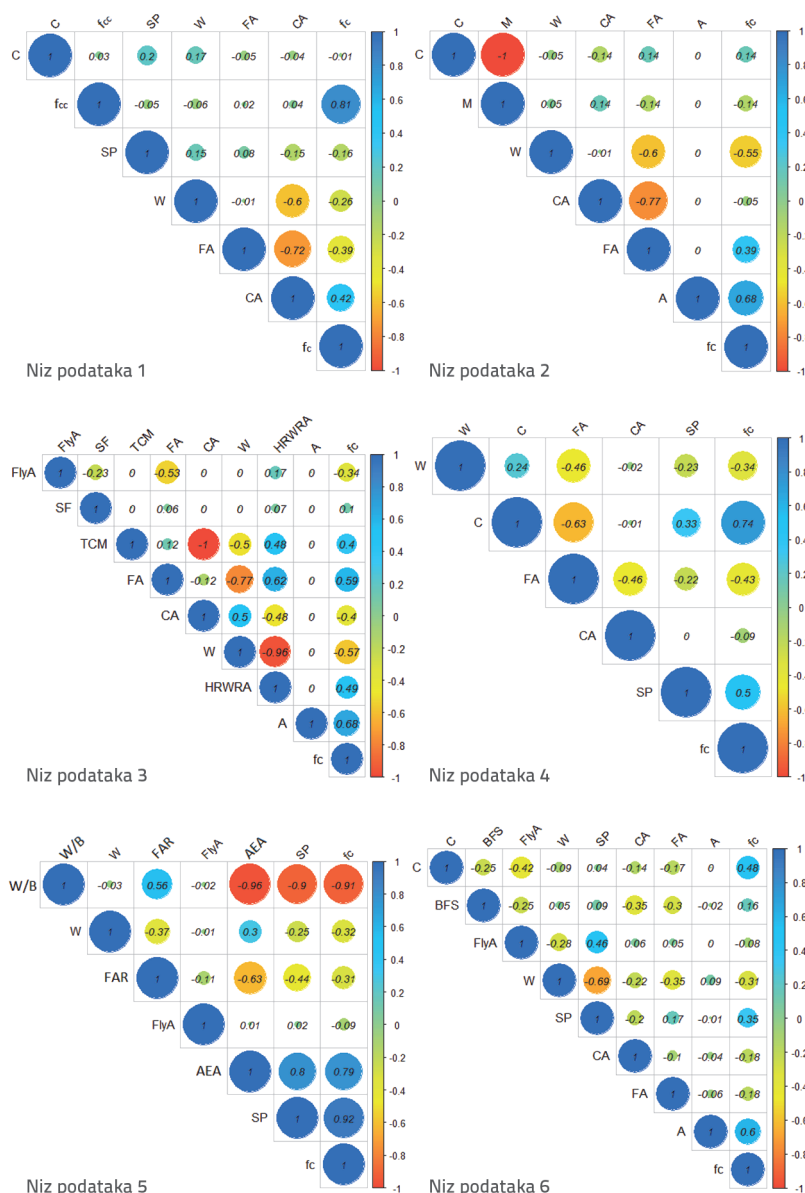
Korelacijski koeficijent upućuje na razinu djelovanja i smjer linearnog odnosa između dva parametra. Na slici 3. prikazana je matrica unakrsnih korelacija za šest nizova podataka.

Prema korelacijskim rezultatima za niz podataka 1, izlazna varijabla f_c uvelike je povezana s ovisnom varijablom f_{cc} (0,81). Ovaj rezultat sličan je rezultatima koji su dobiveni u prethodnim istraživanjima [20, 21, 60]. U normalnim se betonima može očekivati da će utjecaj količine cementa na tlačnu čvrstoću betona biti prilično velik. Osim toga, vodocementni faktor jedan je od faktora koji dominantno utječu na vrijednost f_c . Količina cementa varira vrlo malo (345-330 = 15 kg), a variranje vodocementnog faktora uglavnom proizlazi iz variranja količine vode. Stoga, iako korelacijski koeficijent količine vode (W) iznosi oko -0,26, korelacijski koeficijent količine cementa (C) otprilike je jednak nuli (-0,01). Krupnozrnati agregat u pozitivnom je odnosu (0,42) s f_c jer on predstavlja nosivi okvir normalnog betona. Kako sitnozrnati agregat predstavlja fazu morta u normalnom betonu, korelacija između sitnozrnatog agregata i f_c je negativna (-0,39). Korelacijski koeficijent sitnozrnatog agregata iznosi 0,01 kada se kao ulazne varijable odaberu varijable koje se mogu istovremeno kontrolirati [20]. Zbog toga je prilično teško generalizirati veličinu korelacijskog koeficijenta ponajviše zato što ovisne razine ulaznih varijabli variraju ovisno o odabranim ulaznim varijablama i o intervalima varijacija.

Rezultati korelacijskog koeficijenta za niz podataka 2 pokazuju da je varijabla odziva f_c povezana s ovisnim varijablama A (0,68), W (-0,55), FA (0,39), C (0,14), i M (-0,14). Korelacijski koeficijent CA prilično je nizak (-0,05). Najviši korelacijski koeficijent ulazne varijable A objašnjava doprinos metakaolina povećanju tlačne čvrstoće u duljem njegovanju. Međutim, kada se u obzir uzme interval varijacije za A (7-180), može se zaključiti da korelacijski

koeficijent A ne uključuje samo utjecaj metakaolina već i doprinos cementa, naročito do čvrstoće nakon 28 dana. Tlačna čvrstoća smanjuje se s porastom vrijednosti M i W (negativna korelacija, -0,14 tj. -0,55). U mješavinama s velikom količinom sitnozrnatog materijala, variranje udjela vode više utječe na vrijednost f_c .

U nizu podataka 3, varijabla odziva f_c povezana je sa svim ovisnim varijablama (FlyA: -0,34, SF: 0,10, TCM: 0,40, FA: 0,59, CA: -0,4, W: -0,57, HRWRA: 0,49, A: 0,68). Najniži korelacijski koeficijent uočava se kod ulazne varijable SF. Povećanje količine SF, što utječe na vezanje zbog izrazito sitnozrnate strukture SF-a i visokog udjela amorfnog silikata, uzrokuje porast vrijednosti f_c od samo 0,10 i to zato što SF varira u rasponu od 0 % do 5 %. Osim toga, kako A ima interval variranja od 3-180 dana (korelacijski koeficijent za A iznosi 0,68), korelacijski koeficijenti mineralnih aditiva i ukupnih veznih materijala s tlačnom čvrstoćom, nisu odraz stvarnih razina ovisnosti. Zato bi se pri određivanju intervala promjene za A, naročito u betonima s mineralnim dodacima, prednost trebala dati klasifikacijskom postupku. Zbog vodovezivnog faktora u betonima s mineralnim dodacima, varijabilnost količine vode bitno utječe na tlačnu čvrstoću (korelacijski koeficijent W iznosi -0,57). Uz to, f_c i HRWRA iskazuju pozitivan odnos od otprilike 0,49 za postizanje obradivosti, i to zbog povećanog broja sitnozrnatih čestica u ukupnim vezivnim materijalima. Korelacija varijabli FA i W je negativna (-0,77). To nije posljedica fizikalne interakcije između količine sitnozrnatog materijala i zahtjeva u pogledu vode. Ipak, kada se u obzir uzme pozitivan odnos između FA i HRWRA (0,62), može se uočiti da HRWRA uzrokuje gubitak obradivosti zbog sitnozrnate strukture. Vrijednost f_c u pozitivnom je odnosu s FA (0,59), a u negativnom s CA (-0,40). Kao što se moglo i očekivati, odnos između CA i HRWRA je negativan (-0,48).



Slika 3. Matrica unakrsnih korelacija nizova podataka

Prema korelacijskim rezultatima za niz podataka 4, varijabla odziva f_c povezana je s ovisnim varijablama W (-0,34), C (0,74), FA (-0,43), i SP (0,50). Koeficijent korelacije CA i f_c otprilike je jednak nuli (-0,09). Vrijednost C ima najviši korelacijski koeficijent (0,74). Osim toga, korelacijski koeficijent SP iznosi 0,50. Kada se u obzir uzme interval varijacije varijable C (284-600 kg), može se ustvrditi da dobiveni korelacijski koeficijenti nisu odraz stvarnih korelacijskih razina između tlačne čvrstoće betona i ostalih ulaznih varijabli. Zato se pri ocjenjivanju svakako u obzir trebaju uzeti velike razlike u intervalu varijacije ulaznih varijabli. Rezultati korelacijskih koeficijenata za niz podataka 5 pokazuju da je varijabla odziva f_c povezana s ovisnim varijablama W/B (-0,91), W (-0,32), FA (-0,31), AEA (0,79) i SP (0,92). Korelacija

između FlyA i f_c otprilike je jednaka nuli (-0,09). Kako varijabilnost za W iznosi 20 kg/m³, obradivost se postiže primjenom SP. Dakle, SP ostvaruje značajan pozitivan odnos s f_c (0,92). Kod betona niže čvrstoće AEA uzrokuje manji pad čvrstoće, tj. može uzrokovati čak i manje povećanje tlačne čvrstoće zbog uvlačenja zraka [58]. Međutim, za postizanje visoke pozitivne korelacije između AEA i f_c (od oko 0,79) u obzir se treba uzeti i interakcija ulaznih varijabli ovisno o intervalima varijacije, a ne samo doprinos uvlačenja zraka čvrstoći betona.

Prema korelacijskim rezultatima za niz podataka 6, varijabla odziva f_c u korelaciji je s ovisnim varijablama C (0,48), BFS (0,16), W (-0,31), SP (0,35), CA (-0,18), FA (-0,18) i A (0,60). Korelacija FlyA s f_c otprilike je jednaka nuli (-0,08). Kako je interval varijacije za A izuzetno velik (1-365), može se reći da ulazna varijabla A ima najvišu razinu korelacije s f_c . Rezultati uvježbavanja i rasponi pogreške ostvareni u ovom istraživanju nakon deset iteracija modela prikazani su u tablici 4. Osim toga, nizovi podataka odvojeni su od iste točke kako bi se mogle usporediti sposobnosti predviđanja svih modela. Točnost svih modela prema kriterijima R, RMSE (MPa), MAE (MPa), MAPE (%) i P-vrijednosti prikazana je u tablici 5. i na slikama 4. i 5. Prije ocjenjivanja točnosti predviđanja, za sve je ulazne varijable provedena normalizacija. Za veću učinkovitost modela, vrijednosti RMSE, MAE i MAPE trebaju biti niske, a vrijednost R treba biti visoka.

Uspješnost modela ANFIS u predviđanju vrijednosti f_c postaje itekako jasna nakon pojedinačne analize svakog od šest nizova podataka, tj. nakon analize prosječnih vrijednosti dobivenih na svim nizovima podataka. S obzirom na to da je modelom ANFIS vrijednost f_c predviđena na bazi neviđenih uzoraka (probni niz podataka), predviđena vrijednost gotovo je jednaka registriranoj vrijednosti (R= 0,992, RMSE = 1,81, MAE = 1,409, MAPE = 4,06%, P<0,001). Svi ti rezultati upućuju na vrlo jaku sposobnost predviđanja modela ANFIS u odnosu na ostale modele. Rezultati dobiveni pomoću modela RF bliski su onima koji su ostvareni pomoću modela ANFIS. Najniža stopa točnosti ostvarena je pomoću modela CART. Takva uspješnost modela RF pokazuje da je metoda grupnog učenja uspješnija od metode jednostavnog stabla odlučivanja.

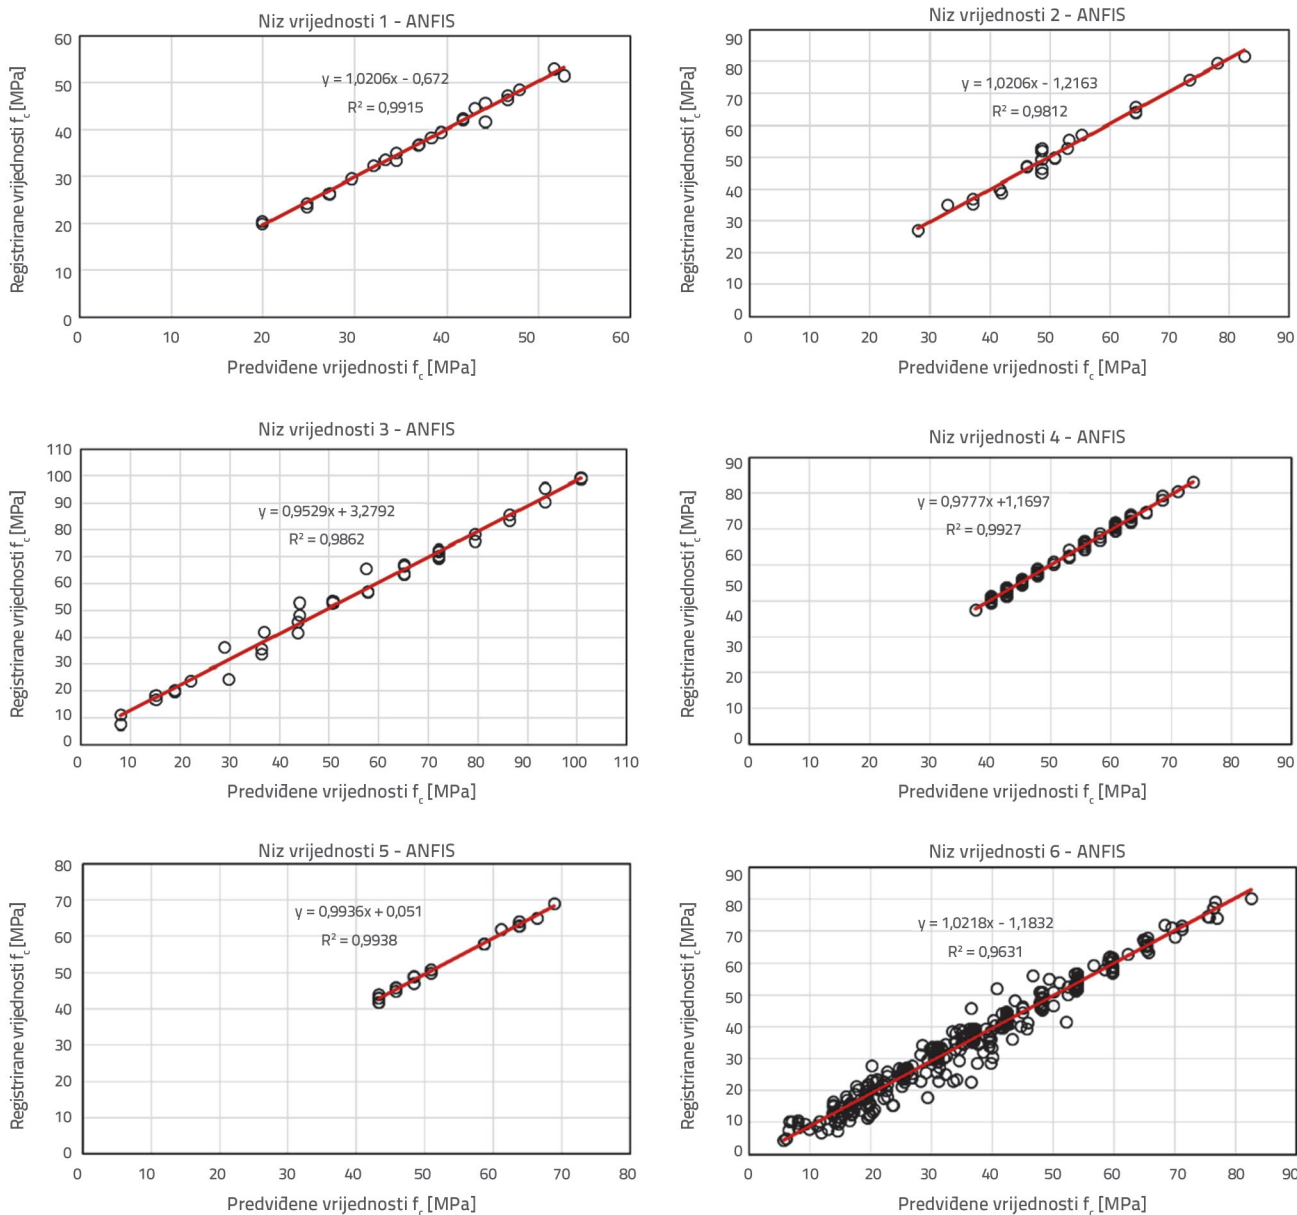
Tablica 4. Točnost predviđanja modela umjetne inteligencije za uvježbavanje i ispitivanje podataka

Niz podataka		RF [%]	LR [%]	CART [%]	SVR [%]	KNN [%]	ELM [%]	ANFIS [%]
Niz podataka 1	Učenje	2,4-3,1	6,4-7,6	5,5-6,4	6,2-6,7	6,9-9,5	5,5-6,3	1,7-1,9
	Ispitivanje	3,7-7,7	4,0-8,6	5,8-8,7	6,8-8,5	8,9-19,9	5,8-9,6	1,6-2,1
Niz podataka 2	Učenje	4,0-5,3	13,1-15,0	10,3-13,2	13,2-15,3	7,3-8,9	9,1-13,4	3,2-3,8
	Ispitivanje	4,8-12,3	11,0-19,8	8,7-18,9	9,1-19,2	10,6-20,2	10,3-14,5	2,4-5,1
Niz podataka 3	Učenje	5,2-6,4	19,5-23,3	15,6-19,5	21,3-24,5	8,8-10,3	20,8-22,7	7,5-8,1
	Ispitivanje	7,3-13,6	18,5-33,2	14,3-26,9	18,8-38,8	9,7-21,9	21,2-29,7	5,5-8,6
Niz podataka 4	Učenje	0,9-1,3	3,7-4,0	4,3-5,3	3,2-3,4	1,7-2,9	3,6-3,8	1,3-1,4
	Ispitivanje	1,3-3,3	3,3-4,4	5,2-6,4	3,0-3,7	6,7-9,0	3,6-4,0	1,2-1,5
Niz podataka 5	Učenje	1,2-1,6	2,6-3,1	2,9-4,5	2,3-2,9	3,5-4,5	2,2-2,7	1,2-1,4
	Ispitivanje	1,5-3,3	2,0-4,5	2,2-5,8	1,9-3,1	5,0-8,0	3,0-4,8	1,1-1,5
Niz podataka 6	Učenje	5,7-6,2	30,7-32,0	23,6-25,3	21,8-23,6	16,4-17,7	30,6-31,2	8,9-10,5
	Ispitivanje	10,8-13,8	29,7-35,0	24,5-33,3	20,9-25,4	18,8-28,3	20,8-35,0	9,9-11,2

Tablica 5. Kriteriji učinkovitosti za modele umjetne inteligencije

Niz podataka	Pokazatelj	RF*	LR*	CART*	SVR*	K-NN*	ELM*	ANFIS*
Niz podataka 1: Turska	<i>R</i>	0,981	0,962	0,967	0,964	0,910	0,965	0,996
	<i>RMSE</i>	2,307	3,011	2,883	3,011	4,293	2,706	0,896
	<i>MAE</i>	1,851	2,454	2,254	2,506	2,936	2,218	0,696
	<i>MAPE</i>	6,13 %	6,81 %	7,11 %	7,13 %	9,89 %	6,11 %	1,88 %
Niz podataka 2: Iran	<i>R</i>	0,929	0,820	0,863	0,835	0,858	0,852	0,991
	<i>RMSE</i>	5,235	8,211	6,936	7,679	7,141	7,692	1,910
	<i>MAE</i>	3,873	6,690	5,609	6,083	5,340	6,033	1,561
	<i>MAPE</i>	8,88 %	14,37 %	11,95 %	13,37 %	11,64 %	12,98 %	3,30 %
Niz podataka 3: Hong Kong	<i>R</i>	0,969	0,921	0,904	0,927	0,945	0,921	0,993
	<i>RMSE</i>	6,335	9,880	10,949	9,464	8,710	9,905	3,262
	<i>MAE</i>	4,925	8,804	8,452	8,203	7,032	8,889	2,518
	<i>MAPE</i>	14,96 %	23,19 %	21,97 %	23,74 %	23,57 %	23,32 %	6,35 %
Niz podataka 4: Južna Koreja	<i>R</i>	0,988	0,97	0,907	0,976	0,952	0,972	0,996
	<i>RMSE</i>	1,364	2,161	3,856	1,933	2,847	2,090	0,785
	<i>MAE</i>	0,944	1,849	2,913	1,595	2,111	1,768	0,676
	<i>MAPE</i>	1,91 %	3,73 %	5,66 %	3,20 %	4,34 %	3,56 %	1,34 %
Niz podataka 5: Sjeverna Koreja	<i>R</i>	0,976	0,974	0,91	0,974	0,948	0,976	0,997
	<i>RMSE</i>	1,917	2,085	3,966	2,052	2,936	1,967	0,745
	<i>MAE</i>	1,143	1,473	2,585	1,413	2,373	1,566	0,651
	<i>MAPE</i>	2,32 %	2,93 %	4,95 %	2,75 %	4,59 %	3,08 %	1,29 %
Niz podataka 6: Tajvan	<i>R</i>	0,953	0,8	0,833	0,87	0,837	0,784	0,981
	<i>RMSE</i>	5,157	10,134	9,325	8,399	9,209	10,472	3,265
	<i>MAE</i>	3,623	8,184	7,330	6,576	6,890	8,310	2,355
	<i>MAPE</i>	13,35 %	33,63 %	28,74 %	25,66 %	28,21 %	34,34 %	10,19 %
Prosjek	<i>R</i>	0,966	0,908	0,897	0,924	0,908	0,912	0,992
	<i>RMSE</i>	3,719	5,914	6,319	5,423	5,856	5,805	1,810
	<i>MAE</i>	2,726	4,909	4,857	4,396	4,447	4,797	1,409
	<i>MAPE</i>	7,93 %	14,11 %	13,40 %	12,64 %	13,71 %	13,90 %	4,06 %

**P* - vrijednosti za sve modele umjetne inteligencije: $P < 0,001$,

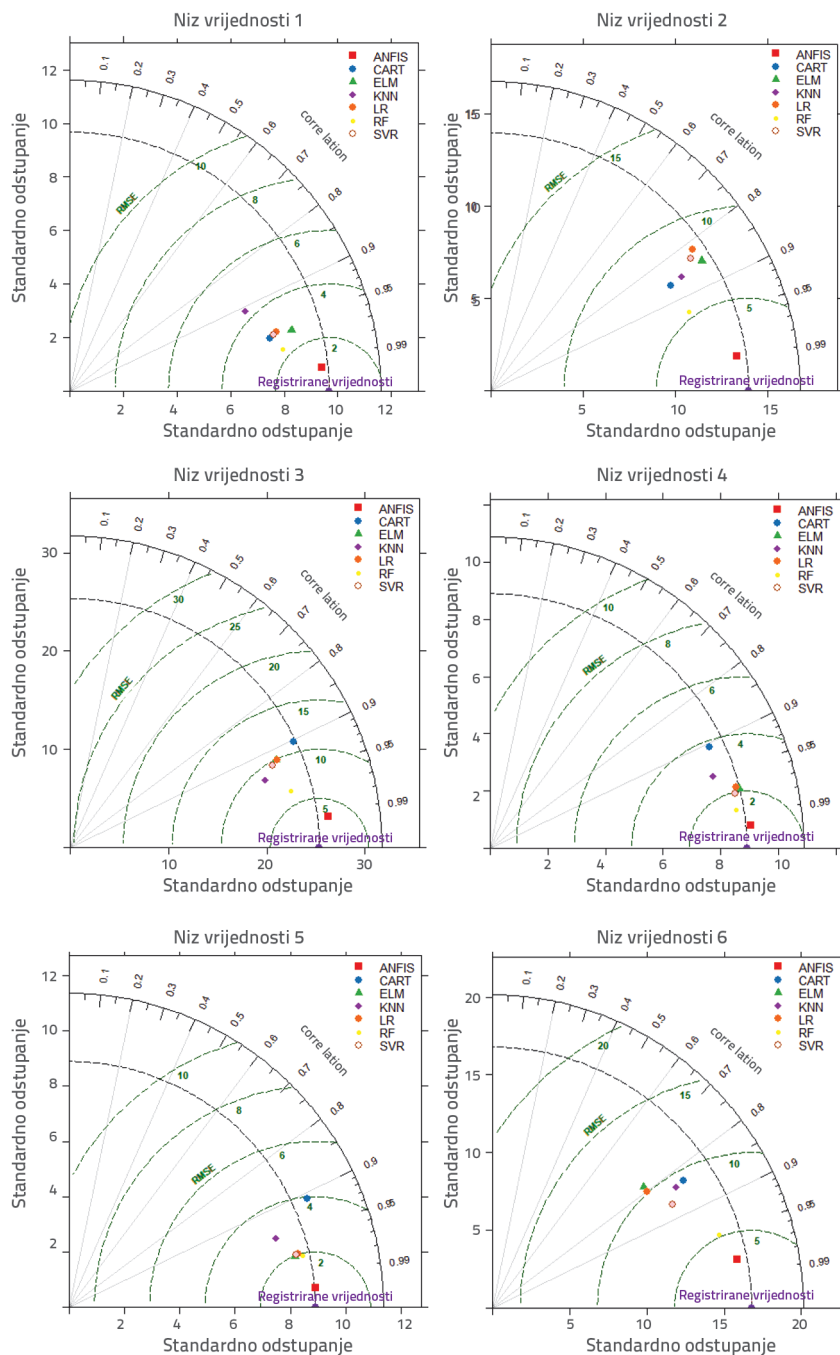


Slika 4. Odnos između registriranih f_c i predviđenih f_c vrijednosti modela ANFIS za probni niz podataka

Odnos između registriranih i predviđenih vrijednosti tlačne čvrstoće betona ostvaren pomoću modela ANFIS prikazan je na slici 4. Zbog velike točnosti predviđanja modela ANFIS, na svim nizovima podataka dobivene su visoke vrijednosti R^2 (raspon R^2 od 0,9938 do 0,9631). Vrijednost R^2 pokazuje stupanj linearne korelacije između registriranih i predviđenih vrijednosti f_c . Stoga vrijedi konstatacija da je sposobnost predviđanja ovog modela veća što je gore spomenuta vrijednost bliža vrijednosti 1. Na slici 4 vidimo da su točke raspoređene blizu linije, što znači da postoji čvrsta korelacija između registriranih i predviđenih vrijednosti f_c .

Taylorovi prikazi [61] dobiveni za svaki niz podataka prikazani su na slici 5. Tim su prikazima iskazane razine učinkovitosti svih modela umjetne inteligencije.

U Taylorovom se dijagramu primjenjuju korelacijski koeficijenti, standardna odstupanja i RMSE za definiranje usporedivosti između pojedinačnih modela umjetne inteligencije. Kao što se može vidjeti na slici 5., ANFIS je vrhunski model za predviđanje pomoću kojeg se dobivaju podaci najbliži registriranim vrijednostima, s niskom vrijednošću RMSE i visokim korelacijskim koeficijentom.



Slika 5. Taylorov dijagram modela umjetne inteligencije

4. Zaključak

Stupanj predvidivosti tlačne čvrstoće betona iznimno je nizak jer se u proizvodnji betona upotrebljavaju brojni različiti materijali, a tome je razlog i sama složenost strukture betona. Industrija tvornički proizvedenog betona itekako je svjesna značenja visoke točnosti predviđanja vrijednosti f_c i to ponajviše zbog složenosti strukture betona. Stoga istraživači predlažu brojne modele kako bi se omogućilo što bolje predviđanje vrijednosti

f_c [20, 22, 57-59, 62, 63]. U ovom se istraživanju uspoređuje učinkovitost predviđanja raznih modela baziranih na umjetnoj inteligenciji i u tom se smislu koristi šest različitih nizova podataka kako bi se odredila opća uspješna metoda za predviđanje tlačne čvrstoće betona i to neovisno o nizovima podataka. U usporedbama učinkovitosti modela korišteni su pokazatelji R, RMSE, MAE i MAPE. Također je istražen i odnos između ulaznih varijabli u nizovima podataka i tlačne čvrstoće betona. Tijekom provedbe ovih istraživanja postignuti su sljedeći rezultati:

- Na korelacijske koeficijente izravno utječu rasponi variranja ulaznih varijabli. Stoga se intervali varijacija ulaznih varijabli trebaju brižljivo odabrati kao bi se mogle odrediti stvarne razine utjecaja ulaznih varijabli na izlazne varijable. Utjecaj komponenta na f_c ne može se točno odrediti kod betona visoke čvrstoće i betona s dodatkom minerala zbog raspona variranja ulazne varijable starosti betona. Klasifikacija dominantnih ulaznih varijabli (starost itd.) u okviru eksperimentalnog projektiranja korisna je za određivanje stvarnih izlaznih funkcija.
- Visoka točnost predviđanja ostvaruje se kod različitih vrsta betona na temelju metoda baziranih na umjetnoj inteligenciji.
- Najviša točnost predviđanja postignuta je pomoću metode ANFIS i to na temelju svih pokazatelja i kod svih nizova podataka (prosjeak: $R = 0,992$, $RMSE = 1,81$, $MAE = 1,409$, $MAPE = 4,06\%$, $P < 0,001$).
- Rezultati postignuti pomoću modela RF bliski su rezultatima modela ANFIS, a najmanja točnost postignuta je primjenom modela CART. Takva uspješnost modela RF pokazuje da je metoda grupnog učenja uspješnija od metode jednostavnog stabla odlučivanja.
- Korelacijski koeficijenti i točnost predviđanja ne mogu se generalizirati u smislu definiranja razine utjecaja ulaznih varijabli na izlazne varijable, i oni u potpunosti variraju ovisno o odabranim ulaznim varijablama i rasponima variranja. Učinkovitost predviđanja metoda strojnog učenja ovisi o raznim situacijama. Tako na učinkovitost modela mogu utjecati brojni faktori kao što su prethodna obrada podataka,

- hiperparametri modela i strategije dijeljenja niza podataka. Značaj metode ($P < 0,0001$) i pokazatelji za ocjenjivanje nisu dovoljni za fizičko određivanje značaja modela. Zato su razvijeni modeli valjani samo za odabrane ulazne varijable i intervale variranja ulaznih varijabli te za podatke koji se koriste u treniranju/ispitivanju.
- U kontekstu ukupne kontrole kvalitete potrebno je poboljšati metode učenja bazirane na umjetnoj inteligenciji u industriju tvornički proizvedenog (transportnog) betona, jer visoka točnost predviđanja doprinosi smanjenju gubitaka u tvorničkoj proizvodnji betona.
 - U praksi se svojstva komponenata betona mijenjaju ovisno o sezonskim parametrima i porijeklu materijala. Zbog toga se u budućim istraživanjima treba odrediti točnost predviđanja tlačne čvrstoće betona na temelju nizova podataka koji nisu definirani isključivo u laboratorijskim uvjetima već uključuju i varijacije svojstava komponenata betona. Osim toga, treba se napraviti i klasifikacija uzimajući u obzir funkcionalna (radna) područja ovisnih varijabli koje se istovremeno mogu kontrolirati, a točnost predviđanja modela treba se određivati zasebno za svako područje.

LITERATURA

- [1] Bederina, M., Makhoulfi, Z., Bounoua, A., Bouziani, T., Quéneudec, M.: Effect of partial and total replacement of siliceous river sand with limestone crushed sand on the durability of mortars exposed to chemical solutions, *Construction and Building Materials*, 47 (2013), pp. 146-158, <https://doi.org/10.1016/j.conbuildmat.2013.05.037>
- [2] Feng, D., Li, J.: Stochastic nonlinear behaviour of reinforced concrete frames. II: numerical simulation, *Journal of Structural Engineering*, 142 (2015) 3, [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0001443](https://doi.org/10.1061/(ASCE)ST.1943-541X.0001443)
- [3] Feng, D., Ren, X., Li, J.: Stochastic damage hysteretic model for concrete based on micromechanical approach, *International Journal of Non-Linear Mechanics*, 83 (2016), pp. 15-25, <https://doi.org/10.1016/j.ijnonlinmec.2016.03.012>
- [4] Topcu, I.B., Saridemir, M.: Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic, *Computational Materials Science*, 41 (2008) 3, pp. 305-311, <https://doi.org/10.1016/j.commatsci.2007.04.009>
- [5] Saridemir, M.: Prediction of compressive strength of concretes containing metakaolin and silica fume by artificial neural networks, *Advances in Engineering Software*, 40 (2009) 5, pp. 350-355, <https://doi.org/10.1016/j.advengsoft.2008.05.002>
- [6] Başıyigit, C., Akkurt, I., Kilincarslan, S., Beycioglu, A.: Prediction of compressive strength of heavyweight concrete by ANN and FL models, *Neural Computing and Applications*, 19 (2010) 4, pp. 507-513, <https://doi.org/10.1007/s00521-009-0292-9>
- [7] Saridemir, M.: Genetic programming approach for prediction of compressive strength of concretes containing rice husk ash, *Construction and Building Materials*, 24 (2010) 10, pp. 1911-1919, <https://doi.org/10.1016/j.conbuildmat.2010.04.011>
- [8] Sobhani, J., Najimi, M., Pourkhorshidi, A.R., Parhizkar, T.: Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models, *Construction and Building Materials*, 24 (2010) 5, pp. 709-718, <https://doi.org/10.1016/j.conbuildmat.2009.10.037>
- [9] Siddique, R., Aggarwal, P., Aggarwal, Y.: Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks, *Advances in engineering software*, 42 (2011) 10, pp. 780-786, <https://doi.org/10.1016/j.advengsoft.2011.05.016>
- [10] Zhang, J., Ma, G., Huang, Y., Aslani, F., Nener, B.: Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression, *Construction and Building Materials*, 210 (2019), pp. 713-719, <https://doi.org/10.1016/j.conbuildmat.2019.03.189>
- [11] Feng, D.-C., Liu, Z.-T., Wang, X.-D., Chen, Y., Chang, J.-Q., Wei, D.-F., Jiang, Z.-M.: Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach, *Construction and Building Materials*, 230 (2020), pp. 117000, <https://doi.org/10.1016/j.conbuildmat.2019.117000>
- [12] Getahun, M.A., Shitote, S.M., Gariy, Z.C.A.: Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes, *Construction and Building Materials*, 190 (2018), pp. 517-525, <https://doi.org/10.1016/j.conbuildmat.2018.09.097>
- [13] Yu, Y., Li, W., Li, J., Nguyen, T.N.: A novel optimised self-learning method for compressive strength prediction of high performance concrete, *Construction and Building Materials*, 184 (2018), pp. 229-247, <https://doi.org/10.1016/j.conbuildmat.2018.06.219>
- [14] Bui, D.K., Nguyen, T., Chou, J.S., Nguyen-Xuan, H., Ngo, T.D.: A modified firefly algorithm-artificial neural network expert system for predicting compressive and tensile strength of high-performance concrete, *Construction and Building Materials*, 180 (2018), pp. 320-333, <https://doi.org/10.1016/j.conbuildmat.2018.05.201>
- [15] Onyari, E.K., Ikotun, B.D.: Prediction of compressive and flexural strengths of a modified zeolite additive mortar using artificial neural network, *Construction and Building Materials*, 187 (2018), pp. 1232-1241, <https://doi.org/10.1016/j.conbuildmat.2018.08.079>
- [16] Naderpour, H., Rafiean, A.H., Fakharian, P.: Compressive strength prediction of environmentally friendly concrete using artificial neural networks, *Journal of Building Engineering*, 16 (2018), pp. 213-219, <https://doi.org/10.1016/j.jobee.2018.01.007>
- [17] Ziolkowski, P., Niedostatkiwicz, M.: Machine learning techniques in concrete mix design, *Materials*, 12 (2019) 8, pp. 1256, <https://doi.org/10.3390/ma12081256>
- [18] Duan, J., Asteris, P.G., Nguyen, H., Bui, X.N., Moayedi, H.: A novel artificial intelligence technique to predict compressive strength of recycled aggregate concrete using ICA-XGBoost model, *Engineering with Computers*, (2020), pp. 1-18, <https://doi.org/10.1007/s00366-020-01003-0>

- [19] Nunez, I., Marani, A., Nehdi, M.L.: Mixture Optimization of Recycled Aggregate Concrete Using Hybrid Machine Learning Model, *Materials*, 13 (2020) 19, pp. 4331, <https://doi.org/0.3390/ma13194331>
- [20] Cihan, M.T.: Prediction of Concrete Compressive Strength and Slump by Machine Learning Methods, *Advances in Civil Engineering*, 2019 (2019), pp. 1-11, <https://doi.org/10.1155/2019/3069046>
- [21] Cihan, M.T., Güner, A., Yüzer, N.: Response surfaces for compressive strength of concrete, *Construction and Building Materials*, 40 (2013), pp. 763-774, <https://doi.org/10.1016/j.conbuildmat.2012.11.048>
- [22] Gilan, S.S., Jovein, H.B., Ramezani-pour, A.A.: Hybrid support vector regression-Particle swarm optimization for prediction of compressive strength and RCPT of concretes containing metakaolin, *Construction and Building Materials*, 34 (2012), pp. 321-329, <https://doi.org/10.1016/j.conbuildmat.2012.02.038>
- [23] Vapnik, V.: *The nature of statistical learning theory*, Springer science & business media, Second edition, 2013.
- [24] Kennedy, J., Eberhart, R.: Particle swarm optimization (PSO), *Proceedings of ICNN'95 - International Conference on Neural Networks*, pp. 1942-1948, 1995.
- [25] Shi, Y., Eberhart, R.: A modified particle swarm optimizer, *IEEE International Conference on Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, pp. 69-73, 1998.
- [26] Atici, U.: Prediction of the strength of mineral admixture concrete using multivariable regression analysis and an artificial neural network, *Expert Systems with Applications*, 38 (2011) 8, pp. 9609-9618, <https://doi.org/10.1016/j.eswa.2011.01.156>
- [27] Baykasoğlu, A., Öztas, A., Özbay, E.: Prediction and multi-objective optimization of high-strength concrete parameters via soft computing approaches, *Expert Systems with Applications*, 36 (2009) 3, pp. 6145-6155, <https://doi.org/10.1016/j.eswa.2008.07.017>
- [28] Yan, K., Shi, C.: Prediction of elastic modulus of normal and high strength concrete by support vector machine, *Construction and Building Materials*, 24 (2010) 8, pp. 1479-1485, <https://doi.org/10.1016/j.conbuildmat.2010.01.006>
- [29] Demir, F.: A new way of prediction elastic modulus of normal and high strength concrete—fuzzy logic, *Cement and Concrete Research*, 35 (2005) 8, pp. 1531-1538, <https://doi.org/10.1016/j.cemconres.2005.01.001>
- [30] Demir, F.: Prediction of elastic modulus of normal and high strength concrete by artificial neural networks, *Construction and Building Materials*, 22 (2008) 7, pp. 1428-1435, <https://doi.org/10.1016/j.conbuildmat.2007.04.004>
- [31] Ghafoori, N., Najimi, M., Sobhani, J., Aqel, M.A.: Predicting rapid chloride permeability of self-consolidating concrete: a comparative study on statistical and neural network models, *Construction and Building Materials*, 44 (2013), pp. 381-390, <https://doi.org/10.1016/j.conbuildmat.2013.03.039>
- [32] Tsai, H.-C.: Predicting strengths of concrete-type specimens using hybrid multilayer perceptrons with center-unified particle swarm optimization, *Expert Systems with Applications*, 37 (2010) 2, pp. 1104-1112, <https://doi.org/10.1016/j.eswa.2009.06.093>
- [33] Tanyildizi, H., Çevik, A.: Modeling mechanical performance of lightweight concrete containing silica fume exposed to high temperature using genetic programming, *Construction and Building Materials*, 24 (2010) 12, pp. 2612-2618, <https://doi.org/10.1016/j.conbuildmat.2010.05.001>
- [34] Team, R.C.: *R: A language and environment for statistical computing*, 2013.
- [35] Breiman, L.: Random forests, *Machine learning*, 45 (2001) 1, pp. 5-32.
- [36] Cihan, P., Kalipsız, O., Gökçe, E.: Computer-aided diagnosis in neonatal lamb, *Pamukkale University Journal of Engineering Sciences*, 26 (2020) 2, pp. 385-397, <https://doi.org/10.5505/pajes.2019.51447>
- [37] Kuhn, M.: Building predictive models in R using the caret package, *Journal of statistical software*, 28 (2008) 5, pp. 1-26, <https://doi.org/10.18637/jss.v028.i05>
- [38] Chattamvelli, R.: *Data Mining Methods*, Alpha Science International, 2009.
- [39] Therneau, T.M., Atkinson, B., Ripley, M.B.: *The rpart package*, 2010.
- [40] Dimitriadou, E., Hornik, K., Leisch, F., Meyer, D., Weingessel, A., Leisch, M.F.: Package 'e1071', R Software package, <http://cran.rproject.org/web/packages/e1071/index>, 2009.
- [41] Beyer, K., Goldstein, J., Ramakrishnan, R., Shaft, U.: When is "nearest neighbour" meaningful?, *International Conference on Database Theory-ICDT*, pp. 217-235, 1999.
- [42] Beygelzimer, A., Kakadet, S., Langford, J., Arya, S., Mount, D., Li, S., Li, M.S.: Package 'FNN', 2015.
- [43] Pacheco, A.G., Krohling, R.A., da Silva, C.A.: Restricted Boltzmann machine to determine the input weights for extreme learning machines, *Expert Systems with Applications*, 96 (2018), pp. 77-85, <https://doi.org/10.1016/j.eswa.2017.11.054>
- [44] Huang, G.-B., Zhou, H., Ding, X., Zhang, R.: Extreme learning machine for regression and multiclass classification, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42 (2012) 2, pp. 513-529, <https://doi.org/10.1109/TSMCB.2011.2168604>
- [45] Mouselimis, L., Gosso, A.: *elmNNRcpp: The Extreme Learning Machine Algorithm*, R package v 1.0.1., 2018.
- [46] Bishop, C.M.: *Pattern recognition and machine learning*, Springer, 2006.
- [47] Team, R.C., Worldwide, C.: *The R stats package*. R Foundation for Statistical Computing, 2002.
- [48] Salleh, M.N.M., Talpur, N., Hussain, K.: Adaptive Neuro-Fuzzy Inference System: Overview, Strengths, Limitations, and Solutions, *International Conference on Data Mining and Big Data*. Springer, Cham, pp. 527-535, 2017.
- [49] Cuevas, E., Díaz, P., Avalos, O., Zaldivar, D., Pérez-Cisneros, M.: Nonlinear system identification based on ANFIS-Hammerstein model using Gravitational search algorithm, *Applied Intelligence*, 48 (2018) 1, pp. 182-203, <https://doi.org/10.1007/s10489-017-0969-1>
- [50] Jang, J.-S.: ANFIS: adaptive-network-based fuzzy inference system, *IEEE transactions on systems, man, and cybernetics*, 23 (1993) 3, pp. 665-685, <https://doi.org/10.1109/21.256541>
- [51] Prasad, K., Gorai, A.K., Goyal, P.: Development of ANFIS models for air quality forecasting and input optimization for reducing the computational cost and time, *Atmospheric environment*, 128 (2016), pp. 246-262, <https://doi.org/10.1016/j.atmosenv.2016.01.007>
- [52] Riza, L.S., Bergmeir, C.N., Herrera, F., Benítez Sánchez, J.M.: *frbs: Fuzzy rule-based systems for classification and regression in R*, American Statistical Association, 2015.
- [53] Azeem, M.F.: *Fuzzy Inference System: Theory and Applications, BoD—Books on Demand*, 2012.

- [54] Howlett, R. J., Jain, L.C.: Knowledge-based intelligent information and engineering systems, Springer Berlin/Heidelberg, 2005.
- [55] Olson, D.L., Delen, D.: Advanced data mining techniques, Springer Science & Business Media, 2008.
- [56] Lam, L., Wong, Y., Poon, C.S.: Effect of fly ash and silica fume on compressive and fracture behaviours of concrete, *Cement and Concrete research*, 28 (1998) 2, pp. 271-283, [https://doi.org/10.1016/S0008-8846\(97\)00269-X](https://doi.org/10.1016/S0008-8846(97)00269-X)
- [57] Al-Shamiri, A.K., Kim, J.H., Yuan, T.F., Yoon, Y.S.: Modeling the compressive strength of high-strength concrete: An extreme learning approach, *Construction and Building Materials*, 208 (2019), pp. 204-219, <https://doi.org/10.1016/j.conbuildmat.2019.02.165>
- [58] Lim, C.H., Yoon, Y.S., Kim, J.H.: Genetic algorithm in mix proportioning of high-performance concrete, *Cement and Concrete Research*, 34 (2004) 3, pp. 409-420, <https://doi.org/10.1016/j.cemconres.2003.08.018>
- [59] Yeh, I.C.: Modeling of strength of high-performance concrete using artificial neural networks, *Cement and Concrete research*, 28 (1998) 12, pp. 1797-1808, [https://doi.org/10.1016/S0008-8846\(98\)00165-3](https://doi.org/10.1016/S0008-8846(98)00165-3)
- [60] CİHAN, M.T.: Tepki yüzeyi yöntem bilgisinin beton uygulamasında kullanılabilirliğinin geliştirilmesi, Yıldız Teknik Üniversitesi, 2012.
- [61] Taylor, K.E.: Summarizing multiple aspects of model performance in a single diagram, *Journal of Geophysical Research: Atmospheres*, 106 (2001) D7, pp. 7183-7192, <https://doi.org/10.1029/2000JD900719>
- [62] Chou, J.S., Tsai, C.F., Pham, A.D., Lu, Y.H.: Machine learning in concrete strength simulations: Multi-nation data analytics, *Construction and Building Materials*, 73 (2014), pp. 771-780, <https://doi.org/10.1016/j.conbuildmat.2014.09.054>
- [63] Chou, J.S., Pham, A.D.: Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength, *Construction and Building Materials*, 49 (2013), pp. 554-563, <https://doi.org/10.1016/j.conbuildmat.2013.08.078>