

Primljen / Received: 2.9.2016.

Ispravljen / Corrected: 4.3.2017.

Prihvaćen / Accepted: 10.3.2017.

Dostupno online / Available online: 10.6.2017.

# Predviđanje svojstava betona od recikliranih agregata

Avtori:



Doc.dr.sc. **Ivana Miličević**, dipl.ing.građ.  
Sveučilište J.J. Strossmayer u Osijeku  
Građevinski fakultet  
[ivana.milicevic@gfos.hr](mailto:ivana.milicevic@gfos.hr)



Doc.dr.sc. **Tanja Kalman Šipoš**, dipl.ing.građ.  
Sveučilište J.J. Strossmayer u Osijeku  
Građevinski fakultet  
[tkalman@gfos.hr](mailto:tkalman@gfos.hr)

Izvorni znanstveni rad

**Ivana Miličević, Tanja Kalman Šipoš**

## Predviđanje svojstava betona od recikliranih agregata

Upotreba recikliranih materijala kao zamjene prirodnog agregata u betonu značajna je iz ekološki prihvatljivog aspekta njegove ponovne upotrebe. Veza između komponenti betona i njegovih svojstava ne može biti prikazana samo na osnovi matematičkih formula. Prema tome, primijenjene su umjetne neuronske mreže i regresijska analiza eksperimentalnih rezultata postignutih planiranjem eksperimenta. Dokazano je da obje primijenjene tehnike omogućuju visoku pouzdanost za modeliranje svojstava betona na osnovi njegovih komponenti.

### Ključne riječi:

neuronska mreža, matematički model, drobljeni crijepl, drobljena opeka, svojstva betona

Original scientific paper

**Ivana Miličević, Tanja Kalman Šipoš**

## Prediction of properties of recycled aggregate concrete

Use of recycled materials as replacement for natural aggregate in concrete is important considering the environmentally beneficial aspect of its re-use. Relations between concrete components and concrete properties cannot be presented based on mathematical formulas only. Consequently, artificial neural networks and regression techniques were applied to analyse experimental results obtained according to previous experimental design. It was established that both techniques enable highly reliable modelling of concrete properties based on its components.

### Key words:

neural network, mathematical model, crushed tile, crushed brick, concrete properties

Wissenschaftlicher Originalbeitrag

**Ivana Miličević, Tanja Kalman Šipoš**

## Vorhersage der Eigenschaften von Recyclingbeton

Die Anwendung von recyceltem Material als Ersatz natürlicher Gesteinskörnung für Beton ist aufgrund des ökologisch akzeptablen Aspekts der Wiederverwertung bedeutend. Der Zusammenhang zwischen den Betonkomponenten und seinen Eigenschaften kann nicht ausschließlich mittels mathematischer Formeln dargestellt werden. Daher wurden künstliche neuronale Netze und eine Regressionsanalyse experimenteller Resultate im Bezug zur Planung des Experiments angewandt. Es wurde bewiesen, dass beide eingesetzten Techniken eine hohe Zuverlässigkeit bei der Modellierung von Betoneigenschaften aufgrund seiner Komponenten aufweisen.

### Schlüsselwörter:

neuronales Netz, mathematisches Modell, zerkleinerte Dachziegel, zerkleinerte Ziegelsteine, Betoneigenschaften

## 1. Uvod

Optimalna upotreba ograničenih kapaciteta prirodnih resursa nužna je kako bismo zaštitali životni okoliš. Uzimajući u obzir da agregat u betonu zauzima između 60 % i 75 % ukupnog volumena betona, svako smanjenje upotrebe prirodnih resursa imat će značajan utjecaj na okoliš [1]. Prema tome, upotreba recikliranih materijala kao zamjene za prirodni agregat u betonu postaje veliki izazov u okolišno prihvatljivom načinu ponovne njihove upotrebe. Neki od tipova recikliranih materijala koji mogu biti upotrijebljeni kao agregat u betonu jesu otpadni materijali nastali tijekom proizvodnje novih glinenih materijala, kao što su glinena opeka ili glineni crijeplji. Dio takvog otpadnog materijala upotrebljava se kao sirovina za nove keramičke ili glinene proizvode, no dio se, posebice otpadni materijal proizveden u građevinskoj industriji, otprema na odlagališta. Stoga, beton s recikliranim agregatom (BRA) postao je zanimljiv iz aspekta okolišno prihvatljivog materijala nepoznatih svojstava koji treba detaljno istražiti. Autori Debieb i Kenai [2] upotrebljavaju su krupnu i sitnu drobljenu opeku u betonu te zaključili da smanjenje tlačne čvrstoće betona s recikliranim agregatom od 20 % do 30 % ovisi prije svega o postotku zamjene prirodnog agregata s recikliranim. Cachim [1] je pokazao da se drobljena opeka može koristiti kao zamjena do 15 % prirodnog agregata pri čemu nema redukcije tlačne čvrstoće betona, te da pri zamjeni 30 % prirodnog agregata s drobljenom opekom dolazi do smanjenja tlačnih čvrstoća (do 20 %, ovisno o tipu opeke). S obzirom na sve to, može se zaključiti da postoji potreba za pouzdanom mogućnošću predviđanja svojstava betona s drobljenom opekom i crijepljom kao agregatom.

Uzimajući u obzir da ponašanje i svojstva drobljene opeke i crijepla (OC) nisu u potpunosti poznati, potrebno je provesti dodatna istraživanja njihova obrasca ponašanja. Ipak, opsežna ispitivanja zahtijevaju određene količine materijala, vremena i troškova. Stoga, kako bi samo unaprijedili znanja o ponašanju OC kao agregata u betonu, a i smanjili troškove te uštedjeli vrijeme potrebno za provođenje opsežnih eksperimentalnih ispitivanja, istraženi su modeli simulacije ponašanja takvog betona uzimajući u obzir ulazne i izlazne podatke dobivene u radu [3].

Pritom su kao ulazni podatci uzimane u obzir komponente betona, a kao izlazni dobivena svojstva materijala. Jedna od tehnika modeliranja koja se primjenjuje za simuliranje ponašanja betona s recikliranim materijalom jesu umjetne neuronske mreže (UNM), a time su i jedno od važnijih istraživačkih područja [4-6]. Bez obzira na korisnost i primjenjivost objavljenih rezultata istraživanja na tom području, veza između komponenti betona i svojstava još uvijek se smatra upitnom. Postoji potreba za točnim i uverljivim modelima predviđanja koji mogu uštedjeti vrijeme i smanjiti troškove, a pritom pružiti pouzdane podatke bez eksperimentalnih ispitivanja. U ovom radu prikazana su istraživanja upotrebe naprednih neuronskih mreža i matematičkog modeliranja (MM) za predviđanje svojstava betona s OC kao djelomičnom zamjenom prirodnog

agregata. Također, određen je doprinos svih izlaznih vrijednosti upotrebljavajući analizu osjetljivosti. Osnovni ciljevi ovog istraživanja su:

- istražiti mogućnost predviđanja svojstava materijala s ograničenim brojem ulaznih podataka, tj. upotrebom obaveznih parametara, upotrebom UNM i matematičkog modela,
- razviti modele predviđanja svojstava betona i razumjeti ponašanje i utjecaj svakog dodatnog ulaznog parametra na izlazne podatke (analiza osjetljivosti).

## 2. Planiranje eksperimenta za mješavine BRA

### 2.1. Tipovi planiranih eksperimenta

Da bi se mogla optimizirati mješavina BRA, potrebno je dobiti osnovna svojstva betonskih mješavina s različitim udjelima njegovih komponenti koje bi trebale biti značajne za samu betonsku mješavinu. Planiranje eksperimenta važno je radi organiziranosti i preglednosti te kako bi se omogućila statistička analiza rezultata eksperimenta, što je vidljivo u različitim područjima inženjerske struke [7-9]. Svrha je statističke analize procijeniti model drugog reda za pojedino svojstvo betona. Cilj ovog dijela istraživanja jest optimiranje svakog svojstva OC betona upotrebom metodologije odzivne površine kako se u konačnici dobio model drugog reda prikazan u jednadžbi (1), gdje je:

$$O_i - M = f(F_1, F_2, \dots, F_k) = \beta_0 + \sum_{i=1}^k F_i + \sum_{i=1}^k \beta_{ii} F_i^2 + \sum_{i < j} \sum_{j=2}^k \beta_{ij} F_i F_j \quad (1)$$

pri čemu odziv označen s  $O_i - M$  predstavlja pojedino svojstvo betona dobiveno matematički, faktori  $F$  predstavljaju vrijednosti BRA komponenti, a koeficijente  $\beta$  treba izračunati kako bi što bolje odgovarali eksperimentalno odzivima. Nakon toga, mješavine betona s OC kao agregatom bit će optimirane uzimajući u obzir jednu od metoda višekriterijskog odlučivanja prikazan konturnim dijagramom baziranim na modelu drugog reda pojedinog svojstva betona.

Prikazane su dvije vrste planiranja eksperimenta prikladne za mogući broj provedenih eksperimentalnih ispitivanja: centralno kompozitni (CK) i Box-Behnkenov (BB). Oba ova planirana eksperimenta ne zahtijevaju velik broj provedenih istraživanja već samo opća potrebna da bi se dobio model drugog reda s faktorom koji može imati tri do pet razina. Obje vrste BB i CK planiranja su rotabilne (procjena odziva jednake je preciznosti u svim točkama područja operabilnosti koje su jednakom udaljene od središta plana eksperimenta), makar i djelomično.

CK planiranje je eksperimentalno i temeljeno na metodi odzivne površine za određivanje jednadžbe regresije drugog stupnja. Sastoji se od faktorskog planiranja (točke kocke) zajedno s centralnim i aksijalnim točkama (slika 1.). Tip CK planiranja koji je primjenjeno za replaniranje eksperimenta (pozicija centralne i aksijalnih točaka) određeno je brojem faktora (k) i brojem zahtijevanih svojstava.

Oblici CK planiranja:


- opisani centralno kompozitni plan (OCK), s razinama faktora  $(-\alpha, -1, 0, 1, \alpha)$
- upisani centralno kompozitni plan eksperimenta (UCK), s razinama faktora:  $(-1, -1/\alpha, 0, 1/\alpha, 1)$
- plošno centrirani kompozitni plan eksperimenta (PCK), s razinama faktora:  $(-1, 0, 1)$

gdje se udaljenost aksijalnih točaka  $\alpha$  može odrediti prema Montgomeryju [10]:


$$\alpha = \left[ 2^k \right]^{\frac{1}{4}} \quad (2)$$

Na slici 1. prikazana su tri tipa CK planiranja. Iz slike se može zaključiti da OCK planiranje obuhvaća najveći, a UCK najmanji eksperimentalni prostor. OCK i UCK su rotatabilne vrste planiranja, a PCK nije. U OCK planiranju, točke su postavljene na način da su raspoređene aksijalno jednako udaljene od središta ili centralnih točaka, [11].

BB planiranje eksperimenta primjenjuje se kada se žele izbjegići ekstremne kombinacije faktora. BB planiranje je rotabilno (slika 2.), i zahtjeva  $2k(k-1)+1$  eksperimenata i tri razine faktora  $(-1, 0, +1)$ .



Slika 1. Primjer centralno kompozitnog planiranja eksperimenta ( $k = 2$ ): a) CK; b) UCK; c) PCK



Slika 2. Primjer Box-Behnkenova planiranja ( $k = 3$ )

### 3. Primjena planiranja eksperimenta

Sedam osnovnih komponenti BRA koje su važne za optimizaciju, a upotrijebljene su u planiranju eksperimenta, jesu: cement, vodocementni faktor, dodatak betonu, postotak udjela drobljenog crijeva (DC) i postotak recikliranog agregata nastalog drobljenjem opeke (DO) frakcija 0 - 4 mm i 4 - 16 mm. Granice svakog od navedenih faktora prikazane su u tablici 1. Gornja i

donja granica odgovaraju normiranim razinama faktora  $-\alpha$  i  $\alpha$  samo za OCK planiranje eksperimenta. Za sve ostale vrste planiranja eksperimenta donja i gornja granica odgovaraju normiranim razinama faktora  $-1$  i  $1$ . Ostale upotrijebljene razine faktora mogu se izračunati pomoću definirane gornje i donje granice razine faktora.

Donje i gornje granice prikazane tablicom 1. odabrane su s obzirom na prijašnja provedena ispitivanja i preporuke iz literature [12-16]. Prema Hansenu [17], udio cementa betonu s recikliranim opekom kao agregatom može se povećati do 20 % u usporedbi s betonom s prirodnim agregatom. Također, uvelike ovisi i o vrsti i sastavu upotrijebljene drobljene opeke i crijeva (DOC).

Tablica 1. Granice osnovnih komponenti sastava BRA (faktori)

Faktor	Komponente betona	Donja granica	Gornja granica
F1	Cement [kg]	300	500
F2	v/c faktor	0,15	0,60
F3	Dodatak betonu [%]	0	1
F4	DO 0-4 mm [%]	0	50
F5	DO 4-16 mm [%]	0	50
F6	DC 0-4 mm [%]	0	50
F7	DC 4-16 mm [%]	0	50

Prirodni agregat (PA) također je upotrijebljen u mješavinama, a njegov postotak ovisi o postotku korištene DO i DC kao agregata:

$$PA(\%) = 100\% - DC(\%) - DO(\%) \quad (3)$$

zato PA nije faktor. Nadalje, postotak DC i DO agregata je ograničen kako slijedi:

$$DO(\%) + DC(\%) \leq 100 \% \quad (4)$$

Centralno kompozitno planiranje ima značajno veći broj eksperimenata u usporedbi s Box-Behnkenovim (BB) planiranjem, tablica 2.

Tablica 2. Broj eksperimenata ovisno od vrste planiranja

Vrste planiranja	CK	OCK	PCK	BB
Broj eksperimenata	143	143	143	62

Kao što je opisano u radu autora Milicević i dr. [18], troškovi jedne mješavine iznose otprilike 6125 eura. Prema tome se može zaključiti da centralno kompozitno planiranje eksperimenta za sedam faktora nije prihvatljivo iz vremenskih i finansijski razloga. Stoga je odabранo Box-Behnkenovo planiranje eksperimenta za određivanje optimalne mješavine betona s recikliranim agregatom. Eksperimentalno ispitivanje definirano Box-Behnkenovim planiranjem opisano je u [19].

## 4. Predviđanje svojstava betona

### 4.1. Eksperimentalni rezultati

Uzorci betona ispitani su u skladu s normama HRN EN 12390-3:2009, HRN EN 12390-5:2009, HRN EN 12390-7:2009 i HRN U.M1.025:1982. Slike 3. i 4. prikazuju rezultate eksperimentalnog ispitivanja gustoće (O1), tlačne čvrstoće (O2), vlačne čvrstoće savijanjem (O3) i modula elastičnosti (O4). Eksperimentalna ispitivanja svojstava betona O1 do O4 provedena su pri starosti betona od 56 dana.


### 4.2. Svojstva betona dobivena matematičkim modelom

Koeficijenti  $\beta$  potrebni za odziv  $O_i - M$  u jednadžbi (1) dobiveni su primjenom regresijske analize u Matlabu, čiji se algoritam temelji na QR dekompoziciji matrica. Uvjet za uspješno izvođenje algoritma jest ispunjeni uvjet (5), to jest


$$\text{broj članova modela} \leq \text{broj mjerena} = 62 \quad (5)$$

Model drugog reda (1) sadrži 36 članova modela čime je zadovoljen uvjet (5). Tablica 3. prikazuje koeficijente  $\beta$  izračunane za svako odabранo svojstvo betona (O1-M do O4-M).

Rezultati izračunanih svojstava definirani matematičkim modelom BRA s DC i DO kao agregatom prikazani su u poglavlju 5 i uspoređeni s rezultatima dobivenim uz pomoć umjetnih neuronskih mreža (UNM).




Slika 3. Gistoča i vlačna čvrstoća savijanjem očvrsnulog betona



Slika 4. Svojstva očvrsnulog betona 56. dan

### 4.3. Primjena umjetnih neuronskih mreža u predviđanju svojstava betona

Prema Haykinu [21], umjetne neuronske mreže (UNM) predstavljaju masivni paralelni distribuirani sustav koji može riješiti i dati odgovore kod zahtjevnih problema uporabom jednostavnih međusobno povezanih elemenata za obradu podataka (umjetni neuroni). Zapravo su umjetni neuroni analogni prirodnim neuronima u mozgu, koji se sastoje od velikog broja jednostavnih međusobno povezanih elemenata raspoređenih u nekoliko slojeva. UNM imaju značajan utjecaj kod obrade i učenja podataka i procesa pa su stoga učinkovito sredstvo za inženjerske primjene.



Slika 5. Tvorba primjenjene neuronske mreže

Neuronsku mrežu (slika 5.) tvori pet osnovnih dijelova: ulazni neuroni, težinski udjeli, sumator, aktivacijska funkcija i izlazni neuroni. Ulazni neuroni primaju podatke na početku obrade neuronske mreže te ih predaju dalje preko susjednih

**Tablica 3. Koeficijenti  $\beta$** 

$\beta$	01-M	02-M	03-M	04-M	$\beta$	01-M	02-M	03-M	04-M
$\beta_0$	2038,40	23,30	2,19	14436,00	$\beta_{24}$	-1,09	3,94	0,05	875,59
$\beta_1$	88,21	9,22	0,49	2153,00	$\beta_{34}$	-89,80	-6,73	-0,36	-1519,80
$\beta_2$	5,90	-3,95	-0,16	-1833,80	$\beta_{35}$	-18,71	0,84	-0,05	-974,25
$\beta_3$	45,90	-0,31	0,31	387,05	$\beta_{36}$	-35,70	-5,37	-0,13	-1614,80
$\beta_4$	-8,82	0,17	-0,05	-123,27	$\beta_{37}$	-82,51	-6,54	-0,36	-1835,40
$\beta_5$	-94,82	-3,25	-0,24	-3432,00	$\beta_{45}$	-23,28	-0,21	0,03	-478,55
$\beta_6$	-25,99	-1,60	-0,04	-1325,90	$\beta_{46}$	-68,08	-4,40	-0,38	-1346,20
$\beta_7$	-119,93	-5,28	-0,29	-3328,60	$\beta_{47}$	-1,05	-0,88	-0,03	-127,80
$\beta_{12}$	54,79	3,38	0,29	954,11	$\beta_{56}$	-3,70	-1,04	-0,06	-361,38
$\beta_{13}$	79,63	3,44	0,28	3298,30	$\beta_{57}$	21,57	3,03	0,05	307,36
$\beta_{14}$	27,94	2,92	0,04	348,44	$\beta_{67}$	-49,77	-0,33	-0,17	-950,54
$\beta_{15}$	-6,05	2,17	0,08	-133,11	$\beta_{11}$	26,60	3,10	0,12	2396,60
$\beta_{16}$	-40,35	-1,55	-0,14	-961,18	$\beta_{22}$	92,68	7,11	0,52	2413,60
$\beta_{17}$	-15,72	-4,56	-0,08	8,54	$\beta_{33}$	21,39	3,18	0,08	1185,40
$\beta_{23}$	100,92	8,77	0,61	546,14	$\beta_{44}$	-34,37	-0,72	-0,05	214,72
$\beta_{24}$	3,85	0,70	0,17	612,30	$\beta_{55}$	-82,66	-5,38	-0,18	607,61
$\beta_{25}$	36,31	5,48	0,13	-77,78	$\beta_{66}$	-47,69	-1,28	-0,14	-670,30
$\beta_{26}$	33,77	0,17	0,09	304,32	$\beta_{77}$	40,25	1,77	0,29	3894,70

neurona. Težinski udjeli prikazuju doprinos ulaznog podatka iz prethodnog sloja na neurone sljedećeg sloja. Sumator predstavlja sumu svih ulaznih podataka i pripadajućih težinskih udjela. Aktivacijska funkcija predstavlja funkciju obrade ulaznog podatka iz funkcije sume i određuje izlazni rezultat neurona.

#### 4.3.1. "Back-propagation" – algoritam povratnog prostiranja

Prema Lippmanu [22], višeslojna mreža algoritma povratnog prostiranja je najpopularnija umjetna neuronska mreža, te se često koristi radi učinkovite sposobnosti generalizacije. Općenito se postupak procesuiranja neuronskih mreža sastoji od dvije različite faze: faze učenja i faze testiranja.

Umetne neuronske mreže imaju sposobnost ostvarivanja povoljnog udjela generalizacije na uzorcima na kojima su naučeni [23]. Učenje podrazumijeva obradu neuronske mreže na skupu ulaznih i izlaznih podataka koji su definirani u slojevima, a to su: ulazni sloj, izlazni sloj, te jedan ili više skrivenih slojeva sa skrivenim neuronima. Postupak učenja se u slučaju algoritma povratnog prostiranja nastavlja i na izlaznom sloju neurona gdje se pogreška, koja predstavlja razliku između izlaznog rezultata neuronske mreže i stvarnog izlaznog rezultata, vraća natrag s ažuriranim težinskim udjelima i to u onom smjeru u kojem funkcija prilagođavanja najbrže opada [24]. Za sve modelle neuronskih mreža u radu je uporabljen Levenberg–Marquardtov algoritam. Učenje neuronske mreže je zaustavljeno ostvarenjem jednog od navedenih uvjeta:

- dosegnut je maksimalni broj iteracija od 10,000 (MAX\_EPOCHS);
- MSE (eng. Mean squared error) kvadratna pogreška je smanjena na vrijednost do 1 % (MIN\_MSE);
- vrijednost gradijanta Levenberg–Marquardtova algoritma se spusti ispod 1e-7 (MIN\_GRAD);
- vrijednost prilagodljivog momentuma Levenberg–Marquardtova algoritma premaši 1e10 (MAX\_MU).

Nakon što je učenje završilo, neuronska mreža se testira na skupu novih ulaznih i izlaznih podataka koji nisu bili uporabljeni u postupku učenja.

#### 4.3.2. Broj skrivenih neurona

Slučajni odabir broja skrivenih neurona može izazvati prenaučenost (eng. overfitting) ili nedovoljnu točnost kod modela za predviđanje [25]. Ovaj problem nastaje uslijed odgovora mreže koji su toliko bliski traženim vrijednostima u postupku učenja da se mogućnost generalizacije pri postupku testiranja gubi.

Broj skrivenih neurona ima značajan utjecaj na stabilnost neuronske mreže koja je određena pogreškom (manja pogreška odražava bolju stabilnost). Prekomjeran broj skrivenih neurona izazvati će prenaučenost, pri kojoj neuronska mreža precjenjuje složenost ciljanog problema. Prema tome, odabir odgovarajućeg broja skrivenih neurona za sprječavanje prenaučenosti ključan je korak u postupku rješavanja problema predviđanja sa stabilnom mogućnosti generalizacije i najmanjim mogućim odstupanjem.


Broj skrivenih neurona definiran je izrazima koje je predložilo 15 autora [25-27], a pritom su testirali i predložili različite metodologije. Empirijski izrazi za broj skrivenih neurona u prvom skrivenom sloju su prikazani u tablici 4.

Rezultati 15 jednadžbi prema tablici 4. prikazani su i rezimirani na slici 6. prema broju ulaznih neurona (Tablica 1: F1-F7,  $N_i=7$  postoji 7 komponenata betona), i prema broju izlaznih neurona (O1-O4, iako postoje 4 svojstva betona  $N_o=1$  zbog točnosti rezultata neuronske mreže). Kako je i prikazano na slici 6., u dalnjem postupku evaluacije primijenit će se neuronske mreže sa 3, 6 i 8 skrivenih neurona u jednom skrivenom sloju.

Tablica 4. Empirijski izrazi za broj skrivenih neurona  $N_h$

Br.	Metodologija	$N_h$	Literatura
1.	Neville (1986.)	$0.75 \cdot N_i$	(Ozturan, 2008.)
2.	Neville (1986.)	$2 \cdot N_i + 1$	(Ozturan, 2008.)
3.	Hecht-Nielsen (1987.)	$\leq 2 \cdot N_i$	Sonmez, 2006
4.	Hush (1989.)	$3 \cdot N_i$	Sonmez, 2006
5.	Popovics (1990.)	$(N_i + N_o)/2$	(Ozturan, 2008.)
6.	Gallant (1993.)	$2 \cdot N_i$	(Ozturan, 2008.)
7.	Wang (1994.)	$2 \cdot N_i / 3$	Sonmez, 2006.
8.	Masters (1994.)	$(N_i + N_o)^{1/2}$	Sonmez, 2006.
9.	Li (1995.)	$((1+8 N_i)^{1/2}-1)/2$	(Sheela, 2013.)
10.	Tamura (1997.)	$N_i + 1$	(Sheela, 2013.)
11.	Lai (1997.)	$N_i$	(Ozturan, 2008.)
12.	Nagendra (1998.)	$N_i + N_o$	(Ozturan, 2008.)
13.	Zhang (2003.)	$2^{N_i}/n + 1$	(Sheela, 2013.)
14.	Shibata (2009.)	$(N_i \cdot N_o)^{1/2}$	(Sheela, 2013.)
15.	Sheela (2013.)	$(4 N_i^2 + 3) / (N_i^2 - 8)$	(Sheela, 2013.)

$N_i$  – broj ulaznih neurona;  $N_o$  – broj izlaznih neurona




Slika 6. Broj skrivenih neurona za  $N_i=7$ ,  $N_o=1$

#### 4.3.3. Parametri i model neuronske mreže

Model umjetne neuronske mreže u ovom radu ima sedam neurona u ulaznom sloju i jedan neuron u izlaznom, kako je i prikazano na slici 7.

Ulagani sloj se sastoji od sljedećih podataka: cement (F1), vodocementni omjer (F2), dodatak (F3), lom crijeva 0-4 mm

(F4), lom crijeva 4-16 mm (F5), lom opeke 0-4 mm (F6) i lom opeke 4-16 mm (F7). Izlazni sloj obuhvaća četiri karakteristike materijala: gustoću (O1-N), tlačnu čvrstoću (O2-N), čvrstoću na savijanje (O3-N) i statički modul elastičnosti (O4-N) (svakiput je uporabljen samo jedan izlazni podatak).



Slika 7. Struktura UNM: jedan skriveni sloj sa šest skrivenih neurona

Raspon vrijednosti ulaznih podataka je prikazan u tablici 5. Jedan skriveni sloj sa 3, 6 i 8 neurona je uporabljen u višeslojnoj neuronskoj mreži. Prema minimalnim vrijednostima apsolutnih pogrešaka setova za učenje i testiranje, u ovom radu su prikazani samo rezultati analize za šest neurona u skrivenom sloju. Učinak UNM prije svega ovisi o tvorbi mreže te o uporabljenim parametrima (tablica 6.). Za učenje i testiranje pomoću UNM uporabljena su 62 eksperimentalna uzorka, od kojih je 50 slučajno odabранo za za učenje, a ostalih 12 uporabljeno je za testiranje.

Tablica 5. Raspon ulaznih parametara za model UNM

Ulazni podaci	Raspon
Cement [kg]	300-500
v/c omjer	0.4-0.6
Dodatak	0-1
CT 0-4	0-50
CT 4-16	0-50
CB 0-4	0-50
CB 4-16	0-50

Tablica 6. Parametri neuronske mreže primjenjeni na modelu UNM

Parametri	UNM
Broj ulaznih neurona	7
Broj skrivenih slojeva	1
Broj skrivenih neurona	6
Broj izlaznih neurona	1
Faktor učenja	0.01
Ciljana pogreška	0
Maksimalni broj ciklusa učenja	10000

U ovom je radu za primjenu UNM uporabljen Matlab ANN toolbox [28]. Svi modeli neuronskih mreža bili su trenirani pomoću

Tablica 7. Raspon vrijednosti izlaznih podataka uporabljenih u UNM

Oznaka	Podatak	Jedinica	Minimalno	Maksimalno	Standardna devijacija	Srednja vrijednost
01	Gustoća	kg/m <sup>3</sup>	1698,84	2450,27	171,06	2047,25
02	Tlačna čvrstoća	N/mm <sup>2</sup>	8,70	61,75	12,05	26,42
03	Čvrstoća na savijanje	N/mm <sup>2</sup>	2,31	8,84	1,49	4,88
04	Statički modul elastičnosti	N/mm <sup>2</sup>	9852,82	31995,86	5133,65	18373,03

Levenberg–Marquardtova algoritma sa "log-sigmoidnom" prijelaznom funkcijom između prvog (ulaznog) i drugog (skrivenog) sloja te "linearnu" prijelaznu funkciju između drugog i trećeg (izlaznog) sloja.

#### 4.3.4. Metode procjene

Da bi se procijenila učinkovitost neuronske mreže te njene sposobnosti točnog predviđanja, uporabljeno je pet statističkih mjera procjene kako slijedi:

- a) Srednja apsolutna pogreška (eng. *mean absolute error* - MAE) – veličina koja služi za mjerjenje koliko su blizu predviđene vrijednosti poznatim izlaznim podatcima:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - y'| \quad (6)$$

gdje je  $y'$  predviđena vrijednost;  $y$  je stvarna vrijednost; a  $n$  je broj promatranih uzoraka.

- b) Korijen srednje kvadratne pogreške:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y' - y)^2} \quad (7)$$


- c) Srednja apsolutna postotna pogreška:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y - y'}{y} \right| \quad (8)$$

- d) Koeficijent korelacije:

$$R = \frac{\sum_{i=1}^n ((y - \bar{y}) \cdot (y' - \bar{y}'))}{\sqrt{\sum_{i=1}^n (y - \bar{y})^2 \cdot \sum_{i=1}^n (y' - \bar{y}')^2}} \quad (9)$$

gdje je  $y'$  srednja predviđena vrijednost;  $y$  srednja stvarna vrijednost.



Slika 8. Rezultati analize osjetljivosti

- e) Nash-Sutcliffeov koeficijent učinkovitosti:

$$E = 1 - \frac{\sum_{i=1}^n (y - y')^2}{\sum_{i=1}^n (y - \bar{y})^2} \quad (10)$$


Manje vrijednosti MAE, RMSE, MAPE i više vrijednosti R i E iznad 0.90 predstavljaju dobru učinkovitost i predvidljivost modela.

#### 4.3.5. Analiza osjetljivosti

Prikaz kompleksnih odnosa između osnovnih komponenta betona  $F_1, \dots, F_7$  i svojstava materijala kao ciljanih izlaznih podataka može se dokazati analizom osjetljivosti. U ovom radu primjenjena je stupnjevita analiza osjetljivosti metodom unaprijed kako bi se utvrdili najznačajniji odnosi između ulaznih i izlaznih podataka.

Stupnjevita metoda unaprijed procjenjuje promjenu korijena srednje kvadratne pogreške (RMSE) sekvensijalnim dodavanjem uvijek jednog i uvijek novog ulaznog podatka u model neuronske mreže za jedan izlazni podatak (obnova neuronske mreže u svakom stupnju-koraku). Promjena RMSE za svaku varijablu ilustrira relativnu važnost ulaznog podatka u odnosu na izlazni.


Vrijednost RMSE, kao što je prikazano na slici 8., normalizirana je na raspon vrijednosti od 0-1 (gdje 0 prikazuje minimalnu RMSE). Viša vrijednost predstavlja veću važnost ulaznog podatka. Prema rezultatima analize osjetljivosti, svi ulazni podatci su izrazito značajni i općenito imaju snažan utjecaj na sva četiri izlazna podatka, te će stoga svi ulazni podaci biti uporabljeni u daljnjoj analizi.



Slika 9. UNM i MM rezultati za izlazni podatak 1

Tablica 8. Statističke mjere za UNM i MM modele izlaznog podatka 1

Model	MAE [kg/m <sup>3</sup> ]	RMSE [kg/m <sup>3</sup> ]	MAPE [%]	R	E
UNM	37,694	2,571	1,897	0,999	0,999
MM	58,645	0,015	2,910	0,999	0,998



Slika 10. ANN i MM rezultati za izlazni podatak 2

Tablica 9. Statističke mjere za UNM i MM modele izlaznog podatka 2

Model	MAE [kg/m <sup>3</sup> ]	RMSE [kg/m <sup>3</sup> ]	MAPE [%]	R	E
UNM	0,974	0,075	4,679	0,998	0,997
MM	5,469	1,970	22,250	0,973	0,931

## 5. Rezultati i rasprava

U ovom istraživanju testirali smo umjetne neuronske mreže (UNM) i matematički model (MM) kao alternativu klasičnim eksperimentalnim ispitivanjima za određivanje materijalnih karakteristika betona s lomljenom opekom i crijeponom kao

agregatom. Rezultati su procijenjeni usporednjom vrijednosti dobivenih modelima MM i UNM.

### 5.1. Izlazni podatak 1 – gustoća

Slika 9. prikazuje gustoću betona s lomljenom opekom i crijeponom

za učenje i testiranje UNM modela, te MM modela. Rezultati pokazuju da su predviđene vrijednosti čvrstoće i za UNM i MM model, za većinu uzoraka, u korelaciji s eksperimentalno dobivenim vrijednostima.

Vrijednosti MAE, RMSE, MAPE, R i E za oba modela, UNM i MM su prikazane u tablici 8. Vidljivo je da MM model ima najmanju vrijednost RMSE ( $0,015 \text{ kg/m}^3$ ), ali UNM model ima najmanji MAE i MAPE i viši E (0,999). Može se primijetiti da su rezultati iznimno precizni pa nema sumnje u pogledu točnosti i primjenjivosti modela UNM i MM za predviđanje gustoće betona s lomljenom opekom i crijeponom.

## 5.2. Izlazni podatak 2 – tlačna čvrstoća

MM model je u slučaju predviđanja tlačne čvrstoće pokazao veća odstupanja kao što je i prikazano na slici 10. Iako su rezultati MM modela dosegli slične srednje vrijednosti koeficijenta korelacije i Nash-Sutcliffeova koeficijenta učinkovitosti, u odnosu na UNM model nisu bile ostvarene tako niske vrijednosti pogrešaka (MAPE of 22.25 %), kako je i prikazano u tablici 9.

Nasuprot tome, UNM model je ostvario izrazito visoku razinu točnosti predviđanja, sa R i E od 0,99 i niskim RMSE i MAPE, čime je prikazana sposobnost simulacije tlačne čvrstoće betona sa lomljenom opekom i crijeponom kao agregatom.

## 5.3. Izlazni podatak 3 – vlačna čvrstoća savijanjem


Prema analizi predviđanja modela UNM i MM, odnosi između eksperimentalnih i modeliranih izlaznih vrijednosti su dobro

definirani, kao što je prikazano na slici 11. Osim toga, statističke mjere su prema najvišoj vrijednosti iznosile 11 % apsolutne pogreške. Između eksperimentalnih i modeliranih vrijednosti je uspostavljena prilično visoka korelacija: koeficijent korelacije između eksperimentalne čvrstoće na savijanje i UNM čvrstoće na savijanje iznosio je 0,98 sa E = 0,96, odnosno za 9 % i 18 % UNM model je imao manja odstupanja u odnosu na MM model. Ovi rezultati pokazuju da UNM model za čvrstoću na savijanje bolje simulira predviđanje traženih vrijednosti u odnosu na matematički model.

## 5.4. Izlazni podatak 4 – statički modul elastičnosti

Rezultati za izlazni podatak 4 pokazuju predviđene vrijednosti za dva načina modeliranja, UNM i MM za modul elastičnosti. Svi rezultati dobiveni eksperimentalnim istraživanjem te oni dobiveni učenjem i testiranjem ANN i MM modela prikazani su na slici 12. Kao što je vidljivo na slici, dobivene vrijednosti učenjem i testiranjem u UNM i MM modelima su vrlo blizu eksperimentalnih. Ovi rezultati pokazuju da su oba modela sposobna ostvariti generalizaciju između ulaznih i izlaznih varijabli s učinkovitim predviđanjem.


Tablica 11. pokazuje statistički učinak modeliranja za oba modela. MM model ima najmanje pogreške kod RMSE =  $7,05 \text{ N/mm}^2$ . Općenito, MM model za predviđanje modula elastičnosti je ostvario dobre rezultate u smislu ukupnih statističkih mjeri. Usporedni rezultati pet statističkih mjeri su pokazali da UNM model ima općenito bolje predviđanje u odnosu na MM s nižim vrijednostima pogrešaka.



Slika 11. ANN i MM rezultati za izlazni podatak 3

Tablica 10. Statističke mjeri za UNM i MM modele izlaznog podatka 3

Model	MAE [ $\text{kg/m}^3$ ]	RMSE [ $\text{kg/m}^3$ ]	MAPE [%]	R	E
UNM	0,199	0,2087	4,069	0,979	0,960
MM	0,5275	0,0823	11,28	0,891	0,798



Slika 12. ANN i MM rezultati za izlazni podatak 4

Tablica 11. Statističke mjere za UNM i MM modele izlaznog podatka 4

Model	MAE [kg/m <sup>3</sup> ]	RMSE [kg/m <sup>3</sup> ]	MAPE [%]	R	E
UNM	538,286	13,298	3,288	0,986	0,969
MM	1759,551	7,047	10,206	0,909	0,826

## 6. Zaključak

Cilj ovog istraživanja bio je sveobuhvatno usporediti različite mogućnosti predviđanja koristeći ih pojedinačno za simulaciju svojstava betona s drobljenom opekom i crijeponom kao agregatom na osnovi prethodnih eksperimentalnih ispitivanja. Dvije pojedinačne tehnike učenja (UNM i MM) uporabljene su za izradu modela predviđanja. U usporedbi s eksperimentalnim rezultatima gustoće, tlačne čvrstoće i čvrstoće na savijanje te statičkog modula elastičnosti dokazano je da oba modela imaju sposobnost generalizacije između ulaznih i izlaznih varijabli s pouzdanom razinom predviđanja. Pojedinačno gledajući, MM model je dao najmanja odstupanja kod RMSE (izlazni podaci 1, 3 i 4), međutim UNM model je rezultirao nižim stopama pogrešaka

za još četiri statističke mjere i to za sva četiri izlazna podatka. Doprinos je ovog rada proširenje osnovnog znanja kroz prijedlog i provjeru tehnika simulacije svojstava betona s recikliranim agregatom. Opisani modeli se mogu uporabiti u slučajevima u kojima postoji velik broj ulaznih podataka i svojstava koji moraju biti poznati ili definirani u ograničenom vremenskom roku. Prikazane metode također pridonose znatnom smanjenju vremena i novca u usporedbi s eksperimentalnim ispitivanjima, bez značajnijeg gubitka točnosti. Statističke mjere kojima su procijenjene učinkovitosti modela pokazale su da se oba pristupa mogu djelotvorno primijeniti za pouzdana predviđanja, iako su umjetne neuronske mreže rezultirale manjim odstupanjima. Može se stoga zaključiti kako predstavljaju moćan alat za predviđanje materijalnih karakteristika kod recikliranog betona u definiranom rasponu ulaznih vrijednosti.

## LITERATURA

- [1] Cachim, P.B.: Mechanical properties of brick aggregate concrete, Construction and Building Materials, 23 (2009), pp. 1292–1297, <https://doi.org/10.1016/j.conbuildmat.2008.07.023>
- [2] Debieb, F., Kenai, S.: The use of coarse and fine crushed bricks as aggregate in concrete. Construction and Building Materials, 22 (2008), pp. 886–893, <https://doi.org/10.1016/j.conbuildmat.2006.12.013>
- [3] Miličević, I.: Fire resistance of concrete with crushed bricks and roof tiles, PhD Thesis, Faculty of Civil Engineering Osijek, University J.J. Strossmayer Osijek, 2014.
- [4] Duan, Z.H., Kou, S.C., Poon C.S.: Prediction of compressive strength of recycled aggregate concrete using artificial neural networks, Construction and Building Materials, 40 (2013), pp. 1200–1206, <https://doi.org/10.1016/j.conbuildmat.2012.04.063>
- [5] Deshpande, N., Londhe, S., Kulkarni, S.: Modeling compressive strength of recycled aggregate concrete by Artificial Neural Network, Model Tree and Non-linear Regression, International Journal of Sustainable Built Environment, 3 (2014), pp. 187–198, <https://doi.org/10.1016/j.ijsbe.2014.12.002>

- [6] Dantas., A.T.A., Batista Leite, M., de Jesus Nagahama, K.:Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. Construction and Building Materials, 38 (2013), pp. 717–722, <https://doi.org/10.1016/j.conbuildmat.2012.09.026>
- [7] Berredo, R.C., Canha, L.N., Ekel, P.Ya., Ferreira, L.C.A., Maciel, M.V.C.: Experimental Design and Models of Power System Optimization and Control, WSEAS Transactions on Systems and Control, 3 (2008) 1, pp. 40-49, 2008.
- [8] Lazić, Lj. and Mastorakis, N.E.: Integrated Intelligent Modeling, Simulation and Design of Experiments for Software Testing Process, Latest Trends on Computers (Volume II), 14<sup>th</sup> International Conference on Computers, pp. 555-567, 2010.
- [9] Briano, E., Caballini, C., Giribone, P., Revetria, R.: Design of Experiment and Montecarlo Simulation as Support for Gas Turbine Power Plant Availability Estimation, Proceedings of the 12<sup>th</sup> WSEAS International Conference on Automatic Control, Modelling & Simulation, pp. 223-230, 2010.
- [10] Montgomery, D.C.: Analysis of Experiments (5<sup>th</sup> ed.) John Wiley & Sons, Inc, 2001.
- [11] Watson, D.F.: Contouring: A Guide to the Analysis and Display of Spatial Data, Pergamon Press, New York, 1992.
- [12] Toledo Filho, R.D., Gonçalvesb, J.P., Americanoc, B.B., Fairbairna, E.M.R.: Potential for use of crushed waste calcined-clay brick as a supplementary cementitious material in Brazil, Cement and Concrete Research, 37 (2007) 9, pp. 1357–1365, <https://doi.org/10.1016/j.cemconres.2007.06.005>.
- [13] Böke, H., Akkurtb, S., İpekoğlu, B., Uğurlua, E.:Characteristics of brick used as aggregate in historic brick-lime mortars and plasters, Cement and Concrete Research, 36 (2006) 6, pp. 1115–1122, <https://doi.org/10.1016/j.cemconres.2006.03.011>
- [14] Khatib, J.M.: Properties of concrete incorporating fine recycled aggregate. Cement and Concrete Research, 35 (2005), pp. 763–769, <https://doi.org/10.1016/j.cemconres.2004.06.017>
- [15] Khalaf, F.M.: Using Crushed Clay Brick as Aggregate in Concrete. Journal of Materials in Civil Engineering, 18 (2006), pp. 518-526, [https://doi.org/10.1061/\(ASCE\)0899-1561\(2006\)18:4\(518\)](https://doi.org/10.1061/(ASCE)0899-1561(2006)18:4(518))
- [16] Tam, V.W.Y., Gao, X.F., Tam, C.M.: Microstructural analysis of recycled aggregate concrete produced from two-stage mixing approach, Cement and Concrete Research, 35 (2005), pp. 1195–1203, <https://doi.org/10.1016/j.cemconres.2004.10.025>
- [17] Hansen. T.C.: Recycling of demolished concrete and masonry. RILEM Rep.6., London: E&FN Spon.1992.
- [18] Miličević, I., Štirmer, N., Bjegović, D.: Optimizing the Concrete Mixture made with Recycled Aggregate Using Experiment Design, Proceedings of Recent advances in fluid mechanics and heat & mass transfer, Florence, Italy : WSEAS Press, pp. 110–115, 2011.
- [19] Miličević, I., Štirmer, N., Bjegović, D.: Optimization of concrete mixtures made with crushed clay bricks and roof tiles, Magazine of Concrete Research, 67 (2015) 3, pp. 109-120, <https://doi.org/10.1680/macr.14.00175>
- [20] Malešev, M., Radonjanin, V., Lukić, I., Bulatović, V.: The Effect of Aggregate, Type and Quantity of Cement on Modulus of Elasticity of Lightweight Aggregate Concrete. Arabian Journal of Science and Engineering, 39 (2013), pp. 705-711, <https://doi.org/10.1007/s13369-013-0702-2>
- [21] Haykin, S.: Neural Networks: A Comprehensive Foundation, (2nd ed.), Prentice Hall, 1999.
- [22] Lippman, R.: An introduction to computing with neural nets, IEEE ASSP Mag., 4 (1987), pp. 4-22, <https://doi.org/10.1109/MASSP.1987.1165576>
- [23] Bilgehan, M. and Turgut, P.:The use of neural networks in concrete compressive strength estimation, Computers and Concrete, 7 (2010) 3, pp. 271-283, <https://doi.org/10.12989/cac.2010.7.3.271>
- [24] Kewalramani, M.A. and Gupta, R.: Concrete compressive strength prediction using ultrasonic pulse velocity through artificial neural networks, Automat. Constr., 15 (2006), pp. 374-379, <https://doi.org/10.1016/j.autcon.2005.07.003>
- [25] Sheela, G.K., Deepa, S.N.: Review on Methods to Fix Number of Hidden Neurons in Neural Networks, Mathematical Problems in Engineering, Article ID 425740, pp. 11, 2013.
- [26] Sonmez, H., Gokceoglu, C., Nefeslioglu, H.A. and Kayabasi, A.: Estimation of rock modulus: for intact rocks with an artificial neural network and for rock masses with a new empirical equation. International Journal of Rock Mechanics and Mining Sciences, 43 (2006), pp. 224–235, <https://doi.org/10.1016/j.ijrmms.2005.06.007>
- [27] Özturan, M., Kutlu, B., Özturan, T.:Comparison of concrete strength prediction, Techniques with artificial neural network approach, Building research journal, 56 (2008) 1, pp. 23-36.
- [28] Beale, M.H., Hagan, M.T., Demuth, H.B. Matlab:Neural networks toolbox user guide, Mathworks, 2015.