

Primljen / Received: 29.5.2018.

Ispravljen / Corrected: 10.10.2019.

Prihvaćen / Accepted: 20.10.2019.

Dostupno online / Available online: 10.8.2020.

# Predviđanje tlačne čvrstoće betona pomoću umjetnih neuronskih mreža

## Autori:



**Pablo Neira**, dipl.ing.fiz.  
Sveučilište Concepción, Čile  
Fakultet fizike i matematike  
Odjel za fiziku  
[pablneira@udec.cl](mailto:pablneira@udec.cl)

Prethodno priopćenje

[Pablo Neira, Leonardo Bennun, Mauricio Pradena, Jaime Gomez](#)

## Predviđanje tlačne čvrstoće betona pomoću umjetnih neuronskih mreža

Svojstva betona, uključujući i tlačnu čvrstoću, uglavnom se mogu smatrati vrlo nelinearnim funkcijama njegovih komponenata. Metode koje se koriste za projektiranje betonskih mješavina u svojoj su osnovi simulacije koje zahtijevaju skupe i vremenski zahtjevne korekcije u laboratoriju. U ovom se radu predlaže korisna podrška utemeljena na umjetnoj neuronskoj mreži, točnije primjeni višeslojne perceptronske mreže, a može se primijeniti za predviđanje tlačne čvrstoće betonskih mješavina. Razvijeni modeli omogućuju smanjenje broja laboratorijskih ispitivanja koja se provode u svrhu korekcije betonske mješavine.

### Ključne riječi:

projektiranje betonskih mješavina, tlačna čvrstoća, laboratorijska ispitivanja, umjetne neuronske mreže

Research paper

[Pablo Neira, Leonardo Bennun, Mauricio Pradena, Jaime Gomez](#)

## Prediction of concrete compressive strength through artificial neural networks

Concrete properties, including its compressive strength, are in general highly nonlinear functions of its components. Concrete mix design methods are basically simulations that require costly and time consuming adjustments in laboratory. A useful support tool based on artificial neural networks, using a multilayer perceptron network, is proposed in this paper as a means to predict compressive strength of concrete mixes. The developed models are useful for reducing the quantity of laboratory tests required for concrete mix design adjustments.

### Key words:

concrete mix design, compressive strength, laboratory tests, artificial neural networks

Vorherige Mitteilung

[Pablo Neira, Leonardo Bennun, Mauricio Pradena, Jaime Gomez](#)

## Vorhersage der Druckfestigkeit des Betons mithilfe künstlicher neuronaler Netze

Die Eigenschaften von Beton, einschließlich der Druckfestigkeit, können im Allgemeinen als nicht lineare Funktionen seiner Komponenten betrachtet werden. Die Methoden, die zur Planung von Betonmischungen verwendet werden, sind im Grunde genommen Simulationen, welche kostspielige und zeitlich aufwendige Korrekturen im Labor erfordern. In dieser Abhandlung wird eine nützliche Unterstützung vorgeschlagen, die sich auf einem künstlichen neuronalen Netz begründet, genauer gesagt auf der Anwendung eines mehrschichtigen Perzeptron-Netzwerkes, und kann für die Vorhersage der Druckfestigkeit der Betonmischungen herangezogen werden. Die entwickelten Modelle ermöglichen eine geringere Anzahl an Laboruntersuchungen, die zum Zweck der Korrektur der Betonmischungen durchgeführt werden.

### Schlüsselwörter:

Planung von Betonmischungen, Druckfestigkeit, Laboruntersuchungen, künstliche neuronale Netze



**Leonardo Bennun**, dipl.ing.fiz.  
Sveučilište Concepción, Čile  
Fakultet fizike i matematike  
Odjel za fiziku  
[lbennun@udec.cl](mailto:lbennun@udec.cl)  
Autor za korespondenciju



**Mauricio Pradena**, dipl.ing.građ.  
Sveučilište Concepción, Čile  
Tehnički fakultet  
Odjel za građevinarstvo  
[mpradena@udec.cl](mailto:mpradena@udec.cl)

**Jaime Gomez**, dipl.ing.kem.  
Sveučilište Simón Bolívar, Venezuela  
[j.gomez@lafargeholcim.com](mailto:j.gomez@lafargeholcim.com)

## 1. Uvod

U proteklih stotinjak godina beton je na globalnoj razini zauzeo vodeće mjesto među građevnim materijalima, i to ponajviše zbog svoje svestranosti, otpornosti na vodu i vatru, dostupnosti i cijene [1]. Općenito, beton je mješavina hidrauličkog mineralnog veziva – cementa (25 %) vode i agregata (65 %) - koja može izdržati velika tlačna naprezanja nakon procesa otvrdnjavanja [2, 3]. Najčešće se koristi portland cement [3] koji se uglavnom sastoji od kalcijevih silikata i kalcijevih aluminata dobivenih termalnom obradom mješavine sitno mljevenih minerala sastavljenih od vapnenca i gline pri temperaturama većim od 1.300 °C. Ovaj materijal nazivamo klinkerom kojemu se u procesu mljevenja u cement dodaje i 2 do 5 posto kalcijevog sulfata (gipsa) kako bi se spriječilo trenutačno vezivanje [4]. Portland-klinker se sastoji od spojeva koji čine četiri mineralizirane faze: trikalcijev silikat ( $\text{Ca}_3\text{SiO}_5$ ) (50 do 70 %) koji se označava kao C3S, zatim dikalcijev silikat (15 do 30 %) ( $\text{Ca}_2\text{SiO}_4$ ) koji nosi oznaku C2S, trikalcijev aluminat ( $\text{Ca}_3\text{Al}_2\text{O}_6$ ) s oznakom C3A, te tetrakalcijev aluminofeferit ( $\text{Ca}_4\text{Al}_2\text{Fe}_2\text{O}_{10}$ ) s oznakom C4AF, pri čemu silikati (C3S i C2S) čine 80 % komponenata, a odgovorni su za čvrstoću cementa. Zapisi u obliku oksida korištenih oznaka su:

- C3S:  $3\text{CaO} \times \text{SiO}_2$
- C2S:  $2\text{CaO} \times \text{SiO}_2$
- C3A:  $3\text{CaO} \times \text{Al}_2\text{O}_3$
- C4AF:  $4\text{CaO} \times \text{Al}_2\text{O}_3 \times \text{Fe}_2\text{O}_3$

Voda se miješa s cementom, a ta smjesa otvrdjava kao posljedica vezivanja. Jedan dio vode (kemijski vezana voda) veže se kao dio čvrste strukture smjese, a preostala voda ispariva je [3]. Vodocementni omjer od ključne je važnosti za kvalitetu betona. Nizak vodocementni omjer (oko 0,3) dovodi do povećanja čvrstoće i trajnosti, iako treba napomenuti da su takve mješavine ponekad teže obradive. Međutim, to se može riješiti primjenom plastifikatora [5].

S druge strane, agregati su zrnati materijali kao što je npr. pjesak, šljunak ili građevni otpad. Utvrđeno je da je beton s drobljenim kamenim agregatom čvršći od betona s oblim agregatom [6]. Što se tiče vrste agregata, veća čvrstoća betona postiže se drobljenim kvarcitom, a nakon njega slijedi riječni šljunak te zatim drobljeni granit [7]. Kada je riječ o aditivima, oni se mogu koristiti za mijenjanje svojstava betona, tj. za usklađivanje sa zahtjevima iz projekta. Neki od aditiva primjerice su sredstva za smanjenje vode (plastifikatori), te usporivači ili ubrzivači vezivanja. Primjerice, uspješnost spravljanja betona visoke čvrstoće leži u primjeni kvalitetnih aditiva za smanjenje vode, koje obično nazivamo superplastifikatorima [8].

Općenito uvezvi, svojstva betona, uključujući i tlačnu čvrstoću, izrazito su nelinearna funkcija njegovih komponenata [8]. Kako bi se postigla odgovarajuća tehnička svojstva betona, te prikladna usklađenost s komercijalnim i ekonomskim zahtjevima, danas se u području projektiranja betona provode razna multidisciplinarna istraživanja.

Matematički pristup, koji je prije bio najčešći, temelji se na modelima jednostavne linearne regresije. Takvi analitički modeli opisuju djelovanje komponenata betona na tlačnu čvrstoću i obično su vrlo složeni [8]. S obzirom na tu činjenicu, predloženi su alati bazirani na mekom računarstvu (područje umjetne inteligencije koje objedinjuje neizrazitu logiku, neuronske mreže i genetske algoritme) kojima je cilj postići robustnost i sljedivost uz istovremeno smanjivanje cijene [10]. Umjetne neuronske mreže omogućuju višestruke analize te se stoga vrlo često koriste za definiranje mehaničkih svojstava betona te za predviđanje tlačne čvrstoće raznih komponenata, i to na bazi početnih podataka [9-11]. Studije o primjeni višestruke regresije i umjetnih neuronskih mreža (eng. *Artificial Neural Networks* - ANN) pokazale su da ANN modeli daju bolje rezultate od nekih modela baziranih na regresijskoj analizi [12]. Umjetne neuronske mreže značajna su disciplina unutar područja umjetne inteligencije upravo zato što se odlikuju sposobnošću učenja i generaliziranja. Umjetne neuronske mreže sastoje se od određenog broja jednostavnih elemenata koje nazivamo neuronima, a oni su organizirani po slojevima [13]. Prvi sloj, također poznat kao ulazni sloj, šalje idućem sloju podatke koji su numeričke vrijednosti "nečega" (kemijskih ili fizikalnih varijabli, starosti ili nekog drugog podatka koji se može kvantificirati). Svaki ulazni neuron spojen je s neuronima sljedećeg sloja pomoću komunikacijskih spojeva (sinaptička grana), a pritom se svakom sloju pripisuje sinaptička težina. Svaka sinaptička težina multiplicira svoj odgovarajući ulaz, definirajući tako relativni značaj svakog ulaza, tj. težine pohranjuju znanje mreže o analiziranom problemu. Da bi se ukupan signal prenio na sljedeći sloj, on treba proći kroz aktivacijsku funkciju kojom je definirano da samo najjači signali nastavljaju svoj put. Obično se koriste stepenaste, sigmoidne ili linearne funkcije [14]. Ako neuroni uspiju prijeći prag aktiviranja aktivacijske funkcije, tada se u dotičnom sloju dobiva izlazni signal.

## 2. Metodologija

U ovom se radu tlačna čvrstoća betona modelira pomoću umjetnih neuronskih mreža na temelju 335 mješavina dobivenih postupcima kontrole kvalitete HOLCIM-ovih standardiziranih laboratorijskih ispitivanja. Tlačna čvrstoća cilindričnih uzoraka mjeri se nakon 1, 3, 7 i 28 dana, a za svaku se mješavinu provodi sedam kemijskih analiza (gubitak žarenjem, LI (ukupna količina materijala koji se gubi u postupku kalciniranja),  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{MgO}$ ,  $\text{SO}_3$ ), i tri ocjene fizikalnih svojstava: R45 (količina materijala zadržanog na filteru veličine 45  $\mu\text{m}$ ), v/c (vodocementni omjer), konzistencija (viskoelastična svojstva mješavine cementa, pjeska i vode). U radu je također prikazan i niz podataka s preciznim informacijama o čvrstoći betona. Ti bi podaci mogli biti korisni za akademске i industrijske krugove, te su pogodni

**Tablica 1.** Korelacije između deset fizikalno-kemijskih varijabli i tlačne čvrstoće betona nakon jednog dana (R1D), 3 dana (R3D), 7 dana (R7D) i 28 dana (R28D)

	R1D	R3D	R7D	R28D
Li	0,4008	0,3986	0,3159	-0,2951
SiO <sub>2</sub>	-0,6299	-0,6832	-0,6011	0,1775
Al <sub>2</sub> O <sub>3</sub>	0,3977	0,3684	0,3657	-0,0405
Fe <sub>2</sub> O <sub>3</sub>	-0,2515	-0,1984	-0,2116	-0,2148
CaO	0,6699	0,7195	0,6460	-0,1242
MgO	0,4815	0,5272	0,4455	-0,0614
SO <sub>3</sub>	0,2034	0,1530	0,1537	0,0587
R45	0,2028	0,1392	0,1558	-0,0825
v/c	-0,6441	-0,7411	-0,6635	-0,0962
Flow	0,0170	0,0258	0,0415	0,0283
R1D	1	0,8518	0,8120	0,3965
R3D	0,8518	1	0,9080	0,3808
R7D	0,8518	0,9080	1	0,4851
R28D	0,3965	0,3808	0,4851	1

za dopunjavanje sličnih istraživanja u svrhu modeliranja čvrstoće betona pomoću umjetnih neuronskih mreža [15-23]. Što se tiče primjene umjetnih neuronskih mreža, jedan od najraširenijih i najuspješnije korištenih modela neuronskih mreža je višeslojni perceptron kojim se mogu analizirati izuzetno nelinearni problemi predviđanja [24-27].

Pravilo ili algoritam učenja je mehanizam prema kojemu su parametri neuronske mreže prihvaćeni ili izmijenjeni. U slučaju višeslojnog perceptronu koristi se algoritam za nadzirano učenje, tj. parametri se mijenjaju tako da izlazni podatak mreže bude što bliži izlaznom rezultatu kojeg je zadao nadziratelj, ili pak poželjnom rezultatu. Stoga se može reći da je postupak učenja neuronske mreže jednak pronaalaženju minimuma funkcije pogreške. Međutim, jedna od najvećih slabosti su dostizanje lokalnih minimuma funkcija pogreške, zbog kojih se učenje zaustavlja iako nisu postignuti odgovarajući parametri konvergencije. Kako bi se to izbjeglo, u ovom se radu predlaže postupak slučajnog variranja nizova učenja i početnih težina. Na taj se način mogu u grubim crtama pratiti rezultati predviđanja neuronske mreže, bez straha da će rezultat ovisiti o prekidu učenja zbog dostizanja lokalnih minimuma. U ovom je radu odabran Levenger-Marquardtov [28] algoritam učenja jer se taj algoritam najčešće preporučuje za nadzirano učenje, i to prije svega zbog brze konvergencije te zato što je za postizanje konvergencije potreban manji broj iteracija.

Kada razmatramo primjenu umjetnih neuronskih mreža za predviđanje čvrstoće betona, važno je odlučiti jesu li

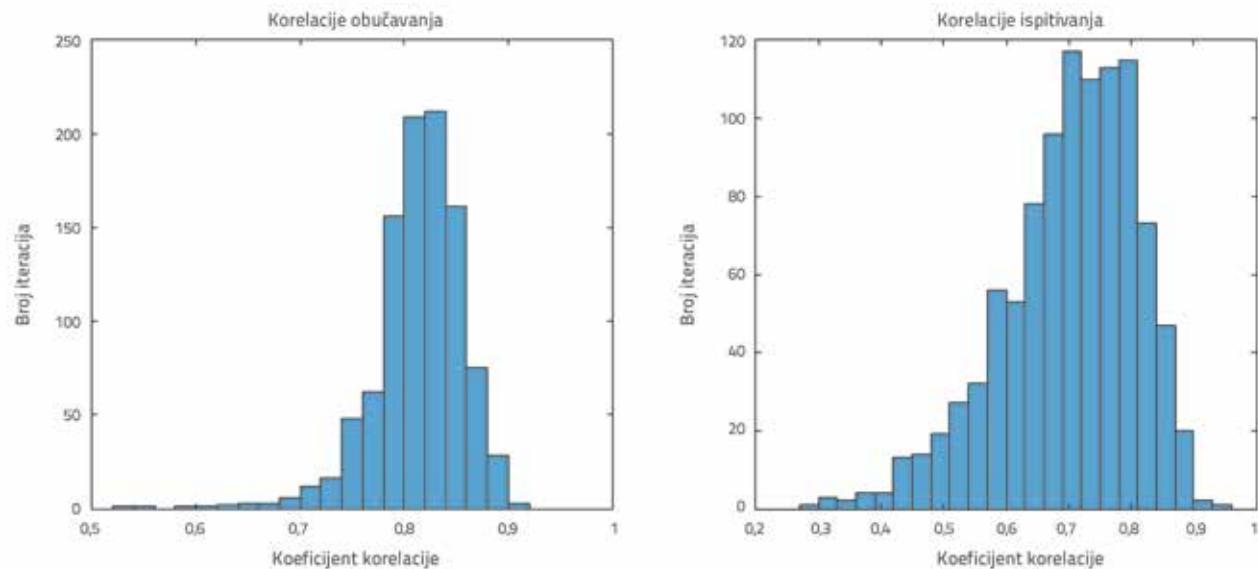
**Tablica 2.** Korelacije ekstremnih podataka između deset fizikalno-kemijskih varijabli i tlačne čvrstoće betona nakon jednog dana (R1D), 3 dana (R3D), 7 dana (R7D) te nakon 28 dana (R28D)

	R1D	R3D	R7D	R28D
Li	-0,2275	-0,2655	-0,5166	-0,7703
SiO <sub>2</sub>	0,0183	0,0265	0,3655	0,7302
Al <sub>2</sub> O <sub>3</sub>	0,3844	0,3699	0,1779	0,0908
Fe <sub>2</sub> O <sub>3</sub>	-0,0362	-0,1072	-0,2137	-0,2273
CaO	0,0795	0,0979	-0,2748	-0,6621
MgO	0,3543	0,2939	-0,0465	-0,3499
SO <sub>3</sub>	-0,2826	-0,1766	-0,0938	-0,0624
R45	-0,4266	-0,3503	-0,4244	-0,4327
v/c	-0,4884	-0,5262	-0,2594	0,0321
Flow	-0,0705	0,1759	0,1185	0,0396
R1D	1	0,8603	0,7670	0,5528
R3D	0,8603	1	0,8726	0,6215
R7D	0,7670	0,8723	1	0,8526
R28D	0,6215	0,6215	0,8526	1

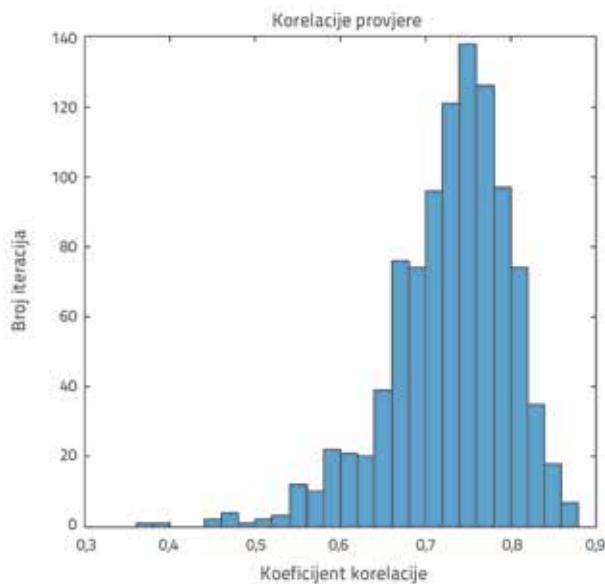
podatak o fizikalno-kemijskoj varijabli i podatak o starosti betona u vrijeme ocjenjivanja pogodni za učenje neuronske mreže. Kako bi se utvrdio stupanj takve pogodnosti, za svaki ulazni podatak određen je Pearsonov koeficijent korelacije. Tim se koeficijentom mjeri linearna povezanost između dviju varijabli. Odgovarajući rezultati prikazani su u tablici 1. U ovom se radu u analizi koriste podaci jednog od najvećih svjetskih proizvođača cementa i betona. U tom smislu je već provedena (ekstremna) optimizacija fizikalno-kemijskih varijabli kako bi se postigle ciljane tlačne čvrstoće u Holcim-Lafargeovim laboratorijima za ispitivanje betona. Zbog te izvršene optimizacije je izgledalo da osnovne varijable poput npr. vodocementnog omjera ne utječu bitno na rezultate tlačne čvrstoće betona. Međutim, to se događalo zato što je raspon poboljšanja vrlo uzak.

Osim toga, je analizirana korelacija ekstremnih podataka. U slučaju koji je prikazan u tablici 2. zasebno je analizirano ukupno 15 uzoraka s najvišom vrijednošću tlačne čvrstoće te 15 uzoraka s najnižom tlačnom čvrstoćom.

U svrhu optimizacije topologije neuronske mreže, razvijen je program u jeziku MATLAB® pomoću alata Neural Network Toolbox® koji je dio programa MATLAB® 2015a. Broj neurona u ulaznom sloju iskazan je brojem ulaza neuronske mreže. U ovom slučaju radi se o deset ulaznih neurona jer ima deset fizikalno-kemijskih varijabli. Kako se u okviru ovog istraživanja trebala odrediti tlačna čvrstoća nakon 7 dana (7D) i 28 dana (28D), u izlaznom se sloju nalazi samo jedan neuron koji odgovara prognoziranoj vrijednosti, slike 1. i 2.



Slika 1. Koeficijent korelacije dobiven pomoću Matlaba u funkciji broja iteracija za podatke o učenju (lijevo) i ispitivanju (desno) tlačne čvrstoće nakon 28 dana



Slika 2. Koeficijent korelacije dobiven pomoću Matlaba u funkciji broja iteracija za podatke o provjeri tlačne čvrstoće nakon 28 dana

Jedna od uobičajenih metoda za određivanje optimalne topologije neuronskih mreža sastoji se u definiranju određenog broja neurona u drugom skrivenom sloju te u povećanju broja neurona u prvom skrivenom sloju; nakon dobivanja optimalnog broja za prvi sloj, potrebno je varirati broj neurona za drugi sloj sve dok se još jednom ne definira optimalna prognozna vrijednost.

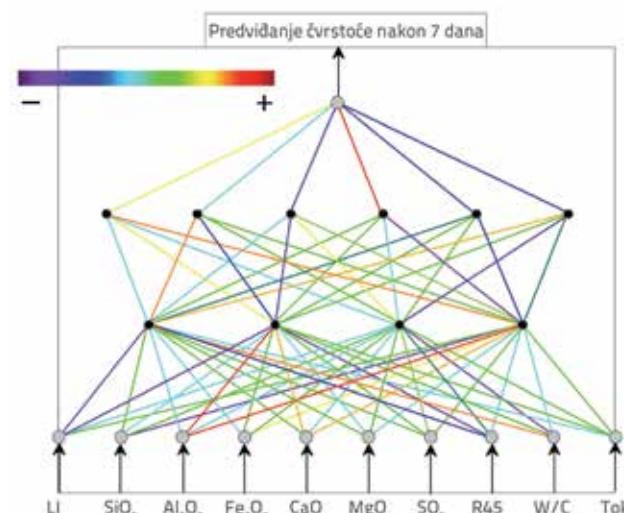
Kriterij koji se primjenjuje za određivanje optimalne topologije mreže, tj. kriterij koji najbolje opisuje prethodni problem jest skup Pearsonovih koeficijenata korelacija kojima se određuje linearna međuzavisnost varijabli. U ovom slučaju radi se o usporedbi stvarnih vrijednosti tlačne čvrstoće nakon 7 i 28 dana s predviđanjem modela, što se primjenjuje na prosjek od tri skupa podataka (učenje, provjera i ispitivanje).

Za dobivanje odgovarajućeg broja neurona u prvom skrivenom sloju analizirano je ukupno 20 različitih kombinacija, dok je za određivanje drugog skrivenog sloja analizirano također 20 kombinacija. U svrhu učenja neuronske mreže, niz od 335 mješavina podijeljen je u tri skupine: 245 mješavina za učenje, 55 mješavina za validaciju te 35 mješavina za ispitivanje.

### 3. Rezultati

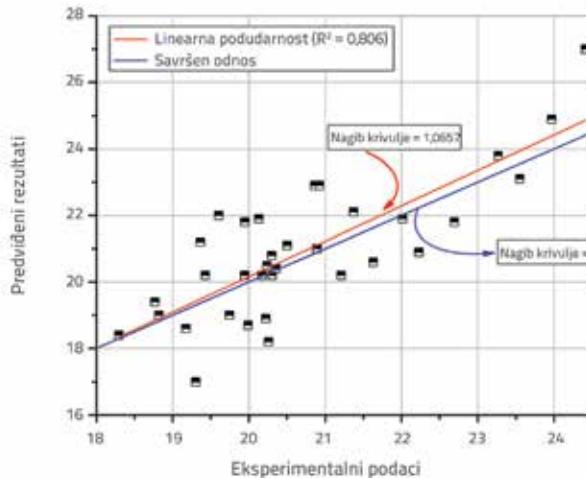
#### 3.1. Modeliranje čvrstoće betona nakon 7 dana

Za predviđanje tlačne čvrstoće nakon sedam dana, dobivena je optimalna topologija od četiri neurona u prvom skrivenom sloju i šest neurona u drugom skrivenom sloju (slika 3.).



Slika 3. Najbolja topologija naučene mreže za procjenu tlačne čvrstoće betona nakon 7 dana

Korelacijski koeficijenti za učenje, validaciju i ispitivanje neuronske mreže prikazani su u tablici 3. Tako je za npr. ispitivanje dobiven korelacijski koeficijent od 0,806. Ciljana tlačna čvrstoća i rezultat prognoze pomoću neuronskih mreža prikazani su na slici 4.



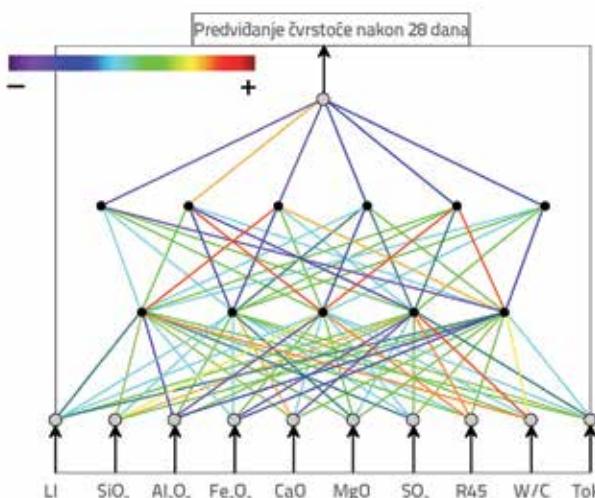
Slika 4. Ciljana tlačna čvrstoća i rezultat prognoze pomoću neuronske mreže, s najboljom topologijom, za čvrstoću betona nakon 7 dana

Tablica 3. Korelacija najbolje mreže za predviđanje tlačne čvrstoće betona nakon 7 dana

	Učenje	Provjera	Ispitivanje
Koeficijent korelacije	0,866	0,812	0,806

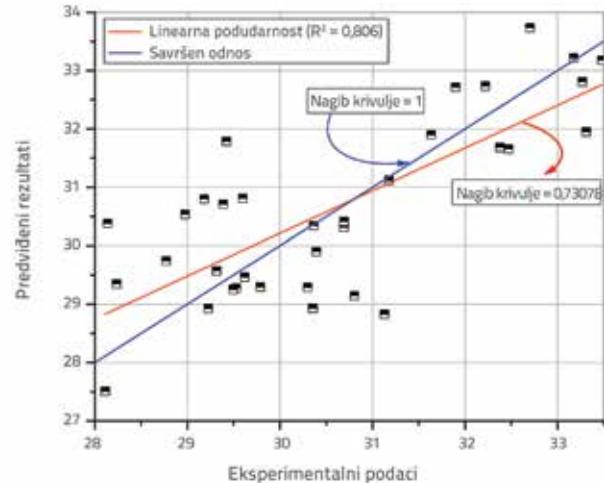
### 3.2. Modeliranje čvrstoće betona nakon 28 dana

Isti je postupak proveden za modeliranje neuronske mreže za procjenu tlačne čvrstoće betona nakon 28 dana. U ovom je slučaju dobivena optimalna topologija od 5 neurona u prvom skrivenom sloju, te od 6 neurona u drugom skrivenom sloju (slika 5.).



Slika 5. Najbolja topologija naučene mreže za procjenu tlačne čvrstoće betona nakon 28 dana

Koeficijenti korelacije za učenje, provjeru (validaciju) i ispitivanje pomoću neuronske mreže prikazani su u tablici 4. Tako koeficijent korelacije za ispitivanje iznosi 0,7350. Ciljana tlačna čvrstoća i rezultat prognoze pomoću neuronske mreže, s najboljom topologijom, prikazani su na slici 6.



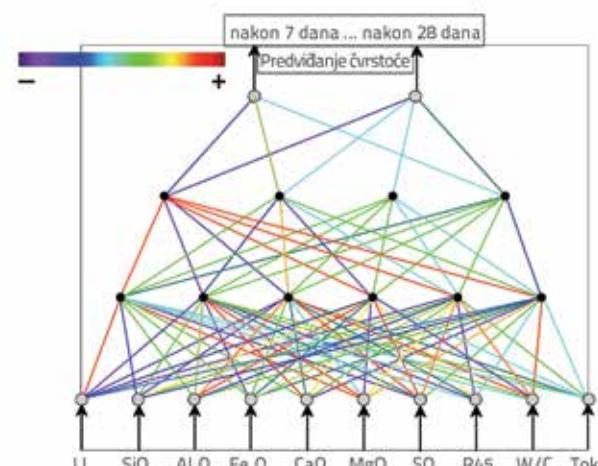
Slika 6. Ciljana tlačna čvrstoća i rezultat prognoze pomoću neuronske mreže s najboljom topologijom, za čvrstoću betona nakon 28 dana

Tablica 4. Korelacija najbolje mreže za predviđanje tlačne čvrstoće betona nakon 28 dana

	Učenje	Provjera	Ispitivanje
Koeficijent korelacije	0,7623	0,6995	0,7350

### 3.3. Kombinirano modeliranje čvrstoće betona nakon 7 i 28 dana

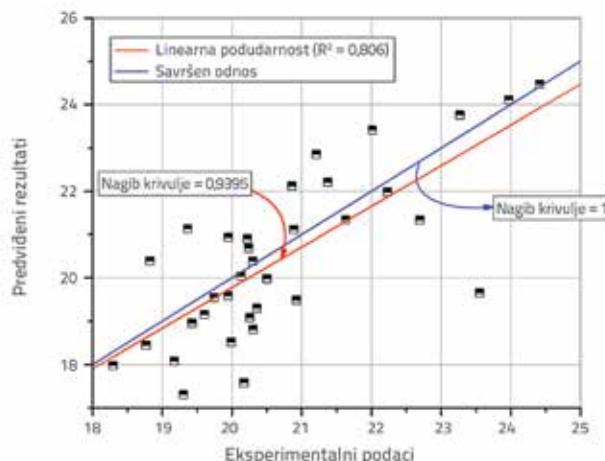
Sličan je postupak proveden za model kombinirane neuronske mreže za procjenu tlačne čvrstoće betona nakon 7 i 28 dana. U ovom je slučaju dobivena optimalna topologija od 6 neurona u prvom skrivenom sloju i od 4 neurona u drugom skrivenom sloju (slika 7.).



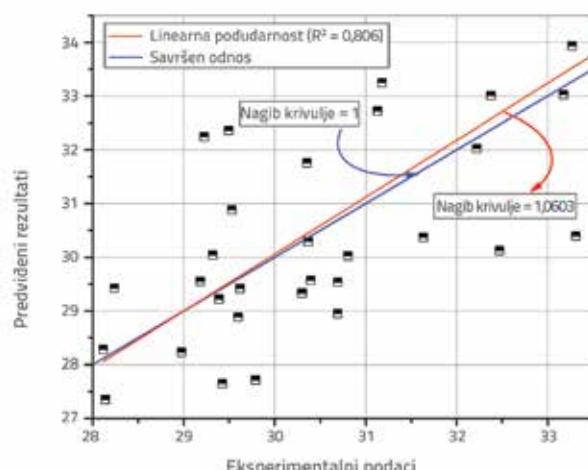
Slika 7. Najbolja topologija za neuronsku mrežu koja procjenjuje vrijednost tlačne čvrstoće nakon 7 i nakon 28 dana

Važno je istaknuti da ovaj model neuronske mreže ima dva izlaza u odnosu na prva dva koji imaju samo jedan izlaz.

Uspoređivanjem slika 4. i 8. te slika 6. i 9. može se uočiti malo smanjenje kosine linearog odnosa između ciljanih i predviđenih podataka za kombinirano modeliranje (model procjene čvrstoće betona nakon 7 i nakon 28 dana). To znači da se pojedinačnim modeliranjem neuronskih mreža nakon 7 ili 28 dana postižu bolji rezultati. Ovdje treba još jednom naglasiti cilj ovog rada. Dakle, svrha nije izraditi sofisticiranu umjetnu neuronsku mrežu koja bi sama sebi bila svrha već, naprotiv, konačan je cilj predložiti korisno sredstvo na bazi umjetnih neuronskih mreža koje služi kao pomoćni alat prilikom predviđanja tlačne čvrstoće betonskih mješavina. Zbog toga nije potrebno koristiti kombinirane već pojedinačne neuronske mreže. Na primjer, ako je praktičan zahtjev predvidjeti tlačnu čvrstoću nakon 7 dana, tada se treba koristiti pripadna pojedinačna umjetna neuronska mreža. Slike 8. i 9. prikazuju ciljanu tlačnu čvrstoću i predviđeni rezultat (nakon 7 i nakon 28 dana) dobiven pomoću kombiniranih neuronskih mreža s najboljom topologijom.



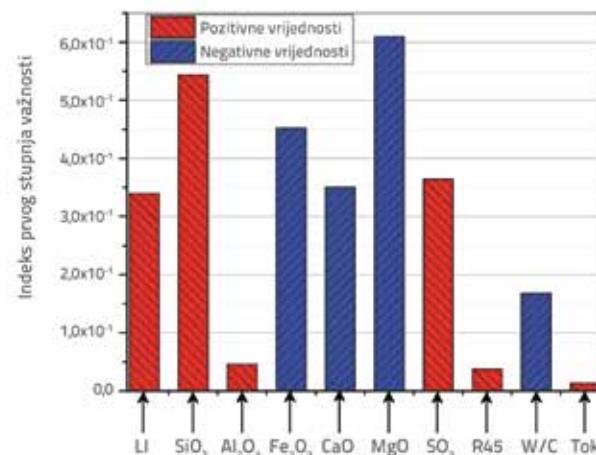
Slika 8. Ciljana tlačna čvrstoća i prognoza pomoću kombinirane neuronske mreže s najboljom topologijom, za čvrstoću betona nakon 7 dana



Slika 9. Ciljana tlačna čvrstoća i prognoza pomoću kombinirane neuronske mreže s najboljom topologijom, za čvrstoću betona nakon 28 dana

### 3.4. Analiza osjetljivosti

Linearna analiza osjetljivosti provedena je kako bi se kvantificirao relativno značenje svake od deset fizikalno-kemijskih varijabli na bazi tlačne čvrstoće nakon 28 dana [29, 30]. Relativne osjetljivosti dobivene na temelju ulaznih varijabli prikazane su na slici 10.



Slika 10. Ocjena utjecaja svake pojedinačne fizikalno-kemijske ulazne varijable na tlačnu čvrstoću betona (28D)

Slika 10. pokazuje da osnovne varijable, kao što je to npr. vodocementni omjer, ne utječu značajno na rezultate tlačne čvrstoće betona. Međutim, važno je uočiti da se u ovom radu za analizu koriste optimizirani podaci ulaznih varijabli, odnosno da je deset fizikalno-kemijskih varijabli već (ekstremno) optimizirano kako bi se postigle laboratorijske ciljane tlačne čvrstoće jednog od najvećih svjetskih proizvođača betona. Stoga je raspon poboljšanja vrlo uzak.

## 4. Zaključci

Postupak projektiranja betonskih mješavina temelji se na tipičnim tehničkim načelima za doziranje komponenata u odgovarajućim količinama kako bi se postigla tražena svojstva betona. Iako su danas dostupne različite metode za projektiranje betonskih mješavina, postupak se u najvećoj mjeri temelji na kvalitativnom pristupu baziranom na znanju, a podložan je varijacijama. Ustvari, sve metode za projektiranje betonskih mješavina zapravo su simulacije za koje su potrebne eksperimentalne korekcije u laboratoriju, što se često provodi postupkom pokušaja i pogreške. Zbog toga je čitav proces dugotrajan i uključuje znatne materijalne troškove. Osim toga, svojstva betona, kao što je npr. tlačna čvrstoća, uglavnom se mogu smatrati vrlo nelinearnim funkcijama njegovih komponenata. Dakle, kako bi se postigla odgovarajuća tehnička svojstva te udovoljilo komercijalnim i ekonomskim zahtjevima, poželjno je optimizirati postupke projektiranja betonskih mješavina, poput postupka optimizacije koji je prikazan u ovom radu.

Višeslojna perceptronska neuronska mreža u ovom se radu poučava kako bi se predvidjeli rezultati tlačne čvrstoće, koja je jedno od najznačajnijih svojstava betona. Modeli umjetnih neuronskih mreža naučeni su za predviđanje tlačne čvrstoće nakon dva razdoblja njege (nakon 7 i nakon 28 dana) primjenom niza od 335 mješavina dobivenih postupcima kontrole kvalitete koji se provode u okviru Holcimovih standardnih laboratorijskih ispitivanja. Tlačna čvrstoća svake mješavine betona izmjerena je nakon 1, 3, 7 i 28 dana, a provedeno je sedam kemijskih analiza i tri fizikalne provjere.

Nakon određivanja optimalne topologije mreže, utvrđeno je da su, u vezi s ispitivanjem, razvijeni modeli imali koeficijente korelacije više od 0,8 za tlačnu čvrstoću betona nakon 7 dana, odnosno, više od 0,7 nakon 28 dana. Stoga se može zaključiti da modeli neuronske mreže omogućuju precizno predviđanje ispitivanja tlačne čvrstoće na bazi fizikalno-kemijskih varijabli betona. Predloženi model omogućuje brže dobivanje rezultata tlačne čvrstoće, a može se očekivati i veća pouzdanost proizvoda kroz definiranje odgovarajućih kombinacija materijala koje udovoljavaju zahtjevima za izradu betona za specifične primjene. Razvijeni se modeli mogu koristiti za smanjivanje broja laboratorijskih ispitivanja koja se provode za korekciju

receptura određenih vrsta betona. Osim toga, oni se mogu koristiti i u istraživanju inovativnih rješenja za nove betone. To je zapravo izuzetno značajna moguća primjena jer se danas u okviru znanstvene zajednice ulažu veliki napor u razvoj novih betonskih mješavina kako bi se poboljšala trajnost i održivost betona. Osim toga, razvijeni se modeli mogu primijeniti i kada su već dostupni brojni laboratorijski podaci o ispitivanju mješavina, tj. kada se treba provesti optimizacija betonskih mješavina. U svim mogućim primjenama, umjetne neuronske mreže omogućuju smanjenje laboratorijskih troškova.

Konačno, u radu je prikazan i niz podataka s detaljnim i preciznim informacijama o čvrstoći betona. Te informacije mogu biti korisne znanstvenoj i stručnoj javnosti, te kao dopunski materijal za izradu drugih studija i za modeliranje čvrstoće betona pomoću umjetnih neuronskih mreža.

## Zahvale

Ovim putem izražavamo svoju zahvalnost dr. H. Barrosu na konstruktivnim raspravama i značajnom doprinosu u izradi ovog rada.

## LITERATURA

- [1] Mehta, P., Monteiro, P.: Concrete: Microstructure, Properties and Materials, 3<sup>rd</sup> Edition, USA: McGraw-Hills, 2006.
- [2] Sánchez, D.: Tecnología del concreto y del mortero, Colombia: Bhandar Editores, 2001.
- [3] Bargas, J., Gomes, A.: Compressive behavior and failure modes of structural lightweight aggregate concrete – Characterization and strength prediction, Materials and Design, 46 (2013), pp. 832–841.
- [4] Taylor, H.: Cement Chemistry, London: Thomas Telford Services, 1997.
- [5] Aïtcin, P.C.: Review Cements of yesterday and today Concrete of tomorrow, Cement and Concrete Research, 30 (2000), pp. 1349–1359.
- [6] Yaqub, M., Bukhari, I.: Effect of size of coarse aggregate on compressive strength of high strength concrete, 31<sup>st</sup> Conference on our world in Concrete & Structures, Singapore, 16 – 17 August 2006.
- [7] Abdullahi, M.: Effect of aggregate type on Compressive strength of concrete, International Journal of Civil and Structural Engineering, 2 (2012) 3, pp. 791–800.
- [8] Baykasoglu, A., Delhi, T., Tanış, S.: Prediction of cement strength using soft computing techniques, Cement and Concrete Research, 34 (2004), pp. 2083–2090.
- [9] Yeh, I.C.: Modeling of strength of high-performance concrete using artificial neural networks, Cement and Concrete Research, 28 (1998) 12, pp. 1797–1808.
- [10] Ozturan, M., Kutlu, B., Ozturan, T.: Comparison of concrete strength prediction techniques with artificial neural network approach. Building Research Journal, 56 (2008), pp. 23–36.
- [11] Başıyigit, C., Akkurt, I., Kilincarsian, S., Beycioğlu, A.: Prediction of compressive strength of heavy weight concrete, 2010.
- [12] 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), pp. 9609–9618.
- [13] Artificial Neural Networks, A Practical Course, da Silva, I.N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L.H.B., dos Reis Alves, S.F. eBook ISBN: 978-3-319-43162-8. [HTTPS://DOI.ORG/10.1007/978-3-319-43162-8](https://doi.org/10.1007/978-3-319-43162-8).
- [14] Haykin, S.S.: Neural Networks: A Comprehensive Foundation, Prentice Hall, ISBN 978-0-13-273350-2, 1999.
- [15] I-Cheng, Y.: Design of a high-performance concrete mixture using neural networks and non-linear programming, Journal of Computing in Civil Engineering, 13 (1999) 1, [https://doi.org/10.1061/\(ASCE\)0887-3801\(1999\)13:1\(36\)](https://doi.org/10.1061/(ASCE)0887-3801(1999)13:1(36))
- [16] Concrete Strength prediction by means of neural network, Construction and building materials, 11 (1997) 2, Sergio Lai and Mauro Serra
- [17] Acuña, L., Torre, A., Moromi, I., García, F.: Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C 39M. Información Tecnológica, 25 (2014) 4, pp. 3–12.
- [18] Chandwani, V., Agrawal, V., Nagar, R.: Applications of Artificial Neural Networks in Modeling Compressive Strength of Concrete: A State of the Art Review, International Journal of Current Engineering and Technology, 4 (2014) 4, pp. 2949–2956.
- [19] I-Cheng, Y.: Modeling Concrete Strength with Augment-Neuron Networks, Journal of Materials in Civil Engineering ASCE, 10 (1998) 4, pp. 263–268.

- [20] I-Cheng Y.: Modeling of strength of high performance concrete using artificial neural networks, *Cement and Concrete Research*, 28 (1998) 12, pp. 1797-1808.
- [21] I-Cheng Y.: Design of High Performance Concrete Mixture Using Neural Networks, *Journal of Computing in Civil Engineering, ASCE*, 13 (1999) 1, pp. 36-42.
- [22] I-Cheng Y.: Prediction of Strength of Fly Ash and Slag Concrete by the Use of Artificial Neural Networks, *Journal of the Chinese Institute of Civil and Hydraulic Engineering*, 15 (2003) 4, pp. 659-663.
- [23] I-Cheng Y.: Analysis of strength of concrete using design of experiments and neural networks, *Journal of Materials in Civil Engineering, ASCE*, 18 (2006) 4, pp. 597-604.
- [24] Rosenblatt, F.: The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65 (1958) 6, pp. 386-408. <https://doi.org/10.1037/h0042519>.
- [25] Minsky, M., Papert, P.: *Perceptrons: An Introduction to Computational Geometry*, The MIT Press, Cambridge MA, 2<sup>nd</sup> edition with corrections 1972, 1<sup>st</sup> edition 1969, ISBN 0-262-63022-2.
- [26] Muniz-Valencia, R., Jurado, J.M., Ceballos-Magana, S.G., Alcazar, A., Hernandez, D.: Characterization of Mexican coffee according to mineral contents by means of multilayer perceptrons artificial neural networks, *Journal of food composition and analysis*, 34 (2014) 1, pp. 7-11, <https://doi.org/10.1016/j.jfca.2014.02.003>.
- [27] Choeh, L.S.: Predicting the helpfulness of online reviews using multilayer perceptron neural networks, *JY, Expert systems with applications*, 41 (2014) 6, pp. 3041-3046, <https://doi.org/10.1016/j.eswa.2013.10.034>.
- [28] Marquardt, D.: An algorithm for least-squares estimation of nonlinear parameters, *SIAM*, 1963.
- [29] I-Cheng, Y., Cheng, W.L.: First and second order sensitivity analysis of MLP. *Neurocomputing*, 73 (2010) 10-12, pp. 2225-2233, <https://doi.org/10.1016/j.neucom.2010.01.011>.
- [30] Tenza-Abril, A. J., Villacampa, Y., Solak, A.M.; Baeza-Brotóns, F.: Prediction and sensitivity analysis of compressive strength in segregated lightweight concrete based on artificial neural network using ultrasonic pulse velocity, *Construction and building materials*, 189 (2018), pp. 1173-1183, <https://doi.org/10.1016/j.conbuildmat.2018.09.096>.