

Primljen / Received: 2.8.2019.

Ispravljen / Corrected: 8.1.2021.

Prihvaćen / Accepted: 15.10.2021.

Dostupno online / Available online: 10.11.2021.

Ocjena čvrstoće betonskih jezgri pomoću umjetnih neuronskih mreža

Autori:

Mr.sc. **Herald Lessly Stephenson**, dipl.ing.grad.

Sveučilište Anna, Chennai, Indija

Fakultet tehničkih znanosti

Odjel za građevinarstvo

heraldjoi.lesly7@gmail.com

Autor za korespondenciju

Prof.dr.sc. **Senthil Rajendran**, dipl.ing.grad.

Sveučilište Anna, Chennai, Indija

Fakultet tehničkih znanosti

Odjel za građevinarstvo

senthilr68@gmail.com

Prethodno priopćenje

Herald Lessly Stephenson, Senthil Rajendran

Ocjena čvrstoće betonskih jezgri pomoću umjetnih neuronskih mreža

U ovom se radu koristi postupak baziran na brzini ultrazvučnih impulsa kao alternativna metoda za određivanje tlačne čvrstoće betonskih jezgri. Primjena nerazornog postupka kojim se ne oštećuje analizirana konstrukcija je dugotrajna, a na tumačenje rezultata utječu brojni faktori. Stoga je, radi definiranja regresije između brzine ultrazvučnih impulsa i tlačne čvrstoće betonskih jezgri, razvijen empirijski odnos zasnovan na primjeni modela umjetnih neuronskih mreža. Ispitivanja su provedena na armiranobetonskim valjcima pri različitim kutovima usmjerenja armature (0°, 45° i 90°). Ispitivanja su provedena eksperimentalnim planiranjem pomoću Box-Behnkenovog modela. Dobiveni rezultati analizirani su postupkom učenja pomoću Levenberg-Marquardtovog modela povratnog prostiranja sa skrivenim slojevima. Rezultati pokazuju da je predviđanje tlačne čvrstoće mješavina točnije za dvorazinski faktorski plan s $R^2 = 0,897$, a ustanovljeno je da suma kvadratne pogreške iznosi 0,9968.

Ključne riječi:

nerazorni postupci, tlačna čvrstoća, brzina ultrazvučnih impulsa, umjetna neuronska mreža, razred tlačne čvrstoće betona

Research Paper

Herald Lessly Stephenson, Senthil Rajendran

Assessment of core strength of concrete by artificial neural networks

The proposed work deals with the use of Ultrasonic pulse velocity technique as an alternative method to identify compressive strength of the core concrete. The use of non-destructive technique without causing damages to the structure is tedious with interpretation of results influenced by various factors. Hence, an empirical relationship is developed using artificial neural network model for creating a regression between pulse velocity and compressive strength of concrete core specimens. Tests were conducted on reinforced concrete cylinders at various orientation angles (0°, 45°, 90°). The tests were conducted based on the design of experiment using the Box-Behnken model. These results were trained using the Levenberg-Marquardt back propagation model with hidden layers. Results indicate that the prediction of core compressive strength for the grade mixes is nearer for the two-level factorial design with $R^2 = 0.897$, and the sum of squared error is found to be 0.9968.

Key words:

non-destructive techniques, compressive strength, ultrasonic pulse velocity, artificial neural network, grade of concrete

1. Uvod

Čvrstoća i trajnost betona kontinuirano variraju tijekom životnog ciklusa konstrukcije i to zbog različitih razloga od kojih vrijedi istaknuti utjecaje okoline. Zato je određivanje čvrstoće betona značajno pri obavljanju aktivnosti periodičnog održavanja, popravaka i obnavljanja betonskih konstrukcija. Betonske konstrukcije obično se ocjenjuju provođenjem odgovarajućih ispitivanja i u tu se svrhu koriste razorne, polurazorne i nerazorne metode. Kvaliteta betona u građevinskim konstrukcijama određuje se ispitivanjem tlačne čvrstoće standardnih betonskih valjaka izvađenih iz dijelova postojećih građevina. Međutim, vađenje uzoraka iz postojeće konstrukcije radi ispitivanja tlačne čvrstoće može uzrokovati štete na samoj konstrukciji. Tlačno ispitivanje betonskih uzoraka najizravnija je metoda za ocjenjivanje tlačne čvrstoće betona postojećih građevina. Iako je provođenje tog ispitivanja prilično jednostavno, rezultati mogu biti prilično netočni zbog različitih utjecaja. Glavna poteškoća pri ocjenjivanju čvrstoće ugrađenog betona jest konverzija rezultata u ekvivalentan podatak na čvrstoći kocke/valjka. Neki od faktora koji utječu na rezultate ispitivanja uzoraka su promjer uzorka, odnos između dužine i promjera (L/d), starost betona, karakteristike agregata, smjer uzimanja uzoraka itd. [1]. Na ispitivanje uzoraka može utjecati i prisutnost armature u uzorku. Uglavnom se preporučuje vađenje uzoraka bez armature, iako se to u nekim slučajevima ipak ne može izbjeći. U takvim slučajevima, prisutnost armature bitno utječe na čvrstoću uzorka. Na čvrstoću betona bitno utječe bušenje jezgre iznad zona armature, čime se znatno povećava faktor otpuštanja naprezanja armature, što utječe na čvrstoću betona. Uslijed naprezanja dolazi do pojave pukotina te stoga i do smanjenja čvrstoće betona [2]. U takvim uvjetima, čvrstoća jezgre ne predstavlja adekvatno tlačnu čvrstoću betona konstrukcije iz koje je uzorak izvađen. Utjecaj prisutnosti armature na čvrstoću uzorka do sada je analizirao tek manji broj istraživača. Armatura koja se nalazi u uzorku povećava nesigurnost rezultata, te se uzorci s armaturom trebaju izbjegavati kada god je to moguće. Faktor korekcije za uzorke s armaturom prikazan je u normi BS EN 12504-1, u britanskoj normi BS 6089, BS 1881: 120. dio te u [3, 4]. Izmjene postojećih propisa prikazane su u radu [5]. Međutim, u nekim normama, kao što su ACI 214, BS EN 13791 i ASTM C42 [6], izričito se preporučuje da se u uzorcima za ispitivanje tlačne čvrstoće ne bi trebala nalaziti armatura. Postojeći podaci o utjecaju armature prilično su kontradiktorni: prema nekim radovima [7], takav utjecaj uopće ne postoji, dok drugi autori upućuju na različite oprečne trendove [8, 9]. Loo i dr. [7] su ustanovili da se pad tlačne čvrstoće zbog prisutnosti armature smanjuje usporedo sa smanjenjem odnosa L/d . Kvaliteta betona obično se određuje analizom empirijskih odnosa između čvrstoće i nerazornih parametara. Metoda bazirana

na brzini ultrazvučnih impulsa (UPV) smatra se jednom od najčešće korištenih tradicionalnih nerazornih metoda za ispitivanje kvalitete betona. Različiti istraživači [9-11] razvili su metodologiju za korištenje ultrazvučnih valova pri određivanju vremena vezivanja betona. Martin i Ford [12] koriste P valove u određivanju svojstava betona.

Model baziran na umjetnim neuronskim mrežama (eng. *Artificial Neural Network* - ANN) smatra se provjerenim proračunskim prototipom za rješavanje različitih složenih problema, uključujući i probleme predviđanja. ANN je zapravo alat koji se koristi za definiranje složenih odnosa između ulaznih i izlaznih parametara. U novije se vrijeme ANN često koristi za rješavanje složenih problema u graditeljstvu. Zaid i dr. [13] predložili su dva algoritma za povratno prostiranje u svrhu određivanja promjera šipki i dubine. Hola i Schabowicz [14] prikazali su model neuronskih mreža za ocjenjivanje tlačne čvrstoće betona integriranjem različitih nerazornih pristupa. Snell i dr. [15] formulirali su različite regresijske funkcije za određivanje tlačne čvrstoće betona. Maitham i dr. [16] izradili su konverzijski model odnosa između rezultata razornih i nerazornih ispitivanja. Razvijen je izraz za pouzdanost u kojem je na minimum sveden broj nesigurnih parametara. Khademi i dr. [17] analizirali su primjenjivost neuronskih mreža (NN) kod procjene tlačne čvrstoće i slijeganja betona visokih čvrstoća (eng. *High Strength Concrete* - HSC). Model ANN je razvijen, podešen i ocijenjen primjenom rezultata ispitivanja provedenih na 187 različitih mješavina betona visoke čvrstoće. Modelom neuronskih mreža (NN) predviđa se tlačna čvrstoća i slijeganje betona HSC. Neki su istraživači za predviđanje kvalitete betona koristili i model višestruke linearne regresije (eng. *Multiple Linear Regression model* - MLR), umjetne neuronske mreže (ANN), prilagodljivi neuroneizraziti sustav zaključivanja te različite statističke [11, 16, 18-21]. Mucteba i Harun [22] razvili su ANN kao alternativni pristup za određivanje tlačne čvrstoće uzoraka samozbijajućeg betona primjenom visokog koeficijenta korelacije. U modelima ANN koje su razvili Ilker i Altin [23], tlačna čvrstoća betona predviđa se za mješavine različitih omjera. Rahmat i dr. [24] predložili su neuronsku mrežu grupne metode upravljanja podacima (GMDH) koja se temelji na eksperimentalnim rezultatima iz dostupne literature i to za čvrstoću betona, omjer L/d , promjer jezgre, veličinu agregata i starost betona. Dobra podudarnost s eksperimentalnim rezultatima postignuta je primjenom višeslojnih neuronskih mreža usmjerenih prema naprijed koje su razvili Bilgehan i Turget [25], a u kojima su korištene vrijednosti UPV i nizovi eksperimentalnih podataka.

U ovom se radu provode eksperimentalna istraživanja u svrhu razvijanja alata u kojem se za ocjenu tlačne čvrstoće betonskih jezgri kombiniraju nerazorna ispitivanja i statistički parametri. Prednost postupka koji se predlaže u ovom radu sastoji se u ocjenjivanju čvrstoće betona na bazi ispitivanja UPV, čime se izbjegava vađenje jezgri

Tablica 1. Udjeli sastojaka različitih betonskih mješavina

Mješavina	Cement [kg/m ³]	Sitnozrnati agregat [kg/m ³]	Krupnozrnati agregat [kg/m ³]		Voda [kg/m ³]
			20 mm	12,5 mm	
M20	350	674	593,5	593,5	158
M25	380	647	595	595	172
M30	410	625	598	598	185

i šteta koja se pritom nanosi postojećim građevinama. Eksperimentalna istraživanja provedena su pomoću posebno lijevanih betonskih jezgri pri čemu su korišteni različiti omjeri L/d, različita usmjerenja armature, te betoni različitih razreda tlačne čvrstoće. Betonske jezgre podvrgnute su razornim i nerazornim ispitivanjima. Rezultati dobiveni tijekom eksperimentalnog dijela istraživanja korišteni su kao ulazni parametri za razvoj ANN mreža te za validaciju razvijenog postupka. U sljedećim su točkama detaljno opisani postupci lijevanja uzoraka, eksperimentalna istraživanja i validacijske analize.

2. Materijali i metode

2.1. Materijali

U ovom eksperimentalnom istraživanju koristi se obični portlandski cement (OPC) razreda čvrstoće 53 u skladu s normom IS 8112. Laboratorijskim su ispitivanjem dobivena fizikalna svojstva cementa, tj. relativna gustoća u iznosu od 2,58 kg/m³ te nasipna gustoća koja iznosi 2708 kg/m³. U istraživanju je korišten lokalno dostupan riječni pijesak bez nečistoća. Primijenjene su odredbe iz norme IS 2386:1975. Vrijednosti relativne gustoće i finoće sitnozrnatog agregata iznose 3,09 tj. 1,95 %. Također je korišten krupnozrnati agregat veličine 20 i 12,5 mm. Fizikalna svojstva krupnozrnatog agregata, tj. relativna gustoća, vodoupojnost i nasipna gustoća, iznosila su redom 2,73, 2,24 % i 1512 kg/m³ za agregat veličine 12 mm, tj. 2,68, 1,38 % i 1491 kg/m³ za agregat veličine 20 mm. Udjeli u mješavini i odgovarajući opisi navode se u tablici 1.


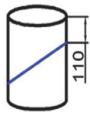

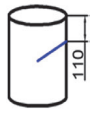

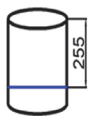

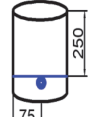

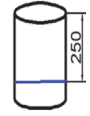



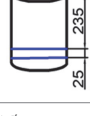
2.2. Priprema uzoraka za eksperimentalni dio istraživanja

Korišteni su različiti odnosi dužine i promjera (L/d) tj. 2, 1,5 i 1, s armaturom i bez nje. U ovom su radu za određivanje tlačne čvrstoće betona korištene šipke promjera 12 mm. Uzorci su njegovani vlaženjem do samog ispitivanja. Za svaki odnos L/d ispitano je po šest uzoraka. U ovom eksperimentalnom istraživanju ispitano je 138 uzoraka s tri ponavljanja svake kombinacije ispitivanih parametara. Kumavat i Patel [26] navode da odnos L/d uzoraka varira od 1 do 2, tj. da su rezultati nepouzdana ako je taj omjer manji od 1. Faktor korekcije prema normi ASTM C42-7.1 & 7.2 [6] primjenjen je za različite odnose L/d, kako je to prikazano u tablici 2. Usmjerenje armature za različite razrede tlačne čvrstoće betona prikazano je u tablici 3.

Tablica 2. Korekcijski faktor za različite odnose L/d


Br. uzorka	Odnos L/d	ASTM C 42-90
1	1,0	0,87
2	1,5	0,86
3	2,0	1,0

Tablica 3. Položaj armature za različite razrede tlačne čvrstoće

	Usmjerenje armature		Razred tlačne čvrstoće betona	Odnos L/d
	Tlocrt	Presjek		
R1			M20	1
			M25	1,5
			M30	2
R2			M20	1
			M25	1,5
			M30	2
R4			M20	1
			M25	1,5
			M30	2
R5			M20	1
			M25	1,5
			M30	2
R6			M20	1
			M25	1,5
			M30	2
R3			M20	1
			M25	1,5
			M30	2
R7			M20	1
			M25	1,5
			M30	2
R1: 45° / potpuno prolazi / Ø 12 mm			R2: 45° / djelomično prolazi / Ø 12 mm	
R3: 90° / potpuno prolazi / Ø 12 mm			R4: 0° / potpuno prolazi / Ø 12 mm	
R5: 0° & 90° / potpuno prolazi / Ø 12 mm			R6: 0° / potpuno prolazi / Ø 12 mm	
R7: 0° / potpuno prolazi / Ø 12 mm				

2.3. Postupak ispitivanja

Ispitivanja tlačne čvrstoće betonskih valjaka (M20, M25 i M30) s različitim usmjerenjima armature (R1-R7) i s različitim odnosima L/d (1, 1,5 i 2) provedena su u skladu s normom ASTM C42 [5]. Tlačno opterećenje nanoseno je brzinom od 0,22 MPa/s u skladu s normom TS EN12390-3 (2012). Fotografija uređaja za tlačno ispitivanje uzoraka prikazana je na slici 1.a. Fotografija pukotina na uzorku nakon sloma prikazana je na slici 1.b.




Slika 1. a) Popuštanje uzorka nakon nanošenja opterećenja; b) Prikaz pukotina nakon popuštanja uzoraka

Ultrazvučna metoda utemeljena na teoriji prostiranja elastičnih valova koristi se za ocjenjivanje mehaničkih i dinamičkih karakteristika betonskih konstrukcija. Na temelju prolaska elastičnih valova visoke frekvencije kroz betonske uzorke može se ocijeniti brzina tlačnih valova ako je poznata dužina uzorka, a postupak se provodi prema uputama iz norme ASTM C597. Baždarenje (eng. *Ultrasonic Pulse Velocity* - UPV) sonde na nultu pogrešku provodi se prebacivanjem ulaznog impulsa na ultrazvučni impuls, a postupak se zasebno provodi za primarne (P) i sekundarne (S) valove. Glatkoća i ujednačenost uzoraka su parametri koji najviše utječu na odziv. Nakon slanja vala s jednog kraja

uzorka, mjeri se vrijeme dolaska vala na drugi kraj uzorka, te se izračunava brzina iz odnosa udaljenosti od odašiljača (predajnika) do prijamnika i vremena T . U ispitivanju su korištene sonde promjera 50 mm, a njihove maksimalne rezonantne frekvencije mogle su se podesiti u skladu s dužinom uzorka. Na početku ispitivanja sonde su baždarene njihovim obostranim postavljanjem na šipku za baždarenje. U radu je korištena izravna metoda prozvučivanja, koja je prikazana na slici 2.

Sonde su postavljene na suprotne strane uzorka, na sredini njegove visine. Mast je nanosena na kontaktnu površinu između uzorka i sonde kako bi se ispunile eventualne neravnine. Zatim je pomoću ultrazvučnog uređaja zabilježeno vrijeme prolaska ultrazvučnih valova kroz betonski uzorak, kao što se to vidi na slici 3.



Slika 2. Izravan prijenos ultrazvučnih impulsa



Slika 3. Ispitivanje betonskog uzorka UPV metodom

Rezultati su prikazani na četveroznamenkastom LCD zaslonu, kao što se može vidjeti na slici 4. Brzina impulsa izračunava se pomoću formule $V = L/T$, gdje je V brzina impulsa (km/s), L je dužina puta (cm), a T je vrijeme prolaska (μ s). Prema ovoj jednadžbi, ultrazvučni uređaji bilježi vrijeme putovanja valova kroz betonski uzorak. Zatim se na temelju dimenzija uzorka izračunava brzina impulsa.



Slika 4. Uređaj za bilježenje podataka s LCD zaslonom

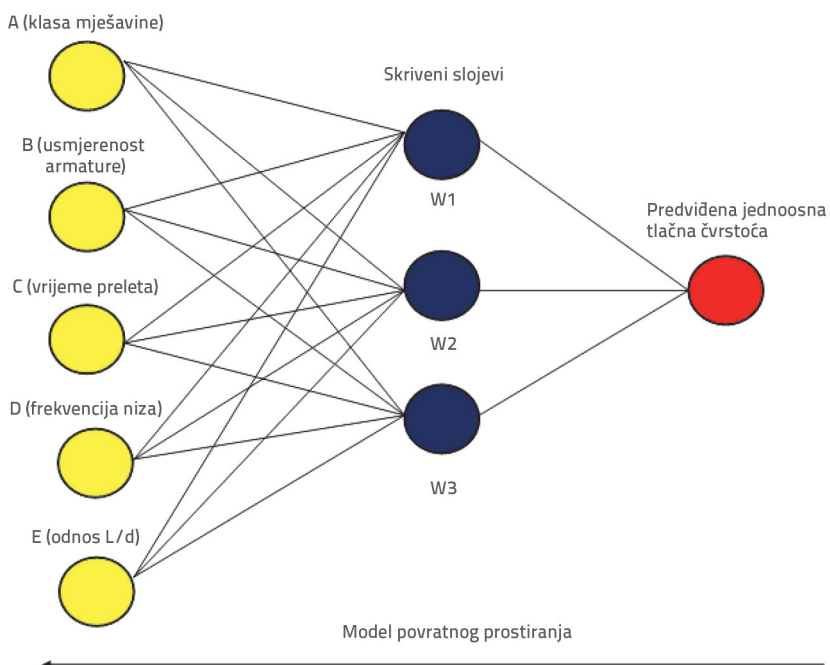
2.4. Plan istraživanja

Eksperimenti su planirani na bazi Box-Behnkenovog modela s 46 proba temeljenih na 5 faktora: razred tlačne čvrstoće betonske mješavine, orijentacija kuta armature (u stupnjevima), vrijeme prolaska (ns), frekvencija (kHz) i odnos L/d , s odzivom jednoosne tlačne čvrstoće (MPa), kako je to prikazano u tablici 4. Ovaj plan pripada klasi rotacijskih planova drugog reda koji se temelje na tro-razinskim nepotpunim faktorskim planovima. Ukupan broj proba definiran je pomoću $N = 2k(k-1) + C_0$, (gdje je k broj faktora, a C_0 je broj središnjih točaka. Box-Behnkenov plan (BBD) uključuje kombinacije svih faktora koji se smatraju značajnima, pri čemu se ne zanemaruju točke podataka pod ekstremnim uvjetima za beznačajne uvjete.

Zbog ortogonalnosti blokova, model drugog reda može se proširiti te uključiti utjecaje blokova bez ugrožavanja postupka procjene parametara, tj. sami utjecaji su ortogonalni u odnosu na utjecaje blokova. Takav ortogonalan raspored blokova je poželjno svojstvo kada se eksperimenti trebaju rasporediti u blokove te kada se očekuje njihov značajni utjecaj.

2.5. Model ANN za predviđanje tlačne čvrstoće uzorka primjenom UPV metode

Neuronska mreža za definiranje vidljivosti predviđanja predloženog Box-Behnkenovog modela odabrana je tako da se može koristiti na široj razini, a ne samo na razini modela, i to za svaku lokaciju ili niz lokacija. Predložena arhitektura neuronske mreže sastoji se od jednog ulaznog sloja, jednog skrivenog sloja i jednog izlaznog sloja, kako je to prikazano na slici 5. Ulazni se sloj sastoji od pet neurona, izlazni se sastoji od jednog neurona, a skriveni se sloj sastoji od tri neurona sa sinapsama (numeričkim ponderima) koje spajaju neurone iz skrivenih slojeva s neuronima iz ulaznih i izlaznih slojeva. Ponderirane vrijednosti svakog faktora ulaznog sloja zbrajaju se u skrivenom sloju. Vrijednost praga prilagođena je kako bi se smanjio kumulativni ulaz radi povezivanja aktivacijske funkcije s izlaznim slojem [27-29]. Suma ponderiranih vrijednosti definirana pomoću neurona koji povezuje susjedne neurone prebačena je u nelinearnu funkciju, koju nazivamo prijenosnom funkcijom. U modelu neuronskih mreža koristi se algoritam usmjeren prema naprijed s povratnim prostiranjem, i to zajedno s linearnim prijenosnim funkcijama na bazi funkcije purelin za skrivene i izlazne slojeve. Za funkciju učenja koristi se Levenberg



Slika 5. Shematski prikaz modela ANN mreže s povratnim prostiranjem

Tablica 4. Plan istraživanja temeljen na Box-Behnkenovom modelu

Faktor 1	Faktor 2	Faktor 3	Faktor 4	Faktor 5	Odziv 1
A: Razred tlačne čvrstoće betonske mješavine	B: Orijentacija kuta armature [°]	C: Vrijeme prolaska [ns]	D: Frekvencija [kHz]	E: Omjer L/d	Jednoosna tlačna čvrstoća [MPa]
25	45 (R1)	-70	4	1	27,63
30	0 (R4)	-50	4	1,5	28,34
30	90 (R3)	-50	4	1,5	29,52
30	45 (R1)	-30	4	1,5	29,62
25	45 (R2)	-50	5	1	22,6
30	45 (R1)	-50	4	1	29,62
25	90 (R5)	-50	4	1	26,41
25	45 (R1)	-50	3	1	27,63
25	45 (R2)	-50	4	1,5	28,02
25	0 (R6)	-30	4	1,5	26,28
20	0 (R7)	-50	4	1,5	24,63
25	0 (R6)	-50	4	2	26,28
20	45 (R1)	-50	5	1,5	23,02
20	45 (R2)	-50	3	1,5	24,11
25	90 (R3)	-50	4	2	26,41
25	45 (R1)	-30	5	1,5	27,63
25	90 (R4)	-70	4	1,5	26,41
25	45 (R2)	-30	4	2	27,63
20	45 (R1)	-50	4	1	24,53
25	45 (R1)	-70	4	2	27,63
25	90 (R3)	-50	3	1,5	26,41
25	45 (R2)	-50	4	1,5	26,14
25	45 (R1)	-30	3	1,5	25,91
25	45 (R1)	-70	3	1,5	26,27
25	45 (R2)	-50	5	2	26,34
25	45 (R1)	-70	5	1,5	26,43
30	45 (R1)	-50	4	2	29,62
25	45 (R2)	-50	4	1,5	26,06
25	45 (R2)	-50	4	1,5	25,86
25	45 (R1)	-50	3	2	26,16
30	45 (R2)	-50	5	1,5	28,13
25	90 (R4)	-50	5	1,5	26,41
25	0 (R7)	-50	4	1	26,28
25	45 (R1)	-50	4	1,5	25,86
30	45 (R2)	-50	3	1,5	30,21
25	90 (R3)	-30	4	1,5	26,53
25	0 (R6)	-50	3	1,5	26,31
20	45 (R1)	-70	4	1,5	24,53
20	90 (R3)	-50	4	1,5	23,36
25	0 (R7)	-70	4	1,5	26,28
25	45 (R1)	-50	4	1,5	27,63
20	45 (R1)	-30	4	1,5	24,53
30	45 (R2)	-70	4	1,5	29,62
25	0 (R4)	-50	5	1,5	26,28
25	45 (R1)	-30	4	1	27,63
20	45 (R2)	-50	4	2	23,02

Marquardtov model kako bi se na minimum svela linearna kombinacija kvadratnih pogrešaka i pondera radi minimaliziranja ukupne pogreške predviđanja, tj. radi približavanja brzini učenja drugog reda bez izračunavanja Hesseove matrice [30]. Ponderi su prilagođeni pomoću vrijednosti pogrešaka gradijenta koje su dobivene u suprotnom smjeru od izlaznog sloja, tj. prema ulaznom sloju mreže koja prolazi kroz skrivene slojeve. U okviru mehanizma učenja razvijaju se ponderi kao male slučajne vrijednosti izvedene iz ulaznih podataka u smjeru prema naprijed. Prvi rezultati stečeni obukom uvelike odstupaju od očekivanog raspona vrijednosti. Model se korigira kako bi se smanjili ponderi s minimalnom pogreškom u odnosu na eksperimentalne podatke i to kroz iteraciju prema natrag [31, 32]. U funkciju učenja uključen je i stohastički gradijent spuštavanja (GDM) radi optimiziranja prijenosne funkcije i to aproksimacijom utemeljenom na odgovarajućim razlučivim svojstvima.

Tablica 5. Parametri postupka umjetne neuronske mreže za RMS

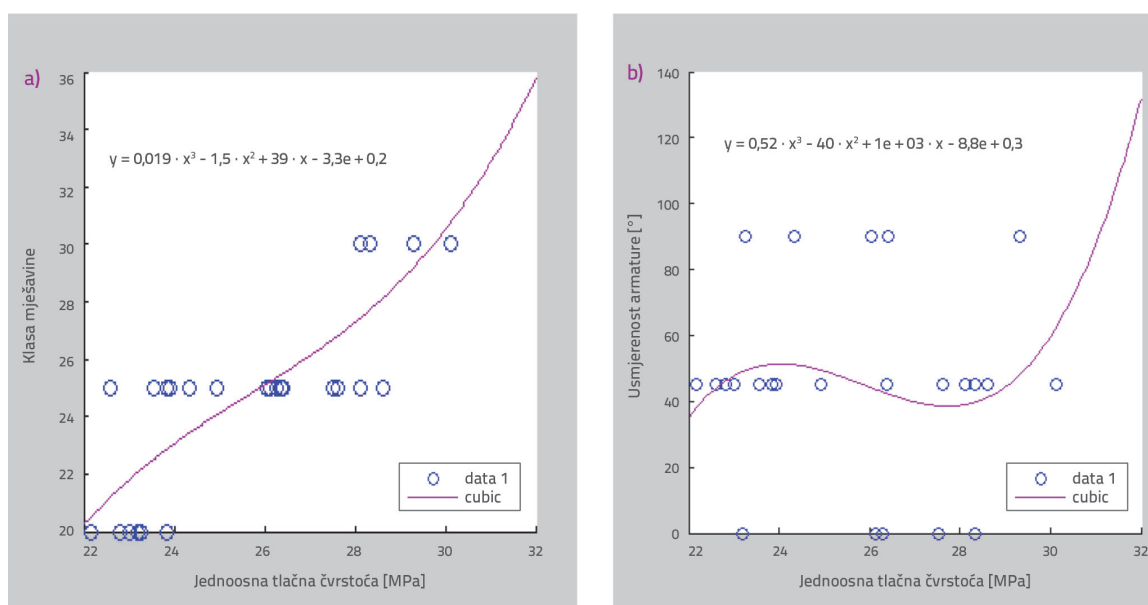
Naziv	Model BBD
Vrsta mreže	Model FFBP
Prijenosna funkcija	PURELIN
Funkcija učenja	TRAINLM
Funkcija učenja	LEARNGDM
Funkcija učinkovitosti	Srednja kvadratna pogreška
Broj neurona	3
Suma kvadratne pogreške	0,9968
Broj epoha	17
Validacijske provjere	6
Učinkovitost	0,878

U tablici 5. rezultati predviđanja dobiveni pomoću ANN mreže uspoređeni su sa stvarnim podacima. Metodologija prikazana u nastavku korištena je kako bi se pomoću ANN mreže mogle učinkovito ocijeniti različitosti u mješavinama betona te njihova tlačna čvrstoća, i to na bazi odnosa između parametara betonskih mješavina različitih razreda tlačne čvrstoće. Odnos između tlačne čvrstoće, vrijednosti UPV i parametara mješavine može se pratiti neuronskom mrežom na temelju broja neurona u skrivenom sloju.

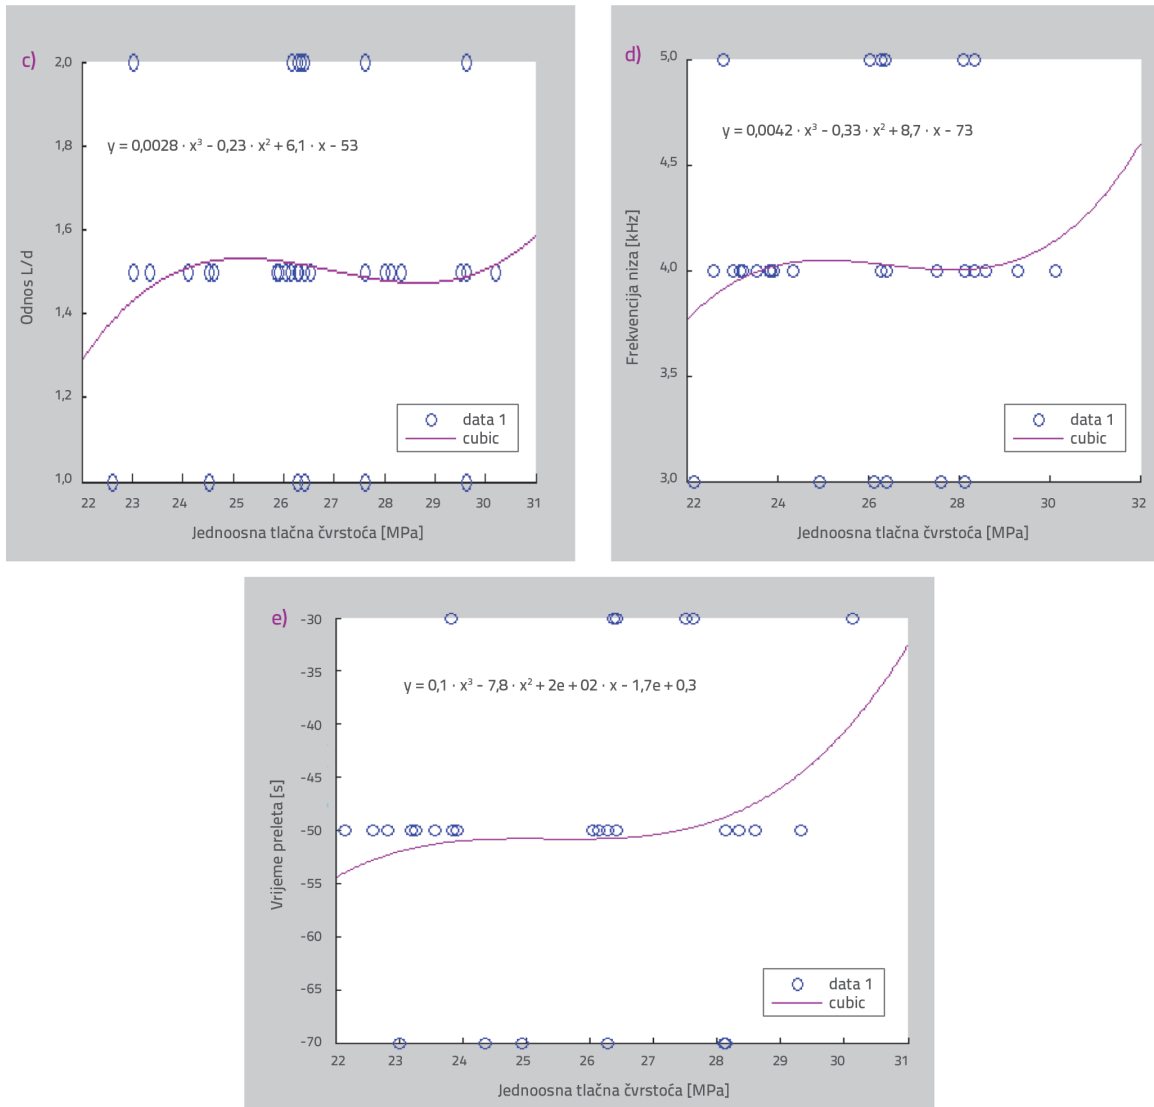
3. Rezultati i analiza

U ovom se poglavlju tlačna čvrstoća uzoraka interpretira pomoću parametara UPV ispitivanja. Whitehurst [33] izvještava da armaturne šipke prisutne u izvađenom uzorku betona utječu na tlačnu čvrstoću uzorka. Zacob i Ishibashi [34] ustanovili su da do smanjenja tlačne čvrstoće može doći i u postupku rezanja armature tijekom bušenja i to zato što između betona i armature dolazi do razvoja pukotina. Čvrstoća se smanjuje za otprilike 3,5 % kada kut usmjerenja armature iznosi 45°, tj. za otprilike 5,2 % kada je armatura pod kutom od 90° u odnosu na ravninu opterećenja. Na tlačnu čvrstoću uzorka betona više utječu parametri kao što su odnos L/d uzorka i razred betona.


Na slikama 6.a do 6.e vidimo regresijski prikaz interakcije između svakog ulaznog faktora i izlaznog odziva (jednoosna tlačna čvrstoća). Regresijske su jednadžbe razvijene na bazi kubne interpolacije modela za prilagodbu krivulje. Na prikazima regresijske analize određuje se odnos između ovisne varijable i jedne ili više neovisnih varijabli. Kubni model definiran je hipotetski i njime se ocjenjuju ulazni faktori za generiranje regresijske jednadžbe.



Slika 6. a) Odnos između razreda tlačne čvrstoće mješavine i UCS [MPa]; b) Odnos između usmjerenja armature (u stupnjevima) i UCS [MPa] (UCS - jednoosna tlačna čvrstoća, eng. Uniaxial Compressive Strength - UCS)



Slika 6. c) Odnos između omjera L/d i UCS [MPa]; d) Odnos između frekvencije (kHz) i UCS [MPa]; e) Odnos između vremena prolaska [ns] i UCS [MPa] (UCS - jednoosna tlačna čvrstoća, eng. Uniaxial Compressive Strength - UCS)



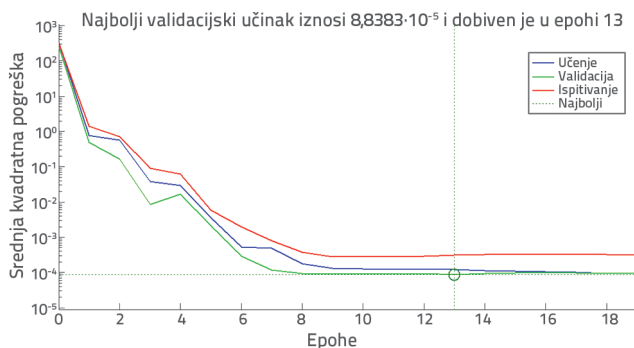
Slika 7. Box – Behnkenov plan (BBD)

Poučavanje i validacijsko ispitivanje učinkovitosti za pet ulaznih faktora i izlazni odziv prikazani je su slici 7. Vrijednost R^2 u iznosu od 0,9258 dobivena je s najbolje prilagođenom krivuljom gdje točnost iznosi 92 %. Dobivena je vrijednost zatim uspoređena s rezultatima razornog ispitivanja te je određen postotak točnosti.

$$\text{Pogreška [\%]} = \frac{(\text{Predviđena vrijednost} - \text{Izmjerena vrijednost})}{\text{Izmjerena vrijednost}} \cdot 100 \text{ [\%]} \quad (1)$$

$$\text{Točnost [\%]} = 100 - \text{Pogreška [\%]}$$

Izraz (1) zatim se koristi za izračunavanje postotka prosječne točnosti, koji iznosi 93,50 %. Može se dakle uočiti da je tlačna čvrstoća betonskog uzorka dobivena analizom pomoću MATLAB-a uvelike podudarna sa stvarnim vrijednostima tlačne čvrstoće koje su dobivene primjenom razornog ispitivanja. Validacijska učinkovitost utemeljena na vrijednostima srednje kvadratne pogreške prikazana je na slici 8.

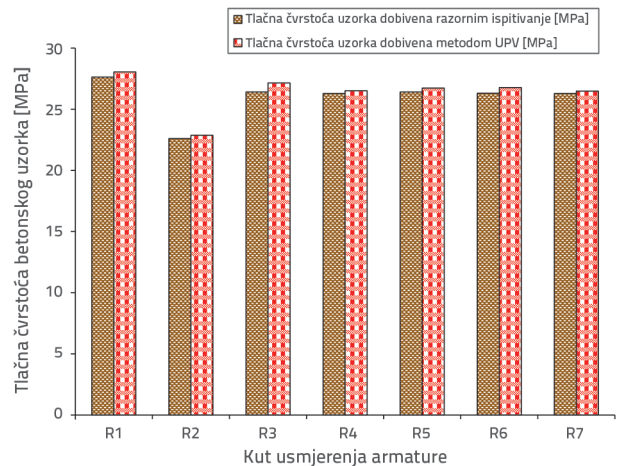


Slika 8. Validacijska učinkovitost utemeljena na vrijednostima srednje kvadratne pogreške

Tu se predviđa najveća podudarnost predloženog modela, a ona je utvrđena pri 13 epoha iteracije te iznosi 0,9968. Usporedba tlačnih čvrstoća dobivenih regresijskom analizom (ANN) i razornim ispitivanjem prikazana je na slici 9.

LITERATURA

- [1] Mustafa, T., Omer, A.: Assessing concrete strength by means of small diameter cores, Construction, and building materials, 22 (2007) 5, pp. 981-988, <https://doi.org/10.1016/j.conbuildmat.2006.11.020>
- [2] Lewandowski, R.: Comparison of In-situ strengths and quality tests of concrete, Betonstein-Zeitung, 37 (1971) 8, pp. 477-481. <https://doi.org/10.4224/20358593>.
- [3] Concrete Core Testing for Strength, Technical Report No. 11, The Concrete Society, London, 1987, pp. 47.
- [4] IS 516 – 1959, Indian Standard: Methods of tests for strength of concrete – Code of practice {Eighteenth Reprint}, Bureau of Indian Standards, New Delhi.



Slika 9. Vrijednosti tlačne čvrstoće dobivene regresijskom analizom (ANN) i razornim ispitivanjem

4. Zaključak

Provedena je eksperimentalna analiza kako bi se razvila metodologija za ocjenjivanje tlačne čvrstoće betone na temelju vrijednosti brzina ultrazvučnih impulsa a pomoću umjetnih neuronskih mreža (ANN). Izrađeni su betonski valjci s različitim odnosima L/d i sa sedam usmjerenja armature. Za različite su uzorke dobiveni redukcijski faktori koji su uneseni u MATLAB kako bi se poboljšala točnost rezultata. Koefficient korelacije između korigirane čvrstoće jezgre i odnosa L/d za M20 ($R_2 = 0,996$), M25 ($R_2 = 0,8704$) i M30 ($R_2 = 0,8268$) upućuje na dobar stupanj linearosti. Drugim riječima, može se ustvrditi da je linearna regresija tlačne čvrstoće pri odnosima L/d od 0,5, 1 i 1,5 podudarna s eksperimentalnim podacima. Čvrstoća betona smanjuje se za otprilike 3,5 % kada je armatura pod kutom od 45° , tj. za 5,2 % pri kutu armature od 90° u odnosu na ravninu opterećenja. To je uzrokovano razvojem pukotina oko armaturnih šipki. Usmjerenost armaturnih šipki u uzorcima ne utječe bitno na UPV (brzine ultrazvučnog impulsa). Eksperimentalni rezultati pokazuju da prosječni postotak iznosi 93,50 %. Dakle, tlačna čvrstoća betonskog uzorka dobivena regresijskom analizom i validacijom pomoću ANN mreža vrlo je bliska stvarnoj vrijednosti tlačne čvrstoće koja je dobivena razornim ispitivanjem. Iz eksperimentalnih se rezultata može zaključiti da je ovaj statistički model za predviđanje čvrstoće betonskih uzoraka vrlo optimističan.

- [5] Shafik, K., Ali Abdel-Hakam, A., Ahmed, G.: Reliability of core test – Critical assessment and proposed new approach', Alexandria Engineering Journal, 53 (2014) 1, pp. 169-184. <https://doi.org/10.1016/j.aej.2013.12.005>
- [6] ASTM C42-99: Standard Test Method for Obtaining and Testing Drilled Cores and Sawed Beams of Concrete – ASTM International, West Conshohocken, PA, 1999, www.astm.org
- [7] Loo, Y.H., Tan, C.W., Tam, C.T.: Effects of embedded reinforcement on measured strength of concrete cylinders, Magazine of Concrete Research, 41 (1989) 164, pp. 11-18. <https://doi.org/10.1680/MACR.1989.41.146.11>.
- [8] Gaynor, R.D.: Effect of Horizontal Reinforcement Steel on the Strength of Molded Cylinders, ACI Journal, 62 (1965) 7, pp. 837-840, <https://doi.org/10.14359/51685622>.
- [9] Cheesman, W.J., Arndt, W.J.: Dynamic testing of concrete with the sonic scope apparatus, 29th Annual Meeting of the Highway Research Board, Washington D.C., pp. 176-203, 1949.
- [10] Jones, R.: The non-destructive testing of concrete, Magazine of concrete research, 1 (1949) 2, pp. 67-78. doi. /10.1680/mac.1949.1.2.67.
- [11] Khademi, F., Mahmoud A., Sayed Mohammadmehdi, J., Mehdi, N.: Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete. Frontiers of Structural and Civil Engineering, 11 (2017) 1, pp. 90-99, <https://doi.org/10.1007/s11709-016-0363-9>.
- [12] Martin, J., Forde, M.C.: Influence of concrete properties on impulse hammer spectrum and compression wave velocity, Construction and building materials, 9 (1995) 4, pp. 245-255, [https://doi.org/10.1016/0950-0618\(95\)00027-D](https://doi.org/10.1016/0950-0618(95)00027-D).
- [13] Zaid, P., Sung, Q., Graham, M., Bosco, F.: Extracting dimensional information from steel reinforcing bars in concrete using a neural network trained on data from an inductive sensor, NDT&E International, 37 (2004) 7, pp. 551-558, <https://doi.org/10.1016/j.ndteint.2004.02.005>.
- [14] Hola, J., Schabowicz, K.: New technique of non-destructive assessment of concrete using artificial intelligence, NDT & E International, 38 (2005) 4, pp. 251-259, <https://doi.org/10.1016/j.ndteint.2004.08.002>.
- [15] Snell, L.M., Roekel, J.V., Wallace, N.D.: Predicting early concrete strength, Concrete international, 11 (1989) 12, pp. 43-47.
- [16] Maitham, A., Denys, B., Zoubir Mehdi, S., Katalin, S., Adorjan B.: Factors affecting the reliability of assessing the concrete strength by rebound hammer and cores, Construction and building materials, 140 (2017), pp.354-363, <https://doi.org/10.1016/j.conbuildmat.2017.02.129>.
- [17] Öztaş, A., Pala, M., Ozbay, E., Kanca, E., Caglar, N., Bhatti, M.A.: Predicting the compressive strength and slump of high strength concrete using a neural network, Construction and building materials, 20 (2006) 9, pp. 769-775. <https://doi.org/10.1016/j.conbuildmat.2005.01.054>.
- [18] Khademi, F., Sayed Mohammadmehdi, J.: Predicting the 28 days compressive strength of concrete using an artificial neural network. i-manager's Journal on Civil Engineering, 6 (2016) 2, pp. 1-6, <https://doi.org/10.26634/jce.6.2.5936>.
- [19] Shafiq, M.A.: Predicting the compressive strength of concrete using neural network and kernel ridge regression, 2016 Future Technologies Conference (FTC)", San Francisco, CA, USA, pp. 821-826, 2016, <https://doi.org/10.1109/FTC.2016.7821698>.
- [20] Chen, X., Shengxing, W., Jikai, Z.: Compressive strength of concrete cores under high strain rates, Journal of Performance of Constructed Facilities, 29 (2014) 1, pp. 06014005 (7), [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000586](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000586)
- [21] Gregor, T., Franci, K., Goran, T.: Prediction of concrete strength using Ultrasonic Pulse-Velocity and Artificial Neural Networks, Ultrasonics, 49 (2009) 1, pp. 53-60, <https://doi.org/10.1016/j.ultras.2008.05.001>.
- [22] Mucteba, U., Harun, T.: Predicting the core compressive strength of self – compacting concrete mixtures with mineral additives using Artificial Neural Networks, Construction and Building Materials, 25 (2011) 11, pp. 4105-4111, <https://doi.org/10.1016/j.conbuildmat.2010.11.108>
- [23] Ilker, A.O., Altin, A.: Estimation of compressive strength of concrete with Artificial Neural Network according to concrete mixture ratio and age, International Journal of Intelligent Systems and Applications in Engineering, 4 (2016) 3, pp. 76-79, <https://doi.org/10.18201/ijisae.263977>.
- [24] Rahmat, M., John, H., Reza, G.: Prediction of the Concrete Compressive strength by means of core testing using GMDH type Neural Network and ANFIS models, Computational material science, 51 (2011) 1, pp. 261-272. <https://doi.org/10.1016/j.commatsci.2011.07.053>.
- [25] Bilgehan, M., 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>.
- [26] Kumavat, H.R., Patel, V.J.: Factors Influencing the Strength Relationship of Concrete Cube and Standard Cylinder, International Journal of Innovative Technology and Exploring Engineering (IJITEE), 3 (2014) 8, pp. 76-79, ISSN: 2278-3075.
- [27] Ali, H.A.M., El-Zaidia, E.F.M., Mohamed, R.A.: Experimental investigation and modeling of electrical properties for phenol red thin film deposited on silicon using back propagation artificial neural network, Chinese Journal of Physics, 67 (2020), pp. 602-614, <https://doi.org/10.1016/j.cjph.2020.07.018>
- [28] Duddu, V.R., Pulugurtha, S.S.: Neural Networks to Estimate Crashes at Zonal Level for Transportation Planning, European Transport Conference: Glasgow, pp. 1-8, 2012.
- [29] Duddu, V.R., Pulugurtha, S.S.: Back-propagation neural network model to predict visibility at a road link-level, Transportation Research Interdisciplinary Perspectives, 8 (2017), pp. 100250 (9), <https://doi.org/10.1016/j.trip.2020.100250>.
- [30] Rumelhart, D.E., Hinton, G.E., Williams, R.J.: Learning representations by back-propagating errors, Nature, 323 (1986) 6088, pp. 533-536, <https://doi.org/10.1038/323533a0>.
- [31] Vora, K., Yagnik, S.: A survey on back propagation algorithms for feed forward neural networks, Int. J. Eng. Dev. Res., 1 (2014) 3, pp. 193-197, <https://doi.org/papers/IJEDR1303040.pdf>.
- [32] Grabec, I., Sachse, W.: Modeling by Neural Networks (12), Synergetics of Measurement, Prediction and Control, Springer Series in Synergetics, Springer, Berlin and Heidelberg, pp. 309-332, https://doi.org/10.1007/978-3-642-60336-5_12, 1997.
- [33] Whitehurst, E.A.: Soniscope test on concrete structures, Journal of the American Concrete Institute, 47 (1951), pp. 443-444.
- [34] Zacob, A., Ishibashi, K.: Point load test application for estimating the compressive strength of concrete structures from the small core, ARPN Journal of Engineering and applied science, 4 (2009) 7, pp. 231-237, ISSN 1819-6608 .