

Primljen / Received: 15.7.2020.

Ispravljen / Corrected: 31.1.2021.

Prihvaćen / Accepted: 3.6.2021.

Dostupno online / Available online: 10.9.2021.

# Jednostavna formula za ranu procjenu troškova na građevinskim projektima

## Autori:



Dr.sc. **Esra Dobrucali**, dipl.ing.građ.  
Sveučilište u Sakaryai, Sakarya, Turska  
Fakultet tehničkih znanosti  
Odjel za građevinarstvo  
[eeken@sakarya.edu.tr](mailto:eeken@sakarya.edu.tr)  
Autor za korespondenciju



Doc.dr.sc. **Ismail Hakki Demir**, dipl.ing.građ.  
Sveučilište u Sakaryai, Sakarya, Turska  
Fakultet za umjetnički dizajn i arhitekturu  
Odjel za arhitekturu  
[idemir@sakarya.edu.tr](mailto:idemir@sakarya.edu.tr)

Prethodno priopćenje

**Esra Dobrucali, Ismail Hakki Demir**

## Jednostavna formula za ranu procjenu troškova na građevinskim projektima

U okviru ovog istraživanja poboljšana je formula koja omogućuje jednostavnu, točnu i brzu procjenu troškova u ranim fazama građevinskih projekata (ESCE). Spomenutu formulu za procjenu ESCE-a razvili su autori na temelju umjetnih neuronskih mreža i evolucijskog programiranja gena. Kvantitativna analiza provedena je na stotinu građevinskih projekata, te je izrađen odgovarajući niz podataka. Taj niz podataka analiziran je pomoću većeg broja umjetnih neuronskih mreža kako bi se odredile varijable koje utječu na procjenu ESCE-a. Konfiguracija algoritma provedena je pomoću evolucijskog programiranja gena, te je na temelju te konfiguracije izrađena formula ESCE. Ta formula omogućuje dovoljno preciznu procjenu ESCE-a. Primjena predložene formule za određivanje troškova u ranoj fazi projekta omogućuje brže i jednostavnije izračunavanje troškova, ali isto tako sprječava pojavu bilo kakvih razlika do kojih bi moglo doći zbog individualnog pristupa proračunu.

### Ključne riječi:

troškovi u ranim fazama građenja, umjetna neuronska mreža, evolucijsko programiranje gena, građevinski projekt, procjena troškova

Research Paper

**Esra Dobrucali, Ismail Hakki Demir**

## A simple formulation for early-stage cost estimation of building construction projects

This study is aimed at improving a formula that enables easy, correct, and fast estimation of an Early-Stage Cost of Buildings (ESCE). This formula, enabling estimation of ESCE, was developed by the authors based on artificial neural networks and gene expression programming. A quantity survey was conducted for a hundred construction projects, and a data set was created. This data set was analysed with many Artificial Neural Networks to determine the variables that affect ESCE. An algorithm configuration was made with Gene Expression Programming, and the ESCE formula was created using this algorithm configuration. This formula estimates ESCE with satisfactory precision. The use of the proposed formula in the early-stage building cost calculations is important not only for faster and easier cost calculation but also to prevent any differences that may arise due to the individual making the calculations

### Key words:

early-stage cost of buildings, artificial neural network, gene expression programming, construction project, cost estimation

## 1. Uvod

Na građevinskim projektima investitori žele točno procijeniti potrebne troškove kako bi osigurali sredstva za svoja ulaganja te utvrdili isplativost projekta. U tom je postupku procjena troškova značajan korak za sve zainteresirane strane, a naročito za investitore i izvođače [1, 2]. Za te se potrebe koriste cijene sa sličnih dovršenih projekata, podaci koje su tijekom rada prikupili iskusni izvođači, te informacije o cijenama koje prikupljaju institucije za istraživanje tržišta, komore i sveučilišta. Spomenute cijene i informacije koriste se za definiranje odgovarajućih podataka koji omogućuju procjenu troškova u ranim fazama građevinskih projekata (eng. the *Early-Stage Cost Estimation* - ESCE).

Na građevinskim projektima, a naročito kada se radi o javnim investicijama s ograničenim proračunom, najtočnija procjena troškova građenja jedno je od najznačajnijih pitanja u okviru upravljanja građenjem u fazi prije podnošenja ponuda. Javne institucije koje nastupaju kao investitori žele što ranije dobiti točne procjene troškova kako bi mogle osigurati potrebna sredstva i definirati dinamiku svojih ulaganja, a s druge strane ponuditelji / potencijalni izvođači žele što točnije izračunati svoje troškove i dobit, te predati što konkurentniju ponudu u izrazito kompetitivnom okruženju. Tijekom izrade studija opravdanosti, u preliminarnim fazama projektiranja, ili u slučajevima kratkog roka za podnošenje ponuda, često dolazi do potreba za hitnom procjenom troškova. Ako u postupku nuđenja za neki građevinski projekt detaljna analiza troškova nije moguća zbog vremenskih ograničenja, investitori i ponuditelji mogu na prikladan način obaviti procjenu troškova u ranoj fazi projekta pomoću jednostavne metode ESCE. ESCE, tj. procjena troškova u ranim fazama građevinskih projekata, može varirati ovisno o subjektu koji provodi procjenu. Imajući na umu spomenute razloge, lako se može zaključiti da se trebaju razvijati metode koje omogućuju što precizniju procjenu ESCE-a i to u teoretskim i u praktičnim segmentima.

Istraživači su u razdoblju od 1998. godine pa do danas u svojim istraživanjima izradili brojne modele u svrhu ranog procjenjivanja troškova građevina. Tako su Elhag i Boussabaine [3] analizirali procjenu troškova na građevinskim projektima te razvili dva modela umjetnih neuronskih mreža koristeći pritom četrnaest varijabli. Lowe i dr. [4] proveli su istraživanje primjenom višestruke regresijske analize za predviđanje troškova građenja. U svojoj studiji Hwang [5] je predložio dva različita regresijska modela za ocjenu troškova na građevinskim projektima. Cheng i dr. [6] u svojoj su studiji u fazi izrade idejnog rješenja integrirali tehnike umjetne inteligencije u svrhu procjene troškova građevinskih projekata u Tajvanu. Kim i dr. [7] (12) analizirali su učinkovitost umjetnih neuronskih mreža, tehnika potpornih vektora i metoda regresijske analize za potrebe ranog određivanja građevinskih troškova. Osim toga, Bostancioglu [8], Gunaydin i Dogan [9], Akinbingol i Gultekin [10], Dogan i dr. [11], Nan i dr. [12], Sonmez [13], Arafa i Alqedra [14], Kuruoglu i dr. [15], Cho i dr. [16], Latief i dr. [17], El-Sawalhi i Shehatto [18], Bayram i dr. [19], Coloma i dr. [20], Dimitrijević i dr. [21] također su proveli razna modeliranja

kako bi procijenili troškove građevina u ranim fazama projekata. Pregled literature iskazan je u tablici 1.

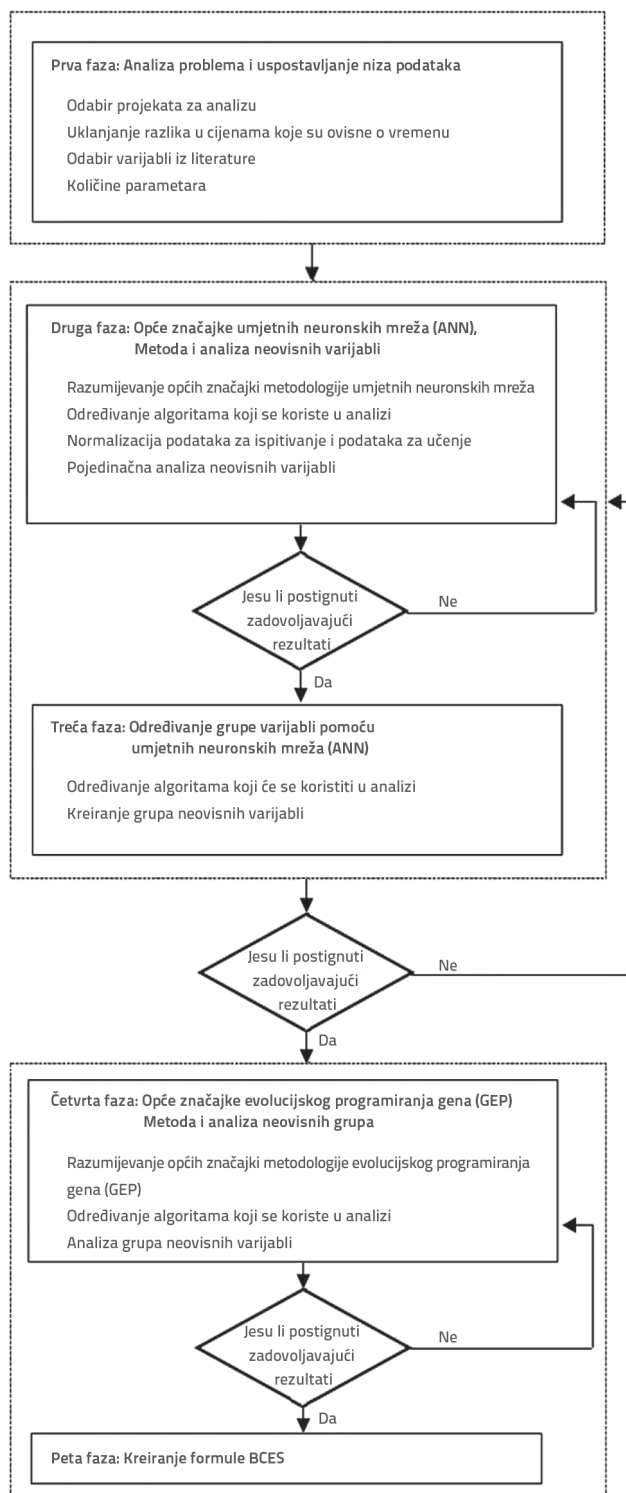
Tablica 1. Pregled literature

Godina	Autor	Metoda
1998.	Elhag i Boussabaine	Umjetne neuronske mreže
2004.	Gunaydin i Dogan	Regresijske analize
2009.	Hwang	Regresijske analize
2006.	Dogan i dr.	Tehnike umjetne inteligencije
2006.	Lowe	Regresijske analize
2010.	Cheng i dr.	Tehnike umjetne inteligencije
2011.	Sönmez	Umjetne neuronske mreže – uzorkovanje s ponavljanjem (bootstrap)
2011.	Arafa i Alqedra	Umjetne neuronske mreže
2013.	Kim i dr.	Regresijske analize – umjetne neuronske mreže – tehnike potpornih vektora
2013.	Cho i dr.	Regresijske analize – umjetne neuronske mreže
2013.	Latief i dr.	Regresijske analize – umjetne neuronske mreže
2014.	El-Sawalhi i Shehatto	Umjetne neuronske mreže
2016.	Bayram i dr.	-
2018.	Dimitrijević i dr.	Regresijske analize

Poznato je da se umjetna inteligencija može primijeniti za precizno modeliranje u mnogim područjima, pa tako i u specijalističkim područjima u građevinarstvu [22]. U novije se vrijeme u raznim segmentima građevinarstva koriste umjetne neuronske mreže (eng. *Artificial Neural Network* - ANN), genetički algoritmi (eng. *Genetic Algorithm* - GA), evolucijsko programiranje gena (eng. *Gene Expression Programming* - GEP) i simulacije, i to bilo zasebno ili u prikladnim kombinacijama. Kao što se može vidjeti u tablici 1., istraživači za ranu procjenu troškova građenja uglavnom koriste razne tehnike umjetne inteligencije (AI) i regresijske analize (RA) te istražuju djelotvornost tih postupaka u procjeni ESCE-a. Studije koje nalazimo u literaturi potvrđuju valjanost umjetne inteligencije u procjenjivanju režijskih troškova građenja. Prema spoznajama autora, do sada u literaturi još nije predložena formula za procjenu ESCE-a. Stoga se u ovom istraživanju kao prvi cilj postavlja predlaganje formule za brzo, jednostavno i točno izračunavanje ESCE-a. Sljedeći je cilj dokazati da postupci umjetne inteligencije omogućavaju kreiranje dovoljno preciznih modela ESCE-a.

U tu se svrhu predlaže nova formula kao rezultat modela integracije ANN-GEP sa specifičnim brojem parametara odabranih iz arhitektonskih projekata i projekata statike. Predložena formula za određivanje ESCE-a može pomoći investitorima i ponuditeljima da izračunaju troškove na brži i jednostavniji način, a ujedno

otklanja i mogućnost pojave razlika u izračunima ESCE-a koje bi mogle nastati zbog individualnih pristupa pri ocjenjivanju.



Slika 1. Metodologija primijenjena u istraživanju (prilagođeno prema metodologiji prikazanoj u radu Leśniak i Juszczyk [23])

## 2. Metodologija

Autori su krenuli od pretpostavke da treba unaprijediti formulu koja omogućuje jednostavno, točno i brzo procjenjivanje troškova građenja. U izradi formule primijenjena je metodologija prikazana na slici 1. Prema spomenutoj metodologiji, a nakon detaljnog pregleda i analize dostupne literature, autori su metodom ANN ocijenili osamnaest neovisnih varijabli koje su grupirali prema njihovim mogućnostima predviđanja ESCE-a. Zatim je pomoću GEP-a razvijen algoritam grupe za koju je utvrđeno da posjeduje najveću sposobnost predviđanja ESCE-a. Na kraju je definirana formula koja omogućuje točno izračunavanje ESCE-a. Prva je faza opisana u poglavlju 3. Detaljni podaci o formuli i ostalim fazama prikazani su u poglavlju 4.

## 3. Analiza problema i definiranje niza podataka

Definiranje troškova građenja u ranoj fazi projekta smatra se jednom od komponenata koje u najvećoj mjeri utječu na financijske analize izvođača i investitora na građevinskim projektima. Investitori žele što točnije i što brže definirati troškove kako bi mogli odrediti opseg svojih ulaganja a, s druge strane, izvođači žele što preciznije odrediti dobit koju bi mogli ostvariti na projektu. Tradicionalan način definiranja troškova građenja, koji se temelji na analizi količina za čitav projekt, također je precizan ali istovremeno dugo traje. Izračun troškova u ranoj fazi projekta može bitno varirati ovisno o subjektu koji provodi izračun. U preliminarnoj fazi projektiranja ili u slučaju kratkog roka za podnošenje ponuda, troškovi građenja trebaju se izračunati u što kraćem vremenu. Ako tijekom postupka nuđenja, zbog kratkoće vremena, nije moguće izraditi detaljnu analizu cijena, tada i ponuditeljima i javnim investitorima definiranje troškova u ranim fazama projekta pomoću jednostavne metode ESCE može biti vrlo prikladno rješenje. Očito je dakle da postoji potreba za definiranjem metode koja omogućuje točnu procjenu ESCE-a, i to kako u teoretskom tako i u praktičnom dijelu. Kao odgovor na tu potrebu, u ovom se radu predlaže alternativna formula koja omogućuje jednostavnu, točnu i brzu procjenu troškova građenja u ranim fazama projekta.

Kako bi se dobili što precizniji ulazni podaci za procjenu ESCE-a (tj. troškova građenja u ranim fazama projekta), koriste se cijene sa sličnih dovršenih projekata, podaci s prethodnih projekata koje su prikupili iskusni izvođači, te cjenovni pokazatelji koje objavljuju razne institucije kao što su uredi za istraživanje tržišta, strukovne komore i sveučilišta. U ovom je radu definirana formula za procjenu ESCE-a na osnovi sto javnih armiranobetonskih građevina koje su izvedene u raznim regijama i gradovima Turske u razdoblju od 2011. i 2016. godine. Ukupna tlocrtna površina projekata korištenih u ovom istraživanju odabrana je kao varijabla, a varira od 141 m<sup>2</sup> do 7.947 m<sup>2</sup>.

Troškovi na projektima mogu se uspoređivati samo ako postoji zajednička osnova za usporedbu, tj. nakon eliminiranja o vremenu ovisnih razlika u cijeni.

Tablica 2. Odabir neovisnih varijabli prema podacima iz literature

Varijabla	Literatura					
	[13]	[7]	[9]	[14]	[18]	[6]
Godina		x				
Funkcija					x	
Područje	x					
Površina prizemlja / površina građevine			x			
Površina kata / površina građevine			x			
Površina građevine / korisna površina						
Površina građevine	x	x				x
Površina prizemlja				x		
Površina kata				x	x	
Indeks troškova građevine	x					
Indeks troškova na određenoj lokaciji	x					
Visina kata		x				
Broj katova	x	x	x	x	x	
Površina održavanja / ukupna površina	x					
Površina za parkiranje / ukupna površina	x					
Ukupna bruto građevinska površina stambene jedinice	x					
Građevinska zona	x	x	x			x
Količina rušenja	x					
Čišćenje	x					
Drveni okvir	x					
Čelični okvir	x					
Betonski okvir	x					
Željezni i betonski okvir	x					
Zidana građevina	x					
Vanjska drvena obloga	x					
Vanjska plastična obloga	x					
Vanjska kamena zidna obloga	x					
Žbuka na vanjskim zidovima	x					
Broj zaustavnih mjesta dizala	x					
Trajanje projekta	x					
Broj konzola u građevini			x			
Struktura tla – topografija						x
Osnovna vrsta			x	x	x	
Vrsta građenja			x			

U analizi ESCE-a trebale su se u obzir uzeti promjene ekonomskih uvjeta definiranjem bazne godine, i to zato što su analizirani građevinski projekti izvedeni u raznim vremenskim razdobljima između 2011. i 2016. Zbog toga su procjene stvarnih vrijednosti ESCE korigirane primjenom "indeksa građevinskih troškova i stopa promjena za baznu godinu 2016.", izraz (1) prema [24].

Osim toga, na bazi podataka koje je objavila Centralna banka Republike Turske, usvojen je tečaj za 2019. godinu prema kojem jedna turska lira iznosi 5,7 američkih dolara.

$$ESCE = \frac{CCI_x}{CCI_i} \times Real\ ESCE \quad (1)$$

gdje *ESCE* označava korigirani trošak građenja definiran u ranoj fazi projekta,  $CCI_x$  označava indeks troškova građenja za odabranu godinu,  $CCI_i$  označava indeks troškova građenja za 2016. godinu, a *Real ESCE* označava vrijednost ESCE koju su izračunali investitori/javne institucije.

Kao osnova za odabir neovisnih varijabli za analizu količina korištene su studije o "određivanju troškova građenja u ranim fazama projekata" koje su objavili Cheng i dr. [6], Sonmez [13], Arafa i Alqedra [14], Kim i dr. [7], El-Sawalhi, Shehatto [18] te Gunaydin i Dogan [9]. Osamnaest parametara koji su pritom odabrani prikazani su u tablici 2. Količine parametara za svaki od analiziranih projekata definirane su na bazi točnih pojedinačno provedenih mjerenja.

## 4. Analize

### 4.1. Opće značajke metode umjetnih neuronskih mreža i analiza neovisnih varijabli

Umjetne neuronske mreže (ANN) jedne su od tehnika umjetne inteligencije zasnovanih na primjerima sposobnosti učenja ljudskog mozga. ANN pruža važeća, točna i neusporedivo dobra rješenja bazirana na umjetnoj inteligenciji [25]. ANN nije algoritamska metoda te može istovremeno i vrlo djelotvorno izvršavati više radnji pa stoga omogućuje vrlo prikladno i serijsko rješavanje složenih i nelinearnih problema [26]. Odabir prave mreže u ANN-u jest najznačajnija faza učenja mreže. Elementi po kojima se jedan model mreže razlikuje od ostalih su topologija mreže, funkcija dodavanja, funkcija aktiviranja i strategija učenja [27]. Najosnovniji dio ANN-a je živčana stanica koja se također naziva i "procesorom". Procesor se sastoji od jednog ili više unosa, pondera ovisnih o unosima, integracijske funkcije (ukupne veze), prijenosne (aktivacijske) funkcije i jednog izlaznog rješenja.

Integracijskom funkcijom dobivaju se neto unosi obradom između ulaza koji dolaze iz stanice i pondera. Od funkcija koje mogu biti funkcija dodavanja, funkcija množenja, funkcija maksimuma, funkcija minimuma, funkcija većine itd. najčešće se koristi funkcija dodavanja [27]. Aktivacijska funkcija, koju također nazivamo "krivuljom učenja" koristi se za kreiranje izlazne vrijednosti [28]. Koristi se nekoliko vrsta aktivacijskih funkcija, kao npr. sigmoidna funkcija, linearna funkcija, fazna funkcija, sinusna funkcija, hiperbolična tangentna funkcija itd. Te funkcije odabire korisnik koji kreira mrežu [27]. Od prijenosnih funkcija najčešće se koriste sigmoidne i hiperbolične tangentne funkcije [28]. Ovisno o broju slojeva, razlikujemo dvije vrste mreža ANN: jednoslojne mreže i višeslojne mreže [29]. Jednoslojna mreža

Tablica 3. Rezultati analize ANN u kojoj se neovisne varijable koriste kao jedan izlaz

Naziv neovisne varijable	Broj neurona u skrivenom sloju	BP			SCG		
		R <sup>2</sup>	SSE		R <sup>2</sup>	SSE	
			Obuka	Ispitivanje		Obuka	Ispitivanje
Vrsta	7	0,4619 <sup>*</sup>	2,1450	0,2476	0,4619 <sup>*</sup>	2,1450	0,2476
Podna površina	7	0,8724	0,6523	0,0618	0,8872	0,5806	0,0727
Visina kata	7	0,7053	1,3706	0,2404	0,7600	1,1518	0,1669
Broj katova	7	0,6795	1,4705	0,0931	0,6805 <sup>*</sup>	1,4641	0,0900
Trajanje	7	0,7393	1,2369	0,2303	0,7496	1,9548	0,2478
Kategorija tla	7	0,2298	2,5830	0,4906	0,2299 <sup>*</sup>	2,5826	0,4905
Vrsta temelja	7	0,1394	2,6738	0,4979	0,1394 <sup>*</sup>	2,6738	0,4979
Broj podruma	7	0,4522	2,1692	0,2782	0,4522 <sup>*</sup>	2,1692	0,2782
Dizalo	7	0,6023 <sup>*</sup>	1,7376	0,0911	0,6023 <sup>*</sup>	1,7376	0,0911
Broj vertikalnih nosača	7	0,7592	1,1566	0,1277	0,8757	0,6356	0,1283
Seizmička zona	7	0,1260	2,6835	0,5293	0,1260 <sup>*</sup>	2,6835	0,5293
Visina građevine	7	0,8228	0839	0,0807	0,8489	0,7621	0,0786
Koeficijent značenja građevine	7	0,4112	2,2659	0,3630	0,4114 <sup>*</sup>	2,2652	0,3633
Površina vertikalnih nosača	7	0,8601	0,7146	0,1015	0,8946	0,5447	0,0941
Ukupna površina unutarnjih zidova	7	0,8578	0,7249	0,0917	0,8901	0,5662	0,0956
Ukupna površina vanjskih zidova	7	0,9485	0,2754	0,2122	0,9560	0,2346	0,2240
Sanitarni čvorovi	7	0,9312	0,3642	0,0500	0,9414	0,3101	0,0528
Ukupna unutarnja površina	7	0,9460	0,2880	0,0135	0,9616	0,2054	0,0144

\* Obuka je prekinuta prije 10000 iteracija jer je na krivulji pogreške zabilježena minimalna kosina  
BP - algoritam povratnog prostiranja (eng. Back Propagation), SCG - skalirani konjugirani gradijent (eng. Scaled Conjugate Gradient)

ANN sastoji se od ulaznih i izlaznih slojeva, a višeslojna mreža ANN sastoji od tri zasebna sloja. Ti su slojevi ulazni sloj, skriveni slojevi i izlazni sloj. Višeslojna mreža ANN, kojom se može ostvariti 95 % rezultata inženjerskih problema, odnosi se na modele koji se danas najčešće koriste [27].

U analizama ANN, ESCE (a to je ovisna varijabla) i neovisne varijable unose se u izrazu (2) te se provodi linearni postupak normalizacije. Cilj ovog postupka je olakšati učenje i spriječiti pojavu pogrešaka [30].

$$y_i = \frac{y}{y_{max}} \quad (2)$$

gdje  $y_i$  označava rezultat normalizacije,  $y$  označava vrijednost koja će se normalizirati, a  $y_{max}$  označava najveću vrijednost varijable.

Analize ANN provedene su pomoću pisanih kodova u programu Matlab R2018a. U modelu ANN, aktivacijska (prijenosna) funkcija odabrana je kao Sigmoid (logsig), a daje pozitivne vrijednosti između [0-1]. S druge strane, integracijska funkcija odabrana je kao sumacijska funkcija koja se najčešće koristi u literaturi. Kao metoda učenja odabrano je učenje s učiteljem (nadzirano učenje). Algoritam povratnog prostiranja (eng. *Back propagation* - BP) najčešće se koristi za višeslojne mreže usmjerene prema naprijed [31]. BP je korišten kao algoritam za učenje jer se može

jednostavno dokazati, a i pregledom literature je ustanovljeno da se taj algoritam primjenjuje mnogo češće od ostalih. Korišten je i skalirani konjugirani gradijent (SCG) jer se njime postižu dobri rezultati u rješavanju problema pomoću BP-a.

#### 4.2. Određivanje grupa varijabli pomoću umjetnih neuronskih mreža

Značajna faza kod umjetnih neuronskih mreža (ANN) je iznalaženje izlazne optimalizirane mreže usklađene s brojem dostupnih neurona na bazi skrivenih slojeva, a za definiranje koeficijenta determinacije ( $R^2$ ). U prvoj fazi analiza koje su provedene pomoću umjetnih neuronskih mreža, definiran je koeficijent determinacije ( $R^2$ ) za ESCE, i to za situaciju u kojoj bi svaka od osamnaest neovisnih varijabli bila ovisna varijabla. U tim analizama, neovisne varijable pojedinačno čine ulazni sloj, a izlazni je sloj sastavljen od ESCE-a. Ustanovljeno je da broj neurona u skrivenom sloju koji daje najbolje rješenje iznosi sedam. Broj iteracija određen je metodom pokušaja nakon svakog učenja. Utvrđeno je da svaka varijabla ima drugačiji broj skrivenih slojeva. U tablici 1. prikazani su rezultati analize ANN za najbolju vrijednost skrivenog sloja za svaku neovisnu varijablu. U analizama je usvojeno da je potrebno predvidjeti najviše 10000 iteracija. Međutim, kako bi smanjenje omjera kosine za podatke dobivene učenjem povećalo marginu popogreške u podacima koji se ispituju, mreža je zaustavljena

kada je krivulja popogreške za podatke dobivene učenjem dostigla spomenutu kosinu.

**Tablica 4. Vrijednosti  $R^2$  ispitanih podataka za najbolje varijable pri određivanju ESCE-a**

Naziv neovisne varijable	Učenje	Ispitivanje
Ukupna unutarnja površina	0,9616	0,9603
Ukupna vanjska površina zidova	0,9560	0,5108
Sanitarni čvorovi	0,9414	0,9033
Površina vertikalnih nosača	0,8946	0,7535
Ukupna unutarnja površina zidova	0,8901	0,7977
Podna površina	0,8872	0,8132
Broj vertikalnih nosača	0,8757	0,7102

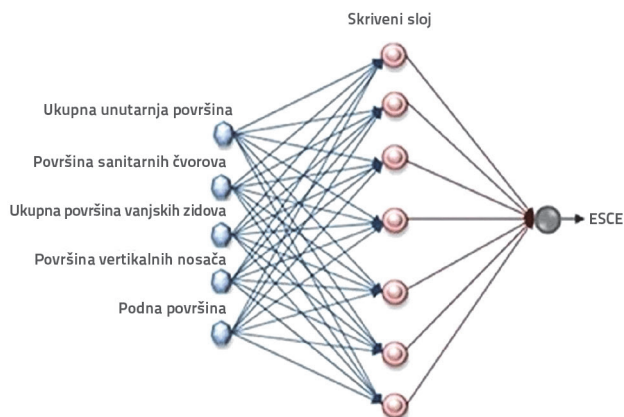
**Tablica 5. Neovisne varijable odabrane pri određivanju ESCE-a**

Naziv neovisne varijable	Kondenzacija
Ukupna unutrašnja površina	$y_1$
Sanitarni čvorovi	$y_2$
Ukupna vanjska površina zidova	$y_3$
Ukupna unutarnja površina zidova	$y_4$
Površina vertikalnih nosača	$y_5$
Podna površina	$y_6$
Broj vertikalnih nosača	$y_7$

Kao što se može vidjeti u tablici 3., pri određivanju ESCE-a, varijable s najvećom vrijednošću  $R^2$  su sanitarni čvorovi (prostori) i ukupne unutarnje građevinske površine. U prvoj fazi analiza ANN usvojene su neovisne varijable odabirom između varijabli čiji su rezultati učenja iznosili 0,85 ili više, kao što se to vidi u tablici 3. Zatim je proveden proračun primjenom

algoritma SCG. Odgovarajuće su vrijednosti prikazane u tablici 4. U tablici 4. vidimo da vrijednost  $R^2$  za ukupnu površinu vanjskih zidova iznosi 0,96 za podatke dobivene učenjem, tj. 0,51 za podatke dobivene ispitivanjem. Kako su vrijednosti  $R^2$  podataka dobivenih ispitivanjem i podatka dobivenih učenjem bile drugačije od očekivanih, pri označavanju neovisnih varijabli, ukupna površina vanjskih zidova označena je kao  $y_3$ , površina sanitarnih čvorova označena je kao  $y_2$ . Neovisne varijable prikazane su u tablici 5.

Pri određivanju grupa neovisnih varijabli, najprije je oblikovana grupa ACG1 s ukupnom unutarnjom površinom i površinom sanitarnih čvorova ( $y_1$  i  $y_2$ ), a to su dvije varijable s najvišom vrijednošću  $R^2$ . Nakon toga je grupi ACG1 dodano pet varijabli, i to jedna po jedna, te je oblikovano pet novih grupa (ACG2-ACG6). Između tih pet novih grupa odabrana je grupa s najboljim rezultatom. Ostale četiri varijable, koje nisu korištene, dodane su odabranoj grupi i formirane su nove grupe ESCE. Postupak je nastavljen sve dok nije oblikovana i grupa ACG16 sa sedam varijabli. Oblikovanje grupa ukratko je prikazano u tablici 6.



**Slika 2. Struktura ANN za ACG 12**

**Tablica 6. Analiza rezultata ANN za grupe neovisnih varijabli (ACG) za određivanje vrijednosti ESCE**

Naziv neovisne varijable	Broj neurona u skrivenom sloju	Broj iteracija	$R^2$ (Učenje)	SSE	
				Učenje	Ispitivanje
ACG 1 ( $y_1$ - $y_2$ )	7	400	0,9733	0,1441	0,0137
	7	600	0,9742	0,1392	0,0123
	7	800	0,9751	0,1346	0,0128
ACG 2 ( $y_1$ - $y_2$ - $y_3$ )	7	1200	0,9781	0,1184	0,0270
	7	1500	0,9785	0,1161	0,0154
	7	1800	0,9792	0,1126	0,0262
ACG 3 ( $y_1$ - $y_2$ - $y_4$ )	8	1000	0,9842	0,0853	0,0167
	8	1200	0,9885	0,0623	0,0100
	8	2000	0,9937	0,0344	0,0082
ACG 4 ( $y_1$ - $y_2$ - $y_5$ )	7	1000	0,9848	0,0824	0,0048
	7	1200	0,9850	0,0815	0,0046
	7	1500	0,9852	0,0800	0,0058

Tablica 6. Analiza rezultata ANN za grupe neovisnih varijabli (ACG) za određivanje vrijednosti ESCE - nastavak

Naziv neovisne varijable	Broj neurona u skrivenom sloju	Broj iteracija	R <sup>2</sup> (Učenje)	SSE	
				Učenje	Ispitivanje
ACG 5 (y1-y2-y6)	6	1000	0,9762	0,1287	0,0365
	6	1500	0,9814	0,1008	0,0492
	6	2000	0,9777	0,1204	0,0591
ACG 6 (y1-y2-y7)	6	800	0,9774	0,1221	0,2285
	6	1200	0,9811	0,1023	0,1495
	6	2000	0,9811	0,1026	0,2651
ACG 7 (y1-y2-y5-y3)	7	600	0,9846	0,0836	0,0059
	7	800	0,9854	0,0789	0,0045
	7	1000	0,9857	0,0773	0,0053
ACG 8 (y1-y2-y5-y4)	7	1000	0,9883	0,0635	0,0063
	7	1200	0,9893	0,0579	0,0059
	7	1500	0,9901	0,0536	0,0067
ACG 9 (y1-y2-y5-y6)	7	800	0,9870	0,0703	0,0071
	7	1000	0,9880	0,0650	0,0064
	7	1200	0,9887	0,0616	0,0069
ACG 10 (y1-y2-y5-y7)	7	1200	0,9846	0,0832	0,0129
	7	1500	0,9868	0,0719	0,0108
	7	1800	0,9882	0,0638	0,0119
ACG 11 (y1-y2-y5-y3-y4)	7	50	0,9655	0,1861	0,0347
	7	80	0,9722	0,1499	0,0208
	7	100	0,9748	0,1359	0,0230
ACG 12 (y1-y2-y5-y3-y6)	7	1200	0,9933	0,0366	0,0077
	7	1400	0,9937	0,0344	0,0069
	7	1800	0,9943	0,0309	0,0091
ACG 13 (y1-y2-y5-y3-y7)	7	1000	0,9885	0,0626	0,0088
	7	1200	0,9887	0,0612	0,0085
	7	1500	0,9894	0,0576	0,0113
ACG 14 (y1-y2-y5-y3-y6-y4)	7	100	0,9790	0,1134	0,0194
	7	200	0,9827	0,0937	0,0193
	7	400	0,9894	0,0581	0,0212
ACG 15 (y1-y2-y5-y3-y6-y7)	7	200	0,9880	0,0651	0,0089
	7	400	0,9926	0,0402	0,0076
	7	600	0,9935	0,0355	0,0088
ACG 16 (y1-y2-y5-y3-y6-y4)	7	100	0,9770	0,1245	0,0180
	7	200	0,9870	0,0708	0,0136
	7	400	0,9924	0,0412	0,0230

Analize grupa neovisnih varijabli provedene su na temelju svojstava mreža ANN. Uočeno je da se algoritmom SCG dobivaju bolji rezultati od rezultata dobivenih algoritmom BP, pa su zbog toga analize nastavljene s algoritmom SCG. Broj neurona u skrivenom sloju i broj iteracija varira kod svake grupe neovisnih varijabli. Vrijednosti pogreške analizirane su pomoću zbroja kvadrata pogrešaka (eng. Sum of Squares of Errors - SSE), kao što se može vidjeti u izrazu (3).

$$SSE = \sum (y - y')^2 \quad (3)$$

Vrijednost SSE (eng. *Sum of Squares of Errors* - SSE) označava ukupnu kvadratnu pogrešku (zbroj kvadrata pogrešaka), vrijednost  $y$  označava stvarne podatke, a vrijednost  $y'$  označava podatke dobivene analizom.

Kada se analiziraju vrijednost  $R^2$  i ukupna kvadratna pogreška (SSE) iz tablice 6., može se vidjeti da je najuspješnija grupa za određivanje ESCE-a zapravo grupa ACG12 koja sadrži pet ulaznih slojeva, sedam skrivenih slojeva i jedan izlazni sloj. Ta grupa sadrži neovisne varijable za ukupnu unutarnju površinu ( $y_1$ ), površinu sanitarnih čvorova ( $y_2$ ), ukupnu površinu vanjskih zidova ( $y_3$ ), površinu vertikalnih nosača ( $y_5$ ) i podnu površinu ( $y_6$ ).

### 4.3. Opće značajke metode evolucijskog programiranja gena (GEP) i analiza neovisnih grupa

Postupak evolucijskog programiranja gena (GEP) razvio je Ferreira, a temelji se na genetičkom algoritmu (GA) i genetičkom programiranju [32]. Razlika između te tri algoritamske metode proizlazi iz strukture kromosoma. Kromosome nalazimo u obliku linearne serije fiksne dužine u genetičkom algoritmu, a oni u genetičkom programiranju javljaju se u nelinearnom obliku i variraju po veličini i obliku. U evolucijskom programiranju gena kromosomi su opisani kao linearne serije fiksne dužine, a zatim se prikazuju kao jednostavni nelinearni dijagrami ili evolucijska stabla različitih veličina i oblika [32]. Kromosomi prikazani kao evolucijsko stablo opisani su različitim oblicima i veličinama pomoću procesora (operatora) koji se nalaze u GEP-u. Genetički operatori kao što su obnova, mutacija, transpozicija i reintegracija koriste se za linearne kromosome. Djelovanjem tih operatora nelinearne varijable određene po broju i dužini pretvaraju se u linearne serije različitih veličina i oblika, te se zatim generiraju funkcije [32-34]. U ovoj se metodi matematički kodovi koriste kao jezik za gene i evolucijska stabla [32, 34-36]. Tom se metodom svi problemi, od najjednostavnijih do najsloženijih, definiraju evolucijskim stablom. Evolucijsko se stablo sastoji od matematičkih izraza, konstanti, varijabli i funkcija [32-34, 37, 38]. Osim toga, evolucijska se stabla mogu konvertirati u gotovo sve programske jezike [39].

Sastavni elementi evolucijskog kodiranja gena su kromosomi i evolucijska stabla. Kodovi modela rješenja u evolucijskom programiranju gena sastavljeni su od gena s glavama, repovima i konstantama, te od kromosoma koji sadrže strukturu s funkcijom vezivanja koja povezuje te gene. Tijekom pripremanja arhitekture rješenja, odabiru se brojevi gena, dužina glava i funkcija vezivanja, koji određuju najveću veličinu svakog izraza modela [40]. S druge strane, genetički operatori su operacije koje se provode korištenjem postojeće populacije u svrhu proizvodnje novih generacija s boljim svojstvima, čime se širi obuhvat pretražnog algoritma. U stvari, postoje dva opća operatora koje nazivamo transpozicija i mutacija [41]. U GEP-u se kreiraju razne genetičke strategije kroz raznovrsno korištenje tih operacija i nasumične konverzije brojeva (RNC) [42].

U ovom se istraživanju koristi GeneXpro 5.0 s pet različitih strategija obučavanja: optimalna evolucija, konstantno poboljšavanje, poboljšavanje modela, odabir podnizova i posebno generirana strategija [42]. Za rješavanje složenih problema potrebna su stabla rješenja s dugim kromosomskim strukturama. Ona se kodiraju u manje strukture (kao što su geni

u kromosomima) s podevolucijskim stablima GEP, te se tako stvara hijerarhijska struktura [33-37, 43]. Maksimalni ponderi i dubine podevolucijskih stabala za svaki se gen izračunavaju prema izrazima (4) i (5).

$$w = (n - 1) \times h + 1 \quad (4)$$

gdje  $w$  označava ponder podevolucijskog stabla,  $h$  označava dužinu glave, a  $n$  označava najveću vrijednost parametara dobivenih pomoću funkcija iz niza funkcija [40].

$$d = \left( \frac{h+1}{m} \right) \times \left( \frac{m+1}{2} \right) \quad (5)$$

gdje  $d$  označava dubinu podevolucijskog stabla,  $h$  označava dužinu glave, a  $m$  označava najmanju vrijednost parametara dobivenih pomoću funkcija iz niza funkcija [40]. Funkcije vezivanja sastoje se od operacija dodavanja, oduzimanja, množenja i dijeljenja, a koriste se za zajedničko povezivanje podevolucijskih stabala [33, 35-37, 43].

Funkcije ispravnosti korištene u GEP-u pokazuju sposobnosti gena u nalaženju rješenja, kao što je to slučaj u genetičkom algoritmu. U regresijskim analizama koje se provode s GEP-om koriste se funkcije ispravnosti kao što su srednja apsolutna popogreška (eng. *mean absolute error* - MAE), srednja kvadratna popogreška (eng. *mean square error* - MSE), korijen srednje kvadratne popogreške (eng. *root mean square error* - RMSE), relativna kvadratna popogreška (eng. *relative square error* - RSE), korijen relativne kvadratne popogreške (eng. *root relative square error* - RRSE), relativna apsolutna popogreška (eng. *relative absolute error* - RAE), krivo izjednačavanje, matrica troškova/prihoda, pozitivna korelacija itd. [40]. Osim toga, GEP je genotipski / fenotipski genetički algoritam koji se koristi kao nova metoda za izradu formula [44].

U ovom se istraživanju model GEP, projektiran pomoću pet prethodnih varijabli, koristi kao ulazni podatak, a ažurirani ESCE kao izlazni podatak. Vrijednosti ESCE revidirane su iteracijskom metodom pri čemu se 2016. godina koristi kao bazna godina. Osim toga, podaci o obučavanju-ispitivanju u analizama su određeni nasumično kao 80 % - 20 %.

Korijen relativne kvadratne popogreške (RRSE) korišten je kao regresijska analiza i funkcija ispravnosti u okviru evolucijskog programiranja gena. Funkcija ispravnosti RRSE-a ( $E_i$ ) matematički je prikazana u izrazima (6) i (7).

$$\bar{T} = \frac{1}{n} \sum_{j=1}^n T_j \quad (6)$$

gdje  $T_j$  označava ciljnu vrijednost za  $j$ , a  $n$  označava broj uzoraka [42].

$$E_i = \sqrt{\frac{\sum_{j=1}^n (P_{ij} - T_j)^2}{\sum_{j=1}^n (T_j - \bar{T})^2}} \quad (7)$$



Tablica 7. Vrijednosti operatora prema genetičkim strategijama \*

Genetički operatori*	Optimalna evolucija	Konstantno poboljšavanje	Poboljšavanje modela
Mutacija	0,00138	0	0
Mutacija fiksnog korijena	0,00068	0	0
Umetanje funkcije	0,00206	0	0
Mutacija lista	0,00546	0	0,0140
Pristrana mutacija lista	0,00546	0	0,0140
Konzervativna mutacija	0,00364	0	0,0140
Konzervativna mutacija fiksnog korijena	0,00182	0	0,0140
Konzervativna mutacija funkcija	0,00546	0	0,0140
Permutacija	0,00546	0	0
Konzervativna permutacija	0,00546	0	0,0140
Pristrana mutacija	0,00546	0	0
Transpozicija Is **	0,00546	0	0
Transpozicija Ris**	0,00546	0	0
Inverzija	0,00546	0	0
Inverzija repa	0,00546	0	0,0140
Mutacija repa	0,00546	0	0,0140
Spotičuća mutacija	0,00141	0	0
Ujednačeno preslagivanje	0,00755	0	0
Ujednačena preslagivanje gena	0,00755	0	0
Preslagivanje u jednoj točki	0,00277	0	0
Preslagivanje u dvije točke	0,00277	0	0
Preslagivanje gena	0,00277	0	0,01290
Transpozicija gena	0,00277	0	0
Nasumični kromosomi	0,00260	0	0
Nasumično kloniranje	0,00102	0,01320	0,00132
Najbolje kloniranje	0,00260	0,07160	0,07160

(\*\* Transpozicijski elementi Ris i Its GEP-a su dijelovi genoma koji se mogu aktivirati te prebaciti na drugu lokaciju u kromosomu)\*\*\*  
 (\*Definicije i detaljnije informacije o ostalim parametrima iz tablice mogu se pronaći u [40, 42])

gdje  $P_{ij}$  označava vrijednosti procijenjene pomoću modela,  $\bar{T}$  označava srednju vrijednost izračunanu pomoću izraza (6),  $T_j$  označava ciljnu vrijednost za  $j$ , a  $n$  označava broj uzoraka [42]. GeneXpro ima nekoliko fiksnih genetičkih strategija. U ovom su istraživanju korištene tri genetičke strategije: optimalna evolucija, konstantno poboljšavanje i poboljšavanje modela. tablica 7. prikazuje spomenute tri genetičke strategije i udio genetičkih operatora u tim strategijama.

Analize počinju s optimalnom evolucijom. Kada se analizom utvrdi najbolja vrijednost ispravnosti (engl. fitness value), te tri strategije koriste se alternativno. Genetički algoritam sadrži dva opća operatora, a to su tranzicija i mutacija [41]. Ostali operatori dobivaju nazive u skladu s njihovim pozicijama i metodama koje se koriste za primjenu ta dva opća operatora na kromosome ili gene, vidi tablicu 7. Omjer konstanti za te tri strategije prikazan je u tablici 8. Osim toga, usvojeno je da maksimalna vrijednost ispravnosti iznosi 1000.

Tablica 8. Nasumične konstante\*

Genetički operatori*	Optimalna evolucija	Konstantno poboljšavanje	Poboljšavanje modela
Mutacija RNC	0,00206	0,0328	0,0328
Konstantno poboljšavanje	0,00206	0,0728	0,0728
Mutacija Dc	0,00206	0,0140	0,0140
Inverzija Dc	0,00546	0,0140	0,0140

(\* Definicije i detaljnije informacije o nasumičnim konstantama i genetičkim operatorima koji se spominju u tablici mogu se pronaći u [40, 42]),

Tablica 9. Korekcije analize GEP

Broj kromosoma	80
Veličina glave	20
Broj gena	1
Funkcija povezivanja	Množenje
Konstante po genu	10

U svakoj se iteraciji odabire dužina glave s brojem gena. Vrsta funkcije povezivanja, broj gena i dužina svakog gena – to su prioriteta koji se trebaju odabrati za svaki problem. Stoga se postupnim povećavanjem dužine glave uvijek može koristiti neki određeni kromosom. Ako suviše raste, broj gena može se povećati te se može odabrati funkcija za povezivanje. U drugim se slučajevima može pokazati da je neka druga funkcija povezivanja prikladnija [32]. Osim toga, broj kromosoma, veličina glave, broj gena i funkcije povezivanja – koji svi čine osnovu arhitekture GEP - određuju se u nekoliko pokušaja kako bi se u studiji dobio najbolji mogući rezultat. Korekcije u analizi GEP prikazane su u tablici 9.

#### 4.4. Oblikovanje formule ESCE

U analizi provedenoj u svrhu određivanja vrijednosti ESCE pomoću GEP-a, pet varijabli koje utječu na ESCE identificirano je kao ulazni podatak, ažurirana vrijednost ESCE identificirana je kao izlazni podatak. Rezultati modela koji najbolje određuju ESCE prikazani su u tablici 10. Kao rezultat modela, izrađena je formula ESCE s pet varijabli. Ta je formula prikazana u izrazu (8). Kao što je prikazano u tablici 10., izračunani koeficijent determinacije ( $R^2$ ) za formulu ESCE iznosi 0,90 za niz učenja tj. 0,96 za niz ispitivanja. Srednja apsolutna postotna popogreška (eng. *Average Absolute Percent Error - MAPE*) često se koristi za ocjenjivanje točnosti predviđanja. Prema tablici 10., vrijednost MAPE za formulu ESCE iznosi 0,24 za niz učenja, tj. 0,18 za niz ispitivanja. Prema Lewisu, raspon vrijednosti MAPE od 0,20 do 0,50 smatra se prikladnim za potrebe predviđanja [47]. Prema podacima iz literature, još uvijek ne postoji norma za precizno određivanje postotka za predviđanje troškova građevina. Ipak, u nekim se studijama navodi da točnost procjene ovisi o dostupnosti informacija o projektu: točnost može varirati od +40 % do -20 % prije idejnog projekta, te od +25 % do -10 % nakon te faze [48, 49]. Usporedba stvarnih vrijednosti dobivenih na temelju formule prikazana je na slikama 3, 4. i 5. Postotak


raspodjele grešaka za niz učenja i niz ispitivanja prema rezultatu formule prikazan je na slikama 6. i 7.

Tablica 10. Rezultati GEP za ESCE

	Učenje	Ispitivanje
$R^2$	0,90	0,96
Najbolja ispravnost	839,05	868,98
Srednja apsolutna popogreška	475000	207000
Srednja apsolutna postotna popogreška	0,24	0,18
Korijen relativne kvadratne popogreške	0,14	0,12


$$ESCE = \frac{CCI_x}{CCI_i} \left[ 130.47 \times \left( \frac{y_2 \times y_3 \times y_5}{y_6} + y_1 \right) + 75215.80 \right] \quad (8)$$

gdje  $ESCE$  označava ranu procjenu troškova građenja,  $CCI_x$  označava indeks troškova građenja za određenu godinu,  $CCI_i$  označava indeks troškova građenja za 2016. godinu,  $y_1$  označava ukupnu unutarnju površinu,  $y_2$  označava površinu mokrih čvorova,  $y_3$  označava ukupnu vanjsku površinu zidova,  $y_5$  označava površinu vertikalnih nosača, a  $y_6$  označava podnu površinu.




Slika 3. Rezultat GEP u vidu dijagrama raspodjele podataka o ispitivanju za ESCE

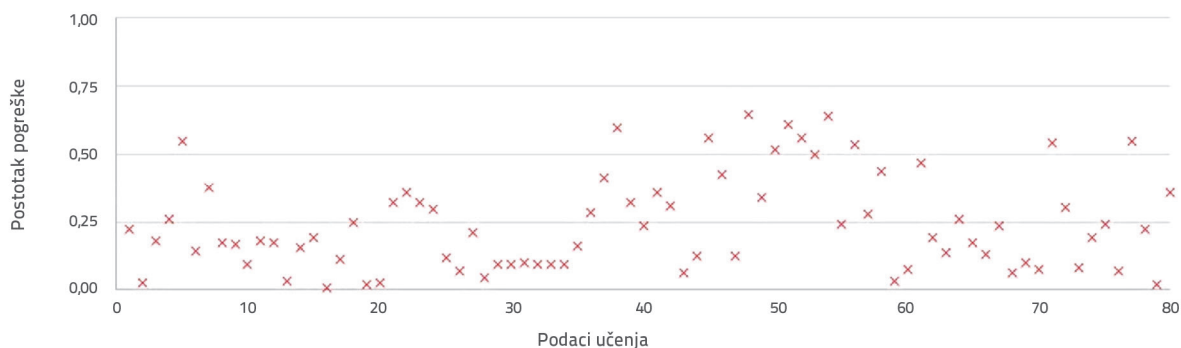
U planiranju i upravljanju građenjem trebaju se koristiti neovisno projektirani modeli koji se izrađuju pomoću specijaliziranih



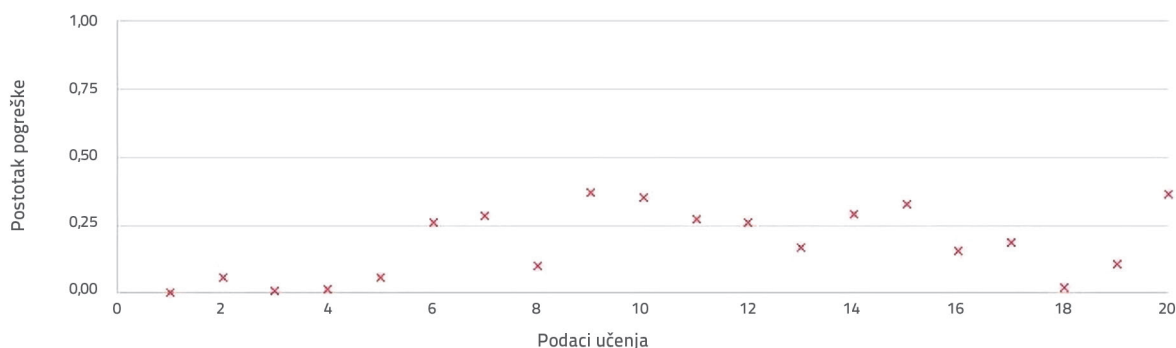
Slika 4. Dijagram raspodjele podataka o učenju za ESCE



Slika 5. Dijagram raspodjele podataka o ispitivanju za ESCE



Slika 6. Postotna raspodjela pogrešaka podataka o učenju za ESCE



Slika 7. Postotna raspodjela pogrešaka podataka o ispitivanju za ESCE

aplikacija [45]. Zbog toga je formula algoritma određena pomoću softverskog paketa GenexPro 5.0 za procjenu vrijednosti ESCE i pritom je korišteno pet neovisnih varijabli.

Informacije o pet neovisnih varijabli koje su uključene u arhitektonske projekte i projekte statike, koje se razlikuju jedne od drugih, određuju se uz pomoć korisnika. U konačnici se na temelju formule ocjenjuje vrijednost ESCE dotičnog projekta. Informacije ESCE izračunate tradicionalnom metodom prikazane su u Elektronskoj platformi za javne nabave (EKAP) [46].

## 5. Analiza konkretnog slučaja

Kako bi se odredila učinkovitost predložene formule, provedena je jednostavna provjera na stvarnoj armiranobetonskoj jednokatnoj građevini javne namjene koja zauzima podnu površinu od 4440 kvadratnih metara. Građevina je odabrana nasumce kao jedan od ugovora o javnoj nabavi (EKAP) za 2019. godinu. Opće informacije o građevini i projektu prikazane su u tablici 11.

Tablica 11. Opći podaci o stvarnoj armiranobetonskoj građevini javne namjene

EKAP broj	442.417
Datum podnošenja ponuda	2 October 2019
Gradilište	Afyonkarahisar / Turkey
ESCE prema EKAP-u	271064.82 \$

Analiza količina provedena je za dotičnu armiranobetonsku građevinu pomoću pet neovisnih varijabli. Odgovarajući rezultati prikazani su u tablici 12. Primijenjen je tečaj Centralne banke Republike Turske za 2019. godinu prema kojem jedna turska lira iznosi 5,7 američkih dolara. Ukupna unutarnja površina svakog kata izračunana je odbijanjem dužina vrata i prozora od tlocrta svakog kata te množenjem s debljinom zida. Ukupna unutarnja površina građevine određena je zbrajanjem tih vrijednosti za svaki kat. Površina mokrih čvorova građevine izračunana je zbrajanjem površine mokrih čvorova za svaku etažu. Ukupna unutarnja površina građevine izračunana je množenjem broja katova i podnih površina. Površina vertikalnih nosača odnosi se na poprečne presjeke stupova i ovješnih elemenata na jednom katu.

Tablica 12. Analiza količina za postojeću armiranobetonsku građevinu javne namjene

Ukupna unutarnja površina (y1)	606 m <sup>2</sup>
Površina sanitarnih čvorova (y2)	40,67 m <sup>2</sup>
Ukupna površina vanjskih zidova (y3)	7,84 m <sup>2</sup>
Površina vertikalnih nosača (y5)	15,12 m <sup>2</sup>
Podna površina (y6)	606 m <sup>2</sup>

Rana procjena troškova građevine za postojeću armiranobetonsku građevinu javne namjene:

$$ESCE = 190.23 / 111.92 [130.47 \times ((40.67 \times 7.84 \times 15.12) / (606 + 606) + 75215.80) = 263994.40 \quad (9)$$

gdje *ESCE* označava ranu procjenu troškova građevine za postojeću armiranobetonsku građevinu javne namjene, 190,23 označava indeks troškova građenja za mjesec rujan 2019. godine, a 111,92 označava indeks prosječnih troškova građenja za 2016. godinu.

Prema izračunu koji je napravio Investitor (javna institucija), vrijednost *ESCE* za armiranobetonsku javnu građevinu iznosi 271064.82 \$, a odgovarajući iznos izračuna prema predloženoj formuli iznosi 263994.40 \$. Analizom ta dva rezultata može se zaključiti da točnost vrijednosti *ESCE* određene prema predloženoj formuli iznosi 97 %.

## 6. Rasprava i zaključak

Definiranje troškova građenja u ranoj fazi projekta (*ESCE*) smatra se jednom od komponenata koje u najvećoj mjeri utječu na financijske analize izvođača i investitora na građevinskim projektima. Investitori žele što točnije i što brže definirati troškove kako bi mogli odrediti opseg svojih ulaganja a, s druge strane, izvođači žele što preciznije odrediti dobit koju bi mogli ostvariti na projektu. Tradicionalan način definiranja troškova građenja, koji se temelji na analizi količina za čitav projekt, također je precizan, ali nažalost i dugotrajan. U preliminarnoj fazi projektiranja ili u slučaju kratkog roka za podnošenje ponuda, troškovi građenja trebaju se izračunati u što kraćem vremenu. Kim i dr. (2004.) predlažu izradu modela baziranog na genetičkom algoritmu u svrhu dobivanja parametara za optimalnu procjenu troškova građenja, što uključuje i definiranje optimalne arhitekture neuronskih mreža [50].

U ovom je radu predložena formula za brzu, efikasnu i točnu ranu procjenu troškova građenja (*ESCE*) pri čemu se koriste podaci odabrani u skladu s projektima građevina te prema metodama ANN i GEP. Analiza količina provedena je za sto građevinskih projekata ugovoreni u razdoblju od 2011. i 2016. godine uz primjenu neovisnih varijabli koje utječu na troškove građenja. Nakon toga je kreiran niz podataka. Ukupna podna površina projekata za koje je izrađen niz podataka varirala je od 141 m<sup>2</sup> do 7947 m<sup>2</sup>. Khamis i dr. (2005) navode da ekstremne vrijednosti u podacima učenja i podacima ispitivanja umanjuju točnost modela [51]. Zbog toga su određene granične vrijednosti ukupne podne površine projekata, što je onemogućilo formiranje ekstremnih vrijednosti te povećalo učinkovitost učenja u okviru modela. Niz podataka je ispitan pomoću analiza utemeljenih na ANN mrežama kako bi se odredile varijable koje utječu na vrijednost *ESCE*. Tijekom tih analiza utvrđene su sljedeće grupe varijabli: ukupna unutarnja površina ( $y_1$ ), površina mokrih čvorova ( $y_2$ ), ukupna površina vanjskih zidova ( $y_3$ ), površina vertikalnih nosača ( $y_5$ ) te podna površina ( $y_6$ ). Te grupe varijabli korištene su za procjenu vrijednosti *ESCE*, a pokazalo

se da su tom procjenom postignuti dobri rezultati. Koeficijent procjene ove grupe iznosio je 0,99 za niz učenja. U sljedećoj je fazi izrađena konfiguracija modela pomoću evolucijskog programiranja gena (GEP) gdje su neovisne varijable definirane analizom ANN usvojene kao ulazni podaci za GenexPro 5.0. Formula modela (formula *ESCE* – izraz (8)) izrađena je pomoću tih pet neovisnih varijabli. Izračunan je koeficijent determinacije ( $R^2$ ) za spomenutu formulu *ESCE*, a iznosio je 0,90 za niz učenja, tj. 0,96 za niz ispitivanja. Izračunana vrijednost MAPE niza ispitivanja za formulu *ESCE* iznosila je 0,18 što je unutar granica razumnog predviđanja.

Osim toga, provedena je korelacijska i linearno regresijska analiza niza podataka kako bi se ovaj model (ova formula) usporedio s regresijskom analizom (tj. s tradicionalnom metodom). Tom je analizom utvrđeno da su parametri, tj. koeficijent značenja građevine, površina vertikalnih nosača i visina građevine, bili djelotvorni u ranoj procjeni troškova građevine, dok je vrijednost  $R^2$  iznosila 0,77. Kim i dr. [7], Cho i dr. [16], Latief i dr. [17], Kim i dr. [50] pokazuju da su tehnike umjetne inteligencije (poput umjetnih neuronskih mreža i neuroneizrazitih sustava) učinkovitije od regresijske analize, tj. od tradicionalne metode za procjenu troškova građenja. Na kraju su provedene provjere kroz analizu konkretnog slučaja kako bi se ustanovila razina učinkovitosti predložene formule.

Na temelju ovog istraživanja doneseni su sljedeći zaključci:

- Predložena formula uklanja teret dugotrajnih analiza količina na projektima armiranobetonskih građevina.
- Predložena formula omogućuje brzu i jednostavnu procjenu vrijednosti *ESCE*.
- Tijekom izrade ove studije uočeno je da analiza količina može varirati, čak i u slučaju *ESCE*, od slučaja do slučaja. Primjena predložene formule za određivanje troškova u ranoj fazi projekta omogućuje brže i jednostavnije izračunavanje troškova, ali isto tako sprječava pojavu bilo kakvih razlika do kojih bi moglo doći zbog individualnog pristupa proračunu.
- S druge strane, rezultati istraživanja upućuju na učinkovitost zajedničke primjene umjetnih neuronskih mreža i evolucijskog programiranja gena u proračunu *ESCE*-a.
- Dokazano je da je moguća izrada *ESCE* formule zadovoljavajuće preciznosti.
- Ovaj je rad značajan doprinos postojećoj literaturi jer predloženi postupak omogućava jednostavnu, brzu i točnu procjenu vrijednosti *ESCE* na građevinskim projektima.

## Zahvale

Jedinica za znanstvenoistraživačke projekte pri Sveučilištu u Sakaryai pružila je pomoć u izradi ovog rada (Projekt br.: 2016-07-12-004).

## LITERATURA

- [1] Park, H.K.: Cash flow forecasting in construction project, *KSCE J. Civ. Eng.*, 8 (2004), pp. 265–271.
- [2] Budak, O.: Solution proposals for the application problems of public procurement law at numbered 4734, M.S. Thesis, Istanbul Technical University, (2006).
- [3] Boussabaine, A.H., Elhag, T.M.S.: An artificial neural system for cost estimation of construction projects, *Proc. 14<sup>th</sup> Annu. ARCOM Conf.*, Reading, United Kingdom, (1998).
- [4] Lowe, D.J., Emsley, M.W.: A harding, predicting construction cost using multiple regression techniques, *J. Constr. Engineering Manag.*, 132 (2016), pp. 750–758.
- [5] Hwang, S.: Dynamic regression models for prediction of construction costs, *J. Constr. Eng. Manag.*, 135 (2009), pp. 360–367.
- [6] Cheng, M.Y., Tsai, H.C., Sudjono, E.: Conceptual cost estimates using evolutionary fuzzy hybrid neural network for projects in construction industry, *Expert Syst. Appl.*, 37 (2010) 6, pp. 4224–4231, doi:10.3923/jai.2011.63.7510.1016/j.eswa.2009.11.080.
- [7] Kim, G., Shin, J., Kim, S., Shin, Y.: Comparison of school building construction costs estimation methods using regression analysis neural network, and support vector machine, *J. Build. Constr. Plan. Res.*, 1 (2013), pp.1–7, doi:10.4236/jbcpr.2013.11001.
- [8] Bostancioglu, E.: The factors that affecting residential buildings cost in pre-design phase and a cost estimating method that is based on these factors, Ph.D. Thesis. Istanbul Technical University, (1999)
- [9] Gunaydin, M.H., Dogan, Z.S.: A neural network approach for early cost estimation of structural systems of buildings, *Int. J. Proj. Manag.*, 22 (2004) 7, pp. 595–602, https://doi.org/10.1016/j.ijproman.2004.04.002.
- [10] Akinbingol, M., Gultekin, A.T.: A cost management model proposal for cost planning and supervision in building production construction, *Gazi University Journal of Engineering and Architecture Faculty*, 20 (2005), pp. 499–505.
- [11] Dogan, S.Z., Arditi, D., Gunaydin, H.M.: Determining attribute weights in a cbr model for early cost prediction of structural systems, *J. Constr. Eng. Manag.*, 132 (2006), pp. 1092–1098, https://doi.org/10.1061/(ASCE)0733-9364(2006)132:10(1092).
- [12] Nan, J., Choi, J.W., Choi, H., Kim, J.H.: A study on estimating construction cost of apartment housing projects using genetic algorithm support vector regression, *KJCEM*. 15 (2014), pp. 68–76.
- [13] Sonmez, R.: Range estimation of construction costs using neural networks with bootstrap prediction intervals, *Expert Syst. Appl.*, 38 (2011) 8, pp. 9913–9917, https://doi.org/10.1016/j.eswa.2011.02.042.
- [14] Arafa, M., Alqedra, M.A.: Early stage cost estimation of building construction projects using artificial neural networks, *J. Artificial Intell.*, 4 (2011) 1, pp. 63–75, doi:10.3923/jai.2011.63.75.
- [15] Kuruoglu, M., Yonez, E., Topkaya, E., Celik, L.Y.: Comparison of preliminary cost estimation methods used in the construction sector, *e-Journal New World Sci. Acad.*, 7 (2012), pp. 263–272.
- [16] Cho, H.G., Kim, K.G., Kim, J.Y., Kim, G.H.: A comparison of construction cost estimation using multiple regression analysis and neural network in elementary school project in the early stages of a construction project, *Journal of the Korea Institute of Building Construction*, 13 (2013) 1, pp. 66–74, doi:10.5345/KJIBC.2013.13.1.066.
- [17] Latief, Y., Wibowo, A., Isvara, W.: Preliminary cost estimation using regression analysis incorporated with adaptive neuro fuzzy inference system, *Int. J. Technol.*, 1 (2013), pp. 63–72.
- [18] El-sawalhi, N.I., Shehatto, O.: A neural network model for building construction projects cost estimating, *Journal of Construction Engineering and Project Management*, 4 (2014), pp. 9–16.
- [19] Bayram, S., Ocal, M.E., Oral, E.L., Atis, C.D.: Comparison of unit price method and unit area cost method for construction cost estimation, *Journal of Polytechnic*, 19 (2016), pp. 175–183.
- [20] Coloma, J.F., Valverde, L.R., García, M.: Estimation of construction costs of rustic homes through artificial neural networks, *Informes de la Construcción*, 71 (2019), pp. 554.
- [21] Dimitrijević, B., Stojadinović, Z., Marinković, D., Dimitrijević, M.: Influence of structural system on the construction time and cost of residential projects, *GRAĐEVINAR*, 71 (2019) 8, https://doi.org/10.14256/JCE.2315.2018
- [22] Naser, M.Z., Abu-Lebdeh, G., Hawileh, R.: Analysis of RC T-beams strengthened with CFRP plates under fire loading using ANN, *Construction and Building Materials* (2012), doi:10.1016/j.conbuildmat.2012.07.001
- [23] Leśniak, A., Juszczyk, M.: Prediction of site overhead costs with the use of artificial neural network based model, *Archives of Civil and Mechanical Engineering* (2018), doi.org/10.1016/j.acme.2018.01.014
- [24] TUIK, Construction Cost Index and Rate, 07 December 2019.
- [25] Naser, M.Z.: Deriving temperature-dependent material models for structural steel through artificial intelligence, *Construction and Building Materials* (2018), doi:10.1016/j.conbuildmat.2018.09.186.
- [26] Caglar, N.: Artificial neural networks in dynamic analysis of buildings, Ph.D. Thesis. Sakarya University. (2001).
- [27] Oztemel, E.: Artificial neural networks, Papatya Publisher, Istanbul, (2012).
- [28] Sagiroglu, S., Besdok, E., Erler, M.: Engineering artificial intelligence applications 1/ artificial neural networks, Ufuk Publisher, Istanbul, (2003).
- [29] Hamzacebi, C.: Artificial neural networks, Ekin Publisher, Bursa, (2011).
- [30] Eren, B., Turp, S.M.: Estimation of Nickel (II) Ion Removal Efficiency From Seepage Water With Artificial Neural Networks, *e-Journal of New World Sciences Academy*, 6 (2011), pp. 398–405.
- [31] Caglar, N.: Neural network based approach for determining the shear strength of circular reinforced concrete columns, *Construction and Building Materials*, (2009), doi:10.1016/j.conbuildmat.2009.06.002.
- [32] Ferreira, C.: Gene expression programming: a new adaptive algorithm for solving problems, *Complex Syst.*, 13 (2001), pp. 87–129.
- [33] Ferreira, C.: Function finding and the creation of numerical constants in gene expression programming, 7<sup>th</sup> Online World Conf. Soft Comput. Ind. Appl. Bristol, (2002).
- [34] Saridemir, M., Kara, I.F.: Estimation of the tensile strength of the fiber-reinforced concrete containing silica fume by GEP, *Journal of Nigde University Engineering Science* 5 (2016), pp. 208–217.
- [35] Kara, I.F.: Prediction of shear strength of frp-reinforced concrete beams without stirrups based on genetic programming, *Adv. Eng. Softw.*, 42 (2011), pp. 295–304.

- [36] Nazari, A., Riahi, S.: Prediction split tensile strength and water permeability of high strength concrete containing TiO<sub>2</sub> nanoparticles by artificial neural network and genetic programming, *Compos. Part B.*, 42 (2011), pp. 473–488.
- [37] Ferreira, C.: Genetic representation and genetic neutrality in gene expression programming, *Adv. Complex Syst.* 5 (2002), pp. 389–408.
- [38] Severcan, M.: Prediction of splitting tensile strength from the compressive strength of concrete using GEP, *Neural Comput. Appl.* 21 (2012), pp. 1937–1945.
- [39] Sette, S., Boullart, L.: Genetic programming: principles and applications, *Eng. Appl. Artif. Intell.*, 14 (2001), pp. 727–736.
- [40] Ferreria, C.: From GeneXproTools Documentation: a gepsoft web resource, (2017). [www.gepsoft.com/GeneXproTools/Regression.htm](http://www.gepsoft.com/GeneXproTools/Regression.htm)
- [41] Isci, O., Korukoglu, S.: An Application in genetic algorithm approach and steering research, *Management and Economics*, 10 (2003).
- [42] Gepsoft, GeneXproTools., [www.gepsoft.com](http://www.gepsoft.com), 10 May 2018.
- [43] Saridemir, M.: Genetic programming approach for prediction of compressive strength of concretes containing rice husk ash, *Constr. Build. Mater.*, 24 (2010), pp. 1911–1919.
- [44] Hadianfard, M.A., Jafari, S.: Prediction of lightweight aggregate concrete compressive strength using ultrasonic pulse velocity test through gene expression programming, *Scientia Iranica A*, 23, (2016), pp. 2506–2513.
- [45] Scherer, R.J., Schapke, S.E.: A distributed multi-model-based management information system for simulation and decision-making on construction projects, *Advanced Engineering Informatics* (2011), doi:10.1016/j.aei.2011.08.007.
- [46] EKAP. Republic of Turkey Electronic Public Procurement Platform Official Website, 07 December 2019.
- [47] Lewis, C.D.: *Industrial and business forecasting methods*. London: Butterworths, 1982.
- [48] Oberlender, G.D.: *Project Management for Engineering and Construction*, McGraw-Hill, Inc., 1993.
- [49] Enshassi, A., Mohamed, S., Madi, I.: Cost estimation practice in the Gaza Strip: A case study, *The Islamic University Journal*, 15 (2007), pp. 153–176.
- [50] Kim, G.-H., An, S.-H., Kang, K.I.: Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning, *Building and Environment*, 39 (10) (2004), pp. 1235–1242.
- [51] Khamis, A., Ismail, Z., Haron, K., Mohammed, A.T.: The effects of outliers data on neural network performance, *Journal of Applied Science*, 5 (2005) 8, pp. 1394–1398.