

Primljen / Received: 8.11.2017.

Ispravljen / Corrected: 19.3.2018.

Prihvaćen / Accepted: 30.5.2018.

Dostupno online / Available online: 10.10.2018.

Ocjena mogućnosti recikliranja pomoću metoda ANN i SVM

Autors:



¹Aleksandra Vujkov, dipl.ing.građ.
vujkova@uns.ac.rs



¹Dragana Bibić, dipl.ing.građ.
draganabibic@uns.ac.rs



¹Doc.dr.sc. Igor Peško, dipl.ing.građ.
igorbp@uns.ac.rs



¹Doc.dr.sc. Vladimir Mučenski, dipl.ing.građ.
mucenskiv@uns.ac.rs



¹Prof.dr.sc. Jasmina Dražić, dipl.ing.građ.
dramina@uns.ac.rs



¹Prof.dr.sc. Milan Trivunić, dipl.ing.građ.
trule@uns.ac.rs

¹Sveučilište u Novom Sadu
Fakultet tehničkih znanosti
Odjel za građevinarstvo i geodeziju

Prethodno priopćenje

[Aleksandra Vujkov, Dragana Bibić, Igor Peško, Vladimir Mučenski, Jasmina Dražić, Milan Trivunić](#)

Ocjena mogućnosti recikliranja pomoću metoda ANN i SVM

U ovom je radu prikazana analiza količina betona i armature koje se mogu reciklirati iz stambenih zgrada sa skeletnim konstrukcijama. Kako bi se procijenile količine tih materijala, izrađeni su modeli bazirani na umjetnoj inteligenciji, pri čemu su korištene metode ANN (umjetne neuronske mreže) i SVM (metoda potpornih vektora). Rezultati pokazuju da se primjenom metoda ANN i SVM postižu dobra rješenja za procjenu mogućnosti recikliranja. Srednja apsolutna postotna pogreška (MAPE) mreža ANN odabranih za predviđanje količine betona i armature iznosi 8,74 % za beton i 12,58 % za armaturu.

Ključne riječi:

zgrade, recikliranje, beton, armatura, umjetne neuronske mreže, metoda potpornih vektora

Preliminary report

[Aleksandra Vujkov, Dragana Bibić, Igor Peško, Vladimir Mučenski, Jasmina Dražić, Milan Trivunić](#)

Estimation of recycling capacity using ANN and SVM

This paper presents estimation of the quantity of concrete and reinforcement that can be recycled for residential buildings constructed as skeleton structures. Models based on artificial intelligence, involving the use of Artificial Neural Networks (ANNs) and the Support Vector Machines (SVM) methods, were formed in order to estimate quantities of these materials. The results show that the application of ANNs and SVM methods is a good solution for the estimation of recycling capacity. The mean absolute percentage error (MAPE) for the selected ANNs for predicting quantity of concrete and reinforcement is 8.74 % and 12.58 %, respectively.

Key words:

buildings, recycling, concrete, reinforcement, artificial neural networks, support vector machine method

Vorherige Mitteilung

[Aleksandra Vujkov, Dragana Bibić, Igor Peško, Vladimir Mučenski, Jasmina Dražić, Milan Trivunić](#)

Beurteilung der Recyclingfähigkeit mithilfe der KNN und SVM-Methoden

In dieser Abhandlung wird die Analyse der Menge an Beton und Bewehrung von Wohngebäuden mit einer Skelettkonstruktion dargelegt, die wiederverwertet werden kann. Um die Menge dieser Materialien einzuschätzen, wurden Modelle angefertigt, die sich auf künstlicher Intelligenz begründen, wobei die KNN- (künstliches neuronales Netzwerk) und die SVM (Stützvektormethode) Methoden angewendet wurden. Die Ergebnisse zeigen, dass durch Anwendung der KNN- und der SVM-Methoden gute Lösungen für die Einschätzung der Recyclingfähigkeit erzielt werden. Der mittlere absolute prozentuale Fehler (MAPE) der für die Vorhersage der Beton- und Bewehrungsmenge ausgewählten Netze des KNN beträgt 8,74 % für den Beton, d. h. 12,58 % für die Bewehrung.

Schlüsselwörter:

Gebäude, Wiederverwertung, Beton, Bewehrung, künstliche neuronale Netzwerke, Stützvektormethode

1. Uvod

Zgrada koja nastaje kao rezultat građevinskog projekta ima svoj vijek trajanja koji počinje s iskazivanjem potrebe za njenim izvođenjem, a završava kada zgrada više nije potrebna i ne može se iskoristiti za neku drugu namjenu, tj. kada se treba srušiti. Uklanjanjem zgrada na kraju njihovog vijeka trajanja dobivaju se velike količine materijala koji bi se mogao barem donekle iskoristiti. Definiranje načina koji bi omogućili lako i jednostavno korištenje materijala koji se generira u postupku rušenja zgrade ima cilj smanjiti tj. potpuno eliminirati troškove uklanjanja građevine. Sve veći troškovi odlaganja otpada, te rastuća svijest o potrebi očuvanja okoliša, doveli su do značajnog porasta u primjeni recikliranih materijala u građevinarstvu. Razni se materijali mogu dobiti tijekom rušenja, što svakako ovisi o vrsti građevine čije se rušenje planira. S obzirom na činjenicu da u Republici Srbiji sada postoji 22.272.500 kvadratna metra stanova koji su stariji od 70 godina, tj. 74.053.973 kvadratnih metara stanova starijih od 45 godina, nije teško zaključiti da u Srbiji postoje značajni potencijali za recikliranje građevnih materijala [1].

Ponovnom upotreboom materijala dobivenih u postupku rušenja postojećih armiranobetonskih građevina, a nakon odgovarajuće pripreme i obrade, u velikoj se mjeri umanjuje potreba za odlaganjem golemih količina materijala. Korištenje materijala dobivenih u postupku recikliranja može dovesti do smanjenja troškova novih građevinskih procesa jer će trebati manje količine novih materijala i bit će niži troškovi odlaganja staroga [2]. Stoga se može reći da procjena količine materijala pogodnih za recikliranje - u našem slučaju procjena količine betona i armature - radi njihove uporabljivosti u izvođenju novih građevina, svakako predstavlja korak u dobrom smjeru.

Međutim, postupak ocjenjivanja količina betona i armature koje ostaju nakon rušenja postojećih građevina nije uvijek jednostavan. Tome je često razlog nedostatak projektne dokumentacije što uvelike otežava procjenu dostupnih količina betona i armature. Razvoj jednostavnih modela za ocjenjivanje smanjuje utjecaj vizualnog pregledavanja projekata, tj. utjecaj podataka koji nisu dostupni. Jeden od načina na koji se mogu uspostaviti takvi modeli jest primjena umjetne inteligencije.

U građevinskoj se industriji umjetna inteligencija može primjeniti u svim stadijima građevinskih projekata, tj. već od najranijih faza planiranja i projektiranja, pa do recikliranja građevnih materijala nakon rušenja građevine. Modeli bazirani na umjetnoj inteligenciji mogu se koristiti za brzu i jednostavnu procjenu količina betona i armature koje se mogu reciklirati, u slučajevima kada projektna i tehnička dokumentacija građevine koja će se rušiti nije dostupna.

Osnovni preduvjet za izradu modela utemeljenog na umjetnoj inteligenciji je priprema odgovarajuće baze podataka kako bi procjena na osnovi modela bila što preciznija [3]. U ovom se radu daje pregled stanja u ovom području te analiza primjene umjetne inteligencije u rješavanju sličnih problema. Analizira se i baza podataka posebno uspostavljena za rješavanje ovog problema,

te se opisuje primjena metode ANN - umjetne neuronske mreže (eng. *Artificial Neural Networks* - ANN) i metode SVM - metoda potpornih vektora (eng. *Support Vector Machines* - SVM) za procjenu mogućnosti recikliranja stambenih zgrada koje se zbog dotrajalosti namjerava rušiti. Osnovni je cilj ovog istraživanja analizirati umjetnu inteligenciju, tj. mogućnosti koje ona nudi kao podrška postupku upravljanja građevinskim otpadom. Osnovna je hipoteza da se modeli ANN i SVM mogu koristiti za dovoljno točno procjenjivanje količina, čime bi se smanjio utjecaj građevinskog projekta na postupak planiranja upravljanja građevinskim otpadom.

2. Pregled literature

Danas se metode ANN i SVM najčešće koriste kao alati za rješavanje problema regresije i klasifikacije kroz promjenu parametara koji kontroliraju njihov postupak učenja. Smatra se da početak razvoja neuronskih mreža obilježava 1943. godinu, kada je objavljen članak Warrena McCullocha i Waltera Pittsa pod nazivom "Logičko računanje ideja tipičnih za neuronsku aktivnost". Velik doprinos razvoju umjetnih neuronskih mreža pružila je i Američka vojna agencija DARPA (Istraživački projekti za poboljšanje obrane) kroz zanimanje koje je iskazala za to područje [4]. Metodu SVM izradio je Vladimir V. Vapnik [5] 1995. godine, i ona je u početku uglavnom služila za rješavanje klasifikacijskih problema. Međutim, u novije se vrijeme ta metoda proširila tako da sada obuhvaća i rješavanje regresijskih problema. SVM je metoda za učenje i definiranje funkcije odjeljivanja u klasifikacijskim problemima, tj. za predviđanja u problemima regresije. Ovaj se pristup temelji na teoriji SLT (statistička teorija učenja) koju su potkraj dvadesetog stoljeća razvili Vapnik i Chervonenkis [6].

Ginaydin i Gibson [7] analizirali su modele bazirane na metodi ANN kod kojih su izlazni podaci, tj. troškovi građevine, formirani na bazi kvadratnog metra građevinskog prostora. Analizirano je trideset građevina od prednapregnutog betona, a točnost predviđanja iznosila je 7 %. Lazarevska i dr. [8] prikazali su primjenu neuronskih mreža u rješavanju složenih građevinskih problema, naročito u određivanju protupožarne otpornosti konstrukcijskih elemenata. Oni su izradili prognozni model za definiranje protupožarne otpornosti AB stupova ugrađenih u zidove i izloženih standardnom požaru s jedne strane. Baza podataka uključivala je 398 slučajeva, a podijeljena je na dvije skupine: podaci o učenju – 318 slučajeva i podaci o ispitivanju – 80 slučajeva. Oni su usporedili izračunane (stvarne) i predviđene krivulje otpornosti na požar za ekscentrično opterećeni AB stup. Zaključeno je da postoji dobra podudarnost između tih krivulja i odgovarajućih rezultata. U svom istraživanju, Lazarevska i dr. [9] prikazali su primjenu umjetne neuronske mreže i predložili model za određivanje protupožarne otpornosti centralno opterećenih spregnutih stupova sastavljenih od betona i čelika. Analizom je obuhvaćeno 87 slučajeva, od čega je 70 odabранo za učenje pomoći neuronskih mreža, a 17 za ispitivanje točnosti predviđanja. Uspoređivanjem predviđanja dobivenih pomoći modela ANN i stvarnih vrijednosti uočene su manje pogreške.

Mučenski i dr. [10] objavili su rad o procjeni mogućnosti recikliranja betona i rebraste armature stambenih zgrada sa skeletnom konstrukcijom. 95 projekata uključeno je u nizu za učenje (termin je korišten i u prethodnim primjerima), s devet ulaznih i dva izlazna podatka. Modeli su bili utemeljeni na metodi ANN, a korišten je računalni program Matlab. Primijenjena je normalizacija podataka pomoći z-vrijednosti. Rezultirajući postotak pogreške i stvarna vrijednost postignuta u ovom radu iznosi je 9,10 %. Peško [3] je primjenom neuronskih mreža predložio model za procjenu troškova i vremena potrebnog za izgradnju cestovnih prometnika u urbanim područjima. U bazu podataka uključio je 130 tekućih i već izvedenih projekata nove gradnje tj. rekonstrukcije urbanih cestovnih prometnika. Podaci su podijeljeni u dvije skupine: podaci za učenje (115 primjera) i podaci za ispitivanje (15 primjera), a primijenjena je metoda pseudo-nasumičnog uzorkovanja. Normalizacija podataka provedena je normalizacijom na temelju z-vrijednosti. Vrijednost MAPE za model kojim je postignut najbolji rezultat iznosi je 7,93 % za troškove tj. 5,87 % za vrijeme građenja.

Kim i dr. [11] objavili su studiju o procjeni troškova na temelju tri modela. Studija uključuje i odgovarajuću usporednu analizu. Spomenuti modeli su bazirani na višestrukoj regresijskoj analizi (MRA), umjetnim neuronskim mrežama (ANN) i rasuđivanju temeljenom na slučajevima (CBR). Analizom je obuhvaćeno 530 stambenih zgrada izgrađenih u razdoblju od 1997. do 2000. godine u Seulu. Točnost modela procijenjena je na temelju apsolutne pogreške. Najbolje predviđanje provedeno je pomoći metode MRA. Međutim, nedostatak te metode u usporedbi s modelom CBR sastojao se u sporosti postupka MRA za traženje optimalne mreže primjenom iterativnog postupka. Sonmez [12] je u razdoblju od 1975. do 1995. godine izradio okvirnu procjenu projekata zgrada u SAD-u. Usporedio je pritom modele temeljene na regresijskoj analizi i metodi ANN. Provjera je obavljena na temelju kvadratne pogreške i apsolutne pogreške. Uz to su prikazane prednosti i nedostaci tih modela. Autor je također komentirao mogućnost istovremene uporabe tih dva modela, što podrazumijeva njihovo kombinirano korištenje. Wang i Gibson [13] analizirali su dvije vrste modela za predviđanje uspješnosti raznih projekata. Prvi se model temeljio na jednostavnoj linearnoj regresiji, a drugi na umjetnim neuronskim mrežama. Analiza njihovog modela pokazala je da se bolje ponašaju projekti za koje je u početnoj fazi obavljeno prikladno planiranje.

Cheng i Wu [14] povezali su dva pristupa umjetnoj inteligenciji (brzi genetski algoritam – fmGA i SVM) u svrhu rješavanja problema u području organizacije građenja. Novi model nosi naziv ESIM (evolucijski model zaključivanja pomoći potpornih vektora, eng. *evolutionary support vector machine inference model*). Model je razvijen kako bi se postigla što manja pogreška u predviđanju te istovremeno odredili optimalni parametri C i Y (parametri razmjerne i kernela). Na bazi analize i postignutih rezultata autori su zaključili da bi se model ESIM mogao koristiti za rješavanje različitih problema u području organizacije građenja. Strobbe i dr. [15] analizirali su mogućnost učenja arhitektonskog stila na temelju niza slučajeva, te mogućnost klasificiranja novih stilova u slične ili različite stilove (projekte) na temelju analize slučajeva. Za to su korištene dvije

metode (SVM i jezgrena funkcija nad grafovima). Osim toga, autori su dokazali primjenjivost predložene identifikacijske metode na primjeru stambenog projekta Malagueira u Portugalu. Zaključili su da se njihov model, s obzirom na postignutu točnost od 87,5 %, može koristiti za generalizaciju stilova koji nisu uzeti u obzir u postupku učenja. Cheng i dr. [16] predložili su model EFSIMT (evolucijski model s neizrazitim zaključivanjem pomoći potpornih vektora za podatke u određenom vremenskom nizu) u svrhu predviđanja betona HPC (betona visokih uporabnih svojstava). Model EFSIMT razvijen je povezivanjem nekoliko metoda: FL (neizrazita logika), wSVM (ponderirana metoda potpornih vektora) i fmGA (brzi neuredni genetski algoritmi). Baza podataka sastojala se od 1030 uzoraka betona, a podaci su podijeljeni u dvije skupine:

- podaci za učenje – 90 % tj. 927 uzoraka
- podaci za ispitivanje – 10 % ili 103 uzorka.

Autori su usporedili rezultate dobivene modelom EFSIMT s rezultatima modela SVM i BNP, koje su prije objavili drugi autori. Ustanovljeno je da su u predviđanju visokih uporabnih svojstava bolji rezultati postignuti modelom EFSIMT u usporedbi s modelima SVM i BPN. Zaključeno je da je EFSIMT prikladno sredstvo za definiranje čvrstoće betona HPC (eng. *High Performance Concrete - HPC*). Zhang i dr. [17] predvidjeli su uspješnost građevinskih poduzeća u Kini pomoći metode PCA (analiza glavnih komponenata, eng. *Principal Component Analysis - PCA*) i metode SVM. Primjenom metode PCA, autori su dobili indeks ("kompozitni indeks") te su zatim na temelju tog indeksa predvidjeli uspješnost pomoći metode SVM. Rezultati pokazuju da se dobro izgrađen model SVM može koristi za predviđanje uspješnosti uz točnost veću od 80 %. Cheng i dr. [18] su predvidjeli uspješnost građevinskih projekata pomoći modela ESIM (evolucijski model zaključivanja pomoći potpornih vektora). Metoda ESIM zapravo je kombinacija dviju metoda: SVM i fmGA. U istraživanju je također primijenjen postupak CAPP (kontinuirano ocjenjivanje uspješnosti projekata) kako bi se odredili faktori koji bitno utječu na uspjeh projekta. U bazu podataka uvršteno je 46 građevinskih projekata. Autori su zaključili da se metodom ESIM postižu dobri rezultati u predviđanju uspješnosti projekata. Primjenom postupaka ANN i SVM, Wang i dr. [19] predvidjeli su troškove i vrijeme građenja, tj. utvrdili su na koji način pravodobno planiranje građevinskih radova utječe na uspjeh projekta. Njihova baza podataka sadržavala je 92 valjana uzorka (projekta) za razdoblje od 2007. do 2010. god, što je predstavljalo ukupan trošak građenja otprilike od 1,1 milijardu dolara. Prikupljeni podaci su korišteni za izradu i ispitivanje niza neuronskih mreža i SVM modela. Podaci su podijeljeni u dvije skupine: 67 primjera za učenje i 25 primjera za ispitivanje. Usporedbom rezultata autori su zaključili da se primjenom SVM modela postiže točnost predviđanja od 92 %, dok točnost predviđanja iznosi samo 80 % za prognozu uspješnosti vremenskog plana uz primjenu metode ANN (adaptivno učenje pomoći neuronskih mreža). Analizom relevantne literature nisu pronađena istraživanja koja se odnose na primjenu metoda ANN i SVM za ocjenjivanje količine građevnih materijala (betona i armature) potrebnih za gradnju, recikliranje itd.

3. Predložena metodologija

Za istraživanje je bilo potrebno prikupiti podatke o količinama materijala skeletnih građevina, što je provedeno preuzimanjem tih informacija iz projekata za građevinsku dozvolu. Na temelju tih podataka formirani su modeli ANN i SVM. Ključni dio svake analize koja uključuje primjenu umjetne inteligencije jest baza podataka, a ona se treba pripremiti na odgovarajući način. Iako je za formiranje dobrog modela potrebno pripremiti odgovarajuću bazu podataka, to ipak nije dovoljno jer dobar model treba imati odgovarajuće sposobnosti generaliziranja. Modeli su formirani na temelju devet ulaznih parametara koji opisuju karakteristike zgrade, te na temelju dva izlazna parametra, a to su količina betona i količina armature. Izrađeni su modeli ANN i SVM te su odabrani modeli za koje je utvrđena najniža vrijednost MAPE i to pomoću iterativnog postupka primjenom programa STATISTICA 8 [20]. U prethodnom je istraživanju [22] formirano 25 modela ANN za ocjenjivanje količine betona i armature za slučaj s dva izlazna podatka [21] te 5 modela SVM za ocjenjivanje količine betona. U oba slučaja je za pripremanje podataka provedena normalizacija pomoću z-vrijednosti.

Kako bi se proširio obuhvat istraživanja prikazanog u nastavku rada, za pripremu podataka korištena je još jedna vrsta minimalno-maksimalne normalizacije, a korišteni su i podaci koji nisu bili normalizirani. Osim toga, formirano je 120 modела ANN što je omogućilo zasebno ocjenjivanje betona i armature. Trideset modela pripremljeno je pomoću metode SVM kako bi se procijenila količina betona i armature. Na kraju testirana preciznost modela koji su dali najprihvatljiviju razinu pogreške i napravljena je usporedna analiza modela ANN i SVM.

3.1. Baza podataka za modele ANN i SVM

Baza podataka sadržavala je informacije o karakteristikama i količinama analiziranih materijala sa stotinu projekata, tj. stambenih zgrada koje su smještene u Novom Sadu, u Republici Srbiji. Pritom je cilj bio izraditi model za procjenu količine betona i armature koja se nalazi u postojećim građevinama, tj. procijeniti količinu betona i armature koja bi bila pogodna za recikliranje (temeljne konstrukcije, stupovi, ukrutni zidovi, grede i podne konstrukcije).

Osnovna postavka pri definiranju baze podataka bila je da baza bude jednostavna ali ipak informativna, tj. da sadrži sve podatke koji su ključni za točnost modela. Podaci iz baze podataka koji su potrebni za formiranje modela ANN i SVM podijeljeni su u ulazne i izlazne. Parametri koji opisuju karakteristike zgrada iskazani su kao numeričke, geometrijske i konstruktivne informacije. Ulazni podaci odnose se prije svega na karakteristike zgrada koje su značajne za količine betona i armatura, a to su između ostalih: razvedenost tlocrta, ukupna bruto površina zgrade, prosječna bruto podna površina, visina zgrade, broj ukrutnih zidova, uzdužna i poprečna raspoloživa zgrada, vrsta katnih konstrukcija i vrsta nosive katne konstrukcije. Izlazni podaci su količina

betona i armature. Sve konstrukcije leže na temeljnoj ploči, pa je taj parametar usvojen kao konstantna vrijednost koja je jednaka za sve zgrade. Karakteristike temelja nisu analizirane u okviru ulaznih podataka. Iako manji broj zgrada ima drugačije temelje, odlučeno je da se ti podaci ne uzimaju u obzir zbog nedostatka informacija te zbog mogućih pogrešaka pri analizi pomoću modela ANN i SVM. U bazu podataka uključene su samo zgrade bez dilatacija ili zgrade sa samo jednom dilatacijom. Parametri odabrani za opisivanje karakteristika konstrukcije prikazani su u tablici 1. Oni uključuju geometrijske i konstruktivne karakteristike građevine.

Tablica 1. Opis ulaznih i izlaznih parametara zgrade za analizu pomoću metoda ANN i SVM

Vrsta podataka	Definicija	Vrijednost ili karakteristika iz projekta	Odgovarajuća vrijednost modela (vrijednost prije normalizacije)
Ulazni podaci	Razvedenost tlocrta	Jednostavna	1
		Srednje složena	2
		Složena	3
		Vrlo složena	4
	Ukupna bruto površina	od 1000 m ² do 8000 m ²	od 1000 m ² do 8000 m ²
	Prosječna bruto razvijena površina	od 200 m ² do 2000 m ²	od 200 m ² do 2000 m ²
	Visina zgrade	od 13 m do 27 m	od 13 m do 27 m
	Broj ukrutnih zidova	od 0 do 13	od 0 do 13
	Uzdužna i poprečna raspoloživa zgrada	1,00 m - 1,99 m 2,00 m - 2,99 m 3,00 m - 3,99 m 4,00 m - 4,99 m 5,00 m - 5,99 m 6,00 m - 6,99 m 7,00 m - 7,99 m	1 2 3 4 5 6 7
	Vrsta stropne konstrukcije	Puna AB ploča Polu montažni stropni sustav "FERT"	1 2
Izlazni podaci	Način potpore stropne konstrukcije	Izravna podupora Podupora gredama	1 2
	Količina betona	od 420 m ³ do 4500 m ³	od 420 m ³ do 4500 m ³
	Količina armature	od 28500 kg do 310000 kg	od 28500 kg do 310000 kg

Tablica 2. Minimalne i maksimalne vrijednosti podskupova za učenje, validaciju i ispitivanje

Vrsta		Podskup za učenje		Podskup za validaciju		Podskup za ispitivanje	
		Min.	Maks.	Min.	Maks.	Min.	Maks.
Ulažni podaci	Ukupna bruto površina [m ²]	1000	7500	1300	6800	1110	5500
	Prosječna bruto razvijena površina [m ²]	200	1500	280	1,300	250	1200
	Visina zgrade [m]	13	27	15	25	16	23
	Broj ukrutnih zidova [kom]	0	13	3	8	3	10
Izlazni podaci	Količina armature [kg]	28500	248000	42000	232000	31200	168000
	Količina betona [m ³]	420	3,800	620	3200	600	2600

Zgrade su podijeljene u četiri kategorije po složenosti. Zgrade koje ulaze u prvu kategoriju (građevine niske razine složenosti) odlikuju se pravokutnom osnovom i kod njih nema promjene u visini građevine; zgrade koje ulaze u drugu kategoriju (srednje složene građevine) također su u osnovi pravokutnog oblika ali se bilježe manje promjene u visini; složene zgrade koje ulaze u treću kategoriju odlikuju se nepravilnom tlocrtu, a vrlo složene zgrade su građevine složenog tlocrta s bitnim promjenama kod katnih konstrukcija. U četvrtu kategoriju ulaze atipične građevine koje nisu ni uvrštene u bazu podataka. Osnovni parametri koji izravno utječu na izlazne podatke su ukupna površina zgrade i podne površine. Pri definiranju površina, podaci o bruto površini uzeti su u fazi analiziranja karakteristika zgrade, kada je bilo teško ocijeniti neto površinu. Visina zgrade, kao jedan od parametara, izravno je povezana s ukupnom površinom zgrade pa na taj način utječe na izlazne podatke. Visina zgrada mjerena je od površine tla do najviše točke na zgradici. U aseizmičkom projektiraju i izvođenju skeletnog sustava očekuje se primjena ukrutnih zidova kako bi se što bolje amortizirao udar potresa. Ukrutni zidovi izvode se od armiranog betona, pa su zbog toga i uključeni u bazu podataka. Rasponi glavnih vertikalnih elemenata izravno su povezane s dimenzijama horizontalnih nosivih elemenata. Građevine s dvije vrste stropnih konstrukcija – puna armiranobetonska konstrukcija i polumontažna katna konstrukcija FERT – prikazane su u tablici 1. zajedno s dvije vrste nosivih katnih konstrukcija. One su uzete u obzir kod prikupljanja materijala za ovo istraživanje.

Za potrebe formiranja modela baziranog na umjetnoj inteligenciji, tj. u našem slučaju za primjenu metoda ANN i SVM, čitava se baza podataka treba podijeliti u dva podskupa a to su: podaci za učenje i podaci za ispitivanje. Osim toga, u podskup za učenje uključene su i ekstremne (najviše i najniže) vrijednosti svih parametara (ulaznih i izlaznih). Tako je proširen obuhvat novoformiranog modela, čime je postignuta viša razina točnosti u postupku procjenjivanja. Uz to, svi projekti koji ne ulaze u okvir definiran za bazu podataka, tj. projekti kod kojih su zabilježene ekstremne vrijednosti bitno različite od uobičajenih veličina, nisu uključeni u daljnju analizu. Zbog toga je i odbačena, tj. isključena iz analize, zgrada koja ima najveću površinu (9500 m²).

Podaci koji ulaze u podskup podataka za učenje i u podskup podataka za ispitivanje nisu definirani nasumice. Naime, u

kontekstu baze podataka sastavljene od 99 zgrada (nakon izbacivanja projekta s najvećom površinom), vrijednost izlaznih parametara podijeljena je na osam intervala za beton (od 0 do 499, od 500 do 999, od 1000 do 1499, od 1500 do 1999, od 2000 do 2499, od 2500 do 2999, od 3000 do 3499, i od 3500 do 3999) i na devet intervala za armaturu (od 25000 do 49999, od 50000 do 74999, od 75000 do 99999, od 100000 do 124999, od 125000 do 149999, od 150000 do 174999, od 175000 do 199999, od 200000 do 224999 i od 225000 do 249999). Nakon izračuna, baza je podijeljena na podatke za učenje i podatke za ispitivanje, ali uz uvjet da struktura jednog podskupa odgovara strukturi drugog i obratno. Kako je gore opisano, odabran je deset projekata i ti projekti čine podskup za ispitivanje. Drugim riječima, u podskup s podacima za učenje uvršteno je preostalih 89 projekata.

Pri odabiru podataka, pazilo se da podaci koji se odnose na materijale budu usklađeni, tj. da odabrani projekti s količinama betona i armature ulaze u interval s najvećim brojem ponavljanja. Tijekom odabira uzoraka za ispitivanje, u obzir se nisu uzimale ekstremne tj. minimalne i maksimalne vrijednosti, kako bi se omogućilo što preciznije predviđanje količina materijala. Uz spomenute podjele, za potrebe formiranja modela ANN odabran je u okviru definirane baze za učenje još jedan podskup od 10 uzoraka (kako bi se izbjegla prevelika podudarnost u mreži). Taj spomenuti podskup je zapravo podskup za unakrsnu validaciju, a uzorci su odabrani prema istom načelu kao i za podskup za ispitivanje. Minimalne i maksimalne vrijednosti podskupova za učenje, validaciju i ispitivanje prikazane su u tablici 2.

S obzirom na ulazne podatke, njihove karakteristike i razlike u redu veličine, poduzete su odgovarajuće mjere u svrhu pripreme podataka za njihovo pravilno korištenje. Za potrebe formiranja modela, podaci su normalizirani kako bi se sveli na isti red veličine. Ta je normalizacija provedena pomoći z-vrijednosti (transformacija podataka u granicama -1 do 1) i min-max normalizacijom (transformacija podataka u granicama od 0 do 1) [23]. Normalizacija je provedena za ulazne i izlazne podatke podskupa za učenje, a također i za ulazne podatke podskupa za ispitivanje. Nakon definiranja modela, proveden je obrnuti postupak (normalizirani podaci su vraćeni na početne vrijednosti) kako bi se omogućila usporedba s očekivanim vrijednostima.

Nakon što je završena priprema baze podataka, uslijedila je aktivnost formiranja modela. Za te je potrebe korišten program Statistica 8 koji omogućuje obradu podataka primjenom metoda ANN i SVM.

3.2. Izrada modela ANN

Umetne neuronske mreže izrađene pomoću programa Statistica 8 omogućuju da se jedan ili više parametara odabere kao izlazni podatak, što je vrlo korisna mogućnost koja nije predviđena u drugim oblicima umjetne inteligencije. Jedan model može predviđati količinu nekoliko različitih materijala. Mreže koje omogućuju procjenu za samo jedan izlazni podatak (beton ili armaturu) formirane su za potrebe ovog istraživanja te da bi se osigurala usporedivost podataka s metodom SVM. Izrađenje najprikladnijeg modela mreže umjetne inteligencije iterativan je postupak koji je proveden u nekoliko faza.

U prvoj fazi izrade modela u program su pohranjeni normalizirani podaci, te su uzorci raspoređeni u tri različita podskupa – učenje, validacija i ispitivanje, kao što je već navedeno u prethodnom poglavljaju. Uzne vrijednosti (devet parametara prikazanih u tablici 1.) i izlazne vrijednosti (količina betona i količina armature) definirane su u drugoj fazi.

Raspored skrivenih i izlaznih neurona, te vrsta neuronske mreže, definirani su u trećoj fazi koja je zapravo i najznačajnija za izradu modela ANN. Mreža tipa MLP (višeslojni perceptron) korištena je za potrebe ovog istraživanja. Osim što se koristi za rješavanje klasifikacijskih problema, mreža MLP također se primjenjuje i za regresijske analize [24].

Aktivacijske funkcije skrivenih i izlaznih neurona postavljene su u četvrtoj fazi. Što se tiče aktivacijskih funkcija za skrivenе neurone, jednopolarne i bipolarne sigmoidne funkcije predstavljaju funkcije koje se najčešće koriste za rješavanje ove vrste problema [25]. Prema tome, logistička aktivacijska funkcija i hiperbolički tangens služe za skrivenе neurone, a aktivacijska funkcija identiteta za izlazne neurone.

Osim spomenutih funkcija koje su odabrane u ranijim iteracijama, program omogućuje oblikovanje mreža tako da on sam odabere najbolje aktivacijske funkcije iz velikog broja ponuđenih funkcija, što je zadnja faza u formiranju modela. Aktivacijske funkcije modela ANN koje omogućuju najbolje predviđanje prikazane su u tablici 3.

Tablica 3. Aktivacijske funkcije modela ANN

Funkcija	Oblik funkcije
Identitet	a
Eksponencijalna	e^a
Logistička	$\frac{1}{1+e^{-a}}$
Hiperbolički tangens	$\frac{e^a - e^{-a}}{e^a + e^{-a}}$

Svaka iteracija za oblikovanje umjetne neuronske mreže uključuje postavljanje broja mreža za učenje koji varira od 50 do 5000 isto kao i broja mreža od kojih se u obzir uzima samo prvorangirana mreža od spomenutih 50 do 5000.

Za procjenu količine betona oblikovano je šezdeset modela, a isti je broj modela oblikovan i za procjenu količine armature. Ti su modeli dobiveni analiziranjem i obradom stvarnih podataka (bez normalizacije) isto kao i obradom podataka normaliziranjem pomoću z-vrijednosti i vrijednosti min-max. Dobivene izlazne vrijednosti uspoređene su s podskupom za ispitivanje, a u rezultatima su prikazani modeli pomoći kojih su postignuta najtočnija predviđanja. Usporedna analiza provedena je na temelju vrijednosti APE (apsolutna postotna pogreška, eng. *absolute percentage error* - APE) i MAPE (srednja apsolutna postotna pogreška, eng. *mean absolute percentage error* - MAPE).

3.3. Izrada modela SVM

Prvi korak u formiranju modela SVM sastoji se u definiranju baze podataka i u podjeli podataka na ulazne i izlazne podatke, kao što je i objašnjeno u prethodnoj točki. Nakon odgovarajuće pripreme baze podataka, pokrenuta je aktivnost formiranja modela. Nakon definiranja podskupa za učenje i validaciju, program nudi odabir jedne od dviju funkcija pogreške (tablica 4.).

Tablica 4. Funkcija pogreške modela SVM

Funkcija	Oblik funkcije	Svođenje na minimum ovisno o
Tip 1	$\frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^*$	$w^T \phi(x_i) + b - y_i \leq \varepsilon + \xi_i$ $y_i - w^T \phi(x_i) - b \leq \varepsilon + \xi_i$ $\xi_i, \xi_i^* \geq 0, i = 1, N$
Tip 2	$\frac{1}{2} w^T w - C \left(v \varepsilon + \frac{1}{N} \sum_{i=1}^N (\xi_i + \xi_i^*) \right)$	$(w^T \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^*$ $y_i - (w^T \phi(x_i) - b) \leq \varepsilon + \xi_i$ $\xi_i, \xi_i^* \geq 0, i = 1, N, \varepsilon \geq 0$

Funkcija koja nosi naziv Tip 1 definirana je parametrima razmjene (C) i zone neosjetljivosti (ε), a funkcija Tip 2 definirana je parametrima razmjene (C) i Nu (v) – gornjom granicom frakcije pogrešaka i donjom granicom frakcije potpornih vektora [26]. Vrijednosti parametara C i ε variraju od 0 do ∞ , a vrijednost parametra v varira od 0 do 1. Također je definirana i jezgrena funkcija RBF u kojoj je parametar v varijabilan:

$$K(x_i, x_j) = \exp(-1/(2\sigma^2 \|x_i - x_j\|^2)), \quad \sigma - \text{devijacija funkcije RBF (Gauss)} \quad (1)$$

Na temelju unesenih podataka i odabira spomenutih parametara formiran je model učenja te je provedena naknadna validacija modela. Točnije, ispitana je preciznost generiranih podataka i podataka vraćenih u prvobitni oblik, tj. definirano je odstupanje od očekivanih vrijednosti. Usporedna analiza provedena je na temelju vrijednosti APE (apsolutna postotna pogreška) i MAPE (srednja apsolutna postotna pogreška).

Za procjenu količine materijala oblikovano je ukupno 30 modela, tj. formirano je 15 modela SVM kako bi se procjenile količine

betona, te 15 modela SVM kako bi se procijenile količine armature. Od 15 modela SVM za procjenu potrebne količine betona, 5 modela je dobiveno na temelju analize i obrade stvarnih vrijednosti, 5 modela je dobiveno iz normalizacije pomoću z-vrijednosti, a 5 modela je dobiveno pomoću min-max normalizacije. Isti je pristup primijenjen i za preostalih 15 modela SVM koji su odabrani za procjenu potrebne količine armature.

4. Rezultati i rasprava

U tablicama 5. i 6. daje se prikaz modela ANN kojima su postignuta najpreciznija predviđanja ciljnih količina materijala, kao i usporedni pregled rezultata po tipu normalizacije.

Potrebno je napomenuti da su od 12 odabranih modela ANN najbolji rezultati dobiveni pomoću mreže MLP 9-6-1, koja je sadržavala 6 skrivenih neurona i 9 ulaznih podataka formiranih na bazi normalizacije pomoću z-vrijednosti. Pogreška MAPE iznosila je 8,74 % za procjenu količine betona pomoću modela 5. Kao što se može vidjeti, za aktivacijsku funkciju Tanh koja se odnosi na skrivene neurone postignuti su rezultati koji su bolji od rezultata za eksponencijalnu funkciju. Zanimljivo je da je min-max normalizacija bila manje precizna od metode ANN s nepromijenjenim ulaznim podacima (bez normalizacije).

Kao što se može vidjeti u tablici 6., model 18 iskazuje najnižu pogrešku MAPE od 12,58 % za procjenu količine armature. Model MLP 9-13-1 ima 13 skrivenih neurona i 9 ulaza koji

Tablica 5. Vrijednost MAPE za modele ANN – procjena potrebne količine betona

Vrsta normalizacije	Model br.	Karakteristike mreže			Predviđanje vrijednosti MAPE za potrebnu količinu betona [%]
		Mreža	Aktivacijska funkcija za skrivene neurone	Aktivacijska funkcija za izlazne neurone	
min-max	Model 1	MLP 9-2-1	Tanh	Identitet	13,37
	Model 2	MLP 9-2-1	Tanh	Identitet	15,26
	Model 3	MLP 9-2-1	Tanh	Identitet	13,89
	Model 4	MLP 9-5-1	Eksponencijalna	Identitet	12,26
z-vrijednost	Model 5	MLP 9-6-1	Tanh	Identitet	8,74
	Model 6	MLP 9-3-1	Tanh	Identitet	11,30
	Model 7	MLP 9-2-1	Tanh	Identitet	14,50
	Model 8	MLP 9-2-1	Eksponencijalna	Eksponencijalna	11,25
Bez normalizacije	Model 9	MLP 9-4-1	Tanh	Identitet	10,20
	Model 10	MLP 9-1-1	Tanh	Identitet	14,25
	Model 11	MLP 9-2-1	Tanh	Identitet	14,87
	Model 12	MLP 9-2-1	Eksponencijalna	Identitet	12,05

Tablica 6. Vrijednost MAPE za modele ANN – procjena potrebne količine armature

Vrsta normalizacije	Model br.	Karakteristike mreže			Predviđanje vrijednosti MAPE za potrebnu količinu armature [%]
		Mreža	Aktivacijska funkcija za skrivene neurone	Aktivacijska funkcija za izlazne neurone	
min-max	Model 13	MLP 9-17-1	Tanh	Identitet	15,94
	Model 14	MLP 9-12-1	Tanh	Identitet	21,41
	Model 15	MLP 9-17-1	Tanh	Identitet	19,08
	Model 16	MLP 9-14-1	Eksponencijalna	Logistička	19,98
z-vrijednost	Model 17	MLP 9-16-1	Tanh	Identitet	15,26
	Model 18	MLP 9-13-1	Tanh	Identitet	12,58
	Model 19	MLP 9-13-1	Tanh	Identitet	14,45
	Model 20	MLP 9-10-1	Eksponencijalna	Identitet	15,29
Bez normalizacije	Model 21	MLP 9-2-1	Tanh	Identitet	14,71
	Model 22	MLP 9-2-1	Tanh	Identitet	14,65
	Model 23	MLP 9-2-1	Tanh	Identitet	12,97
	Model 24	MLP 9-2-1	Eksponencijalna	Identitet	14,57

su formirani na bazi normalizacije pomoću z-vrijednosti. Još jednom je normalizacijom pomoću z-vrijednosti postignuta najviša razina točnosti, dok je min-max normalizacijom postignuta najniža točnost. Općenito uzevši, može se zaključiti da se metodom ANN postižu bolji rezultati kada se predviđa količina betona. To bi se možda moglo objasniti nižom razlikom u projektiranim vrijednostima za količine betona. Projektanti stambenih zgrada obično imaju vrlo veliko iskustvo i mogu bez poteškoća predvidjeti dimenzije elemenata. S druge strane, količina armature najviše ovisi o parametrima opterećenja a

iskazuje se na temelju odgovarajućeg računalnog programa za projektiranje konstrukcija. U tom postupku veliku ulogu obično imaju i dimenzije elemenata. Međutim, već i male promjene u dimenzijama betonskih elemenata mogu bitno utjecati na potrebne količine armature.

Nakon analize točnosti metode ANN, isti je eksperiment proveden za SVM. Kako bi usporedba bila valjana, iste su normalizacije korištene zasebno za beton i armaturu. Pogreška MAPE za svih trideset modela SVM iskazana je posebno za beton, a posebno za armaturu u tablicama 7. i 8.

Tablica 7. Vrijednost MAPE za modele SVM – procjena potrebne količine betona

Vrsta normalizacije	Model br.	C	ϵ	v	y	Pogreška MAPE u predviđanju količine betona [%]
min-max	Model 1	10	0,7	-	0,1	9,30
	Model 2	10	0,1	-	0,05	9,75
	Model 3	10	0,1	-	0,07	9,31
	Model 4	10	-	0,5	0,01	12,63
	Model 5	20	-	0,7	0,01	13,38
z-vrijednost	Model 6	10	0,1	-	0,1	9,28
	Model 7	10	0,1	-	0,05	9,75
	Model 8	10	0,1	-	0,07	9,32
	Model 9	10	-	0,5	0,01	12,64
	Model 10	20	-	0,7	0,01	13,40
Bez normalizacije	Model 11	10	0,1	-	0,1	9,29
	Model 12	10	0,1	-	0,05	9,75
	Model 13	10	0,001	-	0,05	12,22
	Model 14	10	0,1	-	0,07	9,32
	Model 15	20	-	0,7	0,01	13,40

Tablica 8. Vrijednost MAPE za modele SVM – procjena potrebne količine armature

Vrsta normalizacije	Model br.	C	ϵ	v	y	Pogreška MAPE u predviđanju količine armature [%]
min-max	Model 16	10	0,1	-	0,05	18,10
	Model 17	10	0,1	-	0,01	15,81
	Model 18	20	0,1	-	0,007	16,25
	Model 19	20	-	0,1	0,01	16,64
	Model 20	10	-	0,5	0,009	16,28
z-vrijednost	Model 21	10	0,1	-	0,01	15,82
	Model 22	20	0,1	-	0,007	16,25
	Model 23	15	-	0,5	0,03	19,08
	Model 24	20	-	0,1	0,01	16,66
	Model 25	10	-	0,5	0,009	16,29
Bez normalizacije	Model 26	10	0,1	-	0,05	18,10
	Model 27	10	0,1	-	0,01	15,81
	Model 28	20	0,1	-	0,007	16,27
	Model 29	20	-	0,1	0,01	16,66
	Model 30	10	-	0,5	0,009	16,28

Od 15 analiziranih modela za predviđanje količine betona, najbolji su rezultati dobiveni za model 6 gdje je zabilježena najmanja pogreška MAPE od 9,28 % te parametri $C = 10$, $\epsilon = 0,1$ i $\gamma = 1/(2\sigma) \cdot 2 = 0,1$ formirani u okviru normalizacije pomoću z-vrijednosti.

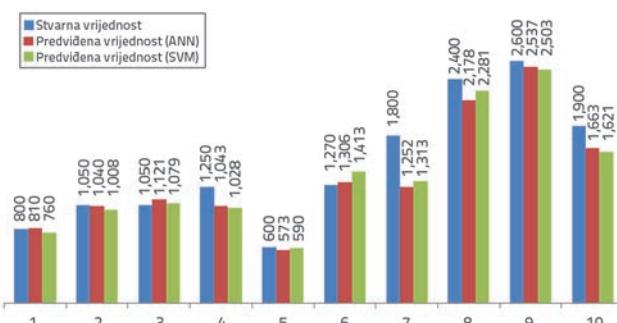
U predviđanju količine armature najbolji su rezultati postignuti primjenom modela 17 gdje je zabilježena pogreška MAPE od 15,81 % te parametri $C = 10$, $\epsilon = 0,1$ i $\gamma = 1/(2\sigma) \cdot 2 = 0,01$ formirani pomoću min-max normalizacije, te primjenom modela 27 kod kojeg je zabilježena ista vrijednost od 15,81 % te parametri $C = 10$, $\epsilon = 0,1$ i $\gamma = 1/(2\sigma) \cdot 2 = 0,01$ gdje podaci nisu normalizirani. Kod metode SVM zabilježena je veća stabilnost rezultata, tj. razlika između najboljeg i najgoreg rezultata bila je manja od odgovarajuće razlike zabilježene pri upotrebi metode ANN.

U tablici 9. prikazana je usporedba rezultata dobivenih primjenom modela ANN i SVM. Na temelju analize primjene metode ANN na nekom specifičnom problemu može se zaključiti da vrsta normalizacije može bitno utjecati na točnost metode ANN. Istovremeno je ustanovljeno da postupak normalizacije uopće ne utječe na metodu SVM.

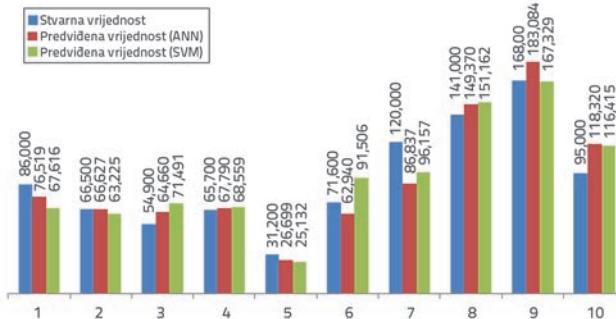
Tablica 9. Vrijednost MAPE za modele ANN i SVM – usporedni pregled

MAPE [%]	Vrsta normalizacije	ANN	SVM
Predviđanje količine betona	min-max	12,26	9,30
	z-vrijednost	8,74	9,28
	bez normalizacije	10,20	9,29
Predviđanje količine armature	min-max	15,94	15,81
	z-vrijednost	12,58	15,82
	bez normalizacije	12,97	15,81

Na temelju analize utjecaja normalizacije može se zaključiti da se najveći stupanj točnosti postiže normalizacijom pomoću z-vrijednosti. Metoda ANN pokazala se preciznijom u predviđanju količina betona i armature. Slike 1. i 2. prikazuju usporedbu između dobivenih (predviđenih) rezultata i stvarnih vrijednosti za beton i armaturu, i to za modele kojima se postiže najpovoljnija vrijednost MAPE.



Slika 1. Usporedba predviđenih i stvarnih vrijednosti količina betona za najbolje modele ANN i SVM



Slika 2. Usporedba predviđenih i stvarnih vrijednosti količina armature za najbolje modele ANN i SVM

5. Zaključak

U ovom je radu prikazana primjena metoda ANN i SVM za predviđanje količine betona i armature na temelju podataka sadržanih u bazi podataka sastavljenoj od 100 projekata. Formirano je nekoliko modela s različitim parametrima te su odabrani modeli s najtočnijim rezultatima. Modeli su formirani na bazi devet ulaznih parametara koji opisuju karakteristike zgrada, te na bazi dva izlazna parametra, a to su količina betona i količina armature. Sljedeći su parametri odabrani za izradu modela ANN: broj ulaznih i skrivenih neurona (od 1 do 20), vrsta aktivacijskih funkcija, broj mreža za učenje (od 50 do 5000) i vrsta mreže (MLP). Za izradu SVM modela odabrane su dvije vrste funkcija: Tip 1 u kojem su varirani parametri C i ϵ (od 0 do ∞) te Tip 2 u kojem su varirani parametri C i v (od 0 do 1).

U postupku procjene potrebne količine betona i armature na bazi ranijih podataka, najbolji su rezultati postignuti pomoću modela s najnižom srednjom apsolutnom pogreškom kod predviđanja. Za procjenu količina betona, vrijednost MAPE iznosila je 8,74 % za ANN model MLP 9-6-1 sa šest skrivenih neurona i devet ulaza formiranih na osnovi podataka normaliziranih pomoću z-vrijednosti. Za procjenu količina armature, vrijednost MAPE iznosila je 12,58 % za ANN model MLP 9-13-1 s 13 skrivenih neurona i 9 ulaza formiranih na osnovi podataka normaliziranih pomoću z-vrijednosti.

Nakon analize zaključeno je da je kod svih modela srednja apsolutna pogreška bila ispod 20 %, što je prihvatljivo za ovu vrstu problema, tj. za procjenu mogućnosti recikliranja stambenih višekatnica.

U okviru budućih istraživanja trebala bi se detaljnije analizirati struktura baze podataka, a u samu bazu bi se trebao uvesti veći broj parametara. Dodavanjem novih parametara znatno bi se poboljšala točnost rezultata o količinama betona i armature. Osim toga, mogao bi se analizirati utjecaj ulaznih podataka na točnost predviđanja, što bi moglo dovesti do smanjenja broja ulaznih podataka, uz eventualno poboljšanje razine točnosti za istu količinu podataka.

Analiza bi se također mogla proširiti uključivanjem drugih vrsta normalizacije u analizu povijesnih podataka, što bi moglo bitno utjecati na točnost rezultata. Iako se u ovom radu analiziraju armiranobetonski skeletni sustavi, to ne isključuje mogućnost proširenja analize na druge sustave kao što su nosive zidane građevine i montažni sustavi, isto kao i građevine izvedene od čelika i drva.

LITERATURA

- [1] Statistical Office of the Republic of Serbia, May (2017)
- [2] The Economic Benefits of Recycling and Waste Reduction – WasteWise Case Studies from the Private and Public Sectors, Case Study, New Jersey, (2015), <http://www.nj.gov/dep/dshw/recycling/wastewise/njwwcasestudy.pdf>, March (2018)
- [3] Peško, I., Trivunić, M., Ćirović, G., Mučenski, V.: A preliminary estimate of time and cost in urban road construction using neural networks, Technical Gazette, 20 (2013) 3, pp. 563-570
- [4] DARPA, Neural Network Study, Massachusetts Institute of Technology (MIT), Lincoln Laboratory, USA, (1988)
- [5] Vapnik, V., Golowich, S., and Smola, A.: Support vector method for function approximation, regression estimation and signal processing (eds. M. Mozer, M. Jordan, T. Petsche), Advances in Neural Information Processing Systems 9, Cambridge, MA, MIT Press, (1997), pp. 281-287
- [6] Vapnik, V.; The Nature of Statistical learning Theory, 2nd ed., Springer, New York, USA, (1999)
- [7] Gunaydin, M., Dogan, Z.: A neural network approach for early cost estimation of structural systems of buildings, International Journal of Project Management, 22 (2004) 7, pp. 595-602
- [8] Lazarevska, M., Knezevic, M., Cvetkovska, M., Trombeva-Gavriloska, A.: Application of artificial neural networks in civil engineering, Technical Gazette, 21 (2014) 6, pp. 1353-1359
- [9] Lazarevska, M., Cvetkovska, M., Gavriloska, A.T., Knežević, M., Milanović, M.: Neural-network-based approach for prediction of the fire resistance of centrally loaded composite columns, Technical Gazette, 23 (2016) 5, pp. 1475-1480
- [10] Mučenski, V., Trivunić, M., Ćirović, G., Peško, I., Dražić, J.: Estimation of recycling capacity of multi-storey buildings structures using artificial neural networks, Acta Polytechnica Hungarica, 10 (2013) 4, pp. 175-192
- [11] Kim, G., Yoon, J., An, S., Cho, H., Kang, K., 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 (2004) 10, pp. 1235-1242
- [12] Sonmez, R.: Conceptual cost estimation of building projects with regression analysis and neural networks, Can. J. Civ. Eng., 31 (2004), pp. 677-683
- [13] Wang, Y., Gibson, E.: A study of pre project planning and project success using ANN and regression models, Automation in Construction, 19 (2009) 3, pp. 341-346
- [14] Cheng, M., Wu, Y.: Evolutionary support vector machine inference system for construction management, Automation in Construction, 18 (2009) 5, pp. 597-604
- [15] Strobbe, T., Wyffels, F., Verstraeten, R., De Meyer, R., Campenhout, J.: Automatic architectural style detection using one-class support vector machines and graph kernels, Automation in Construction, 69 (2016), pp. 1-10
- [16] Cheng, M., Chou, J., Roy, A., Wu, Y.: High-performance concrete compressive strength prediction using time-weighted evolutionary fuzzy support vector machines inference model, Automation in Construction, 28 (2012), pp. 106-115
- [17] Zhang, H., Yang, F., Li, Y., Li, H.: Predicting profitability of listed construction companies based on principal component analysis and support vector machine-Evidence from China, Automation in Construction, 53, pp. 22-28
- [18] Cheng, M., Wu, Y., Wu, C.: Project success prediction using an evolutionary support vector machine inference model, Automation in Construction, 19 (2010) 3, pp. 302-307
- [19] Wang, Y., Yu, C., Chan, H.: Predicting construction cost and schedule success using artificial neural networks ensemble and support vector machines classification models, International Journal of Project Management, 30 (2012) 4, pp. 470-478
- [20] Dell Statistica, <http://en.community.dell.com/techcenter/information-management/statistica>, November (2016)
- [21] Babić, D., Vujkov, A., Peško, I., Mučenski, V., Ćirović, G.: Estimation of recycling capacity of multi-storey building structures using ANN, Savremena dostignuća u građevinarstvu, (2017), pp. 921-929, 10.14415/konferencijaGFS2017.096
- [22] Vujkov, A., Babić, D., Peško, I., Mučenski, V., Ćirović, G.: Estimation of recycling capacity of multi-storey building structures using support vector machines, 1st International Conference on Construction materials for sustainable future - CoMS 2017, pp. 816-820, Zadar, 19-21 April 2017.
- [23] Venugopal, V., Sundaram, S.: An online writer identification system using regression-based feature normalisation and codebook descriptors, Expert system with application, 72 (2017), pp. 196-206.
- [24] Matignon, R.: Neural Networks Modeling using SAS Enterprise Miner, (2005), ISBN: 1-4184-2341-6
- [25] Kecman, V.: Learning and Soft Computing, Support Vector Machines, Neural Networks and Fuzzy Logic Models, Massachusetts Institute of Technology (MIT), USA, (2001)
- [26] Schölkopf, B., Smola, A., Williamson, R.C., Bartlett, P.L.: New support vector algorithms, Neural Computation, 12 (2000), pp. 1207-1245.