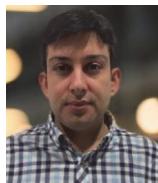


Primljen / Received: 7.4.2022.
 Ispravljen / Corrected: 21.9.2022.
 Prihvaćen / Accepted: 28.12.2022.
 Dostupno online / Available online: 10.4.2023.

Razvijanje empirijske jednadžbe za dubinu podlokavanja ispred nagnutih stupova mosta

Autori:



Doc.dr.sc. **Halil İbrahim Fedakar**, dipl.ing.građ.
 Sveučilište Abdullah Gul, Kayseri, Turska
 Građevinski fakultet
 Zavod za geotehniku
 halilibrahim.fedakar@agu.edu.tr



Izv.prof.dr.sc. **A. Ersin Dinçer**, dipl.ing.građ.
 Sveučilište Abdullah Gul, Kayseri, Turska
 Građevinski fakultet
 Zavod za hidrotehniku
 ersin.dincer@agu.edu.tr

Autor za korespondenciju



Prof.dr.sc. **Zafer Bozkus**, dipl.ing.građ.
 Tehničko sveučilište Bliski istok, Ankara, Turska
 Građevinski fakultet
 Zavod za hidrotehniku
 bozkus@metu.edu.tr

Prethodno priopćenje

Halil İbrahim Fedakar, A. Ersin Dinçer, Zafer Bozkus

Razvijanje empirijske jednadžbe za dubinu podlokavanja ispred nagnutih stupova mosta

Neka istraživanja predlažu različite empirijske korelacije kako bi se predvidjela dubina podlokavanja ispred nagnutih stupova mosta kroz regresijsku analizu dobivenu laboratorijskim mjerjenjima zbog složenih mehanizama toka oko nagnutih stupova mosta. Međutim, kako su se te korelacije razvile za određeni skup podataka, opća je jednadžba i dalje potrebna da bi se točno predvidjela dubina podlokavanja ispred nagnutih stupova mosta. Glavni je cilj istraživanja razviti opću jednadžbu kako bi se predvidjela dubina podlokavanja ispred nagnutih stupova mosta kroz višeslojni perceptron (MLP) i tehniku neuronske mreže s radikalnim baznim funkcijama (RBNN). Eksperimentalni skupovi podataka koji se primjenjuju u ovom istraživanju skupljeni su se iz prijašnjih istraživanja. Jednadžba za dubinu podlokavanja prednjeg stupa koristi se primjenom pet varijabli. Rezultati analiza umjetne neuronske mreže (ANN) otkrivaju da su modeli RBNN i MLP omogućili preciznija predviđanja nego prethodne empirijske korelacije kad su u pitanju izlazne varijable. Prema tome, predlažu se analitičke jednadžbe dobivene RBNN i MLP modelima za točno predviđanje dubine podlokavanja ispred nagnutih stupova mosta. Štoviše, na temelju rezultata analize osjetljivosti utvrđuje se da je na dubinu podlokavanja ispred prednjih i stražnjih stupova najviše utjecao kut nagiba, odnosno intenzitet toka.

Ključne riječi:

podlokavanje stupa, umjetna neuronska mreža, kut nagiba stupova mosta, višeslojni perceptron, radikalna bazna neuronska mreža

Research Paper

Halil İbrahim Fedakar, A. Ersin Dinçer, Zafer Bozkus

Developing empirical formulae for scour depth in front of inclined bridge piers

Because of the complex flow mechanism around inclined bridge piers, previous studies have proposed different empirical correlations to predict the scouring depth in front of piers, which include regression analysis developed from laboratory measurements. However, because these correlations were developed for particular datasets, a general equation is still required to accurately predict the scour depth in front of inclined bridge piers. The aim of this study is to develop a general equation to predict the local scour depth in front of inclined bridge pier systems using multilayer perceptron (MLP) and radial-basis neural-network (RBNN) techniques. The experimental datasets used in this study were obtained from previous research. The equation for the scour depth of the front pier was developed using five variables. The results of the artificial neural-network (ANN) analyses revealed that the RBNN and MLP models provided more accurate predictions than the previous empirical correlations for the output variables. Accordingly, analytical equations derived from the RBNN and MLP models were proposed to accurately predict the scouring depth in front of inclined bridge piers. Moreover, from the sensitivity analyses results, we determined that the scour depths in front of the front and back piers were primarily influenced by the inclination angle and flow intensity, respectively.

Key words:

pier scour, artificial neural network, inclination angle, bridge piers, multilayer perceptron, radial-basis neural network

1. Uvod

Stupovi mosta položeni u riječnom koritu smanjuju poprečni presjek toka vode što uzrokuje preusmjeravanje strujnica toka prema dnu riječnog korita, a to vodi do lokalnog podlokavanja oko stupova. Kako je složen mehanizam djelovanja između toka oko stupova mosta i erodivnog tla riječnog korita, teško se može pouzdano modelirati lokalno podlokavanje [1]. Da bi se bolje razumio mehanizam podlokavanja, mnogi istraživači eksperimentalno i/ili teoretski ispituju pojavu lokalnog podlokavanja oko vertikalnih stupova mosta [2-11]. Opća jednadžba ili kriterij projektiranja ne može se dobiti za sve uvjete zbog složene prirode lokalnog podlokavanja. Iako postoje mnoga istraživanja o lokalnom podlokavanju oko vertikalnih stupova mosta, postoji mali broj istraživanja vezanih uz podlokavanje oko nagnutih stupova.

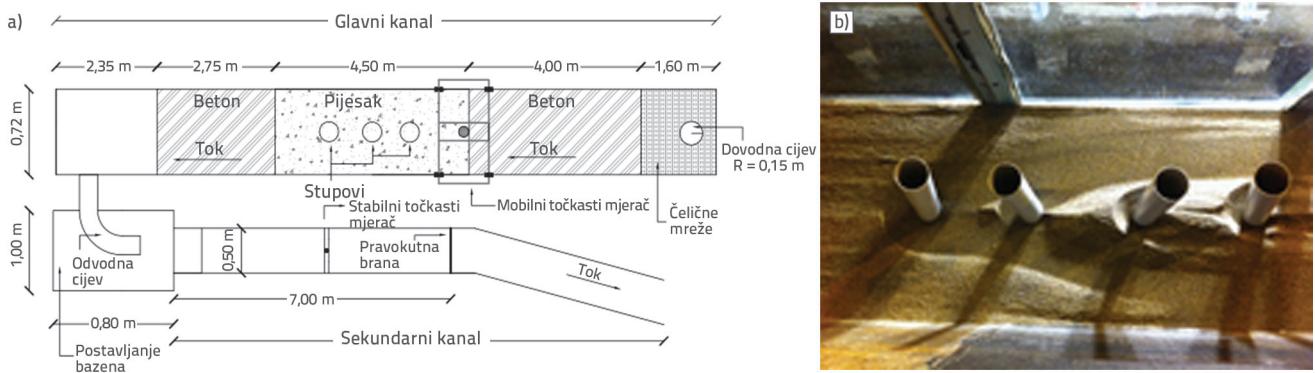
Prvo istraživanje kojim se procijenilo lokalno podlokavanje oko nagnutih stupova mosta proveli su Bozkus i dr. [12]. U istraživanju su se koristili jednim kružnim stupom nagnutim nizvodno. Rezultati pokazuju da se lokalna dubina podlokavanja smanjuje povećanjem nagiba stupa. Učinak nagiba dvostrukih stupova mosta i skupine stupova ispitana je u dalnjim istraživanjima [13, 14]. Karimi i sur. [15] proveli su slično eksperimentalno istraživanje o učinku nagnutih stupova i ustanovili da se smanjuju dimenzije kaverne nastale podlokavanjem, kao i dubina podlokavanja povećanjem kuta stupa. Obrazac podlokavanja oko nagnutog cilindričnog stupa u oštrom luku od 180 stupnjeva proučili su Khajeh i sur. [16]. Osim toga, proučen je nastanak podlokavanja oko bočno nagnutih kružnih stupova, te se odredilo da je maksimalna dubina podlokavanja kod bočno nagnutog stupa gotovo jednaka kao ona u slučaju vertikalnog stupa [17]. Slično, proučio se utjecaj bočnog nagiba kod polukružnih stupova na podlokavanje i ustanovilo se da nagnuti stupovi smanjuju dubinu podlokavanja [18]. Štoviše, predložene su razne empirijske korelacije kako bi se točno predvidjela dubina podlokavanja u prethodno spomenutim istraživanjima. Nedostatak je tih korelacija to što su predložene za određeni broj nagnutih stupova mosta, a njihovo predviđanje nije se potvrdilo u odnosu na različit broj stupova mosta. Kao što se može vidjeti iz istraživanja, prethodne jednadžbe slabo predviđaju dubine podlokavanja različitog broja stupova. Zato su i dalje potrebne univerzalne jednadžbe za različit broj stupova. Zbog složenih mehanizama lokalnog podlokavanja oko stupova mosta, može se primjeniti pristup umjetne neuronske mreže (ANN) kako bi se dobile univerzalne jednadžbe.

Ti se pristupi ponašaju kao univerzalni aproksimatori funkcije te su pogodni za oponašanje problema u kojima se ne razumije veza između ulaznih i izlaznih varijabli. ANN se jednakom tako može razmatrati kao moćni alat za procjene složenih inženjerskih problema kao što je točno predviđanje hidroloških parametara te lokalnog podlokavanja oko stupova mosta. Primjenom ANN-a proučavani su protoci najvećih godišnjih vodnih valova, prosječni mjesecni protok te kratkotrajni vodni događaji kao hidrološki parametri [19-21]. Osim hidroloških parametara, ANN

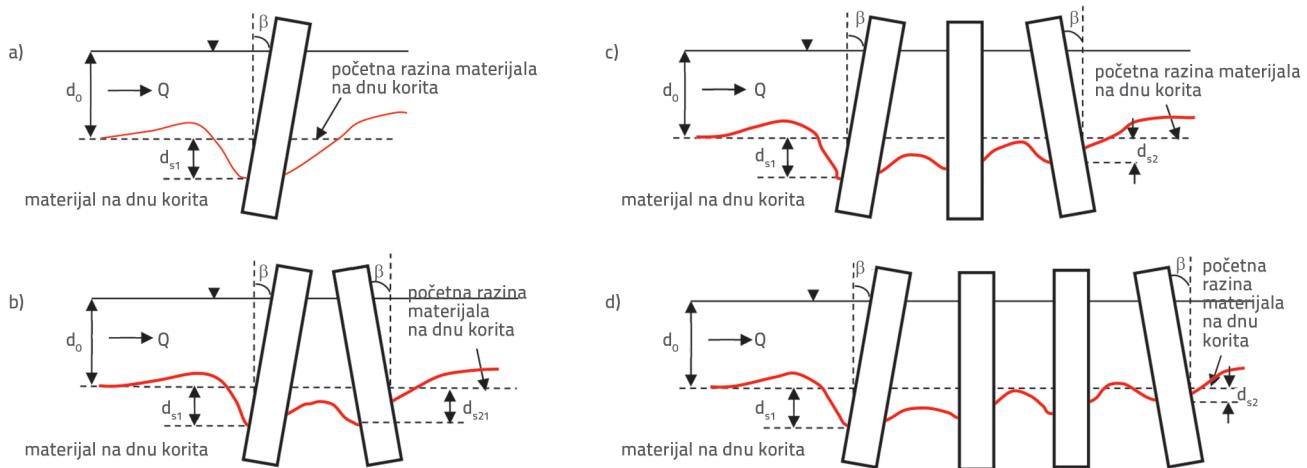
se jednakom tako koristi u predviđanju dubine podlokavanja oko stupova mosta. Među prethodnim istraživanjima proučavala se primjena dvaju tipova ANN-a i neuro-fuzzy sustava kao pristupa u proučavanju podlokavanja, te se zaključilo da su predložene metode predviđale dubinu podlokavanja preciznije nego tradicionalne analitičke metode [22]. Lee i sur. [23] koristili su model povratnog širenja neuronske mreže (BPN) primjenom podataka na temelju promatranja u 13 država u SAD-u. Dubina podlokavanja predviđala se tako što su se kao parametri u BPN modelu uzeli dubina toka, prosječna brzina, dijametar zrna, geometrijska standardna devijacija raspodjele veličine zrna i granična brzina. U istraživanju [24] primijenjen je ANN model kako bi se predviđelo lokalno podlokavanje oko stupova mosta. Prema analizi osjetljivosti ANN modela četiri parametra dovoljna su da se ispravno procijeni dubina podlokavanja oko stupa, a riječ je o obliku stupa i kutu otklona, dubini toka te brzini toka. Kako bi se procijenila dubina podlokavanja, predloženi su različiti hibridni modeli [25-27]. Modeli evolutivne neuronske mreže s radikalnim baznim funkcijama (ERBFNN) razvijeni su kako bi se predviđela dubina podlokavanja oko stupova mosta [28]. Rezultati su pokazali da ERBFNN modeli daju točnija predviđanja u usporedbi s različitim matematičkim jednadžbama uključujući HEC-18, Mississippi, Laursen i Toch te Froehlich. Mehanizam podlokavanja oko grupe pilota proučavao se uz pomoć bagged neuronske mreže u kojoj se naizmjenično iz uzorka odabiru podaci te se sukladno s uzorkom prave nova stabla [29]. U prethodnim istraživanjima, neuronske mreže koristile su se kako bi procijenile podlokavanje pretežno oko vertikalnih stupova mosta. Štoviše, modeli neuronskih mreža nisu dali empirijsku jednadžbu. To je razlog zašto projektanti i dalje trebaju pouzdano empirijsku jednadžbu kako bi precizno procijenili formiranje podlokavanja oko nagnutih stupova mosta. Glavni je cilj ovog istraživanja predložiti pouzdane jednadžbe za preciznu procjenu dubine podlokavanja ispred stupova mosta. U tu se svrhu dubine podlokavanja ispred nagnutih stupova mosta dobivaju predviđanjem uz pomoć višeslojnog perceptronu (MLP) i tehniku neuronske mreže s radikalnim baznim funkcijama (RBNN) te novih empirijskih jednadžbi za procjenu dubine podlokavanja. Koliko je autoru poznato, to je prvo istraživanje u kojem se ANN koristi kako bi se procijenila dubina podlokavanja ispred nagnutih stupova mosta. Osim toga, provodi se niz analiza osjetljivosti da bi se odredili najutjecajniji parametri na formiranje lokalnog podlokavanja.

2. Prikupljanje podataka

Eksperimentalni se podaci dobivaju iz prethodnih istraživanja koja se navode u [12-14, 30]. Eksperimenti koje su proveli Bozkus i Yıldız [12] izvedeni su u laboratoriju za hidrauliku pri Državnom uredu za hidrauličke radove u Turskoj (DSİ), a drugi su se eksperimenti proveli u laboratoriju za hidrauliku pri Tehničkom sveučilištu Bliski istok u Ankari, Turska. Kanal prikazan na slici 1. koristio se u istraživanju navedenom u [13, 14]. Prikaz mjerenja podlokavanja za različit broj stupova može se vidjeti na slici 2.



Slika 1. Tlocrt ispitnog postrojenja: a) prikaz; b) stvarna fotografija



Slika 2. Prikaz mjerjenja podlokavanja oko: a) jednog stupa; b) dvaju stupova; c) tri stup; d) četiri stup

Na slici dubina je podlokavanja ispred prednjeg i stražnjeg stupa označena sa d_{s1} i d_{s2} :

Istraživanje utjecaja nagiba jednog stupa teoretsko je istraživanje zato što nije opravdana izgradnja jednog masivnog stupa. Međutim, uključeno je u ANN analize kako bi se povećao broj podataka te kako bi se pouzdanije jednadžbe moglo predložiti. Umjesto jednog masivnog stupa, skupine se stupova više preferiraju iz konstrukcijskih razloga, no opstrujavanje oko stupova je narušeno te izaziva recirkulaciju kod skupina stupova. Skupina stupova najčešće se formira stupovima poredanim u smjeru toka i/ili okomito na tok. Učinak skupine stupova na opstrujavanje uglavnom ovisi o udaljenosti između stupova, smjeru i položaju stupova. Prema [30], ako je tok okomit na os koju čini skupina stupova te ako je udaljenost između stupova vrlo mala, tada se podlokovanjem stvara jedna kaverna te se uočava povećanje maksimalne dubine podlokavanja. Međutim, ako su stupovi u skupini položeni pazeći na razmak među njima, tada skupina stupova smanjuje dubinu podlokavanja više nego jedan masivni stup. Skupni učinak stupova istražuje se u literaturi [13, 14, 30]. Zbog transporta materijala s dna kaverne nastale podlokovanjem oko uzvodnog stupa do kaverne na nizvodnom stupu, uočavaju se manje dubine podlokavanja na nizvodnim stupovima.

Udaljenost između stupova, smjer i položaj stupova smatraju se glavnim parametrima za skupni učinak prema [14].

U svim eksperimentima primjenjeni su stabilni uvjeti bistre vode, a distribucija sedimenta bila je ujednačena. Dijametri stupova korištenih u eksperimentu iznosili su 50, 70 i 100 mm. Osim toga, različiti su kutovi nagiba $0^\circ, 2^\circ, 5^\circ, 10^\circ, 15^\circ$ bili poželjniji kako bi se jasnije uočio njihov učinak. Ostali parametri bili su protok i veličina sedimenta. Razmak između stupova, dimenzije hidrauličkog kanala i značajke sedimenta bile su konstanta tijekom eksperimenta, a pretpostavilo se da je postignut uvjet ravnotežne dubine podlokavanja. Uočeno je da se s vremenom smanjuje brzina produbljenja kaverne. Drugim riječima, u prvim minutama eksperimenta stvorio se velik sprud, a čestice sedimenta prenijete su nizvodno. Kako bi se uključio učinak transporta, dubina podlokavanja na uzvodnim stupovima razmatra se u izvođenju jednadžbe koja se odnosi na procjenu dubine podlokavanja na nizvodnim stupovima. Jednako tako, tablica 1. prikazuje broj stupova, kut nagiba, dijametar stupa, intenzitet toka (V/V_c), srednju veličinu sedimenta, d_{50} . U tablici, umjesto da se prikazuje protok, poželjnije je prikazati V/V_c kako bi se jasno izrazilo da su se eksperimenti proveli pod gotovo graničnim uvjetima što pokazuje bistru vodu tijekom eksperimenata prema [2].

Tablica 1. Glavne značajke eksperimentalnih podataka

Referenca	Broj stupova	Kut nagiba [°]	Dijametar stupa, D [mm]	Broj mjerena	V/V _c	d _{s0} [mm]
[12]	1	2	50	4		
			100	7		
		5	50	4		
			100	7		
		10	50	4		
			100	7	1,211-1,861	0,5
		15	50	4		
			100	7		
[13]	2	0	50	6		
			70	3		
		5	50	6		
			70	0	0,295-0,437	
		10	50	6		
			70	3		
		15	50	6		
			70	3		
[14, 30]	3 i 4	0	50	6		
			70	6		
		10	50	6	0,589-0,936	
			70	6		
		15	50	6		
			70	6		

3. Metodologija

3.1. Umjetna neuronska mreža

Pristup umjetne neuronske mreže računalnaju je metodologija koja primjenjuje informaciju dobivenu iz iskustva na nove scenarije. Tijekom tog procesa, a analogno ustroju ljudskog mozga, koriste se mnogi jednostavnji računalni elementi, i to umjetni neuroni čije su težine međusobno povezane [31]. Zbog činjenice da ANN ima veliku sposobnost učenja, uspješno se primjenjuje na mnoge složene inženjerske probleme. U ovom istraživanju primjenjuju se višeslojni perceptron i tehnikе neuronske mreže s radikalnim baznim funkcijama za razvijanje empirijskih formula za dubinu podlokavanja oko nagnutih stupova mosta. Višeslojni perceptron sastoji se od ulaznog sloja, barem jednog skrivenog sloja te izlaznog sloja kao što prikazuje slika 3. Na slici, m predstavlja broj ulaznih neurona, w_{ih} je težina koja povezuje ulazne neurone sa skrivenim neuronima, B_h je izraz odstupanja skrivenog sloja, f_h je funkcija transporta skrivenog sloja, w_{ho} je težina koja povezuje skrivene neurone s izlaznim neuronima, B_o je izraz odstupanja izlaznog sloja, a f_o je funkcija transfera izlaznog sloja. Svaki neuron u ulaznim i izlaznim slojevima predstavlja ulaznu, odnosno izlaznu varijablu. Što se tiče neurona u skrivenom sloju, oni pogoduju između ulaznih i izlaznih varijabli [31]. MLP model koji ima više od jednog skrivenog sloja može dati statistiku višeg reda. Međutim, jedan je skriveni sloj dovoljan za približavanje bilo kojem složenom problemu [32, 33]. Zato MLP modeli koji su se razvili u ovom istraživanju koriste jedan skriveni sloj. Postupak koji je primijenjen u usavršavanju MLP modela kratko se može sazeti:

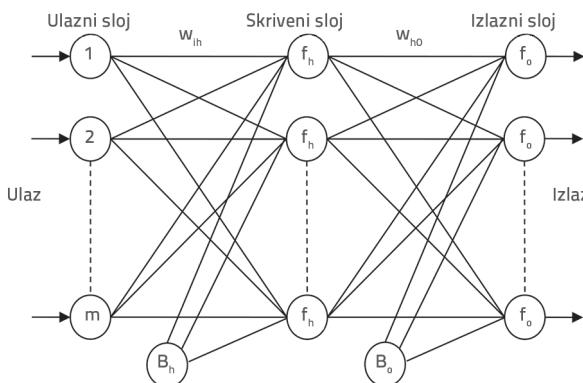
1. sve ulazne (neovisne) i izlazne (ovisne) varijable najprije se normaliziraju kako bi bile usporedive
2. svaki normalizirani ulazni neuron tada se množi težinom koja ga povezuje sa skrivenim neuronom
3. rezultati su sažeti izrazom odstupanja skrivenog sloja
4. funkcija transfera implementira na svakom skrivenom neuronu
5. svaki skriveni neuron množi se s težinom koja ga povezuje s izlaznim neuronom
6. rezultati su sažeti izrazom odstupanja izlaznog sloja
7. funkcija transfera implementira se na svakom izlaznom neuronu
8. algoritam stražnjeg propadanja koristi se kako bi prilagodio parametre težine i odstupanja modela omogućujući minimiziranje pogreške
9. koraci (od 2 do 7) ponavljaju se primjenom ažuriranih vrijednosti težine i odstupanja, te 10) nakon što se razvije MLP model, primjenjuje se denormalizacija na izlaznom neuronu.

Izraz (1) matematički prikazuje navedene računalne korake (od 2 do 7) za MLP model koji ima izlaznu varijablu i skriveni sloj s jednim nevronom.

$$y_n = f_o \left(f_h \left(\sum_{i=1}^m (x_i)_n w_{ih} + B_h \right) w_{ho} + B_o \right) \quad (1)$$

gdje je (x_i)_n normalizirana ulazna varijabla ith, a y_n normalizirana izlazna varijabla. Više teoretskog znanja o modelu MLP može se naći u [34]. S druge strane, model neuronske mreže s radikalnim

baznim funkcijama skuplja ulazne podatke prije izlaganja mreži i različite funkcije nelinearne aktivacije koje su lokalno podešene tako da prekrivaju područje ulaznog prostora. Konstrukcija RBNN-a takva je da skriveni sloj uključuje isti broj čvorova s centrima klastera [35]. Osim toga, kao i u MLP modelima, RBNN model u ovom istraživanju koristi jedan skriveni sloj. Temeljne funkcije u skrivenom sloju donose značajan odgovor koji je različit od nule na ulazni podražaj samo onda kad je unos unutar malog područja ulaznog prostora. Zato je ta paradigma poznata još i kao lokalizirana receptivna mreža polja [36]. Transformacija je unosa ključna za borbu protiv dimenzionalnosti u empirijskom modeliranju. Vrsta je ulazne transformacije RBNN-a nelinearna projekcija koja koristi radikalnu baznu funkciju. Radikalne bazne funkcije u ulozi su regresora nakon što nelinearno stisnu multidimenzionalne ulaze ne uzimajući u obzir izlazni prostor. Zbog toga što izlazni sloj primjenjuje linearni regresor, jedini primjenjivi parametri su težine tog regresora. Ti su parametri određeni metodom najmanjih kvadrata što daje značajnu prednost pri konvergenciji [31, 37]. RBNN ima prednost brze konvergencije vremena bez lokalnih minimuma zato što je njegova funkcija pogreške uvek konveksnog oblika [38]. Opširnije o modelu RBNN može se naći u [39].



Slika 3. Tipični ustroj ANN modela s jednim skrivenim slojem

Tablica 2. Prethodne empirijske jednadžbe za dubinu podlokavanja nagnutih stupova

Prethodna istraživanja	Model	Izlazna varijabla	Broj stupova	Veličina skupa podataka	Jednadžbe	R ²
[12]	DS1A	d _{s1}	1	44	$\frac{d_s}{D} = 0.455 \left(\frac{d_0}{D} \right)^{0.202} \left(\frac{V}{V_c} \right)^{0.591} \alpha^{1.725}$	0,98
[13]	DS1B	d _{s1}	2	33	$\frac{d_s}{D} = 0.232 \left(\frac{d_0}{D} \right)^{0.173} \left(\frac{V}{V_c} \right)^{0.351} \alpha^{2.888}$	0,95
[14]	DS1C	d _{s1}	3 i 4	72	$\frac{d_s}{D} = 1.163 \left(\frac{d_0}{D} \right)^{0.250} \left(\frac{V}{V_c} \right)^{1.047} \alpha^{0.828}$	0,95
[30]	DS2A	d _{s2}	3	36	$\frac{d_s}{D} = 2.058 \left(\frac{D}{d_0} \right)^{1.105} \left(\frac{V}{V_c} \right)^{4.706} \alpha^{-0.255}$	0,79
[30]	DS2B	d _{s2}	4	36	$\frac{d_s}{D} = 1.378 \left(\frac{D}{d_0} \right)^{0.649} \left(\frac{V}{V_c} \right)^{3.814} \alpha^{0.099}$	0,81

3.2. Prethodne empirijske korelacije

Regresijske jednadžbe izložene u tablici 2. predlažu se za određeni broj stupova. Te se jednadžbe koriste kako bi se predvidjela dubina podlokavanja ispred prednjeg stupa (d_{s1}) i stražnjeg stupa (d_{s2}). U jednadžbama, d_s služi za izračun dubine lokalnog podlokavanja, d_0 za izračun dubine prilaznog toka, D za izračun dijametra stupa, V za izračun prosječne brzine toka, V_c za izračun prosječne granične brzine toka, a α je $90 - \beta$ u radijanima gdje β predstavlja izračun kuta nagiba. Broj eksperimenata koji su se proveli kako bi se razvile jednadžbe i koeficijent determinacije, R^2 , prikazani su također u tablici 2. Vrijednosti R^2 koje predlaže d_{s1} blizu su 1, što upućuje na to da se podudara s eksperimentalnim podacima. U jednadžbama predloženim za d_{s2} , R^2 vrijednosti nisu vrlo blizu 1.

3.3. Težinski faktori

Težinskim faktorima [40] rastavljaju se težine spajanja ANN modela kako bi se odredila relativna važnost (RI) svake ulazne varijable na izlaznu varijablu [41]. Da bi se to napravilo, priključne težine na ulazu i izlazu svih skrivenih neurona raspodijeljene su u komponente za svaki ulazni neuron. Prema tome, sljedeće se jednadžbe predlažu u [41]:

$$Q_{ih} = \frac{|W_{ih}|}{\sum_{i=1}^{ni} |W_{ih}|} \quad (2)$$

$$RI [\%]_i = \frac{\sum_{h=1}^{nh} Q_{ih}}{\sum_{h=1}^{nh} \sum_{i=1}^{ni} Q_{ih}} \times 100 \quad (3)$$

gdje ni predstavlja ulazne neurone, nh predstavlja broj skrivenih neurona, W_{ih} je množenje ulazne i izlazne težine, a RI_i je relativna važnost ulazne varijable i^{th} .

Tablica 3. Neki statistički parametri učenja i testiranja skupova podataka

Skup podataka	Varijable	Broj podataka	Minimalni	Maksimalni	Prosječni
Učenje (d_{s1})	NP (broj stupa)	104	1	4	2,39
	β [stupanj]		0	15	10
	D [cm]		5	10	6,59
	d_0 [cm]		3,70	17,50	7,66
	V/V_c		0,30	1,86	0,93
	d_{s1} [mm]		12	142	66,48
Testiranje (d_{s1})	NP (broj stupa)	45	1	4	2,51
	β [stupanj]		0	15	7,02
	D [cm]		5	10	6,44
	d_0 [cm]		3,70	17,50	8,63
	V/V_c		0,32	1,86	0,93
	d_{s1} [mm]		20	130	72,39
Učenje (d_{s2})	NP (broj stupa)	73	2	4	3,10
	β [stupanj]		0	15	8,56
	D [cm]		5	7	5,96
	d_0 [cm]		3,7	17,5	7,28
	V/V_c		0,30	0,94	0,69
	d_{s2} [mm]		6	62	31,63
Testiranje (d_{s2})	NP (broj stupa)	32	2	4	2,88
	β [stupanj]		0	15	7,19
	D [cm]		5	7	5,63
	d_0 [cm]		3,70	17,50	8,40
	V/V_c		0,30	0,94	0,61
	d_{s2} [mm]		12	60	29,28

4. Razvoj modela i procjena učinka

Jedan od najčešćih problema u pronalasku veze između ulaznih i izlaznih varijabli u umjetnoj neuronskoj mreži jest pretreniranje. Pretreniranje se događa kad ANN model pokazuje veliku pogrešku za podatak koji nije vidoio, a vrlo malu pogrešku za uvježbani podatak. Zato se treba izbjegći pretreniranje kad se razvija pouzdani ANN model s boljom sposobnost generalizacije. Kako bi se izbjeglo pretreniranje, skup podataka dijeli se u dva podskupa: skup podataka za učenje i skup podataka za testiranje [42]. Skup podataka za učenje koristi se za treniranje ANN modela, a skup podataka za testiranje primjenjuje se za ispitivanje njihovog predviđanja učinka na neviđenim podacima. Prema tome, ANN model koji najbolje predviđa izlaznu varijablu određuje se uspoređujući predviđanje učinka svih razvijenih ANN modela u fazi testiranja. Prema [43], utvrđeno je da bi se između 15 % i 30 % skupova podataka trebalo koristiti kao skup podataka za testiranje. U ovom istraživanju 30 % skupova podataka (d_{s1} i d_{s2}) koristi se za testiranje ANN modela (vidi tablicu 3.). Podaci su nasumično podijeljeni u skupove podataka za učenje i testiranje primjenom softvera MATLAB. Tablica 3.

prikazuje neke statističke parametre skupova podataka koji su korišteni u ovom istraživanju. U tablici su izlazne varijable masno otisnute. Osim pretreniranja, trebao bi se razmotriti broj podataka tijekom razvijanja pouzdanih ANN modela. Prema [43], omjer podataka u odnosu na ulazne varijable trebalo bi biti veći od 5. U ovom radu taj omjer izračunan je kao 29,8 za skup podataka d_{s1} (149/5), odnosno 21,0 za skup podataka d_{s2} (105/5) (149 i 105 su brojevi podataka, a 5 je broj ulaznih varijabli u skupu podataka d_{s1} , odnosno d_{s2}), što upućuje na to da je broj skupova podataka koji se koriste u ovom istraživanju dostatan za razvijanje ANN modela za točnu procjenu dubine podlokavanja ispred nagnutih stupova. Kao što se vidi iz tablice 3., sve varijable u skupovima podataka imaju različit raspon. Kako bi raspon svih varijabli bio usporediv, one su za početak normalizirane između -1 i 1 primjenom jednadžbe 4 [44]. U toj jednadžbi X_{\max} i X_{\min} su maksimalne i minimalne vrijednosti varijable X u fazi učenja skupa podataka. U ovom istraživanju razvilo se ukupno 1860 ANN modela za različite dubine podlokavanja (180 za d_{s1} i 180 za d_{s2} u MLP modelu te 750 d_{s1} i 750 za d_{s2} u RBNN modelu). U razvijanju MLP i RBNN modela u predviđanju d_{s1} i d_{s2} ulazne varijable koje se

uzimaju u obzir su NP, B, β , D, d_o i V/V_c . Kako bi se postigli najbolji MLP modeli za vrijednosti d_{s1} i d_{s2} , hiperbolička tangentna sigmoidna aktivacijska funkcija (tansig), izraz (5), nelinearna sigmoidna funkcija (logsig), izraz (6) te linearna (purelin) funkcija, izraz (7) koriste se u skrivenim i izlaznim slojevima, a primjenjuje se broj skrivenih neurona koji varira od 1 do 20. Kako se Levenberg-Marquardtova funkcija treniranja najčešće koristi za poboljšanje učinka predviđanja MLP modela, MLP modeli koji su se razvili u ovom istraživanju treniraju se primjenom ove funkcije treniranja. Međutim, u RBNN modelima koristi se radikalna bazna funkcija transfera (radbas) u skrivenom sloju, izaz (8), a purelin aktivacijska funkcija u vanjskom sloju. Što više, koristi se broj skrivenih neurona između 1 i 50 te koeficijent širenja između 1 i 15 kako bi se postigli najbolji RBNN modeli za vrijednosti d_{s1} i d_{s2} . Sve analize ANN modela u ovom radu (MLP i RBNN) provode se primjenom softvera MATLAB.

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} - \frac{X_{\max} - X}{X_{\max} - X_{\min}} \quad (4)$$

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (5)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

$$f(x) = x \quad (7)$$

$$f(x) = e^{-x^2} \quad (8)$$

Učinak predviđanja ANN modela (MLP i RBNN) te prethodnih empirijskih poveznica vezanih uz treniranje i ispitivanje skupa podataka procjenjuju se korijenom srednje kvadratne pogreške, srednjom apsolutnom pogreškom i koeficijentom determinacije (R^2). Korijen srednje kvadratne pogreške (RMSE) pruža informacije o dobroj prilagodbi relevantnoj za visoke izlazne vrijednosti. S druge strane, srednja apsolutna pogreška (MAE) daje uravnoteženiju perspektivu prilagodbe pri umjerenoj izlaznim vrijednostima. Što se tiče R^2 , ta vrijednost pruža informaciju o linearном odnosu između dvije varijable. Formule statistike RMSE, MAE i R^2 (napisane za vrijednost d_{s1}) prikazane su izrazima (9) do (11).

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n [(ds_{s1})_{\text{measured},j} - (ds_{s1})_{\text{predicted},j}]^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |(ds_{s1})_{\text{measured},j} - (ds_{s1})_{\text{predicted},j}| \quad (10)$$

$$R^2 = \frac{\left(\sum_{j=1}^n \{(ds_{s1})_{\text{measured},j} - (\bar{ds}_{s1})_{\text{measured}}\}^2 - \sum_{j=1}^n \{(ds_{s1})_{\text{measured},j} - (ds_{s1})_{\text{predicted},j}\}^2 \right)}{\sum_{j=1}^n \{(ds_{s1})_{\text{measured},j} - (\bar{ds}_{s1})_{\text{measured}}\}^2} \quad (11)$$

gdje je n broj podataka, $(ds_{s1})_{\text{measured}}$ je izmjerena vrijednost d_{s1} , $(ds_{s1})_{\text{predicted}}$ je predviđena vrijednost d_{s1} , a $(\bar{ds}_{s1})_{\text{measured}}$ je srednja vrijednost izmjerene d_{s1} .

5. Rezultati

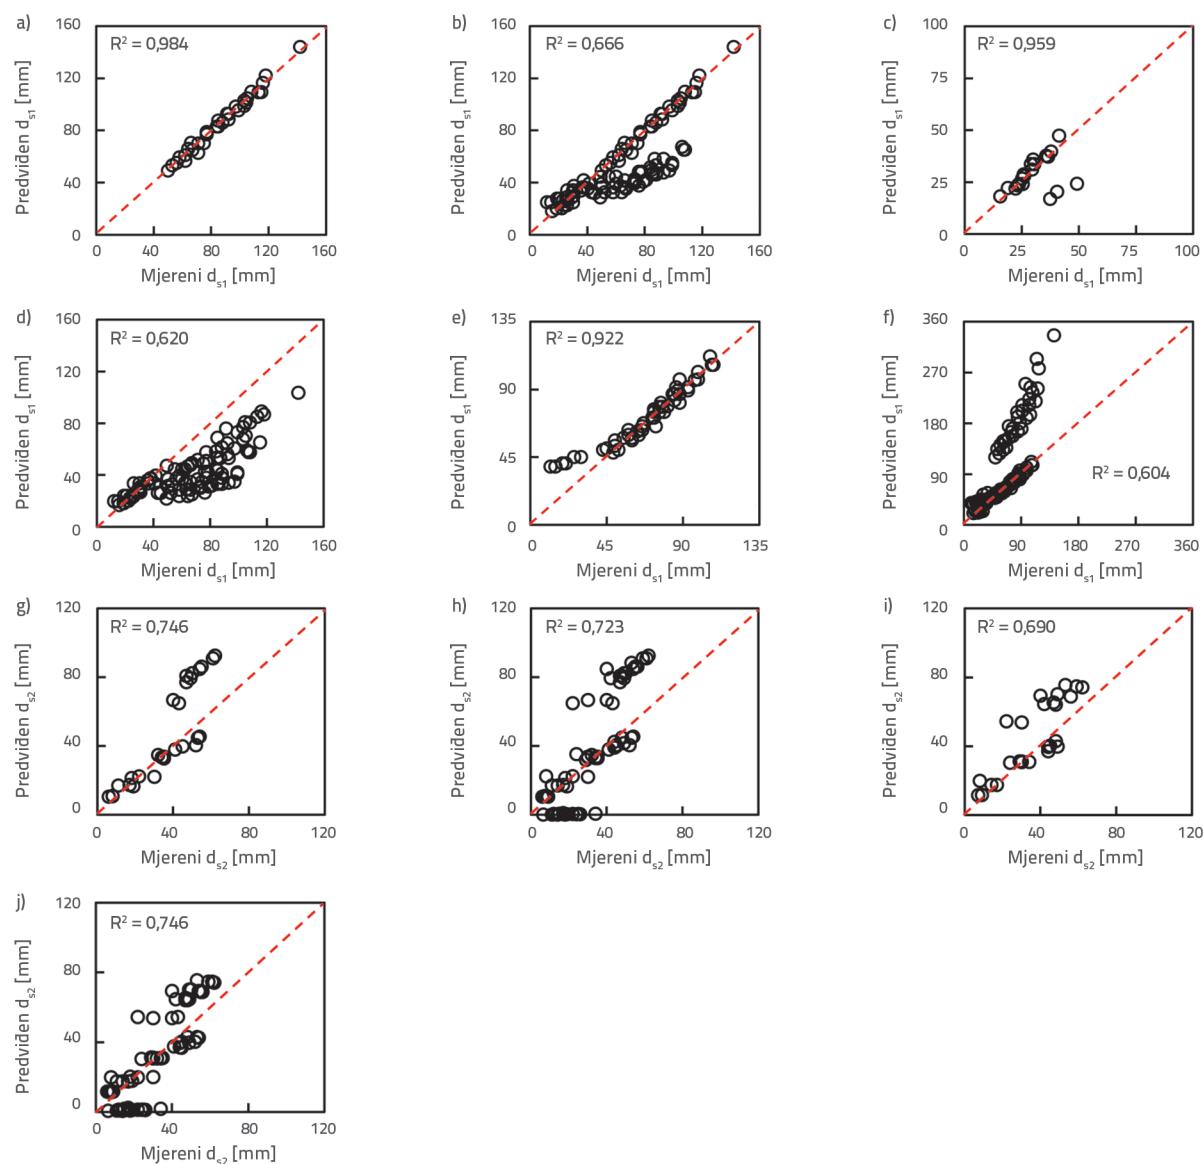
5.1. Predviđanja d_{s1} i d_{s2} prethodnim empirijskim modelima

Kao što je prethodno spomenuto, cilj je ovog istraživanja razviti pouzdanije modele za predviđanje d_{s1} i d_{s2} primjenom MLP i RBNN tehnika u usporedbi s prethodnim empirijskim modelima. Zato se dubine podlokavanja ispred nagnutih stupova mosta (d_{s1} i d_{s2}) prve predviđaju primjenom prethodnih empirijskih modela i njihov učinak predviđanja prikazan je i o njemu se ovdje raspravlja što je jednako tako važno tijekom procjene učinka predviđanja razvijenih ANN modela u sljedećem pododjeljku. Tablica 4. prikazuje rezultate predviđanja empirijskih modela vezanih uz treniranje i ispitivanje skupova podataka u slučaju različitog broja stupova mosta. Što više, usporedba izmjerениh i predviđenih dubina podlokavanja u fazama učenja i testiranja prikazana je na slici 4., odnosno slici 5. U stupcu koji prikazuje broj stupova u tablici 4. gornja vrijednost svakog retka upućuje na broj stupova za koje se jednadžbe predlažu. Primjerice, DS1A se predlaže za izračun dubine podlokavanja s jednim stupom, a DS1B se predlaže za dva stupa. Međutim, svaka se jednadžba primjenjuje kako bi se izračunala dubina podlokavanja za različit broj stupova, ali samo zato da se vidi može li se pojedinom jednadžbom koja se predlaže u literaturi izračunati dubina podlokavanja u slučaju ako se broj stupova promjeni. Budući da učinak DS1A nije zadovoljavajući kada se primjenjuje na više od jednog stupa kao na slici 4.b, DS1B, DS1C, DS2A i DS2B, nisu učinkoviti kad se primjenjuju na različit broj stupova. To je glavni razlog zašto dolazi do grupiranja podataka blizu 0, kao što se uočava na slici 4. i slici 5. Osim toga, utvrđeno je na tim slikama da su h i j predviđene dubine podlokavanja jednakе 0. To znači da jednadžba ne može predvidjeti dubinu podlokavanja te se ne treba koristiti u predviđanju. Kao što je objašnjeno, učinak jednadžbi u slučaju različitog broja stupova istražuje se samo u svrhu akademске znatiželje.

Određuje se da DS1A, DS1B i DS1C modeli daju točna ds_1 predviđanja u slučaju 1, 2, 3 do 4 stupa, odnosno, dajući nisku vrijednost RMSE ($\leq 8,17$ mm u fazi učenja i $\leq 4,13$ mm u fazi testiranja) i MAE ($\leq 5,17$ mm u fazi učenja i $\leq 3,54$ mm u fazi testiranja) te visoku vrijednost R^2 ($\geq 0,922$ u fazi učenja i $\geq 0,947$ u fazi testiranja). S druge strane, ti modeli stvaraju višu RMSE ($\geq 21,31$ mm u fazi učenja i $\geq 24,03$ mm u fazi testiranja) i MAE ($\geq 14,79$ mm u fazi učenja i $\geq 17,64$ mm u fazi testiranja) te nižu R^2 ($\leq 0,604$ u fazi učenja i $\leq 0,703$ u fazi testiranja) kada se primjenjuju na skupove podataka koji imaju 1 do 4 stupna mosta. To je zbog niske procjene DS1A i DS1B te visoke procjene DS1C (slika 4. i slika 5.). Međutim, prema [45], postoji snažni odnos između izmjereni i predviđeni ds_1 po modelima DS1A, DS1B, i DS1C jer imaju $R^2 \geq 0,64$ u fazi testiranja, što upućuje na to da

Tablica 4. Rezultati predviđanja prethodnih empirijskih korelacija u slučaju različitog broja stupova

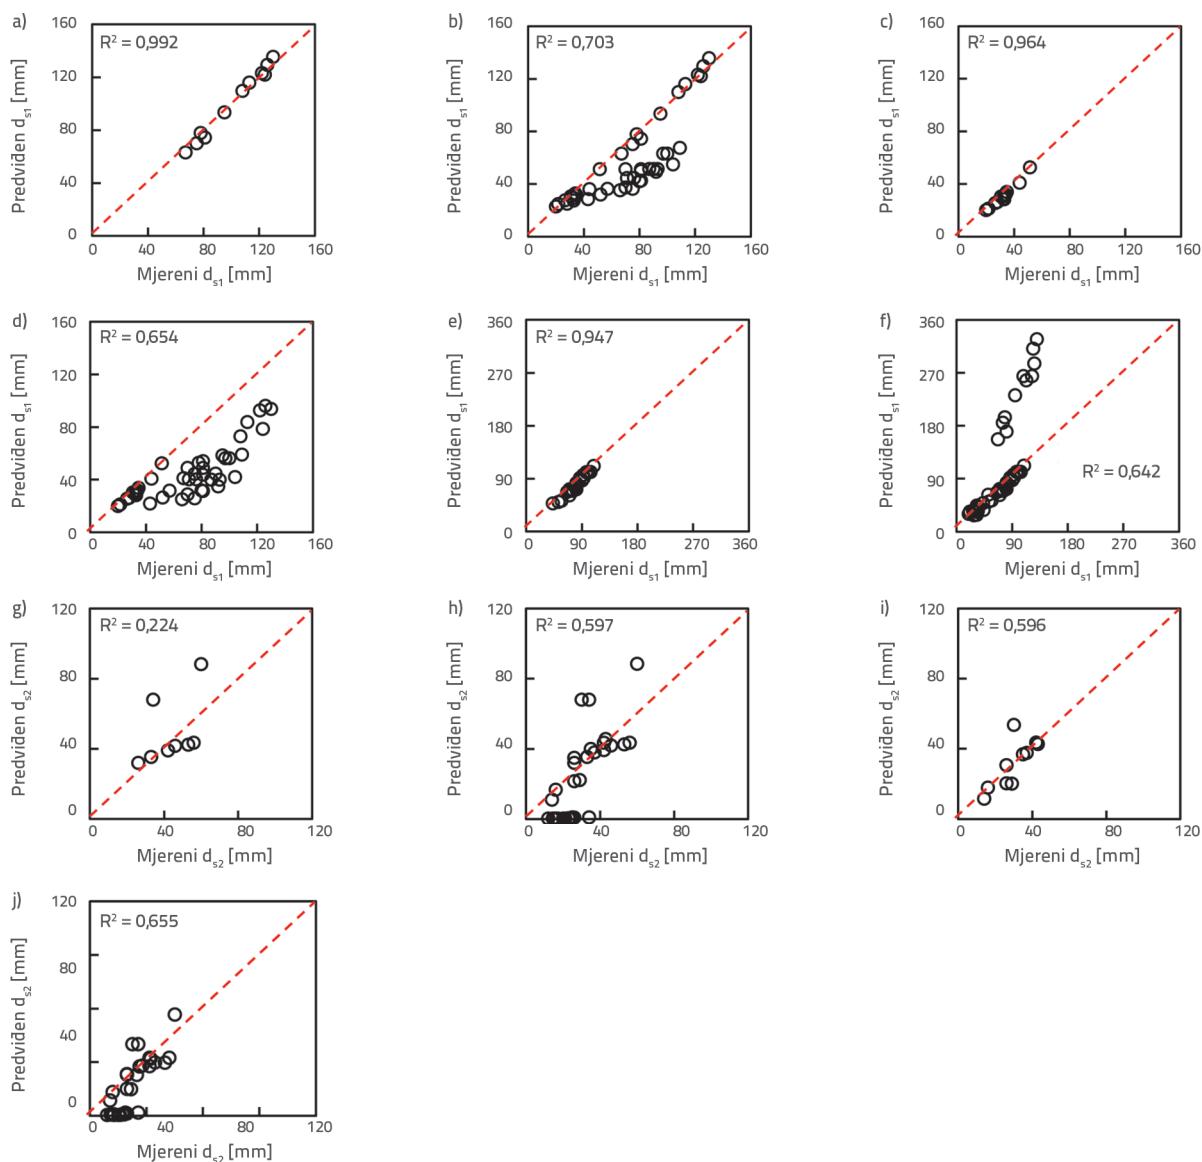
Modeli	Izlaz	Broj stupova	Faza učenja			Faza testiranja		
			RMSE [mm]	MAE [mm]	R ²	RMSE [mm]	MAE [mm]	R ²
DS1A	d_{s1}	1	3,01	2,35	0,984	3,61	3,07	0,992
		1 do 4	21,31	14,79	0,666	24,03	17,64	0,703
DS1B	d_{s1}	2	2,19	1,62	0,959	2,22	1,72	0,964
		1 do 4	30,91	25,45	0,620	33,86	28,36	0,654
DS1C	d_{s1}	3 i 4	8,17	5,17	0,922	4,13	3,54	0,947
		1 do 4	62,00	37,35	0,604	70,78	37,42	0,642
DS2A	d_{s2}	3	18,44	13,33	0,746	16,95	12,60	0,224
		2 do 4	20,42	15,89	0,723	17,72	14,22	0,597
DS2B	d_{s2}	4	14,62	11,33	0,690	8,38	5,14	0,596
		2 do 4	14,16	11,74	0,746	15,25	12,62	0,655

Slika 4. Usporedba mjereneih i predviđeni dubina podlokavanja (d_{s1} i d_{s2}) u fazi učenja: a) DS1A model i 1 stup; b) DS1A model i 1 do 4 stupa; c) DS1B model i 2 stupna; d) DS1B model i 1 do 4 stupna; e) DS1C model i 3 do 4 stupna; f) DS1C model i 1 do 4 stupna; g) DS2A model i 3 stupna; h) DS2A model i 2 do 4 stupna; i) DS2B i 4 stupna; j) DS2B i 2 do 4 stupna

se ti modeli mogu koristiti za predviđanje d_{s_1} u slučaju nagnutih stupova mosta koji imaju 1 do 4 stupa. Međutim, može se reći, prema rezultatima na slici 4. i slici 5., da je potrebna nova opća empirijska korelacija kako bi se točno predvidjelo stvaranje d_{s_1} ispred nagnutih stupova mosta koji imaju 1 do 4 stupa. Kao što je spomenuto u prethodnim empirijskim korelacijskim, DS2A i DS2B modeli predlažu se za predviđanje d_{s_2} u slučaju 3, odnosno 4 stupna.

Za razliku od modela koji se koriste u predviđanju d_{s_1} , DS2A model daje visoku RMSE ($\geq 18,44$ mm u fazi učenja i $\geq 16,95$ mm u fazi testiranja) i MAE ($\geq 13,33$ mm u fazi učenja i $\geq 12,60$ mm u fazi testiranja) te nisku R^2 ($\leq 0,746$ u

fazi treniranja i $\leq 0,597$ u fazi ispitivanja) u slučaju 3, odnosno 2 do 4 stupa (tablica 4., slika 4. i slika 5.), što uzrokuje slabo predviđanje dubine podlokavanja ispred stražnjeg stupa. U slučaju modela DS2B, unatoč tome što stvaraju relativno nisku RMSE (8,38 mm) i MAE (5,14 mm) kad je riječ o 4 stupna u fazi testiranja, to predstavlja slabe rezultate predviđanja u slučaju 2 odnosno 4 stupna (RMSE = 14,16 mm, MAE = 11,74 mm, i $R^2 = 0,746$ u fazi učenja i RMSE = 15,25 mm, MAE = 12,62 mm, odnosno $R^2 = 0,655$ u fazi testiranja, tablica 4., slika 4. i slika 5.). Rezultati očito upozoravaju na to da je potrebna nova opća jednadžba za predviđanje d_{s_2} u slučaju nagnutih stupova mosta.



Slika 5. Uskorovala mjerena i predviđena dubina podlokavanja (d_{s_1} i d_{s_2}) u fazi testiranja: a) DS1A model i 1 stup; b) DS1A model i 1 do 4 stupna; c) DS1B model i 2 stupna; d) DS1B model i 1 do 4 stupna; e) DS1C model i 3 do 4 stupna; f) DS1C model i 1 do 4 stupna; g) DS2A model i 3 stupna; h) DS2A model i 2 do 4 stupna; i) DS2B i 4 stupna; j) DS2B i 2 do 4 stupna

5.2. Predviđanja po ANN modelima

Rezultati RMSE, MAE i R^2 najboljih MLP i RBNN modela u fazama učenja i testiranja prikazuju tablica 5., odnosno tablica 6. Usporedbu mjerjenih i predviđenih d_{s1} i d_{s2} po modelima MLP i RBNN prikazuju slike 6. do 9.

Kao što je spomenuto, prethodni empirijski modeli (DS1A, DS1B, DS1C, DS2A, i DS2B) predloženi su za određen broj stupova mosta. Zato, kako bi se usporedila predviđanja vezana uz podlokavanje po MLP i RBNN modelima s prethodnim empirijskim korelacijama, učinak predviđanja MLP i RBNN modela pri određenom broju stupova mosta (npr. 1, 2 te 3-4 stupa u slučaju d_{s1} , odnosno 3 i 4 stupa u slučaju d_{s2}) prikazan je u tablici 5. i tablici 6. te na slikama 6. do 9. Osim toga, na slici 10. prikazana je usporedba mjerjenih i predviđenih d_{s1} i d_{s2} po MLP i RBNN modelima te empirijskim modelima koji se tiču podataka podložnih ispitivanju (1 do 4 stupa u slučaju d_{s1} , odnosno 2 do 4 stupa u slučaju d_{s2}).

Kao što se vidi u tablici 5., MLP modeli (koji daju najbolje procjene za d_{s1} i d_{s2} od svih razvijenih MLP modela) koriste funkciju *transig* transfera u skrivenom sloju, što pokazuje nelinearni odnos između ulaznih i izlaznih varijabli. Rezultati u tablici 4. i tablici 5. jasno pokazuju da MLP modeli osiguravaju točnija i pouzdanija predviđanja za d_{s1} u slučaju 1 do 4 stupa, odnosno d_{s2} u slučaju 2 do 4 stupa u usporedbi s prethodnim empirijskim modelima (RMSE ≤ 6,62 mm, MAE ≤ 4,89 mm i $R^2 \geq 0,875$ u fazi učenja; RMSE ≤ 5,21 mm, MAE ≤ 4,44 mm i $R^2 \geq 0,802$ u fazi testiranja), što se također vidi na slici 10. Nadalje, određeno je da DS2MLP model točnije predviđa d_{s2} u slučaju 3 i 4 stupa u odnosu na prethodne empirijske modele (slika 10.). Međutim, prema statističkim mjerama pogreške, DS1B model omogućava nešto preciznija d_{s1} predviđanja za dva stupa nego DS1MLP model, a DS1MLP model omogućava nešto preciznija predviđanja nego DS1A i DS1C modeli za jedan stup i 3-4 stupa. Na temelju otkrića prikazanih na slikama 6. i 7.a do 7.d može se

reći da su svojstva dobivena MLP modelima manje raspršena i gotovo da padaju točno na pravilnu crtu, što znači da se izmjereni d_{s1} i d_{s2} točnije mogu predvidjeti MLP modelima. Štoviše, MLP modeli imaju veću vrijednost R^2 od 0,64 u slučaju različitog broja nagnutih stupova mosta i mogu se stoga koristiti za predviđanje stvaranja dubine podlokavanja ispred nagnutih stupova mosta [45]. Iz tog razloga, a zbog gore navedenih otkrića, može se zaključiti da se MLP modeli predloženi u ovom istraživanju mogu koristiti za preciznije predviđanje dubina podlokavanja ispred stupova mosta.

Rezultati u tablici 6. pokazuju da RBNN modeli daju preciznija predviđanja za d_{s1} i d_{s2} nego prethodni empirijski modeli (RMSE ≤ 4,68 mm, MAE ≤ 3,41 mm i $R^2 \geq 0,914$ u fazi učenja; RMSE ≤ 6,16 mm, MAE ≤ 5,75 mm i $R^2 \geq 0,710$ u fazi testiranja), što se također vidi na slici 10. Kao što je slučaj za MLP modele, utvrđeno je da je to značajno u predviđanju d_{s1} za 1 do 4 stupa mosta te d_{s2} za 3, 4 i 2 do 4 stupa mosta. Ipak, RBNN modeli neznatno su precizniji u predviđanju d_{s1} pri određenom broju nagnutih stupova mosta u usporedbi s DS1A, DS1B i DS1C modelima. Poput MLP modela, u fazama učenja i testiranja, RBNN modeli daju manje raspršena predviđanja za d_{s1} i d_{s2} koja gotovo točno padaju na pravilnu crtu (slika 8. i slika 9.). Štoviše, nije uočeno značajno precjenjivanje ni podcenjivanje predviđanja RBNN modela (slika 10.).

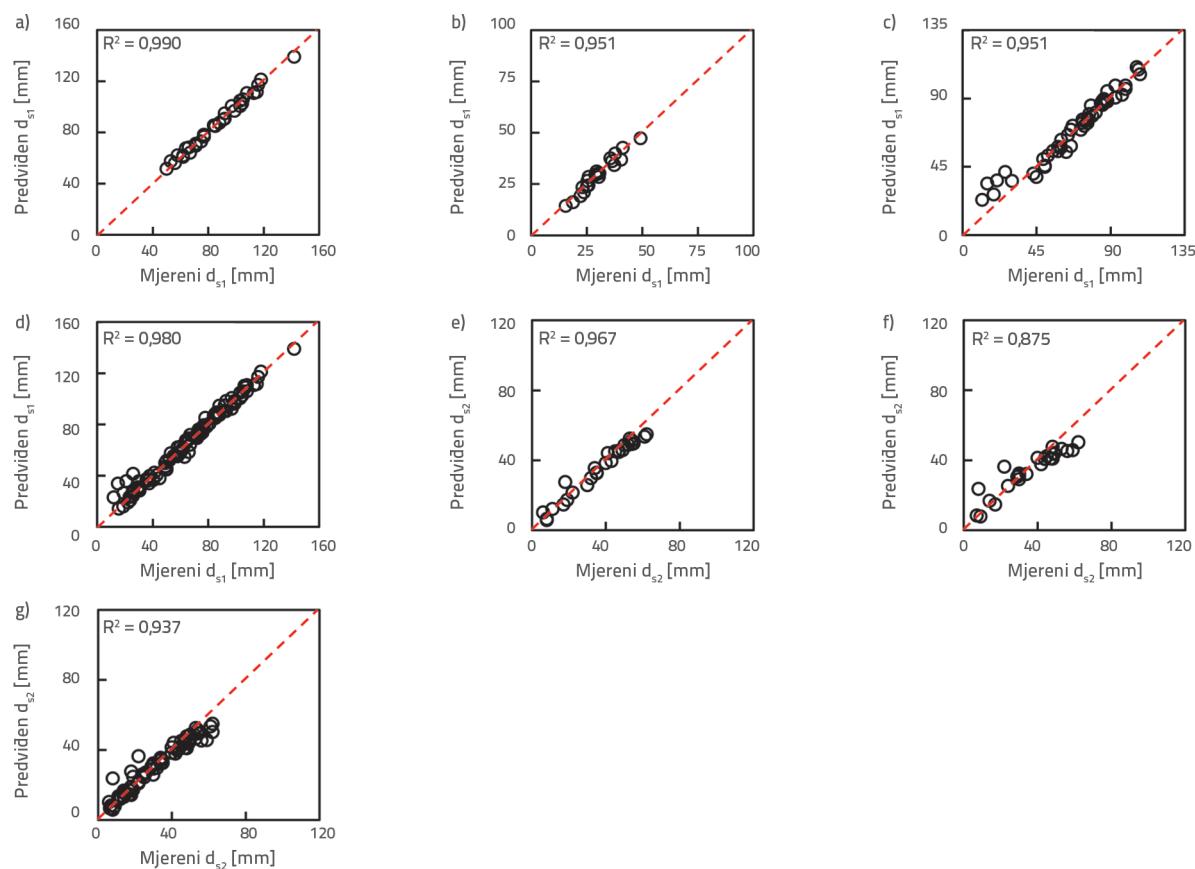
Kako je navedeno, MLP i RBNN modeli daju preciznija predviđanja za d_{s1} i d_{s2} u usporedbi s prethodnim empirijskim modelima. Iz usporede rezultata u tablici 5. i tablici 6. uočava se da DS1RBNN model daje preciznija predviđanja za d_{s1} nego DS1MLP model (tj. imaju niži RMSE i MAE, a viši R^2 u fazi testiranja). Ipak, DS2MLP model daje neznatno preciznija predviđanja nego DS2RBNN model (tj. imaju nižu RMSE (3,51 mm) i MAE (2,76 mm) za 2 do 4 stupa u fazi testiranja). Zato se nove empirijske formule za d_{s1} i d_{s2} dobivaju iz DS1RBNN i DS2MLP modela. Dobivene formule su prikazane i objašnjene detaljno u "Dodatku A. Dopunski materijal"

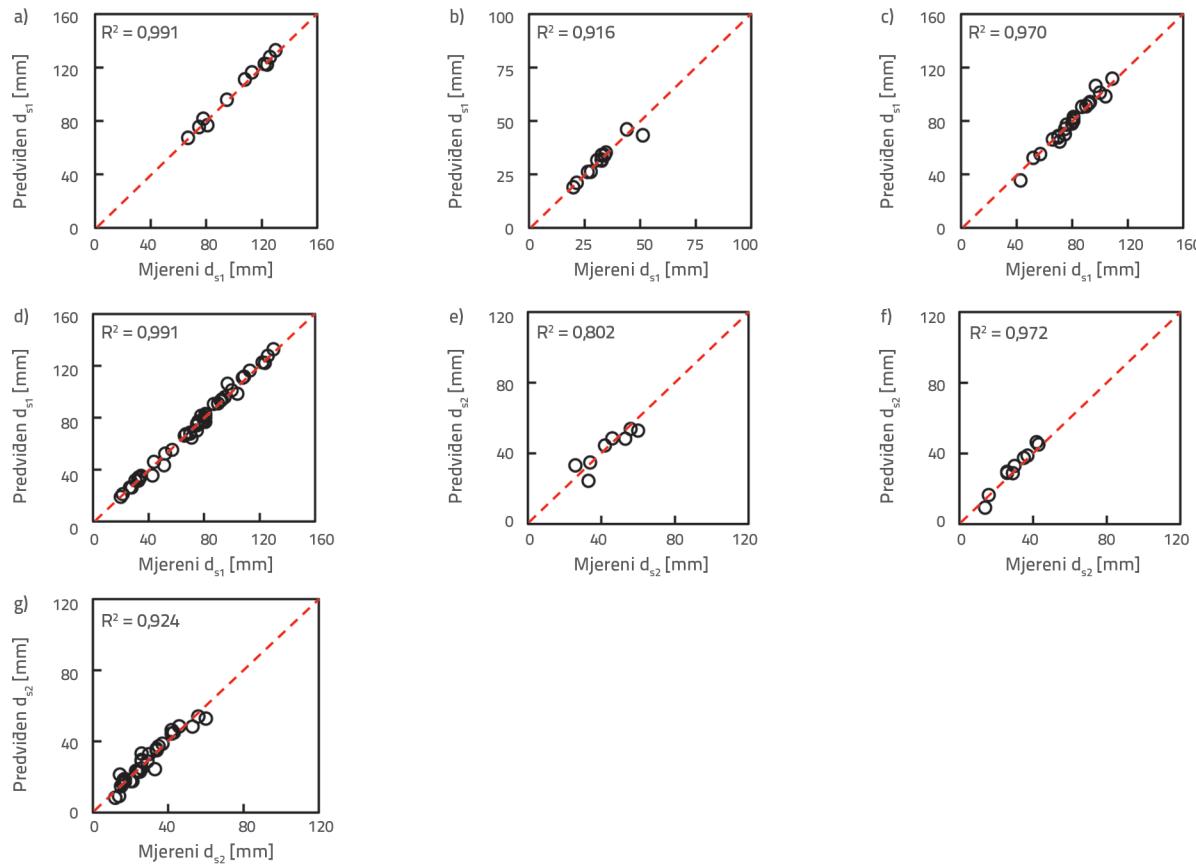
Tablica 5. RMSE, MAE i R^2 rezultati najboljega MLP modela za d_{s1} i d_{s2} u fazama učenja i testiranja

Modeli	Funkcije transfera		Broj skrivenih neurona	Izlaz	Broj stupova	Faza učenja			Faza testiranja		
	Skriveni sloj	Izlazni sloj				RMSE [mm]	MAE [mm]	R^2	RMSE [mm]	MAE [mm]	R^2
DS1MLP	Tansig	Purelin	3	d_{s1}	1	2,24	1,86	0,990	2,43	2,01	0,991
					2	1,98	1,69	0,951	2,55	1,55	0,916
					3 i 4	5,63	3,94	0,951	3,61	2,63	0,970
					1, 2, 3 i 4	4,20	2,83	0,980	3,09	2,19	0,991
DS2MLP	Logsig	Purelin	11	d_{s2}	3	3,65	2,94	0,967	5,21	4,44	0,802
					4	6,62	4,89	0,875	2,85	2,47	0,972
					2, 3 i 4	4,65	3,18	0,937	3,51	2,76	0,924

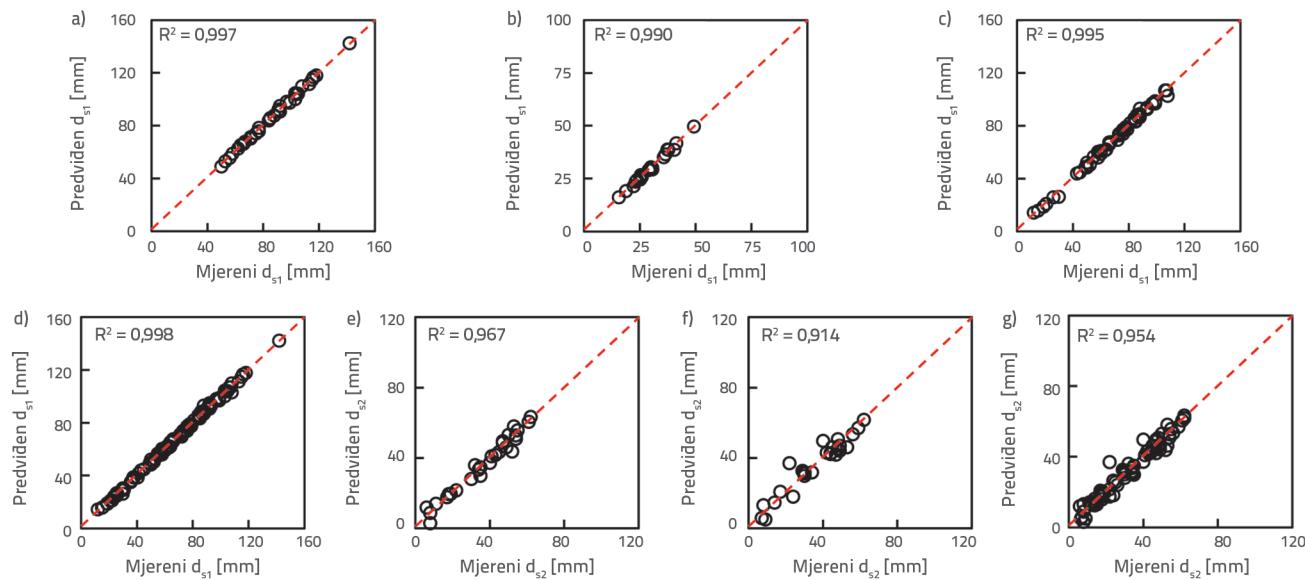
Tablica 6. RMSE, MAE i R² rezultati RBNN modela za d_{s_1} i d_{s_2} u fazama učenja i testiranja

Modeli	Koeficijent širenja	Broj skrivenih neurona	Izlaz	Broj stupova	Faza učenja			Faza testiranja		
					RMSE [mm]	MAE [mm]	R ²	RMSE [mm]	MAE [mm]	R ²
DS1RBNN	7	49	d_{s_1}	1	1,17	0,94	0,997	2,15	1,63	0,992
				2	0,79	0,62	0,990	0,95	0,85	0,992
				3 i 4	1,70	1,27	0,995	2,59	2,06	0,979
				1, 2, 3 i 4	1,40	1,03	0,998	2,16	1,63	0,995
DS2RBNN	1	21	d_{s_2}	3	3,08	2,35	0,967	6,16	5,75	0,710
				4	4,68	3,41	0,914	4,47	3,39	0,893
				2, 3 i 4	3,55	2,60	0,954	4,50	3,63	0,887

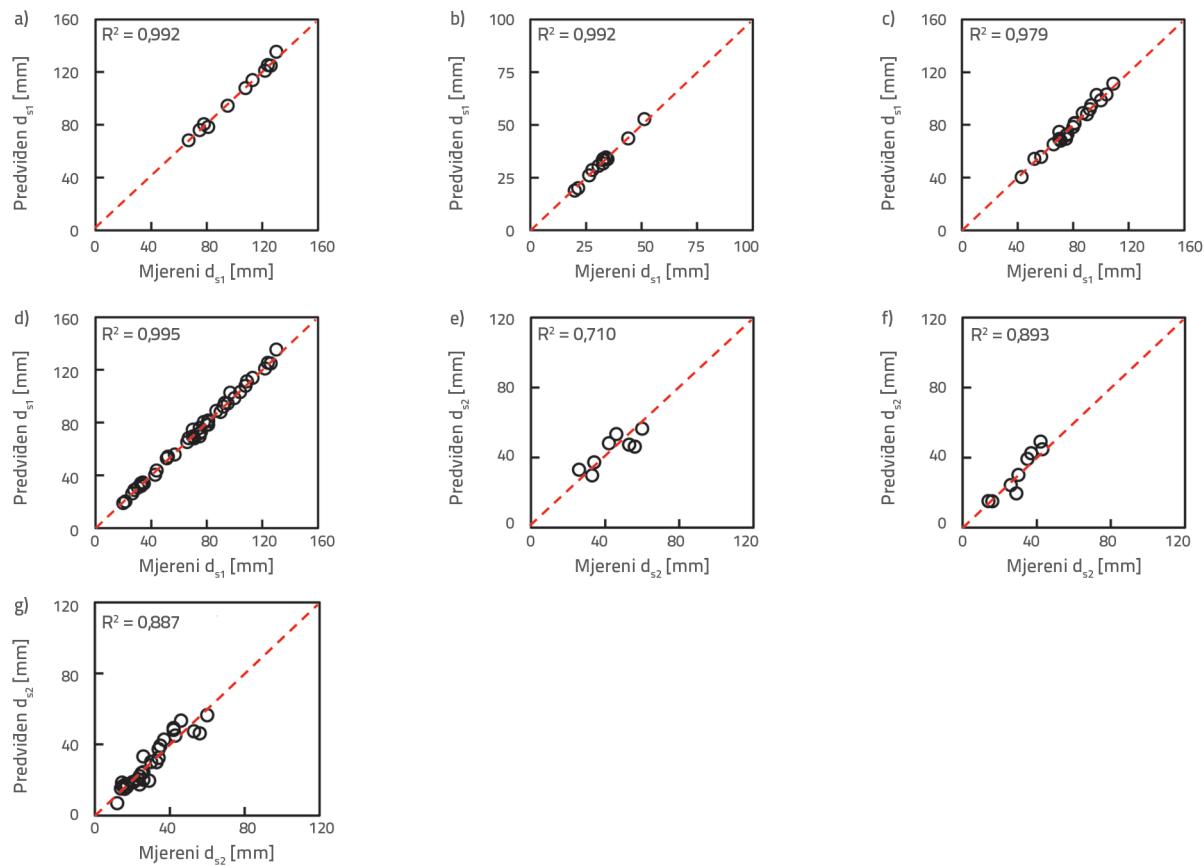
Slika 6. Usporedba mjerene i predviđene dubina podlokavanja (d_{s_1} i d_{s_2}) po MLP modelu u fazi učenja: a) DS1MLP model i 1 stup; b) DS1MLP model i 2 stupa; c) DS1MLP model i 3 i 4 stupa; d) DS1MLP model i 1 do 4 stupa; e) DS2MLP model i 3 stupa; f) DS2MLP model i 4 stupa; g) DS2MLP model i 2 do 4 stupa



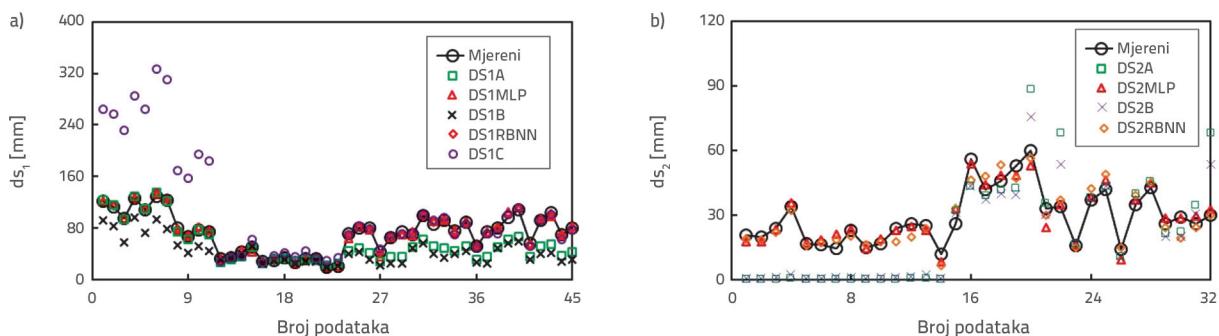
Slika 7. Usporedba mjereneih i predviđenihs dubina podlokavanja (d_{s1} i d_{s2}) po MLP modelu u fazi testiranja: a) DS1MLP model i 1 stup; b) DS1MLP model i 2 stupa; c) DS1MLP model i 3 i 4 stupa; d) DS1MLP model i 1 do 4 stupa; e) DS2MLP model i 3 stupa; f) DS2MLP model i 4 stupa; g) DS2MLP model i 2 do 4 stupa



Slika 8. Usporedba mjereneih i predviđenihs dubina podlokavanja (d_{s1} i d_{s2}) po RBNN modelu u fazi učenja: a) DS1RBNN model i 1 stup; b) DS1RBNN model i 2 stupa; c) DS1RBNN model i 3 i 4 stupa; d) DS1RBNN model i 1 do 4 stupa; e) DS2RBNN model i 3 stupa; f) DS2RBNN model i 4 stupa;



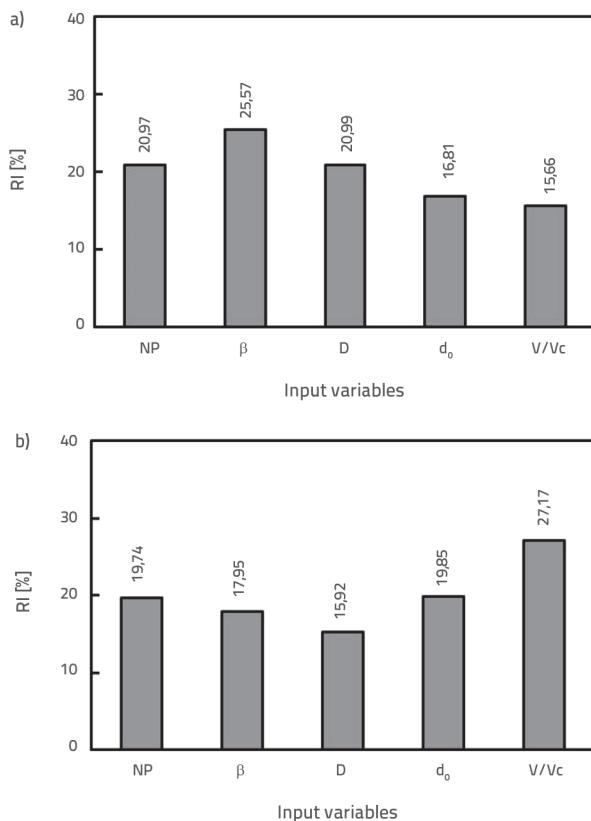
Slika 9. Usporedba mjereneh i predviđeneh dubina podlokavanja (d_{s1} i d_{s2}) po RBNN modelu u fazi testiranja: a) DS1RBNN model i 1 stup; b) DS1RBNN model i 2 stupa; c) DS1RBNN model i 3 i 4 stupa; d) DS1RBNN model i 1 do 4 stupa; e) DS2RBNN model i 3 stupa; f) DS2RBNN model i 4 stupa; g) DS2RBNN model i 2 do 4 stupa



Slika 10. Usporedba mjereneh i predviđeneh dubina podlokavanja po MLP modelu; RBNN modelu te empirijskim modelima u vezi s podacima koji su ispitivani: a) d_{s1} (1-11 za 1 stup; 12-23 za 2 stup; 24-33 za 3 stup i 34-45 za 4 stup) i b) d_{s2} (1-14 za 2 stup; 15-22 za 3 stup i 23-32 za 4 stup)

5.3. Analiza osjetljivosti

Provodi se niz analiza osjetljivosti kako bi se odredila relativna važnost ulaznih varijabli koje se koriste u DS1RBNN i DS2MLP modelima vezanim uz dubine lokalnog podlokavanja ispred nagnutih stupova mosta. Slika 11. prikazuje rezultate analize osjetljivosti.



Slika 11. Rezultati analiza osjetljivosti provedeni na: a) DS1RBNN i b) DS2MLP modelima

Prema otkrićima na slici 11., parametar koji najviše utječe na d_{s1} je kut nagiba stupa i vertikale (β) (25,57 %) nakon kojega slijedi dijametar stupa (D) (20,99 %), broj nagnutih stupova mosta (NP) (20,97 %), dubina prilaznog toka (d_0) (16,81 %) te intenzitet toka V/Vc (15,66 %). U prethodnim istraživanjima u kojima se ispitivala dubina lokalnog podlokavanja, odredilo se da je dijametar stupa najvažniji parametar koji utječe na dubinu podlokavanja ispred prvog stupa [22, 29]. Nasuprot tome, u ovom istraživanju određuje se da je kut nagiba najvažniji parametar, što se može pripisati promjeni toka koji smanjuje utjecaj vrtloga ispred stupa. Što se tiče važnosti dijametra stupa, može se reći da su rezultati na slici 11. (a) u skladu s prethodnim istraživanjima [22, 29]. Valja obratiti pozornost na to da je to prvo istraživanje koje pokazuje

važnost kuta nagiba stupa na dubinu podlokavanja. Rezultati jednako tako pokazuju da ulazne varijable koje se koriste u DS1RBNN modelu značajno utječu na formaciju d_{s1} . S druge pak strane, intenzitet toka (27,17 %) najviše utječe na d_{s2} nakon čega slijedi d_0 (19,85 %), NP (19,74 %), β (17,95 %), i D (15,29 %), Slika 11. Iako najmanje utječe na d_{s1} , pokazalo se da taj parametar najviše utječe na d_{s2} . Dok je raspon intenziteta toka širok za d_{s1} u eksperimentalnim podacima (0,30–1,86), nešto je uži za d_{s2} (0,30–0,94) što je uzrok povećanja važnosti intenziteta toka za d_{s2} . Međutim, to bi se trebalo dalje istražiti.

5.4. Ograničenja predloženih ANN modela

Unatoč tome što se ANN model može uspješno implementirati na složenim problemima, on ne može ispravno ekstrapolirati vrijednosti koje su izvan dosega podataka koji se koriste za učenje modela. Drugim riječima, zato što su konstrukcija ANN modela i njegove težine te parametri naginjanja određeni primjenom skupa podataka za učenje, ANN model može dati precizna predviđanja za vrijednosti koje su unutar ulaznih varijabli koje se koriste kad se razvija model. Iz tog su razloga empirijske formule predložene u ovom istraživanju, izrazi (15) i (19), pouzdane u vezi s rasponom ulaznih varijabli u tablici 3.

6. Zaključak

U ovom se istraživanju primjenjuju dvije različite ANN tehnike, višeslojni perceptron (MLP) i neuronska mreža s radikalnim baznim funkcijama (RBNN) s ciljem da se predlože nove empirijske jednadžbe za precizno i pouzdano predviđanje dubina podlokavanja koje se formiraju ispred nagnutih stupova mosta. Prethodno skupljeni laboratorijski podaci koriste se kako bi se trenirali MLP i RBNN modeli te kako bi se ispitao njihov učinak predviđanja. Rezultati jasno pokazuju da MLP i RBNN modeli daju veća predviđanja d_{s1} i d_{s2} u usporedbi s prethodnim empirijskim modelima. Jednako tako, provodi se niz analiza osjetljivosti kako bi se odredili parametri koji najviše utječu na dubinu podlokavanja ispred nagnutih stupova mosta. Ovo istraživanje otkriva da je kut nagiba stupa prevladavajući parametar za d_{s1} . Intenzitet toka prevladavajući je parametar za d_{s2} , a istovremeno je određen kao parametar koji najmanje utječe na d_{s1} . Na temelju tih otkrića nove empirijske jednadžbe koje se predlažu u ovom istraživanju mogu se koristiti za precizno predviđanje dubina podlokavanja ispred prednjih i stražnjih stupova. Empirijske jednadžbe nastaju na temelju rezultata laboratorijskih eksperimenata. U svrhu budućih istraživanja jednadžbe se mogu ispitati kako bi se izračunala dubina podlokavanja u stvarnosti.

LITERATURA

- [1] Mohammed, T.A., Megat, J.M.M.N., Ghazali, A.H., Yusuf, B., Saed, K.: Physical Modeling of Local Scouring around Bridge Piers in Erodable Bed, *J. King Salld. Univ.*, 19 (2007) 2, pp. 195-207, doi.org/10.1016/s1018-3639(18)30947-4.
- [2] Melville, B.W., Sutherland, A.J.: Design method for local scour at bridge piers, *J. Hydraul. Eng.*, 114 (1988) 10, pp. 1210-1226, doi.org/10.1061/(asce)0733-9429(1988)114:10(1210).
- [3] Raudkivi, A.J., Ettema, R.: Clear water scour at cylindrical piers, *J. Hydraul. Eng.*, 109 (1983) 3, pp. 338-350, doi.org/10.1061/(asce)0733-9429(1983)109:3(338).
- [4] Melville, B.W.: Pier and abutment scour: integrated approach, *J. Hydraul. Eng.*, 123 (1997) 2, pp. 125-136, doi.org/10.1061/(asce)0733-9429(1997)123:2(125).
- [5] Chiew, Y.M.: Scour protection at bridge piers, *J. Hydraul. Eng.*, 118 (1992) 9, pp. 1260-1269, doi.org/10.1061/(asce)0733-9429(1992)118:9(1260).
- [6] Christian, C., Gonzalo, S., Luis, T.: New Experimental Method to Find Equilib., *J. Hydraul. Eng.*, 134 (2008) 10, pp. 1491-1495
- [7] Guan, D., Chiew, Y.M., Wei, M., Hsieh, S.C.: Characterization of horseshoe vortex in a developing scour hole at a cylindrical bridge pier, *International Journal of Sediment Research*, 34 (2019) 2, pp. 118-124, https://doi.org/10.1016/j.ijsc.2018.07.001.
- [8] Chiew, Y.M., Lai, J.S., Link, O.: Experimental, numerical and field approaches to scour research, *Water*, 12 (2020) 6, https://doi.org/10.3390/W12061749.
- [9] Yang, Y., Melville, B.W., Macky, G.H., Shamseldin, A.Y.: Local scour at complex bridge piers in close proximity under clear-water and live-bed flow regime, *Water*, 11 (2019) 8, https://doi.org/10.3390/w11081530.
- [10] Harasti, A., Gilja, G., Potočki, K., Lacko, M.: Scour at bridge piers protected by the riprap sloping structure: A review, *Water*, 13 (2021) 12, https://doi.org/10.3390/w13243606.
- [11] Pizarro, A., Manfreda, S., Tubaldi, E.: The science behind scour at bridge foundations: A review, *Water*, 12 (2020) 2, https://doi.org/10.3390/w12020374.
- [12] Bozkus, Z., Yıldız, O.: Effects of Inclination of Bridge Piers on Scouring Depth, *J. Hydraul. Eng.*, 130 (2004) 8, pp. 827-832, https://doi.org/10.1061/ASCE0733-94292004130:8827.
- [13] Bozkus, Z., Çeşme, M.: Reduction of scouring depth by using inclined piers, *Canadian Journal of Civil Engineering*, 37 (2010) 12, pp. 1621-1630, https://doi.org/10.1139/L10-099.
- [14] Bozkus, Z., Özalp, M.C., Dinçer, A.E.: Effect of Pier Inclination Angle on Local Scour Depth Around Bridge Pier Groups, *Arab. J. Sci. Eng.*, 43 (2018) 10, pp. 5413-5421, https://doi.org/10.1007/s13369-018-3141-2.
- [15] Karimi, N., Heidarnejad, M., Masjedi, A.: Scour depth at inclined bridge piers along a straight path: A laboratory study, *Engineering Science and Technology*, 20 (2017) 4, pp. 1302-1307, https://doi.org/10.1016/j.jestch.2017.07.004.
- [16] Khajeh, S.B.M., Vaghefi, M., Mahmoudi, A.: The scour pattern around an inclined cylindrical pier in a sharp 180-degree bend: An experimental study, *International Journal of River Basin Management*, 15 (2017) 2, pp. 207-218, https://doi.org/10.1080/15715124.2016.1274322.
- [17] Vaghefi, M., Ghodsian, M., Salimi, S.: Scour Formation Due to Laterally Inclined Circular Pier, *Arab. J. Sci. Eng.*, 41 (2016) 4, pp. 1311-1318, https://doi.org/10.1007/s13369-015-1920-6.
- [18] Aghaee-Shalmani, Y., Hakimzadeh, H.: Experimental investigation of scour around semi-conical piers under steady current action, *European Journal of Environmental and Civil Engineering*, 19 (2015) 6, pp. 717-732, https://doi.org/10.1080/19648189.2014.968742.
- [19] Anilan, T., Nacar, S., Kankal, M., Yuksek, O.: Prediction of maximum annual flood discharges using artificial neural network approaches, *Građevinar*, 72 (2020) 3, pp. 215-224, https://doi.org/10.14256/JCE.2316.2018.
- [20] Berbić, J., Ocvirk, E., Gilja, G.: Comparison of supervised learning methods for prediction of monthly average flow, *Građevinar*, 70 (2018) 8, pp. 643-656, https://doi.org/10.14256/JCE.2102.2017.
- [21] Kovačević, M., Ivanišević, N., Dašić, T., Marković, L.: Application of artificial neural networks for hydrological modelling in karst, *Građevinar*, 70 (2018) 1, pp. 1-10, https://doi.org/10.14256/JCE.1594.2016.
- [22] Bateni, S.M., Borghei, S.M., Jeng, D.S.: Neural network and neuro-fuzzy assessments for scour depth around bridge piers, *Eng. Appl. Artif. Intell.*, 20 (2007) 3, pp. 401-414, https://doi.org/10.1016/j.engappai.2006.06.012.
- [23] Lee, T.L., Jeng, D.S., Zhang, G.H., Hong, J.H.: Neural Network Modeling for Estimation of Scour Depth around Bridge Piers, *Journal of Hydrodynamics*, 19 (2007) 3, pp. 378-386, doi.org/10.1016/s1001-6058(07)60073-0.
- [24] Kaya, A.: Artificial neural network study of observed pattern of scour depth around bridge piers, *Comput. Geotech.*, 37 (2010) 3, pp. 413-418, https://doi.org/10.1016/j.compgeo.2009.10.003.
- [25] Sreedhara, B.M., Rao, M., Mandal, S.: Application of an evolutionary technique (PSO-SVM) and ANFIS in clear-water scour depth prediction around bridge piers, *Neural Comput. Appl.*, 31 (2019) 11, pp. 7335-7349, https://doi.org/10.1007/s00521-018-3570-6.
- [26] Bui, D.T. et al.: A hybrid intelligence approach to enhance the prediction accuracy of local scour depth at complex bridge piers, *Sustainability*, 12 (2020) 3, https://doi.org/10.3390/su12031063.
- [27] Qaderi, K., Javadi, F., Madadi, M.R., Ahmadi, M.M.: A comparative study of solo and hybrid data driven models for predicting bridge pier scour depth, *Marine Georesources and Geotechnology*, 39 (2021) 5, pp. 589-599, https://doi.org/10.1080/1064119X.2020.1735589.
- [28] Cheng, M.Y., Cao, M.T., Wu, Y.W.: Predicting Equilibrium Scour Depth at Bridge Piers Using Evolutionary Radial Basis Function Neural Network, *Journal of Computing in Civil Engineering*, 29 (2015) 5, pp. 04014070, https://doi.org/10.1061/(asce)cp.1943-5487.0000380.
- [29] Hosseini, R., Fazloula, R., Saneie, M., Amini, A.: Bagged neural network for estimating the scour depth around pile groups, *International Journal of River Basin Management*, 16 (2018) 4, pp. 401-412, https://doi.org/10.1080/15715124.2017.1372449.
- [30] Özalp, M.C.: Experimental Investigation of Local Scour Around Bridge Pier Groups, *Middle East Technical University*, Ankara, 2013.
- [31] Güllü, H., Fedakar, H.i.: On the prediction of unconfined compressive strength of silty soil stabilized with bottom ash, jute and steel fibers via artificial intelligence, *Geomechanics and Engineering*, 12 (2017) 3, pp. 441-464, https://doi.org/10.12989/gae.2017.12.3.441.

- [32] Cybenkot, G.: Approximation by Superpositions of a Sigmoidal Function, *Math. Control Signals Systems*, 2 (1989), pp. 303-314, doi.org/10.1007/bf02551274.
- [33] Hornik, K.: Multilayer Feedforward Networks are Universal Approximators, *Neural Networks*, 2 (1989) 1, pp. 359-366, doi.org/10.1016/0893-6080(89)90020-8.
- [34] Haykin, S., Haykin, S.: Neural Networks: A Comprehensive Foundation (2nd Edition -Prentice Hall), Delhi, 1998.
- [35] Leonard, J.A., Kramer, M.A., Ungar, L.H.: Using Radial Basis Functions to Approximate a Function and Its Error Bounds, *IEEE Trans Neural Netw.*, 3 (1992) 4, pp. 624-627, https://doi.org/10.1109/72.143377.
- [36] Lee, G.C., Chang, S.H.: Radial basis function networks applied to DNBR calculation in digital core protection systems, *Ann Nucl. Energy*, 30 (2003) 15, pp. 1561-1572, https://doi.org/10.1016/S0306-4549(03)00099-9.
- [37] Gencel, O., Koksal, F., Sahin, M., Durgun, M.Y., Lobland, H.E.H., Brostow, W.: Modeling of thermal conductivity of concrete with vermiculite using by artificial neural networks approaches, *Experimental Heat Transfer*, 26 (2013) 4, pp. 360-383, https://doi.org/10.1080/08916152.2012.669810.
- [38] Kisi, O.: The potential of different ANN techniques in evapotranspiration modelling, *Hydrol. Process.*, 22 (2008) 14, pp. 2449-2460, https://doi.org/10.1002/hyp.6837.
- [39] Kocabas, F., Unal, S.: Compared techniques for the critical submergence of an intake in water flow, *Advances in Engineering Software*, 41 (2010) 5, pp. 802-809, https://doi.org/10.1016/j.advengsoft.2009.12.021.
- [40] Goh, A.T.C.: Back-propagation neural networks for modeling complex systems, *Artificial Intelligence in Engineering*, 9 (1995), pp. 143-151, doi.org/10.1016/0954-1810(94)00011-s.
- [41] Gevrey, M., Dimopoulos, I., Lek, S.: Review and comparison of methods to study the contribution of variables in artificial neural network models, *Ecol Modell.*, 160 (2003) 1, pp. 249-264, doi.org/10.1016/s0304-3800(02)00257-0.
- [42] Ghorbani, B., Arulrajah, A., Narsilio, G., Horplibulsuk, S., Bo, M.W.: Development of genetic-based models for predicting the resilient modulus of cohesive pavement subgrade soils, *Soils and Foundations*, 60 (2020) 2, pp. 398-412, https://doi.org/10.1016/j.sandf.2020.02.010.
- [43] Gandomi, A.H., Yang, X.S., Talatahari, S., Alavi, A.H.: Metaheuristic Algorithms in Modeling and Optimization, *Metaheuristic Applications in Structures and Infrastructures*, 2013., pp. 1-24, https://doi.org/10.1016/B978-0-12-398364-0.00001-2.
- [44] Fedakar, H.I.: Developing New Empirical Formula for the Resilient Modulus of Fine-Grained Subgrade Soils Using a Large Long-Term Pavement Performance Dataset and Artificial Neural Network Approach, *Transportation Research Record*, 2676 (2022) 4, pp. 58-75, https://doi.org/10.1177/03611981211057054.
- [45] Ferguson, C.J.: An Effect Size Primer: A Guide for Clinicians and Researchers, *Prof. Psychol. Res. Pr.*, 40 (2009) 5, pp. 532-538, https://doi.org/10.1037/a0015808.

Dodatak A.

Izrazi (A1) do (A8) opisuju korake u izračunu empirijske formule koja se dobiva iz RBNN i MLP modela. Prvo se izrazima (A1) i (A5) svaka ulazna varijabla koja se koristi u ANN modelima (DS1RBNN i DS2MLP) normalizirala između -1 i +1. RBNN model koristi funkciju radijalnog baznog transfera u skrivenom sloju i funkciju purelin transfera u izlaznom sloju. Ulaganje u funkciju radijalnog baznog transfera (x) je vektorska udaljenost između w_{ih} i ulaznog vektora (Inputs) pomnoženi s B_h (i.e., $x = \|w_{ih} - \text{Inputs}\| * B_h$).

$$[\text{Inputs}]_{ds1} = \begin{bmatrix} (NP)_n = \frac{NP-1}{4-1} - \frac{4-NP}{4-1} \\ (\beta)_n = \frac{\beta-0}{15-0} - \frac{15-\beta}{15-0} \\ (D)_n = \frac{D-5}{10-5} - \frac{10-D}{10-5} \\ (d_0)_n = \frac{d_0-3.70}{17.50-3.70} - \frac{17.50-d_0}{17.50-3.70} \\ (V/V_c)_n = \frac{V/V_c-0.30}{1.86-0.30} - \frac{1.86-V/V_c}{1.86-0.30} \end{bmatrix} \quad (A1)$$

$\text{Inputs} * B_h / \|w_{ih} - \text{Inputs}\| = (w_{ih} - \text{Inputs})^{0.5}$, izraz (A3). $[x]_{ds1}$ i $[x]_{ds2}$ u izrazima (A2) i (A6) matrice su skrivenih neuronskih rezultata (odnosno dobivenih nakon što se primijenila funkcija transfera na skrivene neurone) na DS1RBNN i DS2MLP modelima. Izrazi odstupanja koji se koriste u izlaznim slojevima (B_h) DS1RBNN i DS2MLP modela odredili su se kao 64,04687 odnosno -0,7507 (izrazi (A4) i (A8)). Izrazi (A9) do (A14) daju matrice $[w_{ih}]_{ds1}$, $[w_{ho}]_{ds1}$, $[B_h]_{ds1}$, $[w_{ih}]_{ds2}$, $[w_{ho}]_{ds2}$ i $[B_h]_{ds2}$.

$$[x]_{ds1} = \begin{bmatrix} e^{-((x_{ds1})_1)^2} \\ e^{-((x_{ds1})_2)^2} \\ e^{-((x_{ds1})_3)^2} \\ \vdots \\ e^{-((x_{ds1})_{49})^2} \end{bmatrix} \quad (A2)$$

$$(x_{ds1})_i = \sqrt{\sum_{j=1}^5 \left(((W_{ih})_{ds1})_{i,j} - ((\text{Inputs})_{ds1})_{j,1} \right)^2} \cdot ((B_h)_{ds1})_{i,1} \quad (i:1 \text{ do } 49) \quad (A3)$$

$$ds_1 = \left([w_{ho}]_{ds1} [x]_{ds1} + 64.04687 \right) 65 + 77 \quad (A4)$$

$$[\text{Inputs}]_{ds2} = \begin{bmatrix} (\text{NP})_n = \frac{\text{NP}-2}{4-2} - \frac{4-\text{NP}}{4-2} \\ (\beta)_n = \frac{\beta-0}{15-0} - \frac{15-\beta}{15-0} \\ (\text{D})_n = \frac{\text{D}-5}{7-5} - \frac{7-\text{D}}{7-5} \\ (\text{d}_0)_n = \frac{\text{d}_0-3.70}{17.50-3.70} - \frac{17.50-\text{d}_0}{17.50-3.70} \\ (\text{V}/\text{V}_c)_n = \frac{\text{V}/\text{V}_c-0.30}{0.94-0.30} - \frac{0.94-\text{V}/\text{V}_c}{0.94-0.30} \end{bmatrix} \quad (\text{A5})$$

$$[\text{x}]_{ds2} = \begin{bmatrix} \frac{1}{1+e^{-(x_{ds2})_1}} \\ \frac{1}{1+e^{-(x_{ds2})_2}} \\ \frac{1}{1+e^{-(x_{ds2})_3}} \\ \vdots \\ \frac{1}{1+e^{-(x_{ds2})_{11}}} \end{bmatrix} \quad (\text{A6})$$

$$(x_{ds2})_i = \sum_{j=1}^5 \left(((W_{ih})_{ds2})_{i,j} \cdot ((\text{Inputs})_{ds2})_{j,1} \right) + ((B_h)_{ds2})_{i,1} \quad (\text{A7})$$

(i:1 do 11)

$$ds_2 = \left([w_{ho}]_{ds2} [x]_{ds2} - 0.7507 \right) 28 + 34 \quad (\text{A8})$$

$$[W_{ih}]_{ds1} = \begin{bmatrix} -0.3333 & 1 & -1 & 1 & -0.8186 \\ -1 & -0.3333 & 1 & -0.0870 & 0.76884 \\ 1 & 1 & -0.2 & -0.4638 & -0.1814 \\ 1 & 1 & -0.2 & -0.6087 & -0.2542 \\ -1 & -0.7333 & 1 & -0.6667 & 0.3103 \\ 0.3333 & 1 & -0.2 & -0.8551 & -0.5006 \\ -1 & 1 & 1 & 0.2754 & 1 \\ -1 & -0.7333 & -1 & 0.2754 & 1 \\ -0.3333 & 1 & -1 & 0.5797 & -0.8531 \\ -1 & -0.3333 & -1 & -0.0870 & 0.7688 \\ -0.3333 & 1 & -0.2 & 1 & -0.8186 \\ 0.3333 & 1 & -1 & -0.4638 & -0.1814 \\ 0.3333 & 1 & -1 & -1 & -0.6245 \\ -0.3333 & 1 & -0.2 & -0.4493 & -0.9642 \\ -1 & 0.3333 & -1 & -0.4493 & 0.4981 \\ -0.3333 & 1 & -1 & -0.4493 & -0.9642 \\ -1 & 1 & -1 & -0.4493 & 0.4981 \\ 1 & 1 & -1 & -0.8551 & -0.5006 \\ 1 & 1 & -1 & -0.7536 & -0.3372 \\ -0.3333 & 1 & -1 & -0.6957 & -1 \\ -1 & -0.3333 & 1 & -0.8116 & 0.1699 \\ 1 & -1 & -0.2 & -1 & -0.6245 \\ 0.3333 & 1 & -0.2 & -1 & -0.6245 \\ 1 & 1 & -0.2 & -0.5362 & -0.2184 \\ -1 & 0.3333 & 1 & -0.2319 & 0.6654 \\ 1 & -1 & -0.2 & -0.7536 & -0.3372 \\ 1 & 1 & -1 & -0.6087 & -0.2542 \\ -1 & 1 & 1 & -0.0870 & 0.7688 \\ 1 & 1 & -1 & -0.4638 & -0.1814 \\ 1 & 1 & -0.2 & -1 & -0.6245 \\ -0.3333 & 0.3333 & -1 & 0.5797 & -0.8531 \\ 0.3333 & 1 & -1 & -0.7536 & -0.3372 \\ -1 & 1 & 1 & -0.8116 & 0.1699 \\ -1 & 1 & 1 & -0.3768 & 0.5556 \\ -1 & 1 & 1 & -0.6667 & 0.3103 \\ -1 & 1 & -1 & 0.2754 & 1 \\ 0.3333 & 1 & -0.2 & -0.7536 & -0.3372 \\ -1 & 1 & -1 & -0.2681 & 0.6398 \\ -0.3333 & 1 & -0.2 & 0.2754 & -0.8851 \\ -1 & 1 & -1 & -0.0870 & 0.7688 \\ -1 & 1 & 1 & -0.5217 & 0.4381 \\ 1 & 1 & -1 & -1 & -0.6245 \\ 0.3333 & 1 & -0.2 & -0.6087 & -0.2542 \\ 0.3333 & 1 & -0.2 & -0.5362 & -0.2184 \\ 0.3333 & -1 & -0.2 & -0.4638 & -0.1814 \\ -1 & -0.7333 & 1 & 0.2754 & 1 \\ -0.3333 & -1 & -1 & 0.5797 & -0.8531 \\ -1 & 0.3333 & 1 & -0.8116 & 0.1699 \\ 0.3333 & 0.3333 & -1 & -0.5362 & -0.2184 \end{bmatrix} \quad (\text{A9})$$

$$(A10) \quad [(W_{ho})_{ds1}]^T = \begin{bmatrix} -4538704.59 \\ -43673.80 \\ 191505513.21 \\ 126126178.99 \\ 7164.04 \\ -233114953.61 \\ 27814369.97 \\ -12220.59 \\ 6943159.08 \\ 27386.20 \\ 1848518.25 \\ 22767100.85 \\ 10400965.05 \\ -2616772.65 \\ -22118.07 \\ -12566738.48 \\ 70508155.66 \\ 209367029.44 \\ 491790942.28 \\ 987387.06 \\ -2763.40 \\ -2613.63 \\ 225898050.64 \\ -323026410.43 \\ 26802.22 \\ 4823.34 \\ -867020966.11 \\ -355407809.74 \\ 346786144.26 \\ 4785349.30 \\ 640.75 \\ -33501361.09 \\ -859410528.07 \\ 2524371839.49 \\ 3329063735.95 \\ -23114628.11 \\ -1050816258.93 \\ -184899830.08 \\ 85123.67 \\ 137838909.43 \\ -4666450319.75 \\ -180647166.50 \\ 2805809418.85 \\ -1746455766.97 \\ -3285.15 \\ 16821.29 \\ 289.54 \\ 5762.31 \\ -729.78 \end{bmatrix}$$

$$(A11) \quad [B_h]_{ds1} = \begin{bmatrix} 0.11894 \\ 0.11894 \end{bmatrix}$$

$$(A12) \quad [W_{ih}]_{ds2} = \begin{bmatrix} -5.4522 & 2.0328 & -4.6465 & -2.4832 & -3.6207 \\ -0.3297 & 0.5104 & -0.2894 & -0.1265 & 3.8967 \\ 2.6874 & 4.6845 & 1.6933 & 4.1757 & 1.4625 \\ -2.7495 & 4.6263 & 0.3222 & 5.1695 & 6.2612 \\ -4.6677 & -6.8588 & 0.4018 & -3.3321 & -0.4498 \\ 4.7981 & 1.8756 & 4.2827 & 0.2654 & 7.6707 \\ 0.4246 & -0.2632 & 2.3459 & 4.4322 & 4.5168 \\ -0.0877 & -2.8274 & -1.8966 & -3.5597 & -2.7981 \\ 4.2185 & 1.0157 & -2.6210 & -1.6741 & 2.1604 \\ -7.1621 & -2.7983 & -1.5070 & 1.6558 & 1.3327 \\ -0.3477 & 1.2702 & -3.3066 & 3.3365 & 3.0262 \end{bmatrix} \quad (A12)$$

$$(A13) \quad [(W_{ho})_{ds2}]^T = \begin{bmatrix} -0.1821 \\ 2.1137 \\ -0.2918 \\ -0.0848 \\ 0.1159 \\ 0.1370 \\ 0.5118 \\ -0.2318 \\ 0.0681 \\ 0.4111 \\ -0.4478 \end{bmatrix} \quad (A13)$$

$$(A14) \quad [B_h]_{ds2} = \begin{bmatrix} 2.7360 \\ -3.9680 \\ -2.5328 \\ 2.4190 \\ -5.1266 \\ 0.2650 \\ 4.3694 \\ -2.5586 \\ 4.5601 \\ -4.1516 \\ -4.3449 \end{bmatrix} \quad (A14)$$