

Primljen / Received: 21.9.2012.

Ispravljen / Corrected: 19.2.2013.

Prihvaćen / Accepted: 21.2.2013.

Dostupno online / Available online: 10.5.2013.

# Projektiranje nasipa željezničkih pruga primjenom neuronskih mreža

## Autori:



Prof.dr.sc. **Gökmen Tayfur**, dipl.ing.građ.  
Tehnološki institut u Izmiru  
Odjel za građevinarstvo  
gokmentayfur@iyte.edu.tr



Prof.dr.sc. **İsfendiyar Egeli**, dipl.ing.građ.  
Tehnološki Institut u Izmiru  
Odjel za građevinarstvo  
isfendiyaregeli@iyte.edu.tr

Prethodno priopćenje

[Gökmen Tayfur, İsfendiyar Egeli](#)

## Projektiranje nasipa željezničkih pruga primjenom neuronskih mreža

Osnovni zahtjev pri projektiranju nasipa željezničkih pruga za velike brzine su male vrijednosti ukupnih diferencijalnih slijeganja. U radu se analizira primjena cementom stabiliziranih slojeva u nasipima u odnosu na nestabilizirane slojeve koji se najčešće koriste. Razmatrani su različiti udjeli cementa te različiti vodocementni faktori u stabiliziranom sloju. Dobiveno je da primjena cementom stabiliziranih slojeva u nasipima može značajno smanjiti debljinu pojedinih slojeva te smanjiti slijeganja. Istraživanje je provedeno primjenom prema naprijed usmjerene neuronske mreže.

### Ključne riječi:

željeznice za velike brzine, željeznički nasipi, prema naprijed usmjerena neuronska mreža (FFNN)

Preliminary note

[Gökmen Tayfur, İsfendiyar Egeli](#)

## Railway embankment design based on neural networks

The main requirement in the design of high-speed railway embankments are low values of total differential settlements. The use of cement stabilized layers in embankments, as compared to non-stabilized layers that are now most often in use, is analysed in the paper. Different cement proportions and different water/cement ratios for stabilized layers are considered. It was established that the use of cement stabilized layers in embankments can greatly reduce thickness of individual layers, while also reducing settlement. The research was conducted using the feed forward neural network.

### Key words:

high speed railways, railway embankments, feed forward neural network

Vorherige Mitteilung

[Gökmen Tayfur, İsfendiyar Egeli](#)

## Entwurf von Eisenbahndämmen durch die Anwendung neuronaler Netze

Die Grundanforderung beim Entwurf von Eisenbahndämmen für Hochgeschwindigkeitszüge sind eingeschränkte Werte der gesamten ungleichmäßigen Setzungen. In der vorliegenden Arbeit wird die Anwendung von mit Zement stabilisierten Unterbauschichten im Vergleich zu herkömmlichen Schichten ohne Stabilisierung untersucht. Der Gebrauch verschiedener Zementanteile und Wasserzementwerte in der stabilisierten Schicht ist betrachtet worden. Die Ergebnisse lassen darauf schließen, dass durch die Verwendung mit Zement stabilisierter Schichten, die Abmessungen der einzelnen Schichten bedeutend reduziert und Setzungen vermindern werden können. Für die gegebenen Untersuchungen sind vorwärts gerichtete neuronale Netze angewandt worden.


### Schlüsselwörter:

Hochgeschwindigkeitseisenbahnen, Eisenbahndämme, vorwärts gerichtetes neuronales Netz (FFNN)

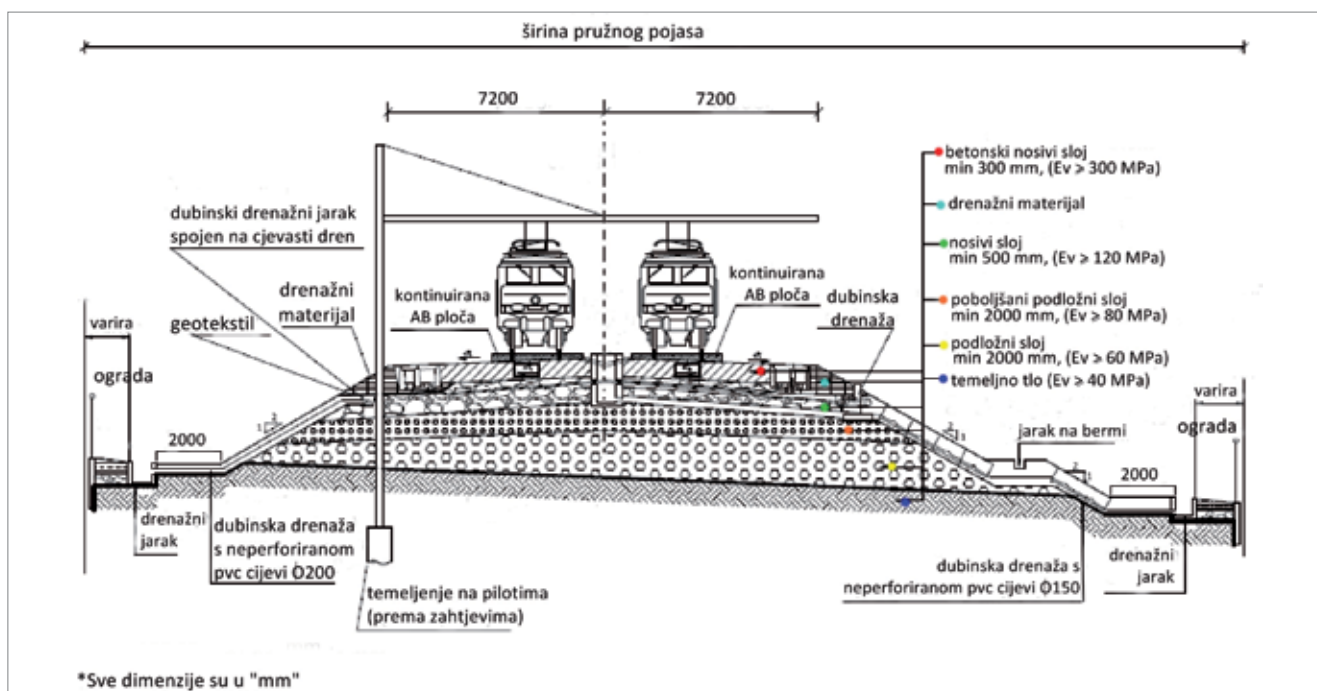
### 1. Uvod

Putovanje željeznicama velikih brzina u današnje vrijeme postaje sve poželjniji način prijevoza zato što takvi tračnički sustavi omogućuju, među ostalim, kraće vrijeme putovanja, sigurnost i udobnost. Projektiranje nasipa za željeznice velikih brzina (eng. High Speed Railway – HSR) razlikuje se od projektiranja nasipa klasičnih željezničkih pruga i to u sljedećem: zahtijevaju se veće dimenzije, veći su zahtjevi na kvalitetu materijala te se zahtijevaju

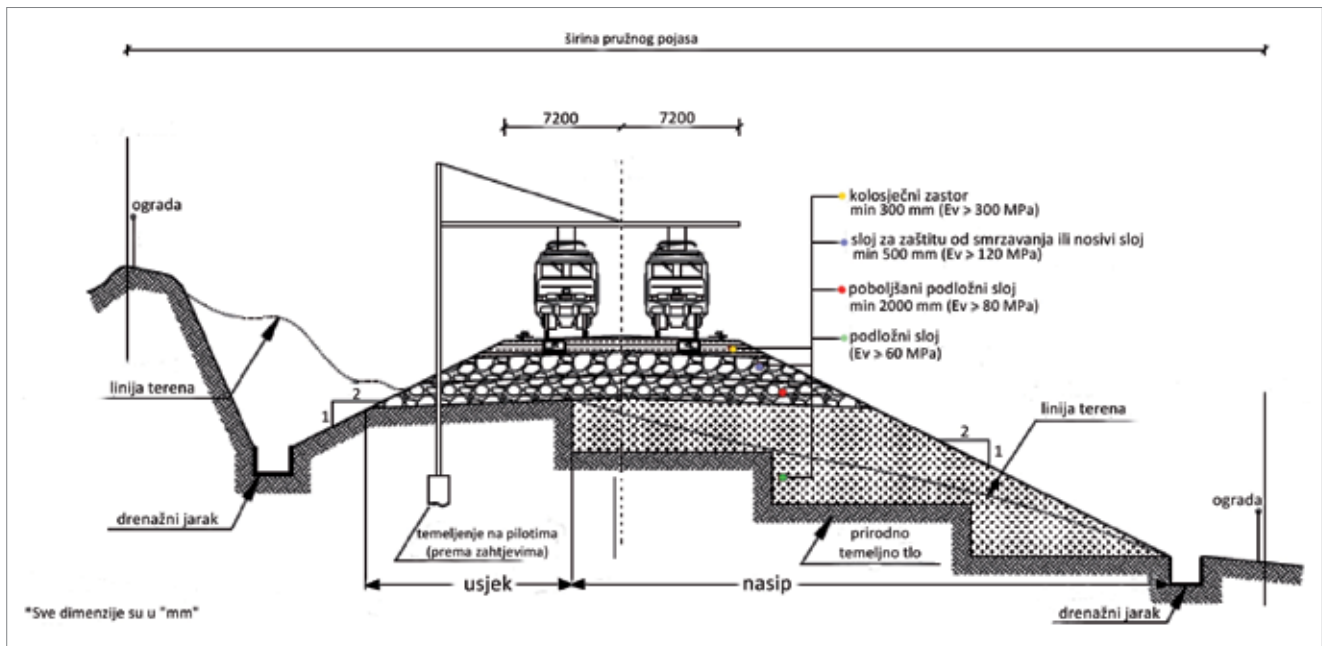
vrlo male vrijednosti ukupnog slijeganja, [1 - 6]. Izgradnja pruga za velike brzine prisutna je još uvijek u malom broju država, pretežno u Europi i na Dalekom istoku (Kina, Japan, Južna Koreja). Na slici 1. prikazan je karakteristični poprečni presjek nasipa pruga za velike brzine s klasičnom kolosiječnom konstrukcijom (kolosijek sa zastornom prizmom) za velike brzine, a na slikama 2. i 3. prikazan je karakteristični poprečni presjek nasipa pruga za velike brzine s konstrukcijom kolosijeka na čvrstoj podlozi koja se najčešće primjenjuje na kolosijecima za velike brzine na Dalekom




Slika 1. Karakteristični poprečni presjek nasipa pruga za velike brzine (klasična kolosiječna konstrukcija)



Slika 2. Karakteristični poprečni presjek nasipa pruga za velike brzine (kolosijek na čvrstoj podlozi, Daleki istok)



Slika 3. Karakteristični poprečni presjek zasjeka pruga za velike brzine (kolosijek na čvrstoj podlozi, Daleki istok)



Slika 4. Karakteristični uzdužni presjek nasipa pruga za velike brzine (Daleki istok)

istoku, [1]. Na slici 4. prikazan je uzdužni presjek željezničkih pruga za velike brzine. U oba se sustava krutost slojeva povećava od donjih prema gornjim slojevima. Standardni slojevi donjeg ustroja željeznica su: prirodno tlo, posteljica, stabilizirani sloj i nosivi sloj. Izrađuje li se klasična kolosiječna konstrukcija, tada se na nosivi sloj ugrađuje tamponski sloj, zastorna prizma i kolosiječna konstrukcija. Ako se izrađuje kolosijek na čvrstoj podlozi, tada se na nosivi sloj ugrađuje betonska podloga kao podloga određenom tipu krute kolosiječne konstrukcije. U praksi se često susrećemo s činjenicom da širina pružnog pojasa nije dovoljna za gradnju nasipa s nagibom pokosa 2 : 1

što zahtijeva otkup zemljišta ili se moraju graditi stabilizirani slojevi nasipa kako bi se postigli strmiji nagibi pokosa. Troškovi izgradnje klasičnih konstrukcija su manji dok su troškovi održavanja veći, a kod kolosijeka na čvrstoj podlozi troškovi su gradnje veći dok su troškovi održavanja manji, [7]. U ovom se radu razmatra sustav izgradnje nasipa kod kolosijeka na čvrstoj podlozi namijenjenih za velike brzine gdje se jedan sloj nasipa, koji se uobičajeno ne stabilizira cementom (eng. Uncemented-Prepared Subgrade Layer: U-PSL), zamjenjuje nosivim slojem koji je stabiliziran cementom (eng. Cemented-Prepared Subgrade Layer: C-PSL) [1].

## 2. Karakteristike materijala nosivih slojeva

Karakteristike materijala za izradu nosivog sloja nasipa koji se ne stabilizira cementom (U-PSL) prikazane su u tablici 1. [1]. U tablici je predočen udio pojedinih frakcija u granulometrijskom sastavu materijala koji služi za izradu nosivog sloja. Svojstva takvog materijala provjeravaju se prema nacionalnim propisima [8-12] te međunarodnim normama za ispitivanje [5, 6]. To uključuje: standardni Proctorov test (ASTM D 698-00) koji služi za određivanje maksimalne gustoće u suhom stanju (eng. *maximum dry density* - MDD) i ispitivanje zbijenosti kružnom pločom (ASTM D 1196-93, 2004) pri čemu maksimalna veličina čestica treba biti manja od 100 mm. Za potrebe laboratorijskog ispitivanja relativna zbijenost s obzirom na maksimalnu gustoću u suhom stanju dobivenu Proctorovim testom ( $\rho_r$ ) ne smije biti veća od 95 %, a vertikalni modul elastičnosti dobiven ispitivanjem kružnom pločom ( $E_v$ ) ne smije biti veći od 80 MPa. Rezultati laboratorijskih ispitivanja provedenih na tipičnom materijalu (lokalno pribavljen) koji se koristi za izradu nestabiliziranih slojeva prikazani su u tablici 2. [12].

Za izradu cementom stabiliziranih nosivih slojeva, za potrebe ovog istraživanja, upotrijebljen je lokalno pribavljen agregat. Za pronalazak prikladnog omjera mješavine s različitim vodocementnim faktorom (0,4 i 0,5) te različitim udjelima cementa (10, 15, 20, 25, 30%) za laboratorijske uzorke upotrijebljen je turgutlu pijesak srednje veličine zrna i portland cement tipa 1 ASTM C150, 1994). U čeličnim kalupima izrađena su tri cilindrična uzorka različitih promjera te su njegovana 7 i 28 dana prije provođenja ispitivanja jednoosne tlačne čvrstoće kako bi se utvrdila jednoosna tlačna čvrstoća (prema TS EN 12390-2, 2002; -3, 2003) [8 - 12]. Parametri za izradu smjese (odnosno granične vrijednosti) prikazani su u tablici 3. [13].

Tablica 1. Granično područje granulometrijskog sastava materijala za izradu nosivog sloja nasipa

Veličina zrna <sup>(*)</sup>	Postotak prolaska kroz sito
P(2D)	100
P(D <sub>max</sub> )	100-99
P(D)	99-85
P(D/2)	84-55
P(D/5)	60-31
P(D/10)	49-23
P(D/20)	40-17
P(D/50)	31-11
P(D/100)	22-8
P(D/200)	16-6
P(D/500)	9-3
P(D/1000)	6-2

(\*)Napomena: D = veličina zrna  
 $D_{max} = 1.25D$ , ako je  $D \geq 50$  mm  
 $D_{max} = 1.58D$ , ako je  $D < 50$  mm

Tablica 3. Propisane vrijednosti za izradu cementom stabiliziranog nosivog sloja

Promatrani parametri	Vrijednost
Slijeganje	70 mm
Maks. veličina zrna agregata	50 mm
Omjer vode i zraka	ovisi o v/c
Vodocementni faktor (v/c)	0.4 - 0.5
Udio cementa u mješavini [%]	10, 15, 20, 25, 30 %
Udio krupnog agregata	ovisi o v/c

Tablica 2. Rezultati laboratorijskih ispitivanja materijala za izradu slojeva nasipa koji se ne stabiliziraju cementom

Ispitivano svojstvo	Primijenjena metoda	ASTM-D	Vrijednost
Određivanje granulometrijskog sastava - mokrim postupkom sijanja	Standardna metoda za ispitivanje granulometrijskog sastava tla	ASTM-D 422-63	-
Određivanje optimalne vlažnosti	Standardni Proctorov pokus	ASTM-D 698-00	$W_{opt} = 13.6\%$ $\gamma_{drymax} = 19,994$ [kN/m <sup>3</sup> ]
Određivanje gustoće čestica tla	Standardna metoda za ispitivanje gustoće čvrstih čestica tla pomoću piknometra	ASTM-D 854-02	2.65
Određivanje sadržaja vode	Standardna metoda za laboratorijsko određivanje sadržaja vode (vlažnosti) tla i stijene u odnosu na masu	ASTM-D 2216	3.3 [%] u laboratorijskim uvjetima
Klasifikacija tla za inženjerske potrebe	Jedinstvena klasifikacija tla	ASTM-D 2487-00	SP
Ispitivanje koeficijenta propusnosti	Standardna metoda za ispitivanje propusnosti saturiranih tla upotrebom promjenljivog potencijala	ASTM-D 5084-03	$10^{-3}$ [m/s]
Maksimalni indeks gustoće	Standardna metoda za ispitivanje indeksa maksimalne gustoće i jedinične težine korištenjem vibrostola	ASTM-D 4253-00	-
Pokus troosnog posmika	Standardna metoda za ispitivanje tla pri troosnom posmiku u konsolidiranim i dreniranim uvjetima	ASTM WK3821	$c=7$ [kPa] $\theta=37$ [°]
Pokus izravnog posmika	Standardna metoda za ispitivanje tla izravnim posmikom u konsolidiranim i dreniranim uvjetima	ASTM-D 3080-04	$c=7$ [kPa] $\theta=36.88$ [°]

Izrađene su tri grupe uzoraka, pri čemu je prva grupa (grupa A) izrađena u maloj veličini uzorka (D=4 cm, H=8 cm), druga (grupa B) u srednjoj veličini (D=8 cm, H=16 cm), a treća (grupa C) u velikoj veličini (D=10 cm, H=20 cm). Dakle, napravljene su tri skupine po tri uzorka, od kojih je prva skupina ispitivana nakon sedam dana njege betona, a ostale dvije su ispitivane nakon 28 dana njege. Ukupno je napravljeno 180 uzoraka koji su potom podijeljeni u tri skupine, svaka s pet različitih cementnih udjela (10 %, 15 %, 20 %, 25 %, 30 %) i dva različita vodocementna faktora v/c (0,4 i 0,5). Za ispitivanje jednoosne tlačne čvrstoće korišteno je 30 uzoraka ispitivanih nakon 28 dana njege i 30 uzoraka nakon 7 dana njege. Ispitivanje je provedeno primjenom univerzalnog uređaja za tlačno ispitivanje u IYTE-MAM laboratoriju. S obzirom na to da analiza ne uključuje učinak starenja uzoraka kompozitnih materijala podvrgnutih dugoročnom dinamičkom opterećenju, daljnje

istraživanje moglo bi biti usmjereno na pripravljanje istih uzoraka koji će biti podvrgnuti ispitivanjima pod dinamičkim opterećenjem (primjenom uređaja za jednoosno i troosno ispitivanje) oponašajući dinamičko opterećenje vlakova. Rezultati provedenih ispitivanja prikazani su u tablici 4. i 5.

### 3. Analiza slijeganja nasipa

Pri projektiranju nasipa kolosijeka na čvrstim podlogama, uzimajući u obzir projektnu brzinu između 200 i 400 km/h i osovinsko opterećenje od približno 200 kN, daju se dva uvjeta za slijeganje:

- maksimalno dugoročno ukupno slijeganje gornjeg ruba tračnica ( $\Delta z$ ) ili maksimalno dugoročno diferencijalno slijeganje jedne u odnosu na drugu tračnicu ne smije prijeći 2 mm u bilo kojem poprečnom presjeku kolosijeka (slike 2. i 3.),

Tablica 4. Eksperimentalni podaci (prva skupina uzoraka)

Skupina uzoraka	D [cm]	H [cm]	v/c	Udio cementa [%]	Njegovanje [dana]	Naprezanje pri slomu [MPa]	Modul elastičnosti [MPa]	Deformacija pri slomu [%]
1A	4	8	0.5	15	28	2,009	42,410	4,736
1B	8	16	0.5	15	28	2,945	50,460	5,835
1C	10	20	0.5	15	28	2,008	40,310	4,982
2A	4	8	0.5	20	28	6,108	103,200	5,919
2B	8	16	0.5	20	28	8,055	109,460	7,359
2C	10	20	0.5	20	28	11,870	145,680	8,148
3A	4	8	0.5	10	28	1,243	25,290	4,916
3B	8	16	0.5	10	28	1,990	37,030	5,373
3C	10	20	0.5	10	28	2,669	44,620	5,982
4A	4	8	0.5	25	28	11,016	205,480	5,361
4B	8	16	0.5	25	28	15,734	289,850	5,428
4C	10	20	0.5	25	28	11,017	181,160	6,081
5A	4	8	0.5	30	28	0.547	271,840	4,788
5B	8	16	0.5	30	28	0.767	317,590	5,171
5C	10	20	0.5	30	28	1,121	329,650	5,324
6A	4	8	0.4	15	28	1,002	18,210	5,201
6B	8	16	0.4	15	28	1,441	25,480	5,354
6C	10	20	0.4	15	28	2,519	43,470	5,495
7A	4	8	0.4	20	28	4,247	92,140	5,109
7B	8	16	0.4	20	28	5,588	110,510	5,257
7C	10	20	0.4	20	28	8,920	171,080	5,214
8A	4	8	0.4	10	28	12,201	11,250	4,960
8B	8	16	0.4	10	28	14,836	14,790	5,188
8C	10	20	0.4	10	28	15,902	20,660	5,424
9A	4	8	0.4	25	28	10,919	232,800	4,690
9B	8	16	0.4	25	28	12,284	229,000	5,364
9C	10	20	0.4	25	28	13,126	240,290	5,462
10A	4	8	0.4	30	28	15,078	313,820	4,805
10B	8	16	0.4	30	28	17,952	353,470	5,079
10C	10	20	0.4	30	28	21,208	421,260	5,035



Tablica 5. Eksperimentalni podaci (druga skupina uzoraka)

Skupina uzoraka	D [cm]	H [cm]	v/c	Udio cementa [%]	Njegovanje [dana]	Naprezanje pri slomu [MPa]	Modul elastičnosti [MPa]	Deformacija pri slomu [%]
1A	4	8	0,5	15	7	1,456	25,409	3,541
1B	8	16	0,5	15	7	2,162	49,826	3,923
1C	10	20	0,5	15	7	2,753	77,271	3,260
2A	4	8	0,5	20	7	4,506	87,754	6,063
2B	8	16	0,5	20	7	7,277	131,308	6,607
2C	10	20	0,5	20	7	9,783	226,891	6,343
3A	4	8	0,5	10	7	0,911	10,964	4,834
3B	8	16	0,5	10	7	1,412	12,713	4,810
3C	10	20	0,5	10	7	2,073	15,723	5,218
4A	4	8	0,5	25	7	7,757	217,926	4,491
4B	8	16	0,5	25	7	12,52	282,256	4,719
4C	10	20	0,5	25	7	15,137	376,064	4,968
5A	4	8	0,5	30	7	12,213	376,527	3,428
5B	8	16	0,5	30	7	14,977	548,467	3,826
5C	10	20	0,5	30	7	16,11	801,863	4,20
6A	4	8	0,4	15	7	1,063	18,068	4,559
6B	8	16	0,4	15	7	1,49	31,713	4,889
6C	10	20	0,4	15	7	2,48	59,204	4,874
7A	4	8	0,4	20	7	4,363	84,910	4,099
7B	8	16	0,4	20	7	5,643	133,558	5,051
7C	10	20	0,4	20	7	8,98	259,747	4,349
8A	4	8	0,4	10	7	0,383	135,882	4,076
8B	8	16	0,4	10	7	0,694	229,160	4,320
8C	10	20	0,4	10	7	0,828	314,502	5,929
9A	4	8	0,4	25	7	7,129	245,592	3,718
9B	8	16	0,4	25	7	11,85	390,017	4,022
9C	10	20	0,4	25	7	13,323	590,704	4,494
10A	4	8	0,4	30	7	7,909	10,615	3,691
10B	8	16	0,4	30	7	13,077	11,553	3,956
10C	10	20	0,4	30	7	11,367	13,395	4,127


- maksimalno dugoročno ukupno slijeganje ili maksimalno dugoročno diferencijalno slijeganje ne smije prijeći 10 mm ni u jednoj sekciji kolosijeka duljine 20 m u uzdužnom presjeku kolosijeka (slika 4.).

Pojam dugoročno obično se odnosi na vijek trajanja (tijekom uporabe nakon izgradnje) od 30 godina [1]. Slijeganja se računaju od "prirodnog temeljnog tla" do gornjeg ruba tračnica, dodavanjem početnih slijeganja svakog sloja izuzev doprinosa od čeličnih dijelova i njihovih priključaka (odnosno tračnica i pribora) koji se smatraju "krutima" te se zanemaruju. Prekoračenjem granica slijeganja nastaju značajni sigurnosni rizici koji mogu dovesti do izbacivanja vlaka iz kolosijeka. Osim toga, izgradnja kolosiječne rešetke na vrlo krutom nasipu (kod kojeg nema slijeganja) može narušiti udobnost putovanja i uzrokovati istrošenje kolosijeka i kotača vozila.

U radu je provedena je analiza slijeganja nasipa te je razmatrana mogućnost zamjene mehanički stabiliziranog nosivog sloja debljine 2 m i modula elastičnosti  $E_v = 80$  MPa s cementom stabiliziranim nosivim slojem. Varirana je debljina i modul elastičnosti cementom stabiliziranog nosivog

sloja, a moduli su dobiveni iz provedenih jednoosnih tlačnih ispitivanja (tablica 4. i 5.) priređenih uzoraka i to nakon 7 dana i nakon 28 dana njege. Za analizu slijeganja nasipa primjenjen je program Plaxis V8 (2D) FEM, a postupak je bio slijedeći:


- Izrađen je model nasipa željezničke pruge za velike brzine (slika 5.),
- Tipični nasip pruge za velike brzine sadrži četiri različita sloja između sloja posteljice i tračnica (slike 2-4). Iako ti slojevi imaju različita svojstva i stanja materijala (tablica 6), u analizi se razmatraju kao nepromjenjiva. S obzirom na to da je svrha ispitivanja zamijeniti nestabilizirani sloj (U-PSL) debljine 2 m (jedan od ukupno četiri sloja) s cementom stabiliziranim slojem C-PSL (varirajući karakteristike sloja ovisno o udjelu cementa) čije su vrijednosti prikazane u tablici 7., uvedena su u proračun svojstva pojedinih slojeva. Radi pojednostavnjenja se pretpostavlja da je nivo podzemne vode ispod posteljice.
- Generiranje mreže konačnih elemenata za promatrani model nasipa (slika 6.)



Slika 5. Usvojeni model nasipa željezničke pruge za velike brzine

Tablica 6. Svojstva materijala usvojenog modela nasipa za pruge velikih brzina

Parametar	Oznaka	Cementni nosivi sloj	Tampon	Poboljšani podložni sloj	Podložni sloj
Model materijala		Mohr-Coulomb	Mohr-Coulomb	Mohr-Coulomb	Mohr-Coulomb
Ponašanje materijala		suh	suh	suh	suh
Jedinična težina suhog uzorka [kN/m <sup>3</sup> ]	$\gamma_{\text{nesat}}$	19	18	17	16
Jedinična težina zasićenog uzorka [kN/m <sup>3</sup> ]	$\gamma_{\text{sat}}$	22	21	20	19
Koeficijent propusnosti u ravnini [m/s]	$k_h$	0.2	$3 \times 10^{-2}$	$10^{-3}$	$10^{-5}$
Koeficijent propusnosti okomito na ravninu [m/s]	$k_v$	0.2	$3 \times 10^{-2}$	$10^{-1}$	$10^{-5}$
Youngov modul [kPa]	$E_{\text{v(ref)}}$	$300 \times 10^3$	$120 \times 10^3$	$80 \times 10^{3(*)}$	$60 \times 10^3$
Poissonov koeficijent	$\nu$	0.40	0.35	0.30	0.2
Kohezija [kPa]	$c_{\text{ref}}$	1	1.5	7	5
Kut trenja [°]	$\phi'$	40	38	37	35
Kut dilatacije [°]	$\psi$	-	-	2	-




Slika 6. Mreža konačnih elemenata za razmatrani model nasipa


d) U laboratoriju je dobiveno šest modula elastičnosti za cementom stabilizirani nosivi sloj (C-PSL) i prikazani su u tablici 7. Za dobivanje modula elastičnosti varirana su dva vodocementna faktora (0,4 i 0,5) i tri udjela cementa (20, 25, 30 %). Rezultati ispitivanja za manje udjela cementa u stabilizacijskoj mješavini (10 i 15 %) nisu razmatrani jer nisu zadovoljavali postavljene kriterije da vrijednost modula elastičnosti bude jednaka ili veća od potrebnog minimalnog modula elastičnosti 80 MPa.

Tablica 7. Vrijednosti modula elastičnosti ovisno od vodocementnog faktora ( $v/c$ ) i udjela cementa (%)

$v/c$	Modul elastičnosti, $E_v$ [MPa]		
	Udio cementa [%]		
	20	25	30
0,5	258.94	261.46	450.47
0,4	352.86	545.20	597.48



Slika 7. Model opterećenja 71 i vertikalno opterećenje u uzdužnom smjeru nasipa



Slika 8. Model opterećenja SW/0 i vertikalno opterećenje u uzdužnom smjeru nasipa

e) Za intenzitet statičkog opterećenja korišten je ( $q_{vk}$ ), prema EN 1991-2: Eurocode 1 [2]. U toj je normi prometno željezničko opterećenje definirano modelima opterećenja. Umjesto opterećenja prema modelu 71, gdje opterećenje ( $q_{vk}$ ), oznaka (1) na slici 7., nema definiranu duljinu (obično se uzima kao 21.5 m), primjenjen je mnogo pouzdaniji model opterećenja - model SW/0 (slika 8.) za prikaz statičkog utjecaja vertikalnog opterećenja uzrokovano normalnim željezničkim prometom na većini željezničkih nasipa. Treba napomenuti da ispitivanje ne uključuje učinak starenja kompozitnih materijala podvrgnutih dugoročnom dinamičkom opterećenju. U tablici 8. prikazane su karakteristične vrijednosti "a", "c" i "(1)" modela SW/0 i modela 71 [1, 2].

Tablica 8. Karakteristične vrijednosti modela opterećenja "SW/0" i "71"

Model opterećenja	$q_{vk}$ [kN/m]	a [m]	c [m]	(1) [m]
SW/0	133	15.0	5.3	-
71	-	-	-	21.5

f) Ukupna slijeganja proračunana su programom Plaxis-FEM varirajući šest različitih modela elastičnosti cementom stabiliziranog sloja (C-PSL) dobivenih u laboratoriju (tablica 5), a rezultati su uspoređeni s minimalnom vrijednošću  $E_v = 80$  MPa cementom stabiliziranog sloja prikazani su u tablici 9.

Tablica 9. Rezultati ispitivanja ukupnog slijeganja za svaku od šest cementom stabiliziranih mješavina (C-PSL) kao zamjena za nosivi sloj debljine 2 m koji nije stabiliziran cementom (U-PSL)

Slojevi	Nosivi sloj bez veziva (U-PSL)	Cementom stabilizirani nosivi sloj (C-PSL)						TTS <sup>(1)</sup> [mm]
	$\Delta S_1$ E=80 MPa [mm]	$\Delta S_2$ v/c=0.4 C=20 % E=352.9 MPa [mm]	$\Delta S_3$ v/c=0.4 C=25 % E=545.2 MPa [mm]	$\Delta S_4$ v/c=0.4 C=30 % E=597.5 MPa [mm]	$\Delta S_5$ v/c=0.5 C=20 % E=258.9 MPa [mm]	$\Delta S_6$ v/c=0.5 C=25 % E=261.5 MPa [mm]	$\Delta S_7$ v/c=0.5 C=30 % E=450.5 MPa [mm]	
Zastorna prizma	1.993	0.401	0.253	0.231	0.552	0.542	0.309	< 2
Tamponski sloj	1.986	0.391	0.247	0.225	0.540	0.531	0.303	< 2
Stabilizirani sloj	1.875	0.377	0.240	0.219	0.518	0.512	0.293	< 2
Podložni sloj	1.598	0.345	0.219	0.197	0.475	0.467	0.268	< 2

<sup>(1)</sup>Napomene:  
 $\Delta S_{1-7}$  - proračun ukupnog slijeganja primjenom Plaxis-FEM programa  
 TTS - prihvatljivo ukupno slijeganje (eng. Tolerable Total Settlement)  
 C - udio cementa



Rezultati su pokazali da su sve vrijednosti ukupnih slijezanja unutar graničnih vrijednosti, pa se stoga svaka od mješavina može upotrijebiti. Korelacijom između modula elastičnosti od šest cementom stabiliziranih mješavina (C-PSL) s modulom elastičnosti nestabiliziranog sloja debljine 2 m, mogu se procjeniti debljine slojeva koje daju tražene uvjete. Naša je procjena pokazala da se primjenom najvećega vertikalnog modula elastičnosti (prikazan u tablici 9.) mogu postići uštede do 70 % u debljini sloja.

## 4. Primjena neuronskih mreža

### 4.1. Općenito o umjetnim neuronskim mrežama

Umjetna neuronska mreža može uočiti vezu u danim uzorcima i stoga može riješiti široki raspon složenih problema kao što su prepoznavanje uzorka, nelinearno modeliranje i klasifikacija [14]. Za uporabu se obično uzima troslojna prema naprijed usmjerena neuronska mreža (eng. Feedforward Artificial Neural Network, tj. Feedforward ANN ili FFNN), slika 9. U toj mreži, ulazni podaci ( $x$ ) stavljaju se u ulazni sloj neuronske mreže koji posredstvom funkcije aktivacije daju impuls neuronima u skrivenom sloju ( $z$ ) nakon umnožavanja s težinskim koeficijentom veze između neurona ( $v_{ij}$ ) [15]:

$$net_j = \sum x_i v_{ij} - b_j \quad (1)$$

Skriveni neuronski sloj dodaje težinske koeficijente dobivene od svakog ulaznog neurona ( $x_i v_{ij}$ ), povezuje ih s definiranim pragom aktivacije (eng. bias) ( $b_j$ ) i zatim predaje informaciju nelinearnoj tangencijalnoj hiperboličnoj funkciji veze [15]:

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

Učenje umjetne neuronske mreže obično se postiže algoritmom sa širenjem pogreške unazad (eng. back propagation algorithm) koji najčešće služi za nadzirano učenje. Svrha je tog algoritma dobiti optimalne vrijednosti težinskih koeficijenata veza koje bi generirale izlazni vektor  $Y = (y_1, y_2, \dots, y_p)$  što je moguće bliži ciljanim vrijednostima izlaznog vektora  $T = (t_1, t_2, \dots, t_p)$  s određenom točnošću. Optimalne težine dobivaju se minimizacijom predodređene funkcije pogreške  $E$  [15]:

$$E = \sum_p \sum_p (y_i - t_i)^2 \quad (3)$$

gdje je  $y_i$  komponenta ANN izlaznog vektora  $Y$ ;  $t_i$  komponenta ciljanog izlaznog vektora  $T$ ;  $p$  = broj izlaznih neurona, a  $P$  = broj uzoraka baze podataka za učenje neuronske mreže.

U algoritmu za povratnu analizu grešaka težinskih koeficijenata (back propagation), signali najprije teku prema naprijed i model sukladno težinskim koeficijentima prve iteracije daje predviđanje rezultata za uzorak iz trening skupa podataka. U odnosu na ukupnu grešku predikcije korigiraju se težinski koeficijenti u obrnutom smjeru - od izlaznog, preko skrivenog do ulaznog sloja neuronske mreže. Korekcija

težinskih koeficijenata definirana je delta pravilom odnosno metodom najbržeg spusta [15]:

$$\Delta v_{ij}(n) = -\delta \frac{\partial E}{\partial v_{ij}} + \alpha \Delta v_{ij}(n-1) \quad (4)$$


gdje su  $\Delta v_{ij}(n)$  = inkrementi težinskih koeficijenata između čvora  $i$  i  $j$  tijekom  $n$ -te iteracije,  $\Delta v_{ij}(n-1)$  = inkrementi težinskih koeficijenata između čvora  $i$  i  $j$  tijekom  $(n-1)$ -te iteracije;  $d$  = brzina učenja i  $a$  = momentum (faktor inercije).

Brzina učenja ( $d$ ) služi kako bi se povećala vjerojatnost da se izbjegne zaustavljanje procesa optimiranja u lokalnom, umjesto u globalnom minimum. Preveniranje lokalnog minimuma u procesu optimizacije može se postići promjenjivom (cik-cak) putanjom, čime se preispituje postignuta minimalna greška predviđanja, što opet može usporiti proces učenja. U takvim situacijama faktor inercije ( $d$ ) može ubrzati treniranje u vrlo ravnim područjima površine pogreške i pomoći u sprječavanju oscilacija u težinama [15].

Mreža uči prilagođavanjem praga aktivacije (eng. bias) i težinskih koeficijenata veza između neurona u slojevima neuronske mreže. Prije učenja se težinski koeficijenti veza i pragovi aktivacije neuronske mreže moraju podesiti na male slučajne vrijednosti. Također, zbog prirode sigmoidne funkcije koja se koristi za "back-propagation" algoritam, sve eksterne ulazne i izlazne vrijednosti prije početka učenja mreže trebaju biti standardizirane. Bez standardizacije, visoke ulazne vrijednosti umjetne neuronske mreže zahtijevaju primjenu vrlo malih težinskih koeficijenata što može prouzročiti brojne probleme [15]. S obzirom na to da se tangencijalna hiperbolična prijenosna funkcija veze asimptotski proteže od  $-\infty$  do  $+\infty$ , nikad ne dostiže  $-1$  ni  $+1$ . Stoga je u većini slučajeva bolje potisnuti podatke u raspon od  $-0.9$  do  $+0.9$ . Jednadžba (5) koja spreže sve podatke u raspon od  $-0.9$  do  $+0.9$  primijenjena je za standardizaciju u ovom istraživanju:

$$z_i = \left[ \frac{1.8 (x_i - x_{\min})}{x_{\max} - x_{\min}} \right] - 0.9 \quad (5)$$


gdje su  $x_{\max}$  i  $x_{\min}$  maksimalne i minimalne vrijednosti  $i$ -tog neurona u ulaznom sloju. Pojednosti o umjetnoj neuronskoj mreži navode se u [15].



Slika 9. Troslojna prema naprijed usmjerena neuronska mreža

### 4.2. Modeli predviđanja

Troslojna prema naprijed usmjerena neuronska mreža korištena je za predviđanje vrijednosti naprezanja, deformacije i elastičnosti u ovom istraživanju. Odabrana neuronska mreža korištena je za tri slučaja gdje su ulazni vektori jednaki, a izlazne varijable različite za svaki slučaj, prikazana je na slici 10. Od ukupne baze podataka za učenje mreže izdvojeno je 45 (trening skup), a za ocjenu uspješnosti izdvojeno je 15 setova podataka (testni skup).



Slika 10. Model umjetne neuronske mreže korišten u istraživanju

Broj neurona u ulaznim i izlaznim slojevima je fiksiran zbog određenog broja ulaznih i izlaznih parametara. S druge strane, broj neurona u skrivenom sloju, broj epoha (trajanja ciklusa), brzina osposobljavanja i faktor inercije određeni su metodom pokušaja i pogreške. Promjenom vrijednosti tih parametara i praćenjem vrijednosti pogrešaka pri svakoj iteraciji, odabrane su optimalne vrijednosti tih parametara. Taj postupak, naravno, uključuje veliki broj iteracija i stoga nije moguće predstaviti sve probne vrijednosti utjecajnih parametara i rezultirajuće pogreške. Vrijednosti parametara koje su rezultirale najmanjom greškom predviđanja naprezanja, deformacija i modula elastičnosti prikazane su u tablici 10.

Tablica 10. Parametri korišteni u modelu umjetne neuronske mreže

Parametri	Vrijednosti parametara
Broj neurona u skrivenom sloju	11
Brzina učenja	0.12
Momentum (faktor inercije)	0.24
Broj epoha	900

Algoritam povratne analize grešaka težinskih koeficijenata (back propagation) prema metodi gradijentnog spusta primijenjen je u ovom istraživanju. S obzirom na to da su dobiveni rezultati zadovoljavajući, nisu primjenjivani drugi algoritmi za učenje, poput radialni bazični algoritam, konjugirana gradijentna funkcija i sl., niti druge konfiguracije umjetnih neuronskih mreža koje sadrže više od jednog

skrivenog sloja. U istraživanju je upotrijebljeno 60 setova podataka za učenje i ocjenu generalizacije umjetne neuronske mreže. Kao što je prikazano u tablicama 9 i 10, rezultati upućuju na to da je broj podataka bio zadovoljavajući. Naravno, poželjno je imati više podataka jer veći broj podataka pozitivno utječe na sposobnost generalizacije naučene neuronske mreže. Ipak, mnoge studije uspješno su koristile jednak [16, 17] ili čak manji broj podataka [18 - 20].

U tablici 11. prikazani su statistički pokazatelji postignutih rezultata učenja neuronske mreže na trening skupu podataka za predviđanje tri promatrana slučaja izlaznih rezultata: naprezanja, deformacija i modula elastičnosti. Za svaki je slučaj napravljeno 900 iteracija nakon čega nije postignuto smanjenje greške predikcije u novim ciklusima učenja, pa je ponavljanje ciklusa učenja prekinuto. Tablica 12. prikazuje postignutu sposobnost generalizacije naučene (trenirane) neuronske mreže na test skupu podataka, odnosno rezultate predviđanja promatranih izlaznih parametara: naprezanja, deformacija i modula elastičnosti. Kao što se može vidjeti, mreža je dala predviđanje promatranih izlaznih parametara s malim pogreškama i visokim koeficijentima korelacije.

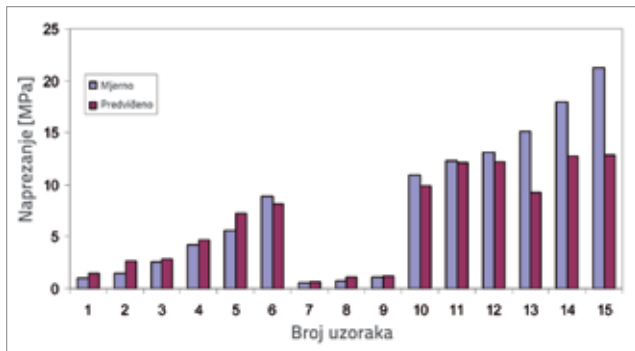
Table 11. Pokazatelji rezultata predviđanja na trening skupu podataka

Ocjena generalizacije	MSE	R <sup>2</sup>
	Promatrani parametri	
Naprezanje [MPa]	0,051	0.94
Deformacija [%]	0,011	0.96
Modul elastičnosti [MPa]	0,014	0.95
MSE - srednja kvadratna pogreška (eng. Mean Square Error) R <sup>2</sup> - koeficijent determinacije		

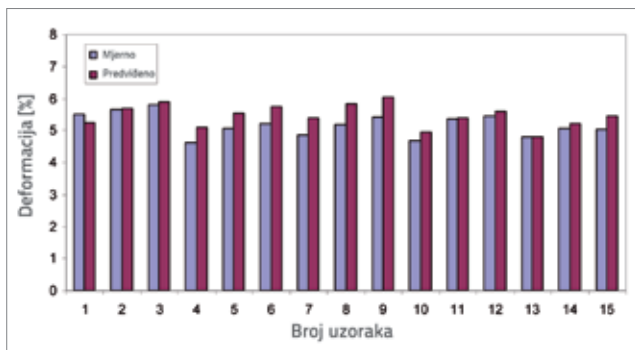
Tablica 12. Pokazatelji rezultata predviđanja na testnom skupu podataka (generalizacija)

Ocjena učenja	MSE	MAE	R <sup>2</sup>
	Promatrani parametri		
Naprezanje [MPa]	8.91	0.20	0.92
Deformacija [%]	0.12	0.31	0.96
Modul elastičnosti [MPa]	340	139	0.90
MSE - srednja kvadratna pogreška (eng. Mean Square Error) MAE - srednja apsolutna pogreška (eng. Mean Absolute Error) R <sup>2</sup> - koeficijent determinacije			

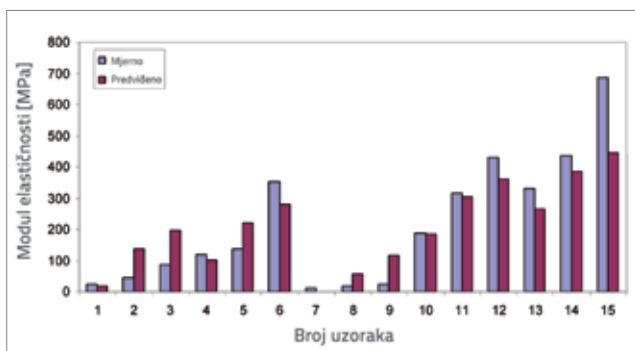
Slike 11. do 13. prikazuju dijagrame s vrijednostima promatranih izlaznih parametara koje su dobivene mjerenjem i predviđanjem pomoću neuronske mreže za



Slika 11. Predviđanje izmjerenih vrijednosti naprezanja primjenom neuronske mreže



Slika 12. Predviđanja izmjerenih vrijednosti deformacija primjenom neuronske mreže



Slika 13. Predviđanja izmjerenih vrijednosti modula elastičnosti primjenom neuronske mreže

svaki promatrani slučaj. Može se zaključiti da su vrijednosti dobivene predviđanjem pomoću modela za sve slučajeve zadovoljavajuće. Analiza osjetljivosti pokazala je da je udio cementa najosjetljiviji parametar za naprezanje i modul elastičnosti. Starost se pak pokazala kao najosjetljiviji parametar za deformaciju.

## 5. Zaključak

U ovom je radu istražena primjena cementom stabiliziranog sloja umjesto nosivog sloja koji nije stabiliziran cementom u nasipima pruga za velike brzine pomoću numeričkih (metoda konačnih elemenata) i primjenom prema naprijed usmjerene neuronske mreže (eng. *Feedforward Neural Network* – FFNN). Projektiranje takvih nasipa uključuje visoke zahtjeve kako na svojstva materijala tako i na male dopustive vrijednosti ukupnog diferencijalnog slijeganja. Navedeni se nasipi projektiraju mnogo krući u usporedbi s nasipima konvencionalnih željezničkih pruga. Laboratorijska ispitivanja provedena su da bi se utvrdili parametri eventualne degradacije cementom stabiliziranih slojeva.

Može se zaključiti da:

- od deset pripremljenih cementom stabiliziranih mješavina, samo je šest zadovoljilo zahtijevane uvjete krutosti (tablica 5.)
- primjena cementom stabiliziranih slojeva u nasipima pruga za velike brzine može omogućiti smanjenje debljine tih slojeva i do 70 % (u usporedbi sa slojevima koji nisu stabilizirani cementom)
- umjetne neuronske mreže (FFNN) mogu se koristiti za predviđanje ključnih svojstava krutosti cementom stabiliziranih slojeva nasipa (naprezanja, deformacije i elastičnosti)
- dobri rezultati postignuti su primjenom algoritma povratne analize grešaka težinskih koeficijenata (back propagation), metode gradijentnog spusta u korekciji težinskih koeficijenata i primjenom hiperboličko-tangetne funkcije aktivacije u postupku učenja neuronske mreže
- daljnja istraživanja treba usmjeriti na analiziranje učinka starenja kompozitnih materijala podvrgnutih dugoročnom dinamičkom opterećenju.

## LITERATURA

- [1] Egeli, I.: Engineering Consultancy-Internal Report: 'Design and Construction Aspects of High-Speed Train Railway Embankments-An Overview', Taiwan High Speed Railway Construction Project, Taiwan, ROC, 2003.
- [2] EN 1991-2: Eurocode 1: Actions on Structures – Part 2: Traffic Loads on Bridges, European Standard: CEN-Cenelec, Brussels, Belgium ([www.cenelec.eu](http://www.cenelec.eu)), 1991.
- [3] Mundrey, J.S.: Railway Track Engineering, 3rd. Ed., Tata-McGraw-Hill Publ.Co. Ltd., N. Delhi, India, 2008.
- [4] Seling, E.T., Waters, J.M.: Track Geotechnology and Substructure Management. Thomas Telford Services Ltd., London, England, 1994.
- [5] UIC Report: High Speed Principles and Advantages, International Union of Railway, Paris, France ([www.uic.org](http://www.uic.org)), 2007.
- [6] UIC Code-719R: Earthworks and track-bed layers for railway lines, International Union of Railway, Paris, France ([www.uic.org](http://www.uic.org)), 1994.

- [7] Lakušić, S., Vajdić, M.: Overview of modern track structures on solid bases, GRAĐEVINAR 63 (2011) 2, 125-134.
- [8] TS 500: Betonarme Yapıların Hesap-Yapım Kuralları(in Turkish), TSE (www.tse.org.tr), Ankara, Tr., 2000.
- [9] TS 706: Beton Agregaları (in Turkish), TSE (www.tse.org.tr), Ankara, Turkey, 2009.
- [10] TS 802: Beton Karışımı Tasarım Hesap Esasları (in Turkish), TSE (www.tse.org.tr), Ankara, Turkey, 2009.
- [11] TS EN 12390-2: Laboratuvarında Dayanım Deneğinde Kullanılacak Deney Numunelerinin Hazırlanması ve Kürlenmesi, TSE (in Turkish), Ankara, Turkey, 2002.
- [12] TS EN 12390-3: Deney Numunelerinde Basınç Dayanımının Tayini, TSE (in Turkish), Ankara, Tr., 2003.
- [13] Usun, H.: Laboratory Study for Determining Geotechnical Engineering Properties of Cement Treated and Untreated Backfill Soils used in High Speed Railway Embankments, M.Sc. Thesis, Dept.of Civil Engineering, Izmir Institute of Technology, (www.iyte.edu.tr), Urla-zmir,Turkey, 2010.
- [14] Farrokhzad, F., Choobbasti, A.J., Barari, A.: Determination of liquefaction potential using artificial neural networks, GRAĐEVINAR 63 (2011) 9/10, 837-845.
- [15] Tayfur, G.: Soft Computing in Water Resources Engineering, WIT Press, Sauthampton, United Kingdom, 2012.
- [16] Tayfur, G.: Artificial neural networks for sheet sediment transport, Hydrological Sciences Journal, 47 (6): 879-892, 2002.
- [17] Tayfur, G., Singh, V.P.: Predicting longitudinal dispersion coefficient in natural streams by artificial neural network, Journal Hydraulic Engineering, 131 (11): 991-1000, 2005.
- [18] Akkurt, S., Ozdemir, S., Tayfur, G., et al.: The use of GA-ANNs in the modelling of compressive strength of cement mortar, Cement and Concrete Research, 33 (7): 973-979, 2003.
- [19] Tayfur, G., Singh, V.P.: ANN and fuzzy logic models for simulating event-based rainfall-runoff , J. Hydraulic Engineering , 132 (12): 1321-1330, 2006.
- [20] Erdem, T.K., Tayfur, G., Kirca, O.: Experimental and modeling study of strength of high strength concrete containing binary and ternary binders , Cement Wapno Beton, 16 (4), 224-237, 2011.