

# Primjena neuralnih mreža za predviđanje strukturalnog ponašanja kolničke konstrukcije uslijed djelovanja prometnog opterećenja

Ana Rudeš<sup>1</sup>, prof. dr. sc. Tatjana Rukavina<sup>2</sup>

<sup>1</sup>TPA d.o.o., ana.rudes@student.grad.hr

<sup>2</sup>Sveučilište u Zagrebu Građevinski fakultet, tatjana.rukavina@grad.unizg.hr

## Sažetak

Poznavanje strukturalnog i funkcionalnog stanja kolnika od iznimne je važnosti za uspješnost cjelokupnog sustava gospodarenja kolnicima. S obzirom da je današnja tendencija da se podaci o stanju kolnika prikupljaju nerazornim metodama, mjerjenje defleksije pomoću uređaja s padajućim teretom postaje sve popularniji način ocjene stanja kolnika. Kako je predviđanje ponašanja kolničke konstrukcije u eksploatacijskom periodu modul od izuzetnog značaja, razvojem tehnologije raste i interes za primjenom umjetne inteligencije, posebice neuralnih mreža. Poznavanjem modela predviđanja ponašanja, postaje moguće predvidjeti trenutak u kojem će biti potrebno izvršiti određenu razinu i oblik intervencije, kako bi se zadржao određeni stupanj sigurnosti i udobnosti prometovanja tijekom dužeg vremenskog razdoblja.

*Ključne riječi: neuralne mreže, kolnička konstrukcija, modeli ponašanja, uređaj s padajućim teretom, nosivost*

## Application of neural networks for predicting the structural behavior of the pavement due to load impact

## Abstract

Knowledge of the structural and functional condition of pavement structure is extremely important for the success of the entire pavement management system. Given that today's tendency is to collect pavement condition data using non-destructive methods, deflection measurement using a falling weight deflectometer device is becoming an increasingly popular method of pavement condition assessment. As the prediction of the behavior of the pavement structure in the exploitation period is a module of exceptional importance, with the development of technology, there is a growing interest in the application of artificial intelligence, especially neural networks. By knowing the pavement behavior prediction model, it becomes possible to predict the moment when it will be necessary to perform a certain level and form of intervention, in order to maintain a certain degree of safety and comfort of traffic over a long period of time.

*Key words: neural networks, pavement structure, pavement performance models, falling weight deflectometer, bearing capacity*

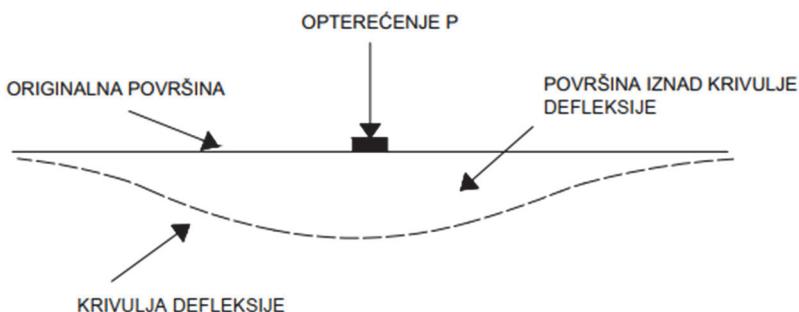
## 1 Uvod

Izgradnja prometne infrastrukture zahtjeva kapitalna ulaganja. Kao i svaki drugi proizvod bez obzira na veličinu početnog ulaganja, unutar predviđenog vijeka uporabivosti, vrijednost prometnice uslijed njene degradacije tijekom uporabnog vijeka postupno pada. Planiranim i pravovremenim poduzimanjem različitih mjera održavanja ili obnove, moguće je proces degradacije kolničke konstrukcije usporiti ili u potpunosti zaustaviti uz utrošak odgovarajućih finansijskih sredstava. Nepravovremenim poduzimanjem mjera održavanja, povećava se razina degradacije, izražena kroz opseg i veličinu oštećenja, uslijed čega dolazi do povećanja troškova održavanja, u odnosu na one koji bi bili da se pravodobno pristupilo odgovarajućim mjerama popravaka.

Uspješno, pravodobno poduzimanje mjera održavanja te poznavanje modela strukturalnog i funkcionalnog ponašanja kolničke konstrukcije u funkciji vremena, od iznimne je važnosti. Funkcionalni zahtjevi odnose se na oštećenje površine kolnika, dok se strukturalni povezuju sa nosivošću kolnika, odnosno njegovom sposobnošću da podnesu određeno prometno opterećenje. Izmjerene vrijednosti parametara stanja kolnika moguće je vrednovati na temelju mjerodavnih kriterija, kako bi se ocijenilo stanje pojedinih slojeva ili kolnika u cjelini. Međutim, posjedovanjem podataka o kolniku od trenutka puštanja ceste u promet do danas, moguće je ocijeniti njegovo stanje te predvidjeti ponašanje pod djelovanjem prometnog opterećenja i uvjeta okoline u eksploracijskom periodu. Kontinuiranim prikupljanjem podataka o napredovanju strukturalnog i funkcionalnog oštećenja tijekom niza godina, moguće je sa dovoljnom točnošću modelirati ponašanje kolnika. Tački modeli su važni jer omogućavaju predviđanje trenutaka u kojem će određena dionica ceste dosegnuti onaj stupanj strukturalne ili funkcionalne degradacije koji neće zadovoljiti niti sudionike u prometu, a niti cestovne uprave [1]. U svijetu je unatrag posljednjih tridesetak godina uočen problem da postojeće klasično iskušto u održavanju cesta više nije dosta to je nužno mijenjati pristup aktivnostima vezanim za to područje. S obzirom da se jasno iskazala potreba za primjenom novih metoda i postupaka u području inženjerstva kolničkih konstrukcija, ubrzanim rastom informatičke tehnologije paralelno raste i interes za primjenom umjetne inteligencije, posebno neuralnih mreža za predviđanje ponašanja kolničke konstrukcije. Prema dosadašnjim istraživanjima neuralne mreže su pokazale visok stupanj točnosti prilikom rješavanja nelinearnih inženjerskih problema [2]. U radu je analizirana mogućnost primjene neuralnih mreža treniranih na bazi podataka dobivenoj terenskim mjeranjima različitih funkcionalnih i strukturalnih oštećenja kolnika. Konačan cilj je prognozirati ocjenu stanja postojećih kolničkih konstrukcija kao i predvidjeti strukturalno ponašanje kolničke konstrukcije u budućem vremenskom periodu.

## 2 Ocjena stanja kolnika

Ocjena stanja kolnika obuhvaća funkcionalnu ocjenu stanja kolnika koja obuhvaća procjenu služnosti i sigurnosti te strukturalnu ocjenu stanja kroz određivanje nosivog kapaciteta kolnika. Strukturalno stanje kolnika ocjenjuje se mjeranjem parametara koji opisuju njegovu nosivost, primjerice mjerjenje defleksija kao vertikalne deformacije kolničke konstrukcije nastale uslijed djelovanja opterećenja, a funkcionalno stanje kolnika mjeranjem pokazatelja o uzdužnoj i poprečnoj ravnosti (dubina kolotraga), otpornosti na klizanje (hvataljivost), teksturi te oštećenjima površine [3,4]. Problem se javlja kada zbog pogrešnog određivanja veličina utjecajnih činitelja prilikom projektiranja kolničke konstrukcije ili zbog loše izvedbe, mogu nastati neočekivana trajna oštećenja u kolničkoj konstrukciji tokom eksploatacijskog perioda. Također, postoji mogućnost da potpuna degradacija kolničke konstrukcije u obliku sloma, nastupi prije kraja projektnog perioda. Vrlo je važno ovaj problem uočiti na vrijeme kako bi se određenom obnovom kolničke konstrukcije spriječila daljnja degradacija prometnice. Iz toga razloga podaci dobiveni razornim i nerazornim metodama ispitivanja predstavljaju vrijedan alat za praćenje ponašanja kolnika, donošenje odluka o prioritetima održavanja kao i uspostavljanja sustava gospodarenja kolnicima. Nosivost kolnika obično se određuje kroz ocjenu fizičko-mehaničkih svojstava svakog sloja kolničke konstrukcije, kao što su npr. moduli elastičnosti, umor materijala ili preostala vlačna naprezanja. Dvije uobičajene metode za vrednovanje tih parametara su laboratorijska ispitivanja uzoraka dobivenih jezgrovanjem ili iz istražnih jama, dakle razorna ispitivanja, te nerazorna terenska ispitivanja. Obzirom na današnju tendenciju ocjene strukturalnog kapaciteta nerazornim metodama ispitivanja, mjerjenje defleksija zbog svoje jednostavnosti, predstavlja uobičajeni pokazatelj strukturalnog ponašanja kolnika. Defleksija kolničke konstrukcije predstavlja elastičnu deformaciju generiranu djelovanjem određenog opterećenja primijenjenog na površinu kolnika, slika 1[5].



Slika 1. Shema nastale krivulje defleksije [6]

Opće je prihvaćeno načelo da je nosivost kolničke konstrukcije obrnuto proporcionalna defleksiji. Kod ispravno projektirane i izvedene konstrukcije defleksija nije velika i ima elastični karakter, odnosno po rasterećenju progibna linija se vraća u prvobitni položaj. Kod slabih dotrajalih kolnika, defleksija pod opterećenjem je znatno veća, a po rasterećenju se u početni položaj vraća samo dio deformacije (elastična deformacija), dok dio deformacije ostaje (plastična deformacija) [5, 7]. Jedan od najraširenijih nerazornih mjernih uređaja s kojim se određuje strukturalno stanje kolnika jest uređaj s padajućim teretom (**Falling Weight Deflectometer**). FWD prikazan na slici 2a mjeri defleksije izazvane padajućim teretom koji izaziva impulsno opterećenje kolnika, čije je vrijeme trajanja i veličina opterećenja slična onoj koju izazivaju teška teretna vozila. Tijekom ispitivanja generira se impulsno opterećenje ispuštanjem tereta preko opružnog sustava postavljenog na kružnu ploču, kao što je prikazano na slici 2b [6]. U većini slučajeva mjerjenja dobivena FWD-om tumače se sa ciljem identificiranja mehaničkih svojstava pojedinih slojeva kolničke konstrukcije. Mehanička svojstva mogu se zatim koristiti za procjenu naprezanja i deformacija na kolniku, koja se nadalje mogu koristiti za procjenu preostalog životnog vijeka kolničke konstrukcije. Podatke dobivene razornim i nerazornim metodama ispitivanja iznimno je važno kontinuirano prikupljati jer se na taj način stvaraju prepostavke za približno točno modeliranje ponašanja kolničke konstrukcije.



**Slika 2. Uredaj za ispitivanje defleksija: a) deflektometar s padajućim teretom; b) uvećani prikaz kružne ploče za prijenos opterećenja [5,8]**

Poznavanjem modela predviđanja ponašanja kolnika postaje moguće planirati vrstu intervencije (održavanje, rehabilitacija ili rekonstrukcija kolničke konstrukcije) kao i odrediti optimalni trenutak u kojem je najpogodnije poduzeti određenu vrstu intervencije. Netočan model predviđanja ponašanja uzrokuje pogrešnu raspodjelu finansijskih sredstava koji će se utrošiti na obnovu kolničke konstrukcije. Sukladno tome, učinkovit sustav prikupljanja podataka razornim i nerazornim metodama ispitivanja kao i periodična održavanja mrežnih odsječaka, zahtijevaju egzaktne modele predviđanja ponašanja. U konačnici, redovitom primjenom pravilnih postupaka održavanja, kvaliteta služnosti kolničkih konstrukcija raste [9].

### 3 Pregled stanja područja

Pozitivni rezultati primjene neuralnih mreža za procjenu ponašanja postojećeg stanja kolničke konstrukcije, potakli su brojne istraživače na primjenu istih prilikom predviđanja ponašanja kolnika u eksploracijskom periodu. Umjetne neuralne mreže su, ne samo jedna od prvih metoda strojnog učenja, nego i jedna od najčešće korištenih metoda umjetne inteligencije u građevinarstvu, a posebice u inženjerstvu kolničkih konstrukcija [9].

U radu [10] se navodi nekoliko prednosti koje opravdavaju primjenu umjetnih neuralnih mreža za rješavanje kompleksnih inženjerskih problema: 1) mogućnost predviđanja modela ponašanja koji mogu vrlo dobro aproksimirati nelinearne odnose; 2) posjedovanjem baze podataka postojećih i budućih terenskih mjerena, moguće je nadograđivati modele predviđanja ponašanja; 3) grupiranje podataka bez obzira na količinu dostupnih informacija; 4) podaci prikupljeni in-situ ispitivanjima ne utječu negativno na proces treniranja neuralne mreže. Nahoujy [11] je koristeći FWD, predložio novi model umjetne neuralne mreže za izračunavanje odstupanja vrijednosti defleksija u bilo kojoj proizvoljnoj točki duž cestovne prometnice, kao dopunu i zamjenu eksperimentalnim mjeranjima. Model je razvijen na temelju povratnog širenja pomoću višeslojne percepcijske mreže. Ovaj način modeliranja predstavlja veliki potencijal za optimizaciju tradicionalnih mjerena u smislu smanjenja troškova terenskih mjerena kao i značajnu preciznost prilikom planiranja strategije održavanja. Meier [12] je u svom radu istraživao mogućnost primjene neuralnih mreža za proračun modula elastičnosti dobivenih temeljem rezultata izmjerениh defleksija pomoću FWD uređaja. Dinamički odgovor kolničke konstrukcije nastao uslijed djelovanja opterećenja izračunat je korištenjem Greenove funkcije temeljene na formirajuće matrice krutosti kolničke konstrukcije. Utvrđeno je da se umjetne neuralne mreže mogu primijeniti za izračunavanje modula elastičnosti kolničke konstrukcije. Abed i dr. [13] su predložili model za predviđanje utjecaja defleksija, temperature i aditiva na krutost asfaltnih mješavina. Za stvaranje modela kombinirana su brojna laboratorijska ispitivanja, različite ulazne varijable, kao i opsežna baza podataka. Istraživanjem su otkrili dobar odnos između stvarnih i očekivanih vrijednosti uslijed čega pretpostavljeni model može s dovoljnom točnošću procijeniti krutost asfaltnih mješavina. Mousa [14] je istraživao uvjete povezanosti između slojeva kolničke konstrukcije na temelju mjerena defleksija dobivenih pomoću uređaja s padajućim teretom. Temeljem dobivenih rezultata zaključio je da povezanost između slojeva značajno utječe na interpretaciju parametara, kao što su moduli elastičnosti generirani povratnom analizom. Razvio je model umjetne neuralne mreže koji omogućava korekciju interpretiranih modula elastičnosti nosivih slojeva na temelju uvjeta povezanosti između slojeva. Predloženi model je pokazao točnost od 95,1%. Pomoću neural-

nih mreža Mosa [15] je predložio model za procjenu oštećenja kolnika kao i model strategije održavanja. Lin i dr. [16] su na temelju podataka o površinskim oštećenjima predvidjeli indeks uzdužne ravnosti (IRI). U svom istraživanju su uočili veliku povezanost između uzdužne ravnosti i pukotina na površini kolničke konstrukcije. Gebely [17] je razvio dva modela za odabir strategije održavanja. Zaključio je da su umjetne neuralne mreže prikladne za ocjenu stanja postojećeg kolnika, kao i predviđanje optimalne strategije održavanja u eksploatacijskom periodu. Thube [18] je predložio četiri modela koja predviđaju stupanj degradacije pojedinih indikatora nosivosti kolničke konstrukcije (pukotine, ljuštenje, uzdužna i poprečna ravnost) na cestama s lakšim prometnim opterećenjem. U svom istraživanju uočio je značajnu povezanost između postojećih i neuralnim mrežama predviđenih oštećenja, što u konačnici rezultira implementacijom predloženih modela za predviđanje ponašanja kolničke konstrukcije u sustave gospodarenja kolnicima. Duckworth i dr. [19] koristili su modele za predviđanje ponašanja kolničkih konstrukcija, uzimajući u obzir različite mjere održavanja na utjecajne činitelje kao što su prometno opterećenje, klimatske okolnosti te okolišni čimbenici. Utvrđeno je da su najrelevantnije rezultate pokazali međunarodni indeks ravnosti (IRI) i indeks stanja kolnika (PCI). Zaključeno je da prepostavljeni model točno generira ponašanje kolnika čak i kad su statistička mjerena bila izvan odgovarajućih raspona. Mjere održavanja implementirane su u predviđeni model ponašanja i u konačnici su se pokazale točnima. Ghанизадеh i Ahadi [20] su pomoću neuralnih mreža istraživali kritične deformacije nastale u savitljivim kolničkim konstrukcijama uslijed djelovanja standardnog osovinskog opterećenja. Rezultati su pokazali da primjena neuralnih mreža ima brojne prednosti, poput smanjenja vremena potrebnog za proračun nosivosti, mogućnost predviđanja zamora i preostalog vijeka trajanja kolničke konstrukcije temeljem podataka o poprečnoj ravnosti kolnika. Pomoću neuralnih mreža Domitrović i dr. [2] su ocijenili stanje postojeće kolničke konstrukcije kao i istražili mogućnost primjene istih za definiranje optimalne strategije održavanja. Neuralna mreža s algoritmom unatražne propagacije primjenjena je na duljini od 481,3 km državnih cesta u Osječko-baranjskoj županiji. Rezultati istraživanja su pokazali uspješnost primjene umjetnih neuralnih mreža za potrebe održavanja kolničkih konstrukcija kao i točnost prilikom predviđanja optimalne strategije održavanja. Dosadašnjim pregledom literature vidljivo je da umjetne neuralne mreže imaju veliki potencijal za predviđanje ponašanja kolničke konstrukcije, kao i definiranje optimalne strategije održavanja.

## 4 Zaključak

Svrha ocjene stanja kolnika je prikupljanje podataka o fizičko-mehaničkim svojstvima kolnika koja opisuju njegovo ponašanje te njihovo iskazivanje kroz određene pokazatelje. Ocjena strukturalnog ponašanja kolničke konstrukcije je relativno složen zadatak, zbog različitih ulaznih varijabli koje otežavaju cijelokupno analiziranje nosivosti (npr. debljina slojeva, prometno opterećenje, nosivost podloge, vremenski uvjeti). Iz toga razloga, razvoj predviđajućih modela ponašanja predstavlja veliki izazov. Sa ciljem rješavanja nelinearnih inženjerskih problema koji se javljaju u kolničkim konstrukcijama, primjena strojnog učenja, posebice neuralnih mreža prema dosadašnjim istraživanjima se pokazala kao kvalitetno rješenje. Većina tih istraživanja odnosi se na predviđanje ponašanja i preostalog vijeka trajanja kolničke konstrukcije ili na temelju funkcionalnih svojstava kolničke konstrukcije ili na temelju strukturalnih svojstava. Za stvaranje egzaktnog modela ponašanja kolničke konstrukcije potrebno je poznavati parametre i funkcionalne i strukturalne nosivosti, te iskoristiti informacije i podatke dobivene razornim i nerazornim metodama ispitivanja. Posebnu pažnju treba posvetiti stvaranju modela koji opisuju postojeće stanje kolničke konstrukcije, a u konačnici predstavljaju neophodan parametar za procjenu preostalog vijeka trajanja. U dalnjim istraživanjima, osim predviđanja strukturalnog ponašanja kolničke konstrukcije, trebalo bi se usredotočiti na stvaranje modela koji će moći inicirati strategiju održavanja. Prednost buduće formirane neuralne mreže koja će obrađivati informacije iz cestovne baze podataka bila bi u tome, što bi mreža, za bilo koji pridodani set novih ulaznih podataka (npr. novo izmjerene vrijednosti defleksija, dubine kolotraga...) sa visokim stupnjem pouzdanosti trebala inicirati ocjenu stanja kolnika na osnovu pravila koje je naučila u prethodnom procesu učenja. Konačnim implementiranjem neuralnih mreža u sustav gospodarenja kolnicima može se dobiti kvalitetni pomoćni alat za donošenje odluke oko usvajanja određene strategije održavanja kolnika za svaku promatrano dionicu ceste [10]. Ovakav rezultat mogao bi poticati umrežavanje industrije, znanosti i politike. Primjena intelligentnih sustava u upravljanju prometnom infrastrukturom očituje se u pružanju pouzdanijih informacija uz manje troškove kao i u razvoju ekonomičnog sustava gospodarenja infrastrukturom.

## Literatura

- [1] Dragovan, H. (2011). Application of neural network in pavement management, Magistarski rad, Sveučilište u Zagrebu, Građevinski fakultet, Zagreb.
- [2] Domitrović, J., Dragovan, H., Rukavina, T., Dimter, S.: Application of an Artificial Neural Network in Pavement Management System, Tehnički vjesnik, vol. 25, br.2, str. 466-473. (2018). <https://doi.org/10.17559/TV-20150608121810>

- [3] Cuculić, M., Pranjić, I., Tibljaš, A.D., Stanić, I.: Analiza asfaltnih kolničkih konstrukcija na temelju podataka strukturalne nosivosti, Zbornik radova (građevinski fakultet Sveučilišta u Rijeci), vol. 23, br. 1, str. 41-55, 2020. <https://doi.org/10.32762/zr.23.1.3>
- [4] Faheem, H.B., Mahmoud, A.A., Hashem, M.D., Moez, M.A.: Modeling of Pavement Maintenance Decisions Using Artificial Intelligence Based on Maintenance Unit, Mansoura Engineering Journal, vol.47, br.3, str. 10-21, 2022. DOI: 10.21608/bfemu.2022.243943
- [5] Rukavina, T.: Korištenje deflektografa s padajućim teretom i georadara za utvrđivanje postojeće i projektiranje potrebne nosivosti kolnika, Seminar Asfaltni kolnici, Zagreb 2014.
- [6] Pierce, L.M., Bruinsma, J.E., Smith, K.D., Wade, M. J., Chatti, K., Vandenbossche, J.M.: Using Falling Weight Deflectometer with Mechanistic-Empirical Design and Analysis, vol.3, U.S. Department of Transportation, Federal Highway Administration, New Jersey, 2017.
- [7] Babić, B.: Projektiranje kolničkih konstrukcija, Zagreb, Hrvatsko društvo građevinskih inženjera, 1997.
- [8] Dynatest-Fast Falling Weight Deflectometer, [www.airport-suppliers.com/product/fast-falling-weight-deflectometer/](http://www.airport-suppliers.com/product/fast-falling-weight-deflectometer/)
- [9] Marcelino, P., Antunes, M.D., Fortunato, E., GAOMES, M.C.: Machine learning approach for pavement performance prediction, International Journal of Pavement Engineering, vol. 22, br.3, str. 341-354, 2019. <https://doi.org/10.1080/10298436.2019.1609673>
- [10] Plati, C., Georgiou, P., Papavasiliou V.: Simulating pavement structural condition using artificial neural networks, Structure and Infrastructure Engineering, vol. 12, br. 9, 2016. <https://doi.org/10.1080/15732479.2015.1086384>
- [11] Nahoujy, M.R.: An Artificial Neural Network approach to model and predict asphalt deflections as a complement to experimental measurements by Falling Weight Deflectometer, Doctoral Thesis, Faculty of Infrastructure and Environmental Engineering Ruhr-Universität Bochum, Germany, 2020, <https://d-nb.info/1212664256/34>
- [12] Meier, R.W., Rix, G.J.: Backcalculation of Flexible Pavement Moduli From Dynamic Deflection Basins Using Artificial Neural Networks, Transportation Research Record, br. 1473, str. 72-81, 1995.
- [13] Abed, M.A., Taki, Z.N.M., Abed, A.H.: Artificial neural network modeling of the modified hot mix asphalt stiffness using Bending Beam Rheometer, Materials Today, vol. 42, br. 5, str. 2584–2589, 2021. DOI:10.1016/J.MATPR.2020.12.583

- [14] Mousa, M., Elseifi, M.A., Omar, E., Mohammad, L.N.: Evaluation of interface bonding conditions based on non-destructing testing deflection measurements, Road Materials and Pavement Design, vol. 20, br. 3, 2017, <https://doi.org/10.1080/14680629.2017.1400995>
- [15] Mosa, A. M.: Neural network for flexible pavement maintenance and rehabilitation, Applied Research Journal, vol. 3, br.4, str. 114-129, 2017.
- [16] Lin, J., Yau, J., Hsiao, L.: Correlation analysis between international roughness index (IRI) and pavement distress by neural network, 82nd Annual Meeting of the Transportation Research Board, Washington DC, str. 12-16, 2003.
- [17] Gebely, H.R.: Pavement maintenance decision model using artificial neural networks, Masters Thesis, Faculty of Engineering, Fayoum University, Egypt, 2015.
- [18] Thube, D.T.: Artificial neural network (ANN) based pavement deterioration models for low volume roads in India, International Journal of Pavement Research Technology, vol. 5, br. 2, str. 115., 2012.
- [19] Duckworth, P., Yasarer, H., Najjar, Y.: Evaluation of Flexible Pavement Performance Models in Mississippi: A Neural Network Approach, Advances in Transportation Geotechnics IV, str. 179-190, 2021.
- [20] Ghanizadeh, A.R., Ahadi, M.R.: Application of Artificial Neural Networks for Analysis of Flexible Pavements under Static Loading of Standard Axle. International Journal of Transportation Engineering, vol.3, br. 1, str. 31–43, 2015.