

Integracija nerazornih ispitivanja i strojnog učenja u sustav gospodarenja kolnicima

Iva Brkić¹, Josipa Domitrović²

¹Županijska uprava za ceste PGŽ, iva.brkic@student.grad.hr

²Građevinski fakultet Sveučilišta u Zagrebu, josipa.domitrovic@grad.unizg.hr

Sažetak

U sustavu gospodarenja kolnicima određivanje homogenih dionica je važan preduvjet za pouzdanu procjenu stanja kolnika i planiranje mjera održavanja. U radu je dan pregled područja određivanja homogenih dionica, uloge nerazornih metoda ispitivanja, s naglaskom na georadar i deflektometar s padajućim teretom, te mogućnosti primjene strojnog učenja. Zaključno, integracija tih pristupa omogućuje pouzdaniju segmentaciju kolnika i kvalitetniju podršku odlučivanju.

Ključne riječi: sustav gospodarenja kolnicima, homogene dionice, nerazorne metode ispitivanja, georadar, deflektometar s padajućim teretom, strojno učenje, segmentacija kolnika

Integration of non-destructive testing and machine learning in pavement management systems

Abstract

In pavement management systems, the identification of homogeneous sections is important for reliable pavement condition assessment and maintenance planning. This paper presents an overview of homogeneous section identification, the role of non-destructive testing methods, with a particular focus on ground penetrating radar and the falling weight deflectometer, as well as the potential application of machine learning. The integration of these approaches can improve the reliability of pavement segmentation and provide better support for decision-making.

Key words: pavement management, homogeneous sections, non-destructive testing, ground penetrating radar (GPR), falling weight deflectometer (FWD), machine learning, pavement segmentation

1 Uvod

Sustav gospodarenja kolnicima predstavlja organiziran pristup upravljanju i održavanju cestovne mreže s ciljem očuvanja njezine funkcionalnosti i sigurnosti [1]. Učinkovitost ovog sustava izravno ovisi o dostupnosti kvalitetnih i preciznih ulaznih podataka o strukturalnom i funkcionalnom stanju kolnika [2, 3]. Analiza podataka na razini cijele cestovne dionice može dovesti do neracionalnog odabira mjera održavanja i sanacije, osobito na dijelovima prometnice koji ne zahtijevaju jednaku razinu intervencije [4, 5]. Stoga je jedan od ključnih koraka u procjeni stanja kolnika podjela prometnice na homogene dionice, odnosno na segmente koji su dovoljno ujednačeni s obzirom na promatrane karakteristike [2, 4, 5]. Tradicionalni pristupi određivanju homogenih dionica uglavnom su se temeljili na ograničenom broju podataka iz projektne dokumentacije te na točkastim destruktivnim ispitivanjima, poput uzimanja uzoraka jezgri kolničke konstrukcije, koja daju točne podatke samo na lokacijama uzimanja uzoraka i ne omogućuju uvid u promjene karakteristika duž prometnice [3, 6]. Nerazorne metode ispitivanja, poput georadara i deflektometra s padajućim teretom, omogućuju kontinuirano prikupljanje podataka o strukturalnom stanju kolnika bez oštećivanja kolničke konstrukcije [2, 3, 6]. Uz razvoj suvremenih metoda prikupljanja podataka, raste i potreba za naprednijim pristupima njihovoj obradi. Razvoj informacijskih tehnologija i umjetne inteligencije otvorio je mogućnosti primjene pristupa temeljenih na podacima (eng. data-driven approach) i strojnom učenju pri ocjeni stanja kolnika [1, 7]. Takvi pristupi olakšavaju obradu većih skupova podataka te pružaju podršku u homogenizaciji i planiranju mjera održavanja i sanacije [1].

Iako su u literaturi razvijeni brojni pristupi za određivanje homogenih dionica, njihova primjena u praksi i dalje je često ograničena na pojedinačne pokazatelje stanja ili djelomičnu interpretaciju rezultata ispitivanja. Za donošenje ispravnih odluka o održavanju potrebno je povezati nerazorna ispitivanja sa suvremenim metodama obrade podataka unutar sustava gospodarenja kolnicima. U radu se daje pregled metoda za određivanje homogenih dionica te uloge nerazornih ispitivanja. Cilj je usporediti tradicionalne i suvremene pristupe te predložiti integraciju podataka dobivenih nerazornim metodama ispitivanja i strojnog učenja, čime se osigurava podloga za pouzdaniju segmentaciju mreže i optimizaciju donošenja odluka u sustavu gospodarenja kolnicima.

2 Homogene dionice u sustavu gospodarenja kolnicima

Promatranje ceste kao jedinstvene cjeline može dovesti do neracionalnih odluka u planiranju održavanja, budući da se svojstva kolnika (nosivost, ravnost, oštećenja) značajno mijenjaju duž dionice, što zahtijeva različite razine intervencije [4,

5]. Homogene dionice mogu se definirati kao dijelovi ceste koji su unutar svojih granica relativno ujednačeni s obzirom na promatrane parametre [5]. Granice homogenih dionica određuju se na mjestima gdje dolazi do izraženijih promjena u promatranim svojstvima kolnika [4, 5, 8]. Takva podjela ceste je važna jer omogućuje pouzdaniju procjenu postojećeg stanja kolnika, racionalnije planiranje mjera održavanja i sanacije te učinkovitiju raspodjelu raspoloživih sredstava unutar sustava gospodarenja kolnicima [1, 9].

Pri određivanju homogenih dionica tradicionalno se primjenjuju jednoparametarski pristupi, odnosno statističke metode. Oslanjanje na samo jedan parametar zahtijeva ponavljanje cjelokupnog postupka za svaki dodatni pokazatelj stanja, što produljuje analizu i povećava vjerojatnost pogrešaka pri interpretaciji rezultata [8]. Od statističkih jednoparametarskih pristupa izdvajaju se Bayesov pristup i minimizacija sume kvadrata pogrešaka (eng. *Minimization of Sum of Squared Errors* – MINSSE). Bayesov pristup probabilistički identificira točke promjene i procjenjuje pouzdanost segmentacije, no primjena mu je ograničena računalnom složenosti. Metoda MINSSE granice određuje minimiziranjem odstupanja unutar pojedinih segmenata, uvažavajući praktična ograničenja poput minimalne duljine dionice. Glavni nedostatak statističkih metoda je osjetljivost na lokalne varijacije podataka, što zbog uvažavanja manje značajnih promjena rezultira povećanjem broja dionica nepraktičnih za održavanje [4]. S obzirom na nedostatke tradicionalnih pristupa sve se više primjenjuju višekriterijski pristupi koji objedinjuju podatke o različitim pokazateljima stanja kolnika te pristupi temeljeni na metodama strojnog učenja, koji omogućuju pouzdanije određivanje homogenih dionica u uvjetima većeg broja ulaznih podataka [2, 4, 8, 9].

Pri određivanju homogenih dionica tradicionalno se primjenjuju jednoparametarski pristupi, odnosno statističke metode. Oslanjanje na samo jedan parametar zahtijeva ponavljanje cjelokupnog postupka za svaki dodatni pokazatelj stanja, što produljuje analizu i povećava vjerojatnost pogrešaka pri interpretaciji rezultata [8]. Od statističkih jednoparametarskih pristupa izdvajaju se Bayesov pristup i minimizacija sume kvadrata pogrešaka (eng. *Minimization of Sum of Squared Errors* – MINSSE). Bayesov pristup probabilistički identificira točke promjene i procjenjuje pouzdanost segmentacije, no primjena mu je ograničena računalnom složenosti. Metoda MINSSE granice određuje minimiziranjem odstupanja unutar pojedinih segmenata, uvažavajući praktična ograničenja poput minimalne duljine dionice. Glavni nedostatak statističkih metoda je osjetljivost na lokalne varijacije podataka, što zbog uvažavanja manje značajnih promjena rezultira povećanjem broja dionica nepraktičnih za održavanje [4]. S obzirom na nedostatke tradicionalnih pristupa sve se više primjenjuju višekriterijski pristupi koji objedinjuju podatke o različitim pokazateljima stanja kolnika te pristupi temeljeni na metodama strojnog učenja, koji omogućuju pouzdanije određivanje homogenih dionica u uvjetima većeg broja ulaznih podataka [2, 4, 8, 9].


Pri određivanju homogenih dionica u obzir se uzima minimalna duljina istih, budući da segmenti moraju biti dovoljno dugi za tehnički i ekonomski opravdanu provedbu mjera održavanja. U literaturi se preporučena minimalna duljina dionice razlikuje ovisno o razini analize, vrsti cestovne mreže, raspoloživim podacima i pravilima pojedinog sustava gospodarenja kolnicima. U radu [4] autori navode da se minimalna duljina segmenta najčešće definira u rasponu od 100 do 300 m, ponajprije zbog tehničkih ograničenja provedbe zahvata i troškova održavanja. S druge strane, noviji radovi za potrebe planiranja održavanja na mrežnoj i projektnoj razini preporučuju dulje segmente. Autori u radu [8] za projektno usmjerene analize navode minimalnu duljinu homogenih dionica od 300 m, u radu [10] za autoceste navode dionice duljine 500 m kao praktično rješenje koje predstavlja kompromis između osjetljivosti na promjene stanja kolnika i provedivosti mjera održavanja. Prekratki segmenti mogu dovesti do prekomjerne segmentacije i otežati provedbu sanacije, dok predugi mogu prikriti lokalne promjene stanja kolnika [4, 8, 10].

U praksi brojni sustavi gospodarenja kolnicima, uključujući Highway Development and Management Model (HDM-4), temelje analizu na homogenim dionicama kao osnovnim jedinicama za modeliranje promjene stanja kolnika i planiranje mjera održavanja, što dodatno potvrđuje važnost njihova pravilnog definiranja [11].

3 Nerazorna ispitivanja u definiranju homogenih dionica

Nerazorne metode ispitivanja imaju važnu ulogu u sustavu gospodarenja kolnicima jer omogućuju brzo, objektivno i kontinuirano prikupljanje podataka o stanju kolnika duž cijele dionice, bez oštećivanja kolničke konstrukcije [2],[3]. U praksi se za procjenu strukturalnog stanja i određivanje homogenih dionica najčešće primjenjuju georadar (eng. *Ground Penetrating Radar* - GPR) i deflektometar s padajućim teretom (eng. *Falling Weight Deflectometer* - FWD), dok se rezultati po potrebi dopunjuju podacima o ravnosti kolnika (eng. International Roughness Indeks, IRI), površinskim oštećenjima i drugim funkcionalnim pokazateljima [2, 3, 12].

Georadar omogućuje brzo i kontinuirano prikupljanje podataka o strukturi kolnika bez oštećivanja kolničke konstrukcije [3, 6]. Metoda se temelji na odašiljanju elektromagnetskih valova i analizi njihovih refleksija na granicama slojeva različitih svojstava, čime se omogućuje procjena debljine slojeva i uočavanje promjena u strukturi kolnika (slika 1.) [2]. GPR omogućuje prepoznavanje nepravilnosti u strukturi kolničke konstrukcije, poput šupljina, zona povećane vlage i drugih karakteristika koje nisu vidljive na površini kolnika. Za razliku od uzimanja uzoraka jezgri, koje daju podatke na pojedinačnim lokacijama, georadar omogućuje kontinuirani uvid u promjene debljine i karakteristika slojeva duž cijele dionice [2, 6].



Slika 1. Shematski prikaz načela rada georadara (GPR)

FWD je nerazorna metoda za procjenu strukturalnog stanja kolnika. Simulira dinamičko opterećenje kotača vozila i mjeri defleksijski odziv kolničke konstrukcije. Osnovni rezultat ispitivanja je defleksijska krivulja, koja omogućava procjenu nosivosti kolnika i uočavanje promjena u nosivosti duž dionice. U kombinaciji s podacima o debljinama slojeva omogućuje provođenje postupka povratnog proračuna za procjenu modula elastičnosti slojeva kolničke konstrukcije. Zbog mogućnosti detektiranja promjene nosivosti, FWD ima važnu ulogu u određivanju granica homogenih dionica [2, 3].

Integracija GPR i FWD podataka omogućuje cjelovitiju procjenu stanja kolnika, pri čemu GPR daje podatke o debljinama slojeva i promjenama u strukturi, a FWD o nosivosti kolnika [3, 6]. Budući da postupak povratnog proračuna ovisi o točnosti podataka o debljinama slojeva, GPR podaci predstavljaju važnu podlogu za interpretaciju rezultata FWD mjerenja. Primjerice, pogreška u debljini asfaltnog sloja od samo 15% može dovesti do precjenjivanja modula elastičnosti za čak 50% [6]. Homogene dionice sve se češće određuju višekriterijskim pristupom koji, uz GPR i FWD podatke, po potrebi uključuje i pokazatelje ravnosti kolnika (IRI), površinskih oštećenja, otpornosti na klizanje te prometnog opterećenja, čime se postiže pouzdanija segmentacija kolnika [2, 8].

Iako nerazorne metode omogućuju prikupljanje velike količine podataka, njihovu širu primjenu u praksi otežavaju složenija obrada podataka, visoki početni troškovi i otpor prema novim tehnologijama unutar cestovnih uprava [1, 6]. Zbog toga se sve više istražuje primjena pristupa temeljenih na podacima i strojnom učenju u analizi stanja kolnika i određivanju homogenih dionica.

4 Primjena strojnog učenja u sustavu gospodarenja kolnicima

Za razliku od tradicionalnih pristupa temeljenih na ručnom prikupljanju podataka i subjektivnim procjenama, suvremeni pristup prikupljanja podataka nerazornim ispitivanjima i njihova računalna obrada omogućuju točnije i objektivnije definiranje stanja kolnika [1]. Velike količine podataka o stanju kolnika dobivene nerazornim metodama zahtijevaju učinkovite postupke obrade kako bi se rezultati mogli pouzdano koristiti u analizi stanja i planiranju mjera održavanja [12]. Pogoršanje stanja kolnika nije linearno tijekom vremena, prvih 50 do 75 % uporabnog vijeka stanje kolnika ostaje relativno stabilno, dok do izraženijeg pogoršanja najčešće dolazi u kasnijim fazama [7]. Zbog toga se pristupi temeljeni na strojnom učenju sve češće primjenjuju kao pomoć pri obradi većih skupova podataka, prepoznavanju obrazaca promjene stanja kolnika i planiranju mjera održavanja.

U sustavima gospodarenja kolnicima pristupi temeljeni na strojnom učenju najčešće se primjenjuju pri određivanju homogenih dionica, predviđanju budućeg stanja kolnika te kao podrška pri planiranju održavanja i sanacije [7, 12]. U određivanju homogenih dionica pritom se često koriste metode grupiranja, poput K-means algoritma i samoorganizirajućih mapa (eng. Self-Organizing Maps, SOM), koje omogućuju prepoznavanje dionica sličnih strukturalnih i funkcionalnih karakteristika [9, 12]. Jedno od važnih područja primjene pristupa temeljenih na strojnom učenju je računalni vid (eng. Computer Vision). Posebno je važan kao zamjena za tradicionalne vizualne preglede, koji su često spori i podložni subjektivnoj procjeni. U praksi se najčešće koristi za automatsku detekciju i klasifikaciju površinskih oštećenja kolnika [1].

Za predviđanje budućeg stanja kolnika primjenjuju se modeli umjetnih neuronskih mreža (eng. Artificial Neural Networks, ANN) te modeli poput algoritma slučajne šume (eng. Random Forest), koji su prikladni za analizu složenih odnosa između prometnog opterećenja, klimatskih utjecaja i svojstva materijala [1, 7]. Kod donošenja odluka strojno učenje pruža podršku pri određivanju prioriteta i odabiru odgovarajućih mjera održavanja i sanacije, dok se u literaturi u tu svrhu navode i optimizacijski pristupi, poput genetskih algoritama [1].

Uspješna primjena strojnog učenja u sustavima gospodarenja kolnicima ovisi o kvaliteti i reprezentativnosti ulaznih podataka, zbog čega su kontinuirani i objektivni podaci prikupljeni nerazornim metodama ispitivanja od posebne važnosti [1, 13]. Međutim, sama dostupnost podataka nije dovoljna, jer pouzdanost takvih pristupa uvelike ovisi o načinu njihove obrade i međusobnog povezivanja te o pravilnoj interpretaciji rezultata. Dodatni izazov predstavlja i činjenica da je složenije modele često teže interpretirati, zbog čega metode strojnog učenja treba promatrati kao alat podrške, a ne kao zamjenu za inženjersku prosudbu [1].

5 Zaključak

Određivanje homogenih dionica jedan je od ključnih postupaka u sustavu gospodarenja kolnicima koji omogućuje pouzdanu procjenu stanja, racionalno planiranje održavanja i učinkovitu raspodjelu sredstava. Postupak zahtijeva integraciju podataka prikupljenih nerazornim ispitivanjima (GPR, FWD, IRI) te pokazatelja površinskih oštećenja i prometnog opterećenja. Glavna prednost takvog integriranog pristupa očituje se u osiguravanju visokokvalitetnih podloga za donošenje odluka, čime se izravno doprinosi optimizaciji prioriteta održavanja i racionalizaciji financijskih resursa.

Velika količina podataka dobivenih nerazornim ispitivanjima nameće primjenu strojnog učenja za određivanje homogenih dionica, predikciju stanja i planiranje održavanja kolnika. Buduća istraživanja trebala bi obuhvatiti uspostavu integrirane baze podataka koja objedinjuje podatke o prometnom opterećenju te funkcionalnim i strukturalnim pokazateljima stanja kolnika, na temelju koje će se primjenom i validacijom algoritama strojnog učenja razviti pouzdani modeli za određivanje homogenih dionica. Budući da pouzdanost navedenih modela ovisi o kvaliteti ulaznih podataka, treba ih promatrati kao podršku, a ne kao zamjenu za inženjersku prosudbu.

Literatura

- [1] Tamagusko, T., Gomes Correia, M., Ferreira, A.: Machine Learning Applications in Road Pavement Management: A Review, Challenges and Future Directions, *Infrastructures* 9 (2024) 12, p. 213.
- [2] Plati, C., Armeni, A., Loizos, A.: Integration of Non-Destructive Testing Technologies for Effective Monitoring and Evaluation of Road Pavements, *NDT* 2 (2024) 4, pp. 430-444.
- [3] Domitrović, J., Rukavina, T.: Application of GPR and FWD in Assessing Pavement Bearing Capacity, *Romanian Journal of Transport Infrastructure* 2 (2013) 2, pp. 11-21.
- [4] Cafiso, S., Di Graziano, A.: Definition of Homogenous Sections in Road Pavement Measurements, *Procedia - Social and Behavioral Sciences* 53 (2012), pp. 1069-1079.
- [5] Misra, R., Das, A.: Identification of Homogeneous Sections from Road Data, *International Journal of Pavement Engineering* 4 (2003) 4, pp. 229-233.
- [6] Marecos, V., Fontul, S., De Lurdes Antunes, M., Solla, M.: Evaluation of a Highway Pavement Using Non-Destructive Tests: Falling Weight Deflectometer and Ground Penetrating Radar, *Construction and Building Materials* 154 (2017), pp. 1164-1172.

- [7] Domitrović, J., Dragovan, H., Rukavina, T., Dimiter, S.: Application of an Artificial Neural Network in Pavement Management System, *Tehnički vjesnik* 25 (2018) Suppl. 2, pp. 466-473.
- [8] Peraka, N.S.P., Biligiri, K.P., Kalidindi, S.N.: Multi-Parametric Delineation Approach for Homogeneous Sectioning of Asphalt Pavements, *Infrastructures* 8 (2023) 10, p. 153.
- [9] Mukhtarli, K., Nik-Bakht, M., Amador-Jimenez, L.: Data-driven Homogeneous Pavement Groups—Soft Versus Hard Clustering, *International Journal of Pavement Research and Technology* 16 (2023) 5, pp. 1135-1157.
- [10] Jannat, G.E., Henning, T.F.P., Zhang, C., Tighe, S.L., Ningyuan, L.: Road Section Length Variability on Pavement Management Decision Making for Ontario, Canada, *Highway Systems*, *Transportation Research Record* 2589 (2016), pp. 87-96.
- [11] Čutura, B., Mladenović, G., Mazić, B., Lovrić, I.: Application of the HDM-4 Model on Local Road Network: Case Study of the Herzegovina-Neretva Canton in Bosnia and Herzegovina, *Transportation Research Procedia* 14 (2016), pp. 3021-3030.
- [12] Mukhtarli, K.: Machine Learning for Homogeneous Grouping of Pavements, Master of Applied Science (Civil Engineering) Thesis, Concordia University, Montreal, Quebec, Canada, 2020.
- [13] Justo-Silva, R., Ferreira, A., Flintsch, G.: Review on Machine Learning Techniques for Developing Pavement Performance Prediction Models, *Sustainability* 13 (2021) 9, p. 5248.