

avgust 2023

letnik 72

Gradbeni vestnik

GLASILO ZVEZE DRUŠTEV GRADBENIH INŽENIRJEV IN TEHNIKOV SLOVENIJE IN
MATIČNE SEKCIJE GRADBENIH INŽENIRJEV INŽENIRSKA ZBORNICE SLOVENIJE



186

INTEGRIRANA METODOLOGIJA
STROJNEGA UČENJA ZA
ANALIZO SLIK BETONSKIH
RAZPOK

194

PRIMERJAVA PRESKUSNIH METOD
DOLOČANJA ZVOČNE IZOLATIVNOSTI
PROTIHRUPNIH OGRAJ

Izdajatelj:
**Zveza društev gradbenih inženirjev in
tehnikov Slovenije (ZDGITS),**
Karlovska cesta 3, 1000 Ljubljana,
telefon 01 52 40 200
v sodelovanju z **Matično sekcijo
gradbenih inženirjev Inženirske
zbornice Slovenije (IZS MSG),**
ob podpori **Javne agencije za
raziskovalno dejavnost RS, Fakultete
za gradbeništvo in geodezijo Univerze
v Ljubljani, Fakultete za gradbeništvo,
prometno inženirstvo in arhitekturo
Univerze v Mariboru in Zavoda za
gradbeništvo Slovenije**

Izdajateljski svet:
ZDGITS: **prof. dr. Matjaž Mikoš, predsednik**
izr. prof. dr. Andrej Kryžanowski
Dušan Jukič
IZS MSG: **dr. Rok Cajzek**
mag. Jernej Nučič
Tina Bučič
UL FGG: **doc. dr. Matija Gams**
UM FGPA: **prof. dr. Miroslav Premrov**
ZAG: **doc. dr. Aleš Žnidarič**

Uredniški odbor: **izr. prof. dr. Sebastjan
Bratina, glavni in odgovorni urednik**
doc. dr. Milan Kuhta

Lektor: **Jan Grabnar**

Lektorica angleških povzetkov:
Romana Hudin

Tajnica: **Eva Okorn**

Oblikovalska zasnova: **Agencija GIG**

Tehnično urejanje, prelom in tisk:
Kočeviski tisk

Naklada: **400 tiskanih izvodov**
3000 naročnikov elektronske verzije

Podatki o objavah v reviji so navedeni
v bibliografskih bazah COBISS in ICONDA
(The Int. Construction Database) ter na
www.zveza-dgits.si

Letno izide 12 številčk. Letna naročnina
za individualne naročnike znaša 25,50 EUR;
za študente in upokoјence 10,50 EUR;
za družbe, ustanove in samostojne podjetnike
188,50 EUR za en izvod revije; za
naročnike iz tujine 88,00 EUR.
V ceni je všteti DDV.
Poslovni račun ZDGITS pri NLB Ljubljana:
SI56 0201 7001 5398 955

Slika na naslovnici:
**pred mesecem dni odprta brv Medvoški lok
je "preživela" katastrofalne poplave,**
foto: Borut Gomboši

**Glasilo Zveze društev gradbenih inženirjev in tehnikov Slovenije in
Matične sekcije gradbenih inženirjev Inženirske zbornice Slovenije.**
UDK-UDC 05 : 625; tiskana izdaja ISSN 0017-2774;
spletna izdaja ISSN 2536-4332.
Ljubljana, avgust 2023, letnik 72, str. 185-204

Navodila avtorjem za pripravo člankov in drugih prispevkov

1. Uredništvo sprejema v objavo znanstvene in strokovne članke s področja gradbeništva in druge prispevke, pomembne in zanimive za gradbeno stroko.
2. Znanstvene in strokovne članke pred objavo pregleda najmanj en anonimen recenzent, ki ga določi glavni in odgovorni urednik.
3. Članki (razen angleških povzetkov) in prispevki morajo biti napisani v slovenščini.
4. Besedilo mora biti zapisano z znaki velikosti 12 točk in z dvojnimi presledkom med vrsticami.
5. Prispevki morajo vsebovati naslov, imena in priimke avtorjev z nazivi in naslovi ter besedilo.
6. Članki morajo obvezno vsebovati: naslov članka v slovenščini (velike črke); naslov članka v angleščini (velike črke); znanstveni naziv, imena in priimke avtorjev, strokovni naziv, navadni in elektronski naslov; oznako, ali je članek strokoven ali znanstven; naslov POVZETEK in povzetek v slovenščini; ključne besede v slovenščini; naslov SUMMARY in povzetek v angleščini; ključne besede (key words) v angleščini; naslov UVOD in besedilo uvoda; naslov naslednjega poglavja (velike črke) in besedilo poglavja; naslov razdelka in besedilo razdelka (neobvezno); ... naslov SKLEP in besedilo sklepa; naslov ZAHVALA in besedilo zahvale (neobvezno); naslov LITERATURA in seznam literature; naslov DODATEK in besedilo dodatka (neobvezno). Če je dodatkov več, so ti označeni še z A, B, C itn.
7. Poglavja in razdelki so lahko oštevilčeni. Poglavja se oštevilčijo brez končnih pik. Denimo: 1 UVOD; 2 GRADNJA AVTOCESTNEGA ODSEKA; 2.1 Avtocestni odsek ... 3 ...; 3.1 ... itd.
8. Slike (risbe in fotografije s primerno ločljivostjo) in preglednice morajo biti razporejene in omenjene po vrstnem redu v besedilu prispevka, oštevilčene in opremljene s podnapisi, ki pojasnjujejo njihovo vsebino.
9. Enačbe morajo biti na desnem robu označene z zaporedno številko v okroglem oklepaju.
10. Kot decimalno ločilo je treba uporabljati vejico.
11. Uporabljena in citirana dela morajo biti navedena med besedilom prispevka z oznako v obliki oglatih oklepajev: [priimek prvega avtorja ali kratica ustanove, leto objave]. V istem letu objavljena dela istega avtorja ali ustanove morajo biti označena še z oznakami a, b, c itn.
12. V poglavju LITERATURA so uporabljena in citirana dela razvrščena po abecednem redu priimkov prvih avtorjev ali kraticah ustanov in opisana z naslednjimi podatki: priimek ali kratica ustanove, začetnica imena prvega avtorja ali naziv ustanove, priimki in začetnice imen drugih avtorjev, naslov dela, način objave, leto objave.
13. Način objave je opisan s podatki: knjige: založba; revije: ime revije, založba, letnik, številka, strani od do; zborniki: naziv sestanka, organizator, kraj in datum sestanka, strani od do; raziskovalna poročila: vrsta poročila, naročnik, oznaka pogodbe; za druge vrste virov: kratek opis, npr. v zasebnem pogovoru.
14. Prispevke je treba poslati v elektronski obliki v formatu MS WORD glavnemu in odgovornemu uredniku na e-naslov: sebastjan.bratina@fgg.uni-lj.si. V sporočilu mora avtor napisati, kakšna je po njegovem mnenju vsebina članka (pretežno znanstvena, pretežno strokovna) oziroma za katero rubriko je po njegovem mnenju prispevek primeren.


Uredništvo

VSEBINA CONTENTS

ČLANKI PAPERS


asist. Luka Gradišar, mag. inž. grad.
doc. dr. Matevž Dolenc, univ. dipl. inž. grad.

**INTEGRIRANA METODOLOGIJA STROJNEGA
UČENJA ZA ANALIZO SLIK BETONSKIH RAZPOK**
*INTEGRATED MACHINE LEARNING
METHODOLOGY FOR CONCRETE
CRACK IMAGE ANALYSIS*



Andraž Zalar, mag. inž. grad.

**PRIMERJAVA PRESKUSNIH METOD DOLOČANJA
ZVOČNE IZOLATIVNOSTI PROTIHRUPNIH OGRAJ**
*COMPARISON OF TEST METHODS FOR
DETERMINATION OF SOUND INSULATION
PERFORMANCE OF NOISE BARRIERS*



FOTOREPORTAŽA Z GRADBIŠČA

dr. Viktor Markelj, univ. dipl. inž. grad.
(Ponting, d. o. o.)

GRADNJA ŽELEZNIŠKEGA VIADUKTA PESNICA



NOVI DIPLOMANTI

Eva Okorn

KOLEDAR PRIREDITEV

Eva Okorn

asist. Luka Gradišar, mag. inž. grad.
Luka.Gradisar@fgg.uni-lj.si



doc. dr. Matevž Dolenc, univ. dipl. inž. grad.
Matevz.Dolenc@fgg.uni-lj.si
Katedra za gradbeno informatiko, Fakulteta za
gradbeništvo in geodezijo, Univerza v Ljubljani,
Jamova cesta 2, 1000 Ljubljana



Znanstveni članek
UDK/UDC: 004.05:620.1/.2:691.32

INTEGRIRANA METODOLOGIJA STROJNEGA UČENJA ZA ANALIZO SLIK BETONSKIH RAZPOK

INTEGRATED MACHINE LEARNING METHODOLOGY FOR CONCRETE CRACK IMAGE ANALYSIS

Povzetek

V zadnjih letih se intenzivno raziskuje odkrivanje razpok v betonskih konstrukcijah s pomočjo strojnega učenja, natančneje z uporabo globokih nevronske konvolucijske mreže. Kljub uporabnosti teh metod je njihova klasifikacija omejena na stanje betona - razpokan ali nerazpokan - medtem ko se redko upoštevajo druge pomembne značilnosti betona, kot so velikost razpok ali različni šumi, ki so prisotni na slikah. V tem članku je opisana integrirana metodologija strojnega učenja za analizo slik razpok v betonu, ki temelji na učenju s prenosom znanja in na nenadzorovanem učenju, ki ne potrebuje podatkov za učenje. Metoda izloča značilnosti slik s pomočjo predhodno naučenih nevronske mreže in jih na podlagi podobnosti razvršča v gruče z uporabo hierarhičnega razvrščanja. Rezultati združevanja v gruče kažejo, da je mogoče slike razdeliti v različne gruče glede na njihove značilnosti, na primer kot so hrapavost površine, vidnost robov, stanje razpokanosti betona, prisotnost različnih predmetov in ostalih шумov. Preizkus te metodologije je pokazal, da je nenadzorovano učenje koristno za analizo slik betonskih razpok, in sicer za razlikovanje med šumnimi slikami in določanjem resnosti razpok. Pridobljene informacije lahko tudi v prihodnje uporabimo za razvoj natančnejših napovednih modelov trajnosti betona oziroma betonskih konstrukcij.

Ključne besede: razvrščanje v gruče, prepoznavanje razpok v betonu, podatkovno rudarjenje, analiza slik, učenje s prenosom znanja, nenadzorovano učenje

Summary

In recent years, the detection of cracks in concrete structures has been intensively researched using machine learning methods, more specifically deep neural convolutional networks. These methods are usually limited in their ability to classify concrete as cracked or uncracked and disregard other features such as the severity of the cracks. In addition, the classification process can be affected by various sources of interference and noise in the images. This paper describes an integrated method for analysing concrete crack images based on transfer and unsupervised learning, without the need for training dataset. The method extracts image features using pre-trained networks and groups them based on similarity using hierarchical clustering. The clustering results demonstrate the ability to partition images into different clusters based on image features so that different clusters can be identified, including clusters containing images of objects, background debris, edges, surface roughness, and cracked and uncracked concrete. The results of this study demonstrate the potential of unsupervised learning for analysing crack image data to distinguish between noisy images and the severity of cracks, which can provide valuable information for developing more accurate predictive models for the sustainability of concrete structures.

Key words: clustering, concrete crack detection, data mining, image analysis, transfer learning, unsupervised learning

1 UVOD

Prepoznavanje slik je pomembno področje računalniškega vida in je predmet intenzivnih raziskav. Pri avtomatskem prepoznavanju slik se pogosto uporabljajo metode strojnega učenja oziroma bolj specifično konvolucijske nevronske mreže (angl. Convolutional Neural Networks - CNN). Te metode prepoznajo značilnosti slik s postopkom, imenovanim konvolucija, pri katerem se na sliki uporabljajo filtri za zaznavanje robov, tekstur in oblik [Zhao Z., 2019]. Takšni modeli se pogosto uporabljajo za spremljanje stanj konstrukcij, vključno z odkrivanjem razpok v betonu. Zgodnje odkrivanje razpok je ključno za oceno stanja in varnosti betonskih konstrukcij, saj razpoke predstavljajo pomemben pokazatelj njihove trajnosti in uporabnosti [Kim, 2019]. Tradicionalne metode odkrivanja razpok, kot so vizualni pregledi ali nedestruktivno testiranje, zahtevajo veliko časa in virov, zaradi česar so se uveljavile različne metode za avtonomno odkrivanje razpok v betonskih konstrukcijah, ki zagotavljajo visoko natančnost in učinkovitost [Zhou, 2023].

Modeli, ki temeljijo na konvolucijskih nevronske mrežah, se za prepoznavanje razpok učijo neposredno iz slikovnih podatkov. Tako naučeni modeli se lahko uporabljajo za različne naloge, kot so klasifikacija slik razpok, zaznavanje robov ali segmentacija [Ali L., 2021]. Eden od glavnih izzivov pri uporabi teh modelov je, da so za učenje potrebne velike zbirke podatkov, kar zahteva tudi veliko računskih virov. Za prepoznavanje slik se pogosto uporabljajo prilagojeni modeli, ki temeljijo na najsoodobnejših konvolucijskih mrežah, kot so AlexNet, VGG, Inception in ResNets [Zaidi, 2022]. Ti modeli so naučeni na obsežnem naboru podatkov o vsakdanjih slikah, kot je na primer nabor podatkov ImageNet [Deng, 2009]. Tako naučeni model lahko razvršča slike, ki so specifične za domeno nabora podatkov za učenje. Čeprav so ti modeli pripravljeni za razvrščanje slik specifične domene, še vedno vsebujejo znanje o prepoznavanju oblik, ki je lahko uporabno tudi na ostalih področjih. Pri tem postopku, znanem kot učenje s prenosom znanja (angl. Transfer Learning), se že naučeni modeli uporabijo kot izhodišče za razvoj modelov na drugih specifičnih domenah. To lahko močno zmanjša količino zahtevanih podatkov in računalskih virov, ki so potrebni za usposabljanje modela za novo nalogo, kljub temu pa se še vedno doseže zahtevana stopnja natančnosti [Pan, 2010]. Metoda učenja s prenosom znanja se je uporabila tudi v raziskavi odkrivanja razpok v betonskih konstrukcijah [Golding, 2022]. V raziskavi so bile predlagane različne kombinacije vnaprejšnjih naučenih modelov s prilagojenimi klasifikatorji za izboljšanje učinkovitosti [Islam, 2022].

Ob tem lahko ugotovimo, da imajo modeli, ki temeljijo na uporabi konvolucijskih nevronske mrež, tudi naslednje omejitve: (1) klasifikacija je pogosto omejena zgolj na dve kategoriji: razpokana in nerazpokana, (2) nezaznavanje drugih pomembnih značilnosti, npr. velikost razpok [Ali R., 2022], in (3) učinkovitost teh modelov je omejena s kakovostjo slik betonskih površin, ki pogosto vključujejo precej šuma, različne ovire, sence in podobno, kar lahko vpliva na natančnost napovedi [Li, 2019]. To je eden glavnih razlogov za razvoj novih metod, ki bi učinkovito razlikovale med podanimi slikami ter jih razvrstile glede na zaznane značilnosti. S tako pridobljenimi informacijami bi lahko izboljšali obstoječe metode in s tem povečali učinkovitost modelov [Cohn, 2021].


V ta namen je predlagana uporaba metod nenadzorovanega učenja (angl. Unsupervised Learning), ki vnaprej ne zahtevajo

označenih podatkov za učenje, temveč se slike analizirajo le na podlagi njihovih implicitnih značilnosti. To omogoča razvrščanje slik v različne gruče, brez vnaprejšnje opredelitve. Te metode so še posebej uporabne v primerih, ko so kategorije slabo določene ali niso podane. V takih primerih se je uporaba nenadzorovanega učenja izkazala za učinkovito in lahko doseže učinkovitost običajnih modelov [Ji, 2019]. Njena uporaba je bila dokazana na različnih področjih, kot so daljinsko zaznavanje, obdelava signalov, spremljanja stanja konstrukcij (angl. structural health monitoring) in segmentacija slik razpok v betonu [Noh, 2017].

V tej raziskavi je predlagana integrirana metodologija za analizo slik razpok v betonu, ki združuje metode učenja s prenosom znanja in nenadzorovano učenje. V predstavljeni metodologiji se metoda učenja s prenosom znanja uporablja za zajem slikovnih značilnosti, na podlagi katerih se lahko nato slike razvrstijo v gruče (angl. Clustering). Gruče se nato analizirajo in razvrstijo glede na zaznane lastnosti z metodo nenadzorovanega učenja. Poleg tega se za dodatno ločevanje podatkov in vizualizacijo rezultatov uporabljajo tehnike za zmanjševanje dimenzij, ki pomagajo pri iskanju napačno razvrščenih slik in izstopajočih podatkov. Predstavljena metodologija tako omogoča pridobivanje informacij o drugih značilnostih slik in ne samo analizo slik glede razpokanosti oz. nerazpokanosti betonske površine.

2 PREDLAGANA METODOLOGIJA

Predlagana metodologija (slika 1) se ukvarja z analizo specifičnega nabora podatkov, ki vključuje slike razpokane betonske površine. Ta postopek vključuje uporabo vnaprejšnjih usposobljenih modelov nevronske mreže za izločanje značilnosti, ki vsebujejo le najpomembnejše informacije v vektorskem formatu. Te značilnosti se nato uporabijo za izračun razdalj med posameznimi podatkovnimi točkami, ki odražajo podobnosti med slikami. Na podlagi teh razdalj se oblikujejo hierarhične gruče. V nadaljevanju analiziramo posamezne gruče. Podatke iz gruč pretvorimo v 2D-prostor z uporabo metod za zmanjšanje dimenzij. Te pretvorijo podatke z veliko parametri v manj razsežen namišljen prostor, tako da se še vedno ohranijo ključne lastnosti [Zhao B., 2022]. To omogoča vizualizacijo podatkov in prepoznavanje odstopajočih elementov in osamelcev, ki lahko predstavljajo napačno razvrščene ali označene slike, kar lahko pripomore k izboljšanju napovednega modela. Metodologija je primerna tako za uporabo z označenimi kot tudi z neoznačenimi podatki. O označenih podatkih govorimo, kadar podatki vsebujejo vnaprejšnje določene oznake, kot je npr. 'razpoka'/'ni razpoke'. V tem primeru ti zagotavljajo dodaten kontekst za uporabnika, vendar ne prispevajo k učenju nenadzorovanih modelov.



Slika 1. Delotok predlagane metodologije.

2.1 Učenje s prenosom znanja

Pri prepoznavanju slik se za prenos znanja pogosto uporablja dva ključna pristopa: prilagajanje uteži in izločanje značilnosti. Pri prilagajanju uteži se arhitektura predhodno naučenega modela ohrani, prilagodi pa se uteži nevronske celice s pomočjo učenja na novem naboru podatkov. Na drugi strani, pri izločanju značilnosti, se odstranijo zadnje plasti vnaprej naučene nevronske mreže in nadomestijo z novo nevronske mrežo, medtem ko se ostalo 'zamrzne' [Ribani, 2019]. Rezultat tega pristopa je običajno visokodimenzionalni vektor, ki vsebuje numerične vrednosti specifičnih značilnosti. Te vrednosti se lahko uporabijo za različne naloge, kot so na primer klasifikacija slik, iskanje podobnih slik v naboru podatkov ali iskanje podobnih slik [Wu, 2017]. Ta pristop je še posebej uporaben v primerih, ko imamo na voljo omejeno količino učnih podatkov [Shaha, 2018].

V tej študiji se uporablja tehnika izločanja značilnosti, vendar brez učenja nove nevronske mreže. V ta namen se uporabijo predhodno naučeni modeli, predvsem VGG-16, VGG-19 in Inception v3. Med njimi je model Inception v3 pokazal najvišjo uspešnost pri izločanju značilnosti slik razpokanega betona [Gradišar, 2023]. Zadnji sloj v modelu nevronske mreže, ki se običajno uporablja za klasifikacijo, pa se odstrani. Na ta način se visokodimenzionalni slikovni prostor predstavi v kompaktnem nizkodimenzionalnem prostoru glavnih značilnosti, v katerem so zajete najpomembnejše značilnosti slike. To nam omogoči izluščiti značilnosti na novem naboru podatkov in jih uporabiti za razvrščanje podobnih slik v gruče.


2.2 Nenadzorovano učenje

Nenadzorovano učenje, podpodročje strojnega učenja, je postopek učenja na neoznačenih podatkih z namenom

prepoznavanja implicitnih struktur podatkov. V nasprotju z učenjem s prenosom, ki za učenje modela za napovedovanje uporablja označene podatke, se pri nenadzorovanem učenju iščejo le razlike med neoznačenimi podatki ter odkrivajo vzorci in povezave med njimi, brez vnaprej pripravljenih točnih pravil. Zaradi pomanjkanja označenih podatkovnih ali s tem povezanih visokih stroškov se metode nenadzorovanega učenja pogosto uporabljajo na različnih področjih, kot so podatkovno rudarjenje, obdelava naravnega jezika in računalniški vid. Te metode vključujejo razvrščanje v gruče, zmanjševanje razsežnosti, odkrivanje anomalij in generativne modele, ki se lahko uporabljajo za različne vrste podatkov, vključno s slikami, besedilom in podatki časovnih vrst [Witten, 2005].

Za iskanje podobnih podatkov se lahko uporablja hierarhično razvrščanje, pri katerem se na podlagi izračunanih razdalj med njimi oblikujejo hierarhične gruče. Posamezne podatkovne točke se v vsaki iteraciji združujejo v vedno večje gruče, kar ustvari hierarhično strukturo. Gruče se sestavijo na način, ki najmanj poveča varianco med podatkovnimi točkami in združenimi skupinami. Tako nastanejo gruče, podobne po velikosti in obliki, ki se jih prikaže v dendrogramu (slika 2) [Murtagh, 2014].

Visokodimenzionalni podatki lahko predstavljajo nekaj izzivov v smislu vizualizacije ali zahtevanih računskih virov. V ta namen se lahko za reševanje teh vprašanj uporabijo tehnike zmanjševanja dimenzije. Njihov cilj je zmanjšati število značilnosti z ustvarjanjem novih, nepovezanih spremenljivk, ki zajamejo najpomembnejše informacije v podatkih [Zhao B., 2022]. Te nove spremenljivke se lahko uporabijo za predstavitev podatkov v manj razsežnem prostoru, kar olajša vizualizacijo podatkov in njihovo nadaljnje ločevanje ali iskanje napačno razvrščenih primerov.



Slika 2. Postopek razvrščanja slik razpok betona v gruče glede na podobnost.

3 PREIZKUS IN REZULTATI

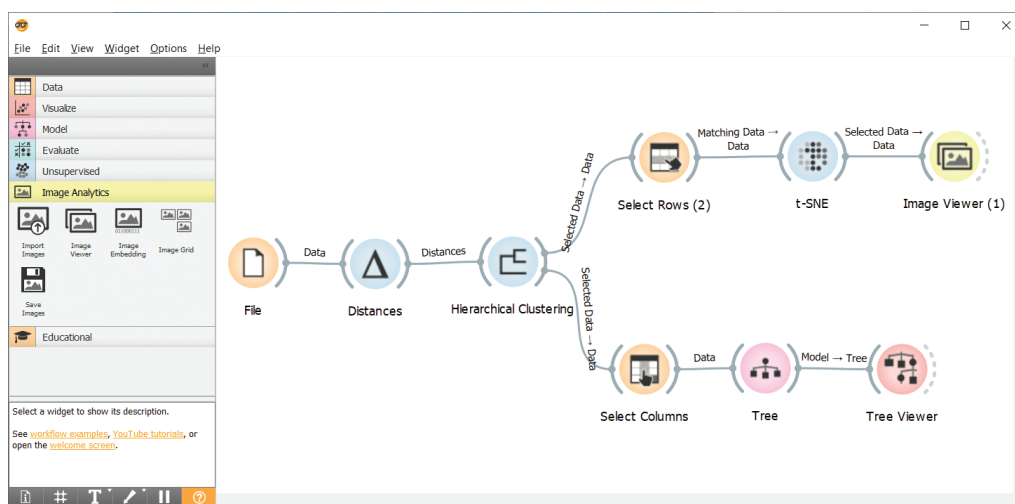
Za preizkus metodologije so bile pridobljene slike razpokanega in nerazpokanega betona iz javnega nabora podatkov, SDNET2018 [Maguire, 2018]. Slike so bile obdelane z vnaprej naučenim modelom nevronske mreže (uporabili smo model Inception v3), kateri je bil odstranjen zadnji sloj z namenom izločanja značilnosti, kot je opisano v razdelku 2.1. Iz izločenih značilnosti so bile izračunane razdalje med podatkovnimi točkami in nato oblikovane hierarhične gruče. Poskus je bil razdeljen na dva dela: (i) ocenjevanje podatkov v skupinah in (ii) analiza podatkov iz posameznih skupin z uporabo metod za zmanjševanje dimenzij.

Za potrebe analize smo uporabili Orange [Demšar, 2013], odprtokodno orodje za rudarjenje podatkov. Program ponuja

3.1 Razvrstitev podatkov v gruče

Za razvrstitev v gruče se je podrobno analiziralo vse slike iz predstavljenega nabora podatkov po predpostavljani metodologiji. Za preverjanje se je spremljalo razvrstitev slik v posameznih skupinah glede na razmerje med obema razredoma slik – število slik z razpokanim betonom in nerazpokanim betonom. Spodaj predstavljeni rezultati so osredotočeni na analizo zbirke slik betonskih sten, ki vsebuje 18.139 segmentov slik, od katerih je 3.851 označenih kot razpokane, 14.287 pa kot nerazpokane. V tem primeru oznake slik služijo ugotavljanju kakovosti razvrščanja slik v različne gruče.


Ta proces je potekal tako, da se je slika celotne stene razdelila na manjše segmente, iz katerih je bilo mogoče prepoznati specifične značilnosti slike. Vsak segment slike se je nato analiziral



Slika 3. Orange – odprtokodno orodje za rudarjenje podatkov v Pythonu.

zbirko gradnikov za strojno učenje in vizualizacijo podatkov, ki omogoča uporabnikom izvajanje različnih nalog analize podatkov. Zbirka orodij podpira gradnjo delotokov s povezovanjem različnih gradnikov za pripravo in analizo podatkov ter vizualizacijo. Natančneje, v naši analizi podatkov o slikah betonskih razpok je bil izdelan delotok (slika 3), ki je vključeval gradnike za vstavljanje slik, izračun razdalje, hierarhično razvrščanje v gruče in zmanjšanje dimenzij z metodo t-SNE [van der Maaten, 2008].


Testni podatki (slike betonskih razpok) so bili pridobljeni iz nabora podatkov SDNET2018, ki je javno dostopen nabor podatkov in vključuje 56.000 označenih slik razpokanih in nerazpokanih betonskih površin, vključno z različnimi dodatnimi elementi, kot so sence, nepravilnosti, robovi, luknje, hrapavost površine in ostanki ozadja. Nabor podatkov vsebuje raznolik izbor betonskih površin iz treh različnih virov: mostnih ploščadi, zidov in pločnikov. Ločljivost slik je bila 256 × 256 slikovnih pik v barvnem spektru RGB [Maguire, 2018]. Pri tem je treba poudariti, da gre za označene podatke, saj vsebujejo oznako, ali je na sliki prisotna razpoka ali ne.




Slika 4. Razdelitev slike stene na segmente in njihova razvrstitev v tri značilne gruče: gruča slik nerazpokanega betona (modro), gruča slik z razpokami in gruča slik (rdeče), ki prikazujejo odprtine v betonu (vijolično).

z nevronske mreže, ki je vsakemu segmentu dodelila vektor značilnih vrednosti. Na podlagi teh vrednosti se je izračunala razdalja med slikami, ki je predstavljala podobnost med njimi. Preko gručenja so se glede na razdalje segmenti slik razvrstili v posamezne gruče, ki so bile nato vizualno pregledane, da so se ugotovile njihove značilnosti. Ta proces je prikazan na sliki 4, ki prikazuje razdelitev celotne slike stene na segmente in njihovo razvrstitev v tri značilne gruče: gruča slik nerazpokanega betona, gruča slik z razpokami in gruča slik, ki prikazujejo odprtine v betonu.


Analiza celotnega obsega slik je pokazala, da je mogoče prepoznati gruče, ki vsebujejo razpokan ali nerazpokan beton s točnostjo 84,5 % in natančnostjo 86,2 % [Gradišar, 2023]. Sicer ta metoda dosega slabše rezultate kot konvencionalne konvolucijske nevronske mreže [Ali R., 2022], vendar omogoča prepoznati dodatne gruče, ki vsebujejo različne šume ali elemente (sence, ovire, nepopolnosti površin), prisotne v podatkovnem nizu (slika 5). Prav tako je mogoče najti tudi slike razpokanega betona, ki so glede na velikost razdeljene v različne gruče, tj. od gruče z ozkimi razpokami (slika 6 levo) do gruče z zelo širokimi razpokami (slika 6 desno).



Slika 5. Gruče z visoko ločljivostjo, ki vključujejo slike betona brez razpok: (levo) gruča slik z ovirami; (sredina) gruča slik z nepopolnostmi; (desno) gruča slik betona brez razpok.



Slika 6. Gruče z visoko ločljivostjo, ki vsebujejo slike razpokanega betona: (levo) gruča slik z ozkimi razpokami; (sredina) gruča slik srednje širokih razpok; (desno) gruča slik s širokimi razpokami.



Slika 7. Gruče z nizko ločljivostjo, ki vsebujejo slike betona z razpokami in brez razpok: (levo) gruča slik z odprtinami; (sredina) gruča slik z luknjasto površino; (desno) gruča slik z zelo ozkimi razpokami.

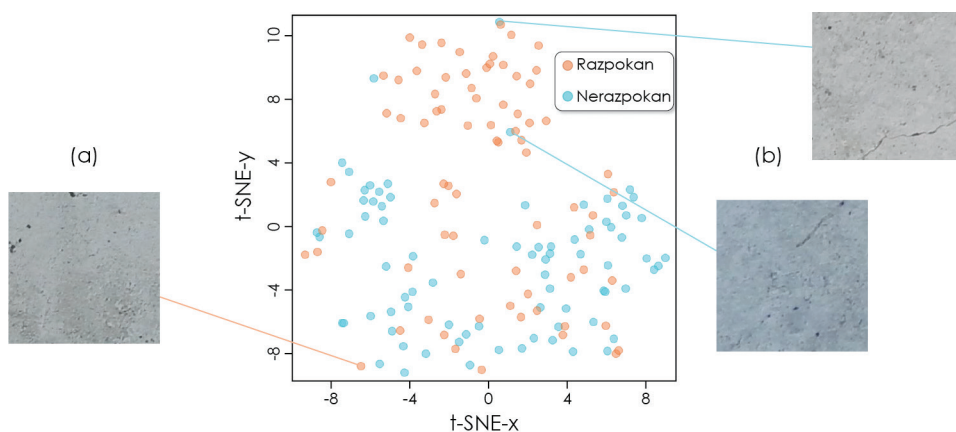
Prisotne so tudi gruče slik z nizko ločljivostjo, ki vključujejo mešanico slik iz obeh razredov. To velja za predvsem za gruče slik, ki vsebujejo zelo majhne in ozke razpoke (slika 7 desno) ali kjer v sliki prevladujejo ostale posebnosti (slika 7 levo). V teh primerih razvrščanja v gruče je težje razlikovati med obema razredoma, saj so si slike zelo podobne ne glede na to, ali vsebujejo razpoke ali ne.

Kljub navedenemu zagotavlja analiza podatkov, ki so razvrščeni v gruče, dragocen vpogled v značilnosti podatkovnih nizov in omogoča bolj poglobljeno razumevanje rezultatov. S pomočjo razvrščanja v gruče lahko dodamo slikam dodatne oznake za razlikovanje različnih značilnosti, kot so nepravilnosti v slikah ali velikosti razpok. Prav tako je mogoče iz nabora podatkov pred uporabo dodatnih napovednih modelov odstraniti slike brez razpok, kar lahko uporabimo za gradnjo natančnejših na-


povednih modelov in izboljšanje splošne učinkovitosti postopka razvrščanja slik.

3.2 Analiza podatkov iz posameznih skupin

Za nadaljnjo analizo rezultatov so bile za posamezne gruče uporabljene metode za zmanjšanje dimenzij. V ta namen je bil visokodimenzionalni vektor izločenih podatkov pretvorjen v vektor z dvema glavnima komponentama z uporabo metode glavnih komponent (angl. Principal Component Analysis - PCA). Za prikaz slik je bila uporabljena statistična metoda t-SNE (angl. t-distributed Stochastic Neighbor Embedding). 2D-diagram prikaza lahko uporabimo za iskanje morebitnih napačno razvrščenih slik ali dodatne povezave med slikovni-



Slika 8. 2D-diagram razpršitve t-SNE, ki vizualizira slikovne podatke iz skupin in omogoča identifikacijo morebiti napačno označenih slik.



Slika 9. 2D-diagram razpršitve t-SNE, ki prikazuje slike z razpokami, ki se zmanjšujejo s koordinato x in kjer se površinske nepopolnosti povečujejo s koordinato y.

mi značilnostmi in njihovim položajem v diagramu. S tem postopkom je bilo odkritih več napačno označenih slik, namreč s slike 8 je razvidno, da so bile nekatere od slik označene kot nepoškodovane, vendar so ob vizualnem pregledu vsebovale le sence ali druge nepravilnosti zaradi majhnih lukenj (a) na površini, druge pa so bile označene kot nerazpokane, vendar so imele vidne razpoke (b). Ob tem je treba opozoriti, da vse izstopajoče navidezne podatkovne točke niso napačno označene, saj so si nekatere točke zaradi drugih prevladujočih znakov zelo podobne, z razpokami ali brez njih. Vizualizacija podatkov iz manjših podskupin pa olajša njihov pregled in določanje njihovih značilnosti.

Vizualizacija slik na razpršeni ploskvi omogoča tudi prepoznavanje korelacij med koordinatami glavnih komponent in značilnostmi slik. Pri analizi večje gruče slik, ki je vključevala slike razpokanega betona, smo ugotovili slednje povezave. Ugotovili smo, da se velikost razpok zmanjšuje v smeri x-koordinate, medtem ko y-koordinata označuje obseg površinskih nepopolnosti in hrapavosti, kot je prikazano na sliki 9.

3.3 Diskusija

Rezultati prikazujejo uspešno razvrščanje v gruče brez potrebe po učenju novih modelov ali po uporabi označenih slikovnih podatkov. Za ta namen so bili slikovni podatki obdelani z vnaprej naučenim modelom nevronske mreže - v našem primeru smo uporabili model Inception v3. Z razvrščanjem v gruče smo uspeli razlikovati med slikami razpokanega in nerazpokanega betona ter različnimi nepravilnostmi (ovire, nepopolnosti, robovi in hrapavost površine) v slikah podatkovnega niza. Poleg tega smo z uporabo tehnik za zmanjšanje dimenzionalnosti odkrili več potencialno napačno označenih slik v uporabljenem podatkovnem naboru.

Razvrščanje v gruče dveh razredov slik (razpokanega in nerazpokanega betona) ne dosega enake uspešnosti kot uveljavljeni modeli konvolucijskih nevronske mreže. To je posledica težav pri razlikovanju med dvema razredoma, kadar na sliki prevladujejo nepravilnosti ali dodatni elementi. V takih primerih razvrščanje v gruče pogosto združuje slike ne glede na prisotnost razpok. To pomanjkljivost bi lahko odpravili s segmentacijo slik na manjša območja, kar bi povečalo njihovo različnost in izboljšalo učinkovitost razvrščanja v gruče. Kljub temu pa razvrščanje v gruče zagotavlja pomembne dodatne informacije, ki se jih lahko uporabi za izboljšanje nabora podatkov, na primer z odstranjevanjem slik z nepravilnostmi ali slik, ki ne prikazujejo betona.

4 SKLEP

Raziskava predlaga integrirano metodologijo za analizo slik razpok v betonu, ki temelji na učenju s prenosom in nenadzorovanem učenju. Predstavljen pristop izloča značilnosti slik s pomočjo predhodno naučenih modelov nevronske mreže in jih na osnovi podobnosti razvršča v gruče. Za dodatno razlikovanje in vizualizacijo podatkov smo uporabili tehniko zmanjševanja dimenzionalnosti, kar je olajšalo pregled razvrščenih slik in iskanje napak.

Rezultati študije potrjujejo uporabnost predlaganega pristopa za analizo slikovnih podatkov o razpokah v betonu z integracijo učenja s prenosom in nenadzorovanega učenja. Iz pridobljenih izkušenj lahko izluščimo več potencialnih aplikacij: (1) razvrščanje v gruče lahko služi za identifikacijo motenj na slikah in njihovo odstranitev iz velikih podatkovnih zbirk, (2) slike razpokanega betona je mogoče razvrstiti v gruče glede na stopnjo razpokanosti in (3) zmanjšanje dimenzionalnosti se lahko uporabi za vizualizacijo rezultatov razvrščanja, identifikacijo napačno razvrščenih slik, izločanje ključnih značilnosti iz skupin slik in povezovanje le-teh z njihovimi lastnostmi v realnem svetu.

Raziskava ponuja tudi alternativno poenostavljeno metodo za odkrivanje razpok v betonu, ki ne zahteva učenja ali učnih podatkov. Predlagano metodologijo bi lahko nadgradili z uporabo nadzorovanih tehnik razvrščanja in tako optimizirali rezultate obstoječih metod.

5 ZAHVALA

Raziskava je bila financirana v okviru programa mladih raziskovalcev Javne agencije za raziskovalno dejavnost Republike Slovenije ter raziskovalnega programa E-Gradbeništvo (P2-0210).

6 LITERATURA

Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., Serhani, M. A., Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures, *Sensors*, 21, 1688, <https://doi.org/10.3390/s21051688>, 2021.

Ali, R., Chuah, J. H., Talip, M. S., Mokhtar, N., Shoaib, M. A., Structural Crack Detection Using Deep Convolutional Neural Networks, *Automation in Construction*, 133, 103989, <https://doi.org/10.1016/j.autcon.2021.103989>, 2022.

Cohn, R., Holm, E., Unsupervised Machine Learning Via Transfer Learning and k-Means Clustering to Classify Materials Image Data, *Integrating Materials and Manufacturing Innovation*, 10, 231-244, <https://doi.org/10.1007/s40192-021-00205-8>, 2021.

Demšar, J., Curk, T., Erjavec, A., Gorup, C., Hočvar, T., Milutinovič, M., Zupan, B., Orange: Data Mining Toolbox in Python, *Journal of Machine Learning Research*, 14, 2349-2353, 2013.

Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L., ImageNet: A Large-Scale Hierarchical Image Database, *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, 22-24 junij, 248-255, 2009.

Golding, V. P., Gharineiat, Z., Munawar, H. S., Ullah, F., Crack Detection in Concrete Structures Using Deep Learning, *Sustainability*, 14, 8117, <https://doi.org/10.3390/su14138117>, 2022.

Gradišar, L., Dolenc, M., Transfer and Unsupervised Learning: An Integrated Approach to Concrete Crack Image Analysis, *Sustainability*, 15, 3653, <https://doi.org/10.3390/su15043653>, 2023.

- Islam, M. M., Hossain, M. B., Akhtar, M. N., Moni, M. A., Hasan, K. F., CNN Based on Transfer Learning Models Using Data Augmentation and Transformation for Detection of Concrete Crack, *Algorithms*, 15, 287, <https://doi.org/10.3390/a15080287>, 2022.
- Ji, X., Vedaldi, A., Henriques, J., Invariant Information Clustering for Unsupervised Image Classification and Segmentation, *IEEE/CVF International Conference on Computer Vision*, Seoul, South Korea, 27. oktober–2. november, 9864–9873, 2019.
- Kim, H., Ahn, E., Shin, M., Sim, S-H., Crack and Noncrack Classification from Concrete Surface Images Using Machine Learning, *Structural Health Monitoring*, 18(3), 725-738, <https://doi.org/10.1177/147592171876874>, 2019.
- Li, S., Zhao, X., Image-Based Concrete Crack Detection Using Convolutional Neural Network and Exhaustive Search Technique, *Advances in Civil Engineering*, 12, <https://doi.org/10.1155/2019/6520620>, 2019.
- Maguire, M., Dorafshan, S., Thomas, R. J., SDNET2018: A Concrete Crack Image Dataset for Machine Learning Applications, Utah State University, Logan, UT, USA, <https://doi.org/10.15142/T3TD19>, 2018.
- Murtagh, F., Legendre, P., Ward's Hierarchical Agglomerative Clustering Method: Which Algorithms Implement Ward's Criterion? *Journal of Classification*, 31, 274-295, <https://doi.org/10.1007/s00357-014-9161-z>, 2014.
- Noh, Y., Koo, D., Kang, Y.-M., Park, D., Lee, D., Automatic Crack Detection on Concrete Images Using Segmentation via Fuzzy c-Means Clustering, *International Conference on Applied System Innovation (ICASI)*, Sapporo, Japan, 13.-17. maj 2017, 877, 2017.
- Pan, S. J., Yang, Q., A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, 22, 1345-1359, <https://doi.org/10.1109/TKDE.2009.191>, 2010.
- Ribani, R., Marengoni, M., A Survey of Transfer Learning for Convolutional Neural Networks, *32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*, Rio de Janeiro, Brazil, 28-31 oktober 2019, 47-57, <https://doi.org/10.1109/SIBGRAPI-T.2019.00010>, 2019.
- Shaha, M., Pawar, M., Transfer Learning for Image Classification, *Second International Conference on Electronics, Communication and Aerospace Technology*, Coimbatore, Indija, 29.-31. marec 2018, 656-660, <https://doi.org/10.1109/ICECA.2018.8474802>, 2018.
- van der Maaten, L., Hinton, G., Visualizing Data using t-SNE, *Journal of Machine Learning Research*, 9, 2579-2605, 2008.
- Witten, I. H., Frank, E., Hall, M. A., *Data Mining: Practical Machine Learning Tools and Techniques*, Morgan Kaufmann, San Francisco, CA, USA, 664, 2005.
- Wu, C., Manmatha, R., Smola, A. J., Krähenbühl, P., Sampling Matters in Deep Embedding Learning, *IEEE International Conference on Computer Vision*, Venice, Italy, 22.-29. oktober 2017, 2859-2867, <https://doi.org/10.1109/ICCV.2017.309>, 2017.
- Zaidi, S. S., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., Lee, B., A Survey of Modern Deep Learning Based Object Detection Models, *Digital Signal Processing*, 126, 103514, <https://doi.org/10.1016/j.dsp.2022.103514>, 2022.
- Zhao, B., Dong, X., Guo, Y., Jia, X., Huang, Y., PCA Dimensionality Reduction Method for Image Classification, *Neural Processing Letters*, 54, 347-368, <https://doi.org/10.1007/s11063-021-10632-5>, 2022.
- Zhao, Z., Zheng, P., Xu, S., Wu, X., Object Detection with Deep Learning: A Review, *IEEE Transactions on Neural Networks and Learning Systems*, 99, 1-21, <https://doi.org/10.1109/TNN-LS.2018.2876865>, 2019.
- Zhou, S., Canchilam, C., Song, W., Deep learning-based crack segmentation for civil infrastructure: Data types, architectures, and benchmarked performance, *Automation in Construction*, 146, 104678, <https://doi.org/10.1016/j.autcon.2022.104678>, 2023.

Andraž Zalar, mag. inž. grad.
andraz.zalar@zag.si
Zavod za gradbeništvo Slovenije,
Dimičeva ulica 12, Ljubljana



Strokovni članek
UDK/UDC: 628.517.2:625.745

PRIMERJAVA PRESKUSNIH METOD DOLOČANJA ZVOČNE IZOLATIVNOSTI PROTIHRUPNIH OGRAJ

COMPARISON OF TEST METHODS FOR DETERMINATION OF SOUND INSULATION PERFORMANCE OF NOISE BARRIERS

Povzetek

Protihrupne ograje so dobra rešitev za zaščito bivalnega okolja pred prometnim hrupom. Prispevek predstavlja zvočno izolativnost ograd. Ugotavlja se z laboratorijskimi in terenskimi merilnimi metodami, pri čemer se rezultati meritev po obeh metodah zaradi različnih zvočnih polj nekoliko razlikujejo. V nadaljevanju se s primerjavo rezultatov laboratorijskih in terenskih meritev zvočne izolativnosti na istih vzorcih ograd določi medsebojna povezava rezultatov obeh vrst meritev v obliki linearne regresije. To se primerja z regresijo, dobljeno v študiji projekta QUIESST. Treba je poudariti, da je zvočna izolativnost vzorcev v prispevku obravnavanih ograd večinoma bistveno manjša od zvočne izolativnosti ograd, obravnavanih v študiji QUIESST.

Ključne besede: protihrupne ograje, zvočna izolativnost, merilne metode, primerjava merilnih metod

Summary

Noise barriers are a good solution to protect the residential environment from traffic noise. This research paper presents sound insulation performance of barriers. It is determined by laboratory and in-situ measurement methods, although the results of measurements using both methods differ somewhat due to the different sound fields. In the following, by comparing the results of laboratory and in-situ sound insulation measurements on the same test samples of barriers, the correlation between both types of measurements is determined in the form of linear regression. This regression is compared with the one obtained in the study of the QUIESST project. It should be emphasized that the samples measured in this paper mostly perform significantly lower in terms of sound insulation than those used in the QUIESST study.

Key words: noise barriers, sound insulation performance, measurement methods, comparison of measurement methods

1 UVOD

Splošno najbolj moteč hrup v bivalnem okolju je hrup cestnega prometa [Čudina, 2001]. Zaradi povečevanja števila motornih vozil ta hrup še narašča, zato se omejuje z različnimi protihrupnimi ukrepi. Med najpogostejše ukrepe v Sloveniji sodijo protihrupne ograje, saj z vidika zmanjšanja hrupa predstavljajo učinkovito in enostavno rešitev. Najmanj posegajo v sam vir hrupa oz. cestni promet in sprejemnike, npr. stanovanjske objekte, zaščitijo pa lahko velika območja v bližini cest. V prispevku so predstavljene akustične lastnosti ograj in njihov vpliv na učinkovitost pri zaščiti pred hrupom prometa. V nadaljevanju prispevek prikaže ovrednotenje akustičnih lastnosti ograj z uporabo standardiziranih laboratorijskih in terenskih merilnih metod ugotavljanja zvočne izolativnosti. Po laboratorijskih in terenskih merilnih metodah dobljene vrednosti zaradi uporabe različnih zvočnih polj medsebojno niso neposredno primerljive. Zaradi različnih v nadaljevanju prispevka opisanih dejavnikov je smiselno iz vrednosti rezultatov laboratorijskih meritev določiti vrednosti rezultatov terenskih meritev in obratno.

Namen prispevka je potrditi, da je z laboratorijskimi in terenskimi meritvami zvočnih izolativnosti istih vzorcev ograj možno določiti regresijo, ki opiše povezavo med vrednostmi rezultatov laboratorijskih in terenskih meritev zvočne izolativnosti. Naslednji cilj je potrditev skladnosti dobljene regresije z regresijo, dobljeno v študiji projekta QUIESST (Quietesting the Environment for a Sustainable Surface Transport), kjer je pri meritvah sodelovalo več evropskih laboratorijev [Conter, 2021]. Ograje, obravnavane v prispevku, imajo večinoma majhno zvočno izolativnost. Študija QUIESST takih ograj ni obravnavala. Torej se z določitvijo regresije, dobljene v prispevku, potrdi njena uporabnost tudi za ograje z majhno zvočno izolativnostjo.

2 AKUSTIČNE LASTNOSTI PROTIHROPNIH OGRAJ

Pri cestah brez protihrupnih ograj se zvok med prometom, ki predstavlja zvočni vir, in sprejemnikom prenaša nepo-

sredno ter z odbojem zvoka od tal do sprejemnika [Kotzen, 2009]. S postavitvijo ograje se ti dve poti prekineta. Kot je prikazano na sliki 1, se pri tem zvok deloma prenaša skozi ograjo, deloma od nje odbija, deloma v njej absorbira in deloma ukloni preko nje. Od zvočnega vira na eni strani do sprejemnika na drugi strani ograje se prenaša zvok torej neposredno skozi ograjo in z uklonom okrog stranskih robov ograje ter preko ograje.

3 ZVOČNA IZOLIRNOST

V splošnem predstavlja mero za zvočno izolativnost ograje zvočna izolirnost R , ki je definirana kot logaritemsko razmerje vpadle in prenesene zvočne moči. Določi se z enačbo [Simons, 2004]:

$$R = 10 \cdot \log\left(\frac{1}{\tau}\right) = 10 \cdot \log\left(\frac{W_1}{W_2}\right) \quad (\text{dB}), \quad (1)$$

kjer je:

τ - koeficient prenosa zvoka ($/$),


W_1 - zvočna moč, ki vpada na ograjo s strani vira (W),

W_2 - zvočna moč, ki se prenaša skozi ograjo in seva proti sprejemniku (W).


Konkretno za hrup prometa se zvočna izolativnost ograje ovrednoti z enoštevlično vrednostjo izolirnosti pred zvokom v zraku DL_R , izmerjeno v laboratoriju, in enoštevlično vrednostjo izolirnosti pred zvokom v zraku DL_{SR} , izmerjeno na terenu. Obe vrednosti sta predstavljeni v nadaljevanju prispevka.

3.1 Laboratorijska metoda ugotavljanja zvočne izolirnosti ograj


Enoštevlično vrednost izolirnosti pred zvokom v zraku DL_R se uporablja za prikaz in primerjavo splošne zvočnoizolacijske učinkovitosti različnih ograj, projektiranih za ceste v odmevnih pogojih, na primer v globokih vkopih ali ob visokih stavbah. Dobljena je v laboratoriju z meritvami po preskusni metodi za ugotavljanje izolirnosti ograj pred zvokom v zraku v difuznem (razpršenem) zvočnem polju. Metoda je



Slika 1. Prenos zvoka pri postavljeni ograji [Vanhooreweder, 2017].



Slika 2. Skica postavitve vzorca ograje v laboratorijski preskusni odprtini [SIST, 2018a].



Slika 3. Laboratorijsko merjenje zvočne izolirnosti ograje.

določena v standardu [SIST, 2018a]. Pri meritvah se uporabljata dve sosednji sobi. Ena je soba z virom hrupa (oddajna soba), druga pa sprejemna soba. Preskusni vzorec ograje, sestavljen iz akustičnih elementov in stebra, je vstavljen v preskusno odprtino med obema sobama in sestavljen na enak način kot na terenu (sliki 2 in 3). V oddajni sobi je postavljen neusmerjeni zvočnik, ki ustvarja odmevne pogoje kot približek difuznega zvočnega polja. Difuzno zvočno polje je definirano kot idealno odmevno zvočno polje, v katerem je gostota zvočne energije enakomerna po celotnem prostoru, in če izberemo katerokoli točko v prostoru, bo obstajala enaka verjetnost, da bo zvočni val, ki prihaja v to točko, prispel v kateremkoli trenutku iz katerekoli smeri [Hopkins, 2007]. Neprekinjeno premikajoča se mikrofona, eden v oddajni in drugi v sprejemni sobi, istočasno po prostoru merita ravni zvočnega tlaka v terčnih frekvenčnih pasovih s srednjimi frekvencami med 100 in 5000 Hz [SIST, 2021]. V sprejemni sobi se izvedejo še meritve odmevnega časa. To je čas, ki je potreben, da po prekinitvi zvoka iz zvočnika pade raven zvočnega tlaka v prostoru za 60 dB [SIST, 2004].

Izmerjene ravni zvočnega tlaka v oddajni in sprejemni sobi ter odmevni čas so osnova za izračun laboratorijske zvočne izolirnosti R_i i-tega terčnega pasu po enačbi [SIST, 2021]:

$$R_i = L_{1i} - L_{2i} + 10 \cdot \log \frac{S \cdot T_i}{0,16 \cdot V} \quad (\text{dB}), \quad (2)$$

kjer je:

L_{1i} - povprečna raven zvočnega tlaka i-tega terčnega pasu v oddajni sobi (dB),

L_{2i} - povprečna raven zvočnega tlaka i-tega terčnega pasu v sprejemni sobi (dB),

S - površina odprtine med oddajno in sprejemno sobo, v katero je vstavljen preskusni vzorec (m^2),

T_i - odmevni čas i-tega terčnega pasu (s),

V - volumen sprejemne sobe (m^3).

Posamezne izmerjene zvočne izolirnosti R_i v i-tih terčnih pasovih med 100 in 5000 Hz se utežijo z uporabo v standardu [SIST, 1999] definiranih ravni zvočnega tlaka za frekvenčni spekter prometnega hrupa, kar je osnova za izračun enoštevilčne vrednosti izolirnosti ograje DL_R po enačbi [SIST, 2018a]:


$$DL_R = -10 \cdot \log \left[\frac{\sum_{i=1}^{18} 10^{0,1 \cdot L_i} \cdot 10^{-0,1 \cdot R_i}}{\sum_{i=1}^{18} 10^{0,1 \cdot L_i}} \right] \quad (\text{dB}), \quad (3)$$

kjer je:

R_i - zvočna izolirnost i-tega terčnega pasu (dB),

L_i - raven zvočnega tlaka za frekvenčni spekter prometnega hrupa v i-tem terčnem pasu ob upoštevanju korekcije po korekcijski krivulji A (dB).

Pri ograji z vrednostjo DL_R vsaj 25 dB je prispevek skozi ograjo prenesenega zvoka zanemarljiv v primerjavi s celotnim zvokom, ki se prenese od zvočnega vira na eni do sprejemnika na drugi strani ograje. V tem primeru se predpostavi, da se celoten zvok prenese z uklonom okrog robov pri straneh ograje ali preko vrha ograje. Takšna ograja ima zadostno izolirnost in se obravnava kot zvočno neprepustna [Kotzen, 2009].



Slika 4. Merilna greda in merilne točke [SIST, 2018b].


3.2 Terenska metoda ugotavljanja zvočne izolirnosti ograj

Enoštevilčna vrednost izolirnosti pred zvokom v zraku DL_{S_I} se uporablja za prikaz in primerjavo splošne zvočnoizolacijske učinkovitosti različnih ograj, projektiranih za ceste v neodmevnih pogojih, ocenjevanje ustrežne zvočne izolirnosti ograj na terenu in preverbo skladnosti vgrajenih ograj z načrti. Dobljena je na mestu vgradnje ograj ali na testnem polju s terenskimi meritvami po preskusni metodi za ugotavljanje izolirnosti ograj pred zvokom v zraku v usmerjenem zvočnem polju. Metoda je določena v standardu [SIST, 2018b].

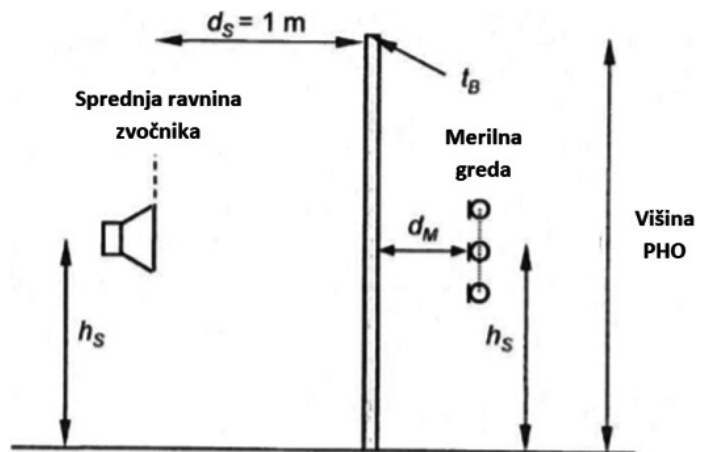
Meritve potekajo na način, da se na eno stran ograje namesti zvočnik z usmerjenim zvočnim poljem, ki generira impulzni zvočni signal, na drugo stran pa merilno gredo, sestavljeno iz okvirja, na katerem je devet vertikalnih in medsebojno enako razporejenih mikrofonskih pozicij v kvadratni 3x3 razporeditvi (sliki 4 in 5). Mikrofon, ki se namesti na vsako izmed devetih merilnih mest merilne grede, z meritvijo impulznega odziva beleži signal skozi ograjo prenesenega zvoka. Načrt postavitve pri meritvah je podan na sliki 6.

Za pridobitev rezultatov referenčnega direktnega zvoka v prostem polju se enaka meritev kot pri merjenju z ograjo ponovi še na mestu brez vmesne ograje. S primerjavo močnostnih spektrov direktnega in skozi ograjo prenesenega signala, ki predstavljata porazdelitev moči signala po frekvencah tega signala, se določi posamezna impulzna zvočna izolirnost ograje v i -tem terčnem pasu SI_i med 100 in 5000 Hz. Pri tem v obravnavo ne sme biti zajet uklon zvoka preko robov ograje, kar je odvisno od najmanjše dimenzije (višine ali dolžine) obravnavane ograje. Zato se z grafa, prikazanega v standardu [SIST, 2018b], določi glede na najmanjšo dimenzijo ograje najnižji za upoštevanje pri določitvi izolirnosti SI_i še zanesljiv terčni pas od 100 Hz navzgor f_{min} . Posamezne izolirnosti SI_i se utežijo z uporabo ravni zvočnega tlaka za frekvenčni spekter prometnega hrupa, kar je osnova za izračun enoštevilske vrednosti izolirnosti ograje DL_{S_I} po enačbi [SIST, 2018b]:

$$DL_{S_I} = -10 \cdot \log \left[\frac{\sum_{i=m}^{18} 10^{0,1 \cdot L_i} \cdot 10^{-0,1 \cdot SI_i}}{\sum_{i=m}^{18} 10^{0,1 \cdot L_i}} \right] \quad (\text{dB}), \quad (4)$$



Slika 5. Merilna greda z mikrofonom pri terenskih meritvah zvočne izolirnosti z vmesno ograjo.



Slika 6. Prikaz merjenja skozi ograjo prenesenega zvoka pri terenskih meritvah zvočne izolirnosti [SIST, 2018b].

kjer je:

- m - število najnižjega še zanesljivega terčnega pasu od 100 Hz navzgor f_{min} ,
- L_i - raven zvočnega tlaka za frekvenčni spekter prome-tnega hrupa v i -tem terčnem pasu ob upoštevanju korekcije po korekcijski krivulji A (dB),
- SI_i - impulzna zvočna izolirnost ograje v i -tem terčnem pasu (dB).

V primeru, da je ograja sestavljena iz akustičnih elementov in stebrov, se meritev in izračun vrednosti DL_{SI} izvedeta tako pri akustičnem elementu kot tudi pri stebri. S kombinacijo obeh vrednosti se določi skupna vrednost $DL_{SI,G}$ po enačbi [SIST, 2018b]:

$$DL_{SI,G} = -10 \cdot \log \left[\frac{10^{-0,1 \cdot DL_{SI,E}} + 10^{-0,1 \cdot DL_{SI,P}}}{2} \right] \quad (\text{dB}), \quad (5)$$

kjer je:

- $DL_{SI,E}$ - enoštevilična vrednost izolirnosti akustičnega elementa (dB),
- $DL_{SI,P}$ - enoštevilična vrednost izolirnosti stebra (dB).

4 PRIMERJAVA LABORATORIJSKE IN TERENKE METODE

Laboratorijska in terenska metoda preiskav za ugotavljanje zvočne izolirnosti ograj imata vsaka svoje prednosti. Z laboratorijskimi preiskavami proizvajalci ograj ugotavljajo ustreznost ograj še pred njihovo izgradnjo na terenu. Terenske preiskave so glede na laboratorijske enostavnejše za izvedbo, saj ograj ni treba transportirati v laboratorij, ampak se lahko preverjajo kar na samem mestu vgradnje. Pomembna prednost terenskih preiskav je tudi odkrivanje in odpravljanje različnih napak pri sami izvedbi vgradnje, kot so npr. vrzeli, slabi stiki, neustrezna sestava ograj in drugo.

Pri načrtovanju ograj je npr. lahko zahtevano, da se morajo ograje uvrstiti v določeno kategorijo zvočnoizolacijske učinkovitosti, ki je definirana le v standardu o laboratorijskih preiskavah [SIST, 2018a], v standardu o terenskih preiskavah [SIST, 2018b] pa ne. S kategoriziranjem se preveri akustična ustreznost ograj. V primeru, da je možno izvesti le terenske preiskave, npr. zaradi že vgrajenih ograj na samem mestu vgradnje, ali če želimo npr. ugotoviti zvočno izolirnost ograje v neodmevnih zvočnih pogojih, ki so prisotni na mestu vgradnje, vendar pa v laboratoriju niso zagotovljeni, je treba rezultate terenskih preiskav pretvoriti v laboratorijske.

Ti rezultati medsebojno niso neposredno primerljivi [SIST, 2018b], saj je, kot že omenjeno, pri terenskih preiskavah zvočno polje usmerjeno (zvočno valovanje se od zvočnika proti mikrofону brez odbojev širi pod določenim vpadnim kotom), pri laboratorijskih pa je odmevno (vsi vpadni koti zvočnih valov na mikrofón so enako verjetni). Zato se je izvedla raziskava, s katero se je ugotavljalo, v kakšni medseboj-

ni povezavi so rezultati obeh meritev. Opravile so se meritve zvočne izolirnosti različnih vzorcev ograj. Vsak vzorec se je meril tako na terenu kot v laboratoriju. Iz dobljenih rezultatov meritev se je nato s pomočjo linearne regresije določila povezanost laboratorijskih in terenskih rezultatov.

V raziskavi ugotovljena linearna regresija, ki rezultatom laboratorijskih meritev zvočne izolirnosti ograj DL_R priredi rezultate $DL_{SI,R}$, ki bi bili dobljeni s terenskimi meritvami, je predstavljena z enačbo:

$$DL_{SI,R} = 1,251 \cdot DL_R - 1,750 \quad (\text{dB}). \quad (6)$$

Z linearno regresijo se lahko ugotavlja tudi obratno, torej da rezultatom terenskih meritev zvočne izolirnosti DL_{SI} priredi rezultate $DL_{R,I}$, ki bi bili dobljeni z laboratorijskimi meritvami, in sicer z naslednjo enačbo, določeno na podlagi izvedene raziskave:

$$DL_{R,I} = 0,799 \cdot DL_{SI} + 1,399 \quad (\text{dB}). \quad (7)$$

Korelacijski koeficient linearne regresije R^2 je 0,988, kar nakazuje, da z dobljeno linearno regresijo lahko zelo dobro opišemo povezavo med laboratorijskimi in terenskimi rezultati.


Dobljeni rezultati so se primerjali z rezultati raziskovalne študije, narejene v okviru evropskega projekta QUIESST, kjer so se izvedli medlaboratorijski preizkusi za različne vrste ograj. Po študiji QUIESST je linearna regresija, ki iz rezultatov laboratorijskih meritev zvočne izolirnosti ograj DL_R priredi rezultate terenskih meritev $DL_{SI,Q}$, podana z naslednjo enačbo:

$$DL_{SI,Q} = 1,225 \cdot DL_R - 1,493 \quad (\text{dB}). \quad (8)$$

Korelacijski koeficient linearne regresije R^2 je po tej enačbi 0,954. Tudi študija QUIESST torej potrjuje zelo dobro povezanost med laboratorijskimi in terenskimi rezultati.

Na sliki 7 so prikazane primerjalne vrednosti laboratorijskih in terenskih meritev zvočne izolirnosti, izmerjene na vzorcih v prispevku predstavljene študije in dobljene iz rezultatov vzorcev iz študije QUIESST, poleg tega pa še premici linearne regresije izmerjenih vzorcev $DL_{SI,I}$ in linearne regresije iz študije QUIESST $DL_{SI,Q}$. Linearni regresiji $DL_{SI,I}$ in $DL_{SI,Q}$ sta enakovredni, kar je razvidno iz grafičnega ujemanja obeh regresijskih premic na sliki 7. Analitično pa se njuno enakovrednost potrdi z izračunom standardne napake linearne regresijske ocene za $DL_{SI,I}$ in $DL_{SI,Q}$ pri čemer je seštevek obeh standardnih napak večji od medsebojne razlike med realno največjima izračunanima terenskima vrednostma zvočne izolirnosti $DL_{SI,I}$ in $DL_{SI,Q}$ po enačbah (6) in (8).

Kot je razvidno s slike 7, je večina v študiji izmerjenih vzorcev ograj imela nizke vrednosti izolirnosti (DL_R pod 25 dB). Takih vzorcev študija QUIESST ni zajela v obravnavo. Tako se je z določitvijo linearne regresije potrdila njena uporabnost tudi pri zvočno manj izolativnih ograjah z DL_R vrednostjo, manjšo od 25, vendar večjo od 10 dB.



Slika 7. Primerjalne vrednosti laboratorijske in terenske zvočne izolirnosti izmerjenih vzorcev in vzorcev iz študije QUIESST ter premici linearne regresije $DL_{Si,I}$ in $DL_{Si,Q}$

5 UKLON ZVOKA

V povezavi s prenosom zvoka od zvočnega vira na eni strani ograje do sprejemnika na drugi strani je treba omeniti tudi uklon zvoka okrog robov pri straneh ograje in preko vrha ograje, saj je ta najpomembnejši vzrok omejevanja zvočnoizolacijske učinkovitosti ograj. Njegov vpliv na zvočnoizolacijsko učinkovitost ograj je sicer neizogiben, vendar lahko k njegovemu zmanjšanju in posledično večji učinkovitosti ograj največ prispevajo višje in bolj navpične ograje. Dodatno lahko k temu pripomoreta še povečanje površine absorpcijskih oblog na ograjah in namestitve dodatnih ovir na vrhu ograj. Pri višjem deležu tovornega prometa glede na promet osebnih vozil je učinkovitost ograj manjša, saj se nizkofrekvenčni zvok, ki ga v prometu ustvarjajo predvsem tovorna vozila, v primerjavi z visokofrekvenčnim veliko enostavneje uklanja preko ograje [Vanhooreweder, 2017].

6 SKLEP

Laboratorijski in terenski rezultati meritev zvočne izolirnosti ograj zaradi različnih zvočnih polj med seboj niso neposredno primerljivi. Lahko se zgodi, da je zaradi izpolnjevanja zahtev treba ograje uvrstiti v določene kategorije zvočnoizolacijske učinkovitosti, ki so definirane le pri laboratorijskih meritvah. Zato je v primeru, ko je možna le izvedba terenskih meritev, treba določiti povezavo med rezultati obeh vrst meritev. V prispevku obravnavana študija je potrdila, da

je z laboratorijskimi in terenskimi meritvami zvočnih izolirnosti istih vzorcev ograj možno določiti linearno regresijo, ki dobro opiše to povezavo. Dobljena linearna regresija se ujema z linearno regresijo iz študije projekta QUIESST. Obravnavane ograje so imele večinoma manjšo zvočno izolirnost od tistih, zajetih v študiji QUIESST. V prispevku predstavljena povezava med rezultati laboratorijskih in terenskih meritev je torej potrdila njeno uporabnost tudi pri ograjah z nizkimi vrednostmi zvočnih izolirnosti, katerih izmerjena vrednost DL_R pa je večja od 10 dB.

7 LITERATURA

Conter, M., Deliverable 2.2: Final report on the main results of WP2 (including M2.1, M2.2. and M2.3) - Acoustic assessment of the intrinsic performances of noise barriers. CEDR Transnational Road Research Programme 2018, spletna stran portala - <https://drive.google.com/file/d/1zYBkZZiiUqyyOefSLsgpesUR816IWXdj/view?pli=1>, 2021.

Čudina, M., Tehnična akustika. Merjenje, vrednotenje in zmanjševanje hrupa in vibracij, Ljubljana, Univerza v Ljubljani, Fakulteta za strojništvo, 2001.

Hopkins, C., Sound Insulation. 1st ed., Oxford, Burlington, Elsevier Ltd., 2007.

Kotzen, B., English, C., Environmental Noise Barriers. A guide to their acoustic and visual design, London, New York, Spon Press, 2009.

Simons, M. W., Waters, J. W., Sound Control in Buildings. A Guide to Part E of the Building Regulations, Oxford, Blackwell Publishing Ltd., 2004.

SIST, SIST EN 1793-3: 1999, Protihrupne ovire za cestni promet - Preskusna metoda za ugotavljanje akustičnih lastnosti - 3. del: Normalizirani spekter hrupa cestnega prometa, Slovenski inštitut za standardizacijo, Ljubljana, 1999.

SIST, SIST EN ISO 354: 2004, Akustika - Merjenje absorpcije zvoka v odmevnici, Slovenski inštitut za standardizacijo, Ljubljana, 2004.

SIST, SIST EN 1793-2: 2018, Protihrupne ovire za cestni promet - Preskusna metoda za ugotavljanje akustičnih lastnosti - 2. del: Karakteristike, značilne za izolacijo pred zvokom v zraku, Slovenski inštitut za standardizacijo, Ljubljana, 2018a.

SIST, SIST EN 1793-6: 2018, Protihrupne ovire za cestni promet - Preskusna metoda za ugotavljanje akustičnih lastnosti - 6. del: Bistvene karakteristike - Terenske vrednosti izolirnosti pred zvokom v zraku pri usmerjenem zvočnem polju, Slovenski inštitut za standardizacijo, Ljubljana, 2018b.

SIST, SIST EN ISO 10140-2: 2021, Akustika - Laboratorijsko merjenje zvočne izolirnosti gradbenih elementov - 2. del: Merjenje izolirnosti pred zvokom v zraku, Slovenski inštitut za standardizacijo, Ljubljana, 2021.

Vanhooreweder, B., Marcocci, S., De Leo, A., Technical Report 2017-02. State of the art in managing road traffic noise: noise barriers. Conference of European Directors of Roads, Bruselj, CEDR's Secretariat, spletna stran portala - <https://www.cedr.eu/download/Publications/2017/CEDR-TR2017-02-noise-barriers.pdf>, 2017.

FOTOREPORTAŽA GRADNJA ŽELEZNIŠKEGA VIADUKTA PESNICA



Slika 1. Dvotirni viadukt Pesnica dolžine 912 m, avgust 2023 (foto: Ponting, d. o. o.).

Lokacija: Pesnica pri Mariboru

Investitor: Direkcija RS za infrastrukturo

Projektant viadukta: Ponting, d. o. o., Maribor, odg. projektant dr. Viktor Markelj, univ. dipl. inž. grad.

Inženir: DRI upravljanje investicij, d. o. o., Ljubljana

Izvajalec odseka: JV Pomgrad, d. d., Kolektor Koling, d. o. o., SŽ-ŽGP Ljubljana, d. d., GH-Holding, d. o. o., Gorenjska gradbena družba, d. d.

Izvajalec viadukta: Pomgrad, d. d., Murska Sobota

Končna vrednost del: 14,8 mio. EUR z DDV (objekt je sofinanciran s strani Evropskega kohezijskega sklada)

Konec leta 2020 se je začela gradnja novega 3,7 km dolgega železniškega odseka med Mariborom in Pesnico. Poleg 1,5 km dolgega predora se na tem odseku proge nahaja tudi novi dvotirni viadukt Pesnica širine 14,36 m ter dolžine 912,60 m, s čimer bo to najdaljši železniški viadukt v Sloveniji. Viadukt premošča poplavno dolino reke Pesnice in pritoka Cirknice, poteg tega pa premošča še avtocesto A1 Ljubljana-Šentilj, glavno cesto Pesnica-Lenart ter lokalne ceste. Viadukt je namenjen elektrificirani dvotirni železniški progi, ki pa bo v prvi fazi izvedena kot enotirna. Tesna obremenitev viadukta je bila izvedena avgusta 2023, nakar je bil sproščen tudi železniški promet po tem novem odseku.

V ekstremnem vremenu, ki je doletelo Slovenijo to poletje, je poplavljala tudi reka Pesnica. Zato je treba poudariti, da je koncept viadukta odporen proti velikim železniškim obtežbam pa tudi proti vsem ekstremnim naravnim dogodkom kot so poplave, plazovi, neurja z vetrovi, spremembe temperature in potresi.

Viadukt je inovativno zasnovan kot serija integralnih okvirjev ter je v celoti brez konstrukcijskih ležišč. Posamezen okvir sestavljajo piloti, trije različni tipi stebrov ter prednapeta prekladna konstrukcija. Elementi so med sabo monolitno povezani v duktilno okvirno konstrukcijo, s čimer imajo dodatno rezervo nosilnosti. Viadukt je sestavljen iz 7 okvirjev dolžine 112 m ter dveh krajnih okvirjev polovične dolžine. Oba krajna opornika sta nepomična, brez ležišč, monolitno povezana s prekladno konstrukcijo. Prekladna konstrukcija ima prečni prerez dveh reber konstrukcijske višine 2,30 m. Prednapenjanje segmenta dolžine 112 m je inovativno iz sredine s po 8 kablov na rebro, pri čemer je vsak kabel prednapet s silo 3800 kN. Kabli so elektroizolirani v PEHD-cevi sistema Freyssinet.

Preko viadukta in opornikov poteka tir na togi podlagi (TTP), kar je prva implementacija TTP na viaduktu v Sloveniji. Tir poteka kot zvezno zavarjen tir brez dilatacijskih naprav v progi, kar je velik prispevek k varnosti prometa, stroškom izgradnje in vzdrževanja ter varovanju okolja pred hrupom.



Slika 2. Kompleksna armatura razdeljenega stebra (foto: Srečko Prša, Pomgrad, d. d.).



Slika 3. Razdeljeni steber je podpora dveh okvirjev (foto: Ponting, d. o. o.).



Slika 4. Viadukt z odrom za novi segment (foto: Srečko Prša, Pomgrad, d. d.).



Slika 5. Pogled od spodaj (foto: Ponting, d. o. o.).



Slika 6. Betoniranje zadnjega segmenta, oktober 2022 (foto: Pomgrad, d. d.).



Sliki 7 in 8. Viadukt premošča avtocesto, glavno cesto, poplavno območje, reko pesnico in Cirknico ter lokalne ceste (foto: Ponting, d. o. o.).



Slika 9. Prva aplikacija tira na togi podlagi na viaduktu v Sloveniji (foto: Ponting, d. o. o.).



Slika 10. Med okvirji so vgrajene hidravlične naprave za prenos udarnih sil STU 2500 kN (foto: Ponting, d. o. o.).



Slika 11. Viadukt se nevsiljivo vklaplja v okolje (foto: Ponting, d. o. o.).

Avtor fotoreportaže: dr. Viktor Markelj, univ. dipl. inž. grad. (Ponting, d. o. o.)

NOVI DIPLOMANTI GRADBENIŠTVA

UNIVERZA V LJUBLJANI, FAKULTETA ZA GRADBENIŠTVO IN GEODEZIJO

I. STOPNJA – UNIVERZITETNI ŠTUDIJSKI PROGRAM VODARSTVO IN OKOLJSKO INŽENIRSTVO

Lana Radulović. Vpliv prestrežanja padavin na mikrostrukturo padavin, mentorica prof. dr. Mojca Šraj, somentor doc. dr. Nejc Bezak;
<https://repozitorij.uni-lj.si/lzpisGradiva.php?id=148101>

II. STOPNJA – MAGISTRSKI ŠTUDIJSKI PROGRAM GRADBENIŠTVO (smeri Gradbene konstrukcije, Geotehnika-hidrotehnika, Nizke gradnje)

Ožbej Vene. Analiza učinkovitosti prezračevanja stavb na osnovi meritev in simulacij koncentracij ogljikovega dioksida in radona, mentorica izr. prof. dr. Mateja Dovjak, somentorica prof. dr. Janja Vaupotič;
<https://repozitorij.uni-lj.si/lzpisGradiva.php?id=148100>

Ana Likovič. Projektiranje konstrukcij s steklenimi nosilnimi elementi s primerom zimskega vrta, mentor izr. prof. dr. Primož Može, somentor doc. dr. David Antolinc;
<https://repozitorij.uni-lj.si/lzpisGradiva.php?id=148082>

UNIVERZA V MARIBORU, FAKULTETA ZA GRADBENIŠTVO, PROMETNO INŽENIRSTVO IN ARHITEKTURO

I. STOPNJA – UNIVERZITETNI ŠTUDIJSKI PROGRAM GRADBENIŠTVO

Zala Petauer. zaključek študija brez zaključnega dela.

Nejc Luetič. zaključek študija brez zaključnega dela.

UNIVERZA V MARIBORU, FAKULTETA ZA GRADBENIŠTVO, PROMETNO INŽENIRSTVO IN ARHITEKTURO – EKONOMSKO POSLOVNA FAKULTETA

INTERDISCIPLINARNI ŠTUDIJ GOSPODARSKEGA INŽENIRSTVA – SMER GRADBENIŠTVO

II. STOPNJA – MAGISTRSKI ŠTUDIJSKI PROGRAM

Elvis Zadavec. Uvedba delotoka BIM in koordinacije BIM v gradbeno podjetje, mentorja izr. prof. dr. Andrej Tibaut in izr. prof. dr. Igor Perko, somentorica asist. dr. Sara Filipa Guerra de Oliveira;
<https://dk.um.si/lzpisGradiva.php?id=83342&lang=slv>

Rubriko ureja **Eva Okorn**, gradb.zveza@siol.net

12.-15.9.2023

TKZ2023- 20th Technical Dam Control International Conference
Chorzów, Poljska
<https://tkz.is.pw.edu.pl/en/>

17.-20.9.2023

ICPIC2023 - 17th International Congress on Polymers in Concrete
Varšava, Poljska
<https://icpic23.org/>

17.-21.9.2023

12ICG - 12th International Conference on Geosynthetics
Rim, Italija
www.12icg-roma.org

18.-20.9.2023

FRC 2023 - 4th ACI-fib-RILEM Workshop on Fiber Reinforced Concrete: From Design to Structural Applications
Tempe, Arizona, ZDA
<https://faculty.engineering.asu.edu/frc2023>

18.-22.9.2023

ICCC 2023 — 16th International Congress on the Chemistry of Cement 2023
Bangkok, Tajska
www.iccc2023.org

21.-23.9.2023

ICCUE 2023 - 10th International Conference on Civil and Urban Engineering
Rim, Italija
www.iccue.org/

22.-24.9.2023

ICCPM 2023 — The 14th International Conference on Construction and Project Management
Peking, Kitajska
www.iccpm.org/

28.-30.9.2023

11th International Conference on Auditorium Acoustics 2023
Atene, Grčija
<https://auditorium2023.org/>

3.-5.10.2023

SEG 2023 — Symposium on Energy Geotechnics
Delft, Nizozemska
<https://seg23.dryfta.com>

13.-15.10.2023

ICACHE 2023 — 2023 9th International Conference on Architectural, Civil and Hydraulic Engineering
Čingdao, Kitajska
www.icache.net/

19.-20.10.2023

3. slovenski kongres o vodah
Ptuj, Slovenija
<https://kongresvode.si/>

23.-25.10.2023

TINCE'23 - Technological Innovations in Nuclear Civil Engineering
Pariz, Francija
www.sfen.org/evenement/tince23/

26.-27.10.2023

44. zborovanje gradbenih konstruktorjev Slovenije
Bled, Slovenija
www.sdgk.si/

14.-15.11.2023

4th BahnBau Kongress - The Future of Track Construction
Darmstadt, Nemčija
www.bahnbau-kongress.com/de/

14.-17.11.2023

WLF6 - 6th World Landslide Forum
Firence, Italija
<https://wlf6.org/>

15.-17.11.2023

14. mednarodna konferenca o predorih in podzemnih objektih
Ljubljana, Slovenija
<https://conference.ita-slovenia.si/>

25.-29.6.2024

28th European Young Geotechnical Engineers Conference 2024
Skopje, Makedonija
<https://mag.net.mk/>

Rubriko ureja **Eva Okorn**, ki sprejema predloge za objavo na e-naslov: gradb.zveza@siol.net