

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 шумов. 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 najsoodnejših 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 računalniških 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 vnaprej 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 vnaprej 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 razseženi 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 vnaprej 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 mreže, 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 klasificiranje 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 predpostavljeni 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 lučnasto 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 učenjskih 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., Hočevár, T., Milutinović, 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.