

Primljen / Received: 17.1.2026.

Ispravljen / Corrected: 11.5.2026.

Prihvaćen / Accepted: 18.5.2026.

Dostupno online / Available online: 10.9.2026.

Trodimenzionalna rekonstrukcija oštećenog betona: Neuronsko polje zračenja naspram eksplicitnih metoda

Autori:



Shengpeng Zuo, dipl.ing.građ.

Sveučilište znanosti i tehnologije Liaoning, Kina
Građevinski fakultet
zuoshengpeng@stu.ustl.edu.cn



Dr.sc. **Xixian Chen**, dipl.ing.građ.

Ministarstvo stanovanja i urbano-ruralnog razvoja
Istraživački institut za standarde i norme, Kina
chenxixian1996@163.com



Izv.prof.dr.sc. **Bowen Chen**, dipl.ing.građ.

Sveučilište Guangxi, Kina
Građevinski i arhitektonski fakultet
zltchenbowen@sina.com



Dr.sc. **Jiaqi Li**, dipl.ing.građ.

Sveučilište znanosti i tehnologije Liaoning, Kina
Građevinski fakultet
lijiaqi@ustl.edu.cn

Autor za korespondenciju

Prethodno priopćenje

Shengpeng Zuo, Xixian Chen, Bowen Chen, Jiaqi Li

Trodimenzionalna rekonstrukcija oštećenog betona: Neuronsko polje zračenja naspram eksplicitnih metoda

Kako bi se ispitala primjenjivost metoda implicitnog modeliranja u trodimenzionalnoj (3D) rekonstrukciji građevnih materijala, uveden je algoritam neuronskog polja zračenja (*Neural Radiance Field* - NeRF) radi procjene učinkovitosti 3D rekonstrukcije slika oštećenih betonskih površina. Provedena je usporedna analiza dvjema tradicionalnim eksplicitnim metodama rekonstrukcije, odnosno metodama strukture iz gibanja (*Structure from Motion* - SfM) i višepogledne stereorekonstrukcije (*Multi-View Stereo* - MVS). Pomoću pametnog telefona prikupljene su 42 slike betonskih blokova te su formirana četiri skupa podataka. Na temelju tih slika provedeni su trodimenzionalna rekonstrukcija i renderiranje modela. Rezultati pokazuju da vršni omjer signal-šum (PSNR) NeRF modela temeljenog na tehnologiji trenutačnih neuronskih grafičkih primitiva (instant neural graphics primitives, Instant-NGP) doseže 24,13 dB, što nadmašuje vrijednost od 17,94 dB ostvarenu tradicionalnim metodama. Model također pokazuje bolje performanse u pogledu brzine rekonstrukcije i kvalitete rekonstrukcije detalja. Osim toga ta metoda ima izražene prednosti u smanjenju diskontinuiteta površine i nazubljenosti rubova. Rezultati istraživanja potvrđuju izvedivost i prednosti NeRF-a u vizualizaciji građevnih materijala te pružaju novi tehnološki pristup za 3D modeliranje i automatiziranu identifikaciju površinskih oštećenja građevnih materijala.

Ključne riječi:

neuronsko polje zračenja (*Neural Radiance Field*, NeRF), vizualizacija, 3D rekonstrukcija, inteligentno prepoznavanje, duboko učenje

Research Paper

Shengpeng Zuo, Xixian Chen, Bowen Chen, Jiaqi Li

Three-dimensional reconstruction of damaged concrete: Neural radiance field versus explicit methods

To explore the applicability of implicit modelling methods in the three-dimensional (3D) reconstruction of building materials, the neural radiance field (NeRF) algorithm is introduced in this paper to study the effectiveness of 3D reconstruction of images of damaged concrete surfaces, and a comparative analysis is conducted with two traditional explicit reconstruction methods, namely structure from motion and multi-view stereo. Forty-two images of concrete blocks were collected using a smartphone, and four datasets were constructed. Three-dimensional reconstruction and visual rendering were performed on these images. The results show that the peak signal-to-noise ratio of the NeRF model based on instant neural graphics primitives reaches 24.13 dB, outperforming the 17.94 dB of traditional methods. The model also exhibits higher performance in terms of modelling speed and reconstruction details. In addition, this method has obvious advantages in mitigating the surface holes and edge aliasing. The research results verify the feasibility and advantages of NeRF in the visualisation of building materials and provide a new technical path for the 3D modelling and intelligent identification of surface damage in building materials.

Key words:

neural radiance field (NeRF), visualization, 3D reconstruction, intelligent recognition, deep learning

1. Uvod

Kako se vijek trajanja građevina produljuje, tako se na njihovim površinama neizbježno pojavljuju različite vrste oštećenja poput ljuštenja zidova i širenja pukotina. Radi pravodobnog praćenja razvoja vidljivih oštećenja razvijene su različite metode automatskog otkrivanja i procjene.

Među brojnim inteligentnim tehnologijama, tehnologija računalnog vida temeljena na dubokome učenju posljednjih se godina ubrzano razvija te nalazi široku primjenu u područjima građevinarstva, medicine, prometa i sigurnosti [1-4]. Međutim, tradicionalna analiza dvodimenzionalnih slika ograničena je na pojedinačna gledišta i nedostatne informacije, što otežava cjelovitu procjenu prostorne morfologije i prostornog rasporeda oštećenja na građevinama. Trodimenzionalna (3D) rekonstrukcija omogućuje visokopreciznu obnovu strukturnih oblika spajanjem podataka iz više gledišta, podržava promatranje i procjenu oštećenja iz proizvoljnih kutova te pruža cjelovitu analitičku osnovu za dijagnostiku sigurnosti konstrukcija.

Razvoj tehnologije 3D rekonstrukcije može se pratiti do diferencijalno-matematičkog okvira metode strukture iz gibanja (engl. *Structure from Motion* – SfM) predstavljenog u pionirskoj knjizi "Robot Vision" autora Horna [5], objavljenoj 1986., koja je postavila temelje mnogim algoritmima računalnog vida. Danas metode 3D rekonstrukcije ponajprije uključuju strukturirano svjetlo [6], stereoskopski vid [7], SfM [8], višepoglednu stereorekonstrukciju (engl. *Multi-View Stereo* – MVS) [9], lasersko skeniranje [10] te implicitni algoritam rekonstrukcije koji se pojavio posljednjih godina – tehnologiju neuronskog polja zračenja (engl. *Neural Radiance Field* – NeRF) [11].

EksPLICITNI algoritmi 3D rekonstrukcije razvijeni u ranijim godinama znatno su pridonijeli razvoju discipline i postavili važan temelj za područje trodimenzionalnoga računalnog vida. U području građevinskog inženjerstva 3D rekonstrukcija omogućuje znatno potpunije bilježenje prostornih obilježja površina betonskih konstrukcija, uključujući geometriju pukotina i promjene volumena u područjima ljuštenja, u usporedbi s analizom 2D slika. Time se osigurava intuitivnija osnova za procjenu oštećenja i planiranje naknadnih sanacijskih zahvata. Posljednjih godina brojna su istraživanja pokazala da tehnologija 3D rekonstrukcije ima važnu ulogu u automatskome otkrivanju i volumetrijskoj karakterizaciji oštećenja betona. Tehnologije 3D rekonstrukcije temeljene na slikama snimljenima iz više pogleda generiraju rijetke oblake točaka primjenom metoda SfM i MVS, čime se dobivaju osnovni geometrijski podaci za otkrivanje oštećenja. Naprimjer, Kim i suradnici [12] predložili su automatiziranu metodu procjene pukotina u betonu koja kombinira stereoskopski vid s dvjema žarišnim duljinama te je pokazala velike prednosti u obradi dubinskih slika. Beckman i suradnici [13] kombinirali su algoritam Faster R-CNN s dubinskim kamerama kako bi ostvarili automatsku kvantifikaciju volumena odljuštenog betona. Liu i suradnici [14] koristili su pametne telefone za snimanje višestrukih fotografija oko betonskih elemenata te primijenili MVS metode za 3D rekonstrukciju.

Kvaliteta rekonstrukcije dobivene tim pristupom bila je bolja od kvalitete rekonstrukcije ostvarene metodama temeljenima na dubinskim kamerama.

Međutim, eksPLICITNI algoritmi 3D rekonstrukcije i dalje imaju nekoliko ograničenja [15]. Prvo, eksPLICITNI modeli teško obrađuju složene topološke strukture u geometrijskim modelima te su skloni pojavi rupa ili deformacija pri modeliranju tankostijenih ili vrlo finih detalja. Drugo, kvaliteta rekonstrukcije osjetljiva je na cjelovitost ulaznih podataka i prisutnost šuma, što lako dovodi do nedostajućih geometrijskih elemenata kada nema dovoljno gledišta ili postoje zaklanjanja. Treće, visokoprecizna eksPLICITNA rekonstrukcija zahtijeva znatne računalne resurse, što negativno utječe na učinkovitost procesa rekonstrukcije.

Kako bi prevladali ograničenja tradicionalnih eksPLICITNIH metoda, istraživači su posljednjih godina počeli razvijati metode 3D rekonstrukcije temeljene na dubokome učenju. Među njima je NeRF, algoritam za 3D rekonstrukciju temeljen na implicitnim neuronskim mrežama, ostvario znatan iskorak u tome području. NeRF se temelji na potpuno povezanim neuronskim mrežama i parametrizira scenu kao kontinuirano polje zračenja (eng. *Continuous Radiance Field*). Ta metoda trenira višeslojni perceptron (MLP) na temelju slika iz više pogleda kako bi implicitno naučila boju i volumensku gustoću 3D točaka te primjenjuje tehnologiju volumenskog renderiranja za generiranje novih pogleda na scenu.

Takav implicitni prikaz ne samo da može precizno rekonstruirati fine teksture i varijacije osvjetljenja u složenim scenama, nego izbjegava uobičajene probleme tradicionalnih metoda rekonstrukcije mreža poput rupa i nazubljenosti rubova (eng. *edge aliasing*). NeRF tehnologija uspješno je primijenjena u različitim područjima. Peng i suradnici [16] osigurali su robusnu geometrijsku i semantičku podršku primjenom poboljšanih NeRF algoritama, pružajući učinkovito tehničko rješenje za automatizirane operacije u pametnoj poljoprivredi. Wen i suradnici [17] koristili su module za poboljšanje pogleda (eng. *View-Enhancement Modules*) i strategije dubokog nadzora (eng. *Deep Supervision*) kako bi učinkovito prevladali problem zamućenih geometrijskih obilježja u tradicionalnim NeRF modelima za velike scene, nudeći rješenje bolje od tradicionalnoga eksPLICITNOG modeliranja za izradu visokovjernih digitalnih kampusa i geografskih okružja.

U području konstrukcijskog inženjerstva potencijal NeRF modela za 3D rekonstrukciju i pregled konstrukcija još uvijek nije dovoljno istražen. Očekuje se da bi visoka preciznost i kvaliteta renderiranja svojstvena NeRF algoritmu mogla unaprijediti kvalitetu 3D rekonstrukcije građevinskih konstrukcija, dodatno poboljšati prepoznavanje i vizualizaciju oštećenih područja te pružiti pouzdaniju i precizniju podatkovnu osnovu za praćenje stanja konstrukcija i planiranje naknadnog održavanja.

U tu svrhu ovo istraživanje koristi oštećene betonske blokove kao predmet proučavanja, primjenjuje metodu neuronskog polja zračenja za 3D rekonstrukciju te uvodi pokazatelje kvalitete rekonstrukcije, uključujući vršni omjer signal-šum (PSNR) [18], indeks strukturne sličnosti (SSIM) [19] i mjeru perceptivne

sličnosti slikovnih zakrpa naučenu strojnim učenjem (LPIPS) [20]. Ti pokazatelji primjenjuju se za sustavnu usporedbu i analizu performansi NeRF-a i tradicionalnih eksplicitnih algoritama 3D rekonstrukcije u rekonstrukciji građevnih materijala. Procjena se provodi na temelju triju aspekata: točnosti rekonstrukcije, sposobnosti obnove detalja i cjelovitosti modela.

2. Pregled metode

U ovome istraživanju primijenjene su dvije vrste NeRF algoritama (temeljene na izvedbama *NeRF-PyTorch* i *Instant Neural Graphics Primitives, Instant - NGP*) [21] te tradicionalni algoritam temeljen na eksplicitnoj rekonstrukciji slike (koji se oslanja na okvire SfM i MVS uz alat *ContextCapture Center Master*) za provedbu visokoprecizne 3D rekonstrukcije oštećenih betonskih uzoraka i njihovu usporednu analizu. Sveobuhvatna procjena učinkovitosti provedena je uporabom pokazatelja PSNR, SSIM i LPIPS. Cjelokupan tehnički tijek rada prikazan je na slici 1. te opisan u nastavku. Slike oštećenih betonskih uzoraka snimljene su pametnim telefonom *Xiaomi 12*. Te višeperspektivne RGB slike poslužile su kao zajednički ulazni podaci za sva tri rekonstrukcijska pristupa.

U postupku eksplicitne 3D rekonstrukcije, prikazanom u gornjem dijelu slike 1., višeperspektivne slike obrađene su u platformi *ContextCapture Center Master*. Postupak započinje izdvajanjem i uparivanjem značajki (*feature extraction and matching*) radi pronalaženja odgovarajućih značajki iz različitih gledišta. Nakon toga primjenjuje se algoritam SfM za procjenu poza kamera i generiranje rijetkog oblaka točaka (*sparse point cloud*), a zatim algoritam MVS za izračun gustog oblaka točaka (*dense point cloud*). Na kraju provode se rekonstrukcija mreže (*mesh reconstruction*) i mapiranje tekstura (*texture mapping*), čime se dobiva 3D model oštećenoga betonskog uzorka s realističnim površinskim teksturama.

U grani *NeRF-PyTorch*, prikazanoj u donjem lijevom i donjem desnom dijelu slike 1., najprije je primijenjen alat COLMAP [22] za izdvajanje značajki, procjenu poza kamera i generiranje rijetkog oblaka točaka. Zatim je skripta *imgs2poses.py* korištena za pretvorbu dobivenih podataka o pozama kamera u standardni LLFF format prikladan za ulazak u neuronsku mrežu. Tijekom faze treniranja modela primijenjena je strategija kružnog snimanja kamerama usmjerenima prema unutrašnjosti scene (*360° inward-facing training strategy*), a višeslojni perceptron (MLP) korišten je za cjelovitu (*end-to-end*) aproksimaciju petodimenzionalnoga neuronskog polja zračenja. Prostorne koordinate i smjerovi promatranja korišteni su kao ulazni podaci za predviđanje volumenske gustoće i boje ovisne o kutu promatranja, čime su volumenskim renderiranjem generirani kontinuirani prikazi visoke rezolucije površine oštećenog betona. U grani *Instant-NGP*, prikazanoj u donjem desnom dijelu slike 1., izlazni podaci programa COLMAP analizirani su i pretvoreni u datoteku *transforms.json*, koju prepoznaje okvir *Instant-NGP*. Ulazne trodimenzionalne prostorne koordinate i smjerovi promatranja najprije su obrađeni višerezolucijskim

hash kodiranjem (*multiresolution hash encoding*) radi učinkovitog mapiranja značajki, a zatim proslijeđeni laganoj MLP mreži za predviđanje volumenske gustoće i RGB boje proizvoljnih točaka unutar scene. U usporedbi sa standardnim NeRF-PyTorch modelom, taj je pristup znatno ubrzao proces treniranja uz zadržavanje visokovjerne rekonstrukcije i renderiranja u stvarnome vremenu.

Na kraju su rezultati 3D modela renderirani iz istovjetnih gledišta te su sustavno uspoređene performanse dviju vrsta NeRF algoritama i tradicionalnih eksplicitnih metoda 3D rekonstrukcije primjenom triju pokazatelja: PSNR-a, SSIM-a i LPIPS-a. Usporedba je bila usmjerena na točnost rekonstrukcije, sposobnost obnove detalja te prilagodljivost složenim površinskim geometrijama.

2.1. Skupovi podataka


Kako bi se osigurali pouzdanost i mogućnost generalizacije procjene algoritama, kao referentna platforma za sustavnu provjeru triju algoritama odabran je službeni LLFF skup podataka [23], koji sadržava velik broj visokofrekventnih detalja. Skup podataka Fern prikupljen je kamerom koja se kretala kružnom putanjom oko objekta, stvarajući gledišta koja ga okružuju sa svih strana. Skup sadržava 20 slika rezolucije 4032×3024 piksela, pri čemu je veličina pojedine datoteke približno 3 MB. Dodatni detalji prikazani su na slici 2.

Nadalje, za potrebe izrade skupa podataka o oštećenome betonu provedeno je snimanje pametnim telefonom metodom kružnog snimanja iznad betonskog bloka. Ukupno su prikupljene 42 slike. Svaka slika imala je veličinu približno 3 MB i rezoluciju 3072×4096 piksela, a skup slika obuhvatio je cjelokupni raspon oštećenja prisutnih na betonskome uzorku. Dodatni detalji prikazani su na slici 3.

Primjenom strategije aritmetičkog izdvajanja iz početnog skupa od 42 slike konstruirana su četiri skupa podataka različitih veličina, koji su sadržavali 42, 32, 22 odnosno 12 slika. Tijekom izdvajanja slike su odabirane u pravilnim razmacima kako bi se osigurala ujednačena kutna raspodjela unutar svih skupova podataka, čime je zajamčena sveobuhvatna reprezentacija stanja oštećenja betonskog bloka. Nakon završetka izdvajanja svaki je skup sustavno organiziran, format slika pretvoren u PNG, a datoteke su preimenovane.

Dva skupa podataka služila su različitim svrhama te su zato prikupljena različitim strategijama, s različitim brojem slika i rezolucijama. Skup Fern korišten je kao javni referentni skup za provjeru algoritamskih postupaka, pa su njegove izvorne postavke snimanja kružnom putanjom kamere strogo zadržane kako bi se izbjegla pristranost uzrokovana predobradom podataka i osigurala pravedna usporedba.

Nasuprot tome, skup podataka o oštećenome betonu sadržavao je slike stvarnih konstrukcijskih elemenata te predstavljao glavni inženjerski skup podataka ovog istraživanja, namijenjen procjeni primjenjivosti implicitnih i eksplicitnih metoda rekonstrukcije na površinska oštećenja betona. Primijenjena je kružna putanja



Slika 1. Cjelokupni postupak 3D rekonstrukcije i neuronskog renderiranja temeljenog na višeperspektivnim slikama

snimanja iznad objekta s većom gustoćom uzorkovanja gledišta kako bi se osiguralo dovoljno preklapanje pogleda i potpuno zabilježile složene topologije površinskih oštećenja. Osim toga rezolucija slika izravno utječe na kvalitetu obnove detalja i na računalne zahtjeve obrade. Iako veće rezolucije omogućuju očuvanje ključnih visokofrekventnih tekstura oštećenja važnih za preciznu rekonstrukciju, one istodobno znatno povećavaju potrošnju memorije i vrijeme treniranja modela. Zbog toga je za skup podataka o betonu odabrana rezolucija 3072×4096 piksela, koja predstavlja optimalnu ravnotežu između očuvanja visokovjernih detalja oštećenja i računalne izvedivosti postupka.


2.2. Algoritmi 3D rekonstrukcije

2.2.1. Eksplicitni algoritmi 3D rekonstrukcije

U zadacima stereoskopske rekonstrukcije temeljenima na više gledišta metode eksplicitnog modeliranja obično primjenjuju dvostupanjski postupak obrade koji se sastoji od algoritama



Slika 2. Skup podataka Fern



Slika 3. Skup podataka o oštećenome betonskom bloku


SfM i MVS. Cjelovit vizualni prikaz toga postupnog okvira prikazan je na slici 4. Kao što je to prikazano numeriranim modulima na dijagramu, postupak se sastoji od četiriju koraka:

1. Procjena poze kamere (*Camera Pose Estimation*): Analizom prostornog pomaka uparenih karakterističnih točaka na više slika algoritam izračunava točan položaj, orijentaciju i unutarnje parametre objektiva kamere u trenutku snimanja svake pojedine slike.
2. Triangulacija (*Triangulation*): U tom se koraku određuju stvarne trodimenzionalne koordinate odgovarajućih karakterističnih točaka izračunavanjem sjecišta zraka promatranja koji potječu iz različitih položaja kamera.

3. Rijetki oblak točaka (*Sparse Point Cloud*): Trodimenzionalne koordinate dobivene triangulacijom objedinjene su u početni rijetki oblak točaka. Međutim, zbog neizbježnih netočnosti u postupku uparivanja značajki, u toj fazi pojavljuju se manja odstupanja položaja pojedinih točaka.
4. Paketna prilagodba (*Bundle Adjustment*): Kako bi se uklonile početne pogreške, primjenjuje se globalni nelinearni optimizacijski postupak poznat kao paketna prilagodba. Taj se postupak temelji na modelu prednje projekcije kamere (*camera forward projection model*), koji preslikava trodimenzionalnu prostornu točku na dvodimenzionalnu ravninu slike te se matematički izražava na sljedeći način:

$$\pi_i: \mathbb{R}^3 \rightarrow \mathbb{R}^2, X_j \rightarrow \pi_i(X_j) = \text{normalize}(K_i(R_i X_j + t_i)) \quad (1)$$

gdje π_i označava funkciju projekcije i -te kamere, K_i unutarnju matricu kamere (*camera intrinsic matrix*), R_i i t_i vanjsku matricu rotacije odnosno vektor translacije (*extrinsic rotation matrix and translation vector*), dok X_j predstavlja j -tu trodimenzionalnu točku.



Slika 4. Tradicionalni SfM-MVS okvir rekonstrukcije

Postupak paketne prilagodbe istodobno optimira procijenjene položaje kamere i trodimenzionalne koordinate rijetkog oblaka točaka u cilju minimiziranja pogreške reprojekcije (*reprojection error*), čime se osigurava ukupna geometrijska konzistentnost modela.

Na kraju se tim postupkom generira gusti oblak točaka (*dense point cloud*) koji predstavlja konačni rezultat 3D rekonstrukcije. Iako rijetki oblak točaka pruža osnovni prostorni okvir modela, njegova razlučivost površine nije dovoljna za detaljnu analizu materijala. Metoda MVS nadopunjuje taj osnovni geometrijski model kontinuiranim površinskim detaljima provođenjem pretrage dubine i izračunom dubinskih vrijednosti na homogenim betonskim površinama. Time se učinkovito popunjavaju strukturne praznine između rijetko raspoređenih točaka, pretvarajući osnovni geometrijski kostur u visokodetaljan gusti oblak točaka koji vjerno prikazuje specifične mikrostrukture površine, volumenske gubitke materijala te složena morfološka obilježja oštećene površine.

2.2.2. Implicitni algoritmi 3D rekonstrukcije

Implicitna rekonstrukcija oslanja se na implicitne funkcije za prikazivanje trodimenzionalnih modela, čime se uklanja potreba za izravnom izradom mreža (*mesh*) ili drugih geometrijskih struktura. Takav pristup odlikuje se velikom fleksibilnošću i visokom prilagodljivošću različitim vrstama podataka.

Ulazni podaci za NeRF sastoje se od rijetko raspoređenih višeperspektivnih RGB slika te unutarnjih i vanjskih parametara kamere koji opisuju smjer promatranja kamere. Rekonstrukcija

modela zahtijeva snimanje objekta iz više kutova kako bi se osiguralo dovoljno preklapanje detalja u svim dijelovima scene. Potrebni parametri kamere, uključujući žarišnu duljinu, optičko središte te položaj i orijentaciju kamere, dobiveni su pomoću programa COLMAP. Zrake (*rays*) generiraju se povratnom projekcijom piksela slike u trodimenzionalni prostor korištenjem unutarnjih i vanjskih parametara kamere. Svaka zraka predstavlja trodimenzionalnu prostornu putanju koja odgovara pojedinome pikselu. Izraz zrake glasi:

$$\mathbf{r}(t) = \mathbf{o} + t\mathbf{d} \quad (2)$$

gdje je "o" optičko središte kamere, "d" jedinični vektor smjera zrake, a "t" udaljenost od točke "o" do položaja $\mathbf{r}(t)$ duž smjera promatranja "d".

Duž svake zrake ravnomjerno se uzorkuje N točaka kako bi se dobile njihove trodimenzionalne koordinate (x, y, z). Kako bi se poboljšala sposobnost modela za prikaz visokofrekventnih obilježja, nad koordinatama uzorkovanih točaka provodi se pozicijsko kodiranje (*positional encoding*), pri čemu se one preslikavaju u prostor veće dimenzionalnosti:

$$\gamma(\mathbf{x}) = [\sin(2^0\pi\mathbf{x}), \cos(2^0\pi\mathbf{x}), \dots, \sin(2^{L-1}\pi\mathbf{x}), \cos(2^{L-1}\pi\mathbf{x})] \quad (3)$$


gdje L predstavlja frekvencijski niz visokodimenzionalnog prostora.

Pozicijsko kodiranje omogućuje višeslojnom perceptronu (MLP) učinkovito hvatanje visokofrekventnih prostornih detalja poput kontinuiteta površine i tekture [24]. Na temelju trodimenzionalnih koordinata (x, y, z) MLP predviđa volumensku gustoću scene i raspodjelu točaka. Dobivena volumenska gustoća zatim se primjenjuje u postupku volumenskog renderiranja za izračun prozirnosti i težinskih koeficijenata, čime se određuje konačni doprinos boji piksela zraka koje prolaze kroz promatrane točke. Radi jasnijeg povezivanja s arhitekturom mreže prikazanom na slici 5., standardni NeRF-ov MLP koristi razdvojenu (*decoupled*) arhitekturu u kojoj se geometrija i izgled scene obrađuju slijedno. Najprije se trodimenzionalne prostorne koordinate (x, y, z) putem pozicijskoga kodiranja preslikavaju u 63-dimenzionalni vektor visokofrekventnih značajki. Taj se vektor zatim prosljeđuje glavnoj mreži koja se sastoji od osam potpuno povezanih slojeva, pri čemu svaki sloj sadržava 256 kanala. Kako bi se očuvale prostorne informacije i spriječilo propadanje značajki tijekom duboke obrade, u petome sloju

uvodena je preskočna veza (eng. *skip connection*), kojom se početni kodirani ulaz spaja s međurezultatima mreže. Izlaz te osmoslojne grane mreže daje volumensku gustoću neovisnu o smjeru promatranja (σ), posredni vektor značajki (*intermediate feature vector*).

Nakon toga, radi generiranja realističnih prikaza ovisnih o kutu promatranja, smjerovi gledanja (θ, ϕ) preslikavaju se pozicijskim kodiranjem u 24-dimenzionalni vektor. Taj se vektor smjera spaja s prethodno dobivenim posrednim vektorom značajki te se zajedno obrađuju u završnom potpuno povezanome sloju koji sadržava 128 kanala.

Takvo strukturno rješenje osigurava da volumenska gustoća (σ) ovisi isključivo o prostornim koordinatama, dok se predviđena RGB boja može dinamički mijenjati ovisno o kutu promatranja. Na taj način moguće je precizno prikazati površinske teksture i vizualna obilježja koja ovise o gledištu promatranja.



Slika 5. Arhitektura višeslojnog perceptrona (MLP)

Kao temeljna tehnologija NeRF-a, volumensko renderiranje (*volume rendering*) određuje boju svakog piksela akumuliranjem predviđenih vrijednosti svih uzorkovanih točaka duž promatrane zrake. Temeljeno na optičkome modelu, volumensko renderiranje integrira te predviđene vrijednosti u konačnu boju piksela simulirajući širenje svjetlosti kroz medij. Fizikalni izraz koji opisuje taj postupak dan je izrazima (4) i (5):

$$C(r) = \sum_{i=1}^N T_i (1 - \exp(-\sigma_i \delta_i)) c_i \quad (4)$$

$$T_i = \prod_{j=1}^{i-1} \exp(-\sigma_j \delta_j) \quad (5)$$

gdje je r vektor smjera zrake koju emitira kamera, $C(r)$ rezultat volumenskog renderiranja, c_i boja i -te uzorkovane točke, T_i prozirnost između ishodišta zrake i točke i , $\exp(-\sigma_i \delta_i)$ stopa apsorpcije svjetlosti u točki i , δ_i udaljenost između susjednih uzorkovanih točaka, a σ_i volumenska gustoća.

Kako bi se dodatno povećala brzina renderiranja i kvaliteta generiranih slika, NeRF primjenjuje strategiju hijerarhijskog uzorkovanja (*hierarchical*


sampling), koja se sastoji od dviju faza: grubog (*coarse*) i finog (*fine*) uzorkovanja.

U fazi grubog uzorkovanja duž svake zrake ravnomjerno se uzorkuje N točaka kako bi se dobila približna raspodjela gustoće i boje. U fazi finog uzorkovanja NeRF koristi raspodjelu težina dobivenu u prethodnoj fazi te koncentrira uzorkovanje dodatnih N' točaka u područjima visoke gustoće. Na taj se način detalji scene mogu zabilježiti znatno preciznije.

Radi optimizacije parametara višeslojnog perceptrona (MLP) unutar neuronskog polja zračenja, NeRF uvodi funkciju gubitka temeljenu na razlici boja, čiji je cilj minimizirati odstupanje između predviđenih i stvarnih vrijednosti boje. Primjenom algoritma povratnog širenja pogreške (*backpropagation*) parametri mreže kontinuirano se prilagođavaju, čime se postupno poboljšavaju realizam i ukupna kvaliteta sintetiziranih prikaza.

U ovome istraživanju primijenjene su dvije vrste NeRF algoritama. NeRF-PyTorch predstavlja tradicionalnu izvedbu NeRF-a za 3D rekonstrukciju razvijenu u sklopu biblioteke PyTorch. Iako taj pristup pokazuje izvrsne rezultate u očuvanju detalja i sintezi novih pogleda na scenu (*novel view synthesis*), suočava se s određenim ograničenjima poput dugog vremena treniranja, sporog izvođenja zaključivanja (*inference*) te slabe prilagodljivosti rekonstrukciji velikih scena. Zbog tih su nedostataka razvijene brojne izvedenice izvornog modela. Godine 2022. predstavljen je algoritam Instant-NGP, koji koristi višerezolucijsko hash kodiranje (*multiresolution hash encoding*). Ta metoda preslikava ulazne prostorne koordinate u visokodimenzionalni prostor značajki te uvodi laganu arhitekturu MLP mreže s dvjema granama. Konkretno, MLP za gustoću (*density MLP*) koristi se za predviđanje volumenske gustoće i geometrijskih značajki, a MLP za boju (*colour MLP*) za dekodiranje RGB vrijednosti u kombinaciji sa smjerovima promatranja.

U kombinaciji s visokooptimiziranim tehnikama volumenskog renderiranja ubrzanim grafičkim procesorom (GPU), taj algoritam znatno smanjuje broj prostornih parametara i računalno opterećenje te omogućuje visokovjernu rekonstrukciju u stvarnome vremenu, kao što je to prikazano na slici 6. Prednosti te metode uključuju vrlo brzo treniranje modela, malu potrošnju memorije, znatno brže izvođenje zaključivanja (*inference*) i očuvanje visoke kvalitete renderiranja.



Slika 6. Arhitektura algoritma Instant-NGP

Tablica 1. Informacije o eksperimentalnome okruženju i verziji biblioteke ovisnosti

Okruženje	Python	OpenCV-python	CUDA	PyTorch	TorchVision	TorchAudio	Matplotlib	tqdm
Verzija	3.9	4.11	12.6	2.6	0.21	2.6	3.9.4	4.65.2

3. Rezultati: usporedba i analiza performansi modela

3.1. Treniranje modela

Svi eksperimenti provedeni su na radnoj stanici s operacijskim sustavom Windows 11, opremljenoj grafičkom karticom NVIDIA GeForce RTX 4090 (24 GB VRAM-a), procesorom Intel Core i9-13900K i 32 GB radne memorije (RAM). Programsko okruženje uključivalo je CUDA verzije 12.6 i upravljački program (*driver*) verzije 560.94. Treniranje modela i izvođenje zaključivanja (*inference*) provedeni su u sklopu PyTorch 2.6, kako je to prikazano u tablici 1.

Za algoritam NeRF-PyTorch odabrana je scena "Fern" iz javno dostupnog LLFF skupa podataka, koja sadržava 20 slika te vlastito izrađen skup podataka o oštećenome betonskom uzorku, podijeljen na podskupove od 12, 22, 32 i 42 slike. Parametri treniranja bili su jednako postavljeni za sve skupove podataka: factor = 8; label = 8; N_rand = 1024; N_samples = 64; N_importance = 64; use_viewdirs = true; raw_noise_std = 1e0. Svi skupovi podataka trenirani su tijekom 200.000 iteracija, a na testnome skupu provedeno je 120 evaluacija renderiranja. Za platformu Instant-NGP parametri treniranja postavljeni su na sljedeće vrijednosti: batch size = 262.144; rays/batch = 3072; samples/ray=90,83; seed=1337. Koristeći prethodno navedene skupove podataka, modeli su trenirani do konvergencije, što je zahtijevalo približno 10.000 iteracija. Isti postupak testiranja poslužio je za dodatnu usporedbu performansi i brzine dvaju okvira za neuronsko renderiranje. Radi usporedbe, platforma *ContextCapture Center Master* (CCCMaster), koja se temelji na eksplicitnoj rekonstrukciji, korištena je za izvođenje potpune 3D rekonstrukcije na istim skupovima podataka. Taj je postupak uključivao kalibraciju kamera, generiranje rijetkog oblaka točaka, rekonstrukciju gustog oblaka točaka i modeliranje površinske mreže (*mesh*).

3.2. Usporedba na javnim skupovima podataka

Performanse algoritama analizirane su s obzirom na tri aspekta: kvalitetu rekonstrukcije, vrijeme treniranja i učinkovitost NeRF rekonstrukcije pri različiteme broju ulaznih slika. Za procjenu performansi svih algoritama primijenjeni su i javni skup podataka Fern i vlastito izrađeni skup podataka o oštećenome betonskom uzorku. Kao što je to prikazano na slici 7., radi lakše usporedbe sitnih detalja, u donjem desnom kutu svake slike prikazani su uvećani isječci lokalnih područja. U usporedbi s NeRF algoritima, tradicionalne metode eksplicitne rekonstrukcije (SfM-MVS) na skupu podataka Fern pokazuju znatne rekonstrukcijske artefakte, deformacije tekstura i djelomične

šupljine modela. Posebno je uočljivo da, kako je to prikazano na slici 7.b, eksplicitni algoritmi imaju poteškoća pri obradi područja bez izražene teksture ili područja složene geometrije, što rezultira znatnim gubitkom pozadinskih informacija. Njihove su performanse bile osobito slabe u pogledu cjelovitosti modela, pri čemu su nedostaci poput nedostajućih rubova i rekonstrukcijskih artefakata postali znatno izraženiji.


Nasuprot tome, modeli NeRF-PyTorch i Instant-NGP uspješno su sintetizirali kompletnu pozadinu scene te učinkovito uklonili probleme povezane s rupama u modelu. Time su znatno poboljšali cjelovitost rekonstruiranog modela i kvalitetu prikaza detalja u uvećanim područjima slike.



Slika 7. Usporedba performansi rekonstrukcije različitih algoritama u javnome referentnom skupu podataka Fern. Uvećani prikazi lokalnih detalja prikazani su u donjem desnom kutu svake slike: a) stvarna slika; b) rezultat rekonstrukcije eksplicitnim algoritmom; c) rezultat rekonstrukcije algoritmom NeRF-PyTorch; d) rezultat rekonstrukcije algoritmom Instant-NGP


3.3. Usporedba 3D rekonstrukcije površinskih oštećenja betona

Na slici 8. prikazani su rezultati 3D rekonstrukcije različitih algoritama na skupu podataka oštećenog betonskog uzorka. Rezultati pokazuju da u scenarijima s malim brojem ulaznih slika, kada algoritmi raspolažu ograničenim brojem karakterističnih točaka, NeRF u najvećoj mogućoj mjeri zadržava cjelovitost modela. Međutim, njegova je učinkovitost u prikazu vidljivih detalja površinskih oštećenja betonskih uzoraka u toj fazi nešto slabija od učinkovitosti eksplicitnih algoritama. Kako se broj ulaznih slika povećavao, tako se kvaliteta trodimenzionalne rekonstrukcije NeRF algoritma stabilizirala prije nego kod eksplicitnih metoda. Istodobno je NeRF pokazao izvrsnu sposobnost fotorealističnog prikaza betonskih površina. U usporedbi s eksplicitnim algoritmom CCCMaster, koji po pitanju



Slika 8. Usporedba performansi rekonstrukcije različitih algoritama na skupovima podataka oštećenih betonskih uzoraka (Napomena: 12, 22, 32 i 42 označavaju broj obrađenih slika)

količine detalja, cjelovitosti modela i realizma daje rezultate najbližije NeRF-u, NeRF i dalje pokazuje određene nedostatke u reprodukciji boja.



Slika 9. Performanse NeRF rekonstrukcije u uvjetima slabog osvjetljenja (Napomena: 12, 22, 32 i 42 označavaju broj obrađenih slika)

Na slici 9. prikazana je usporedba rezultata rekonstrukcije oštećenih betonskih uzoraka između algoritama NeRF-

PyTorch i Instant-NGP u uvjetima slabog osvjetljenja. Eksperimentalni rezultati pokazuju da Instant-NGP posjeduje bolje mogućnosti izdvajanja značajki pri obradi slika snimljenih u uvjetima nedostatnog osvjetljenja. U usporedbi s algoritmom NeRF-PyTorch, uspješnije očuva visokofrekventne teksturalne detalje betonske površine te učinkovitije smanjuje artefakte uzrokovane šumom iz okoline. Ti rezultati potvrđuju da NeRF tehnologija zadržava robusne sposobnosti geometrijske rekonstrukcije čak i u složenim uvjetima slabog osvjetljenja.

U tablici 2. prikazane su performanse različitih algoritama 3D rekonstrukcije na skupu podataka o betonskim uzorcima

te da NeRF algoritmi ostvaruju znatne prednosti u više ključnih pokazatelja kvalitete. Konkretno, vrijednost PSNR-a kod NeRF metode bila je 19,5 % veća u odnosu na tradicionalne eksplicitne metode. Pri korištenju 42 ulazne slike, PSNR dosegno je 24,13 dB, čime je potvrđena prednost te metode u očuvanju strukturne konzistentnosti i detalja tekture. Posebno je važno istaknuti da se NeRF algoritam pokazao iznimno učinkovitim u rekonstrukciji visokofrekventnih detalja. Vrijednost pokazatelja LPIPS za Instant-NGP iznosila je 0,42, što je puno bolje od vrijednosti 0,52 ostvarene kombinacijom algoritama SfM i MVS. To upućuje na veću sposobnost očuvanja finih strukturnih obilježja. U pogledu računalne učinkovitosti, Instant-NGP završio je rekonstrukciju za samo minutu i 30 sekundi, ostvarivši 112 puta veću brzinu od algoritma NeRF-PyTorch te 5,5 puta veću brzinu od kombinacije algoritama SfM i MVS. To obilježje daje NeRF metodama znatnu prednost u praktičnim primjenama. Eksperimentalni podaci također pokazuju da je povećanjem broja ulaznih slika s 22 na 42 vrijednost PSNR-a za Instant-NGP porasla s 22,83 dB na 24,13 dB, što je povećanje od 5,4 %. Istodobno je kod NeRF-PyTorch algoritma zabilježeno povećanje od 1,3 %. Ti rezultati dodatno potvrđuju robusnost NeRF pristupa pri povećanju količine dostupnih podataka. S druge strane, kod kombinacije

Tablica 2. Kvantitativna procjena kvalitete rekonstrukcije na skupu podataka oštećenoga betonskog bloka

Metoda	Metrike evaluacije	42 slike s više prikaza	32 slike s više prikaza	22 slike s više prikaza
SfM + MVS	PSNR↑	17,94	18,87	18,93
	LPIPS↓	0,36	0,41	0,39
	SSIM↑	0,60	0,64	0,63
NeRF-PyTorch	PSNR↑	20,20	20,68	20,47
	LPIPS↓	0,53	0,51	0,52
	SSIM↑	0,71	0,72	0,71
Instant-NGP	PSNR↑	24,13	22,56	22,83
	LPIPS↓	0,43	0,43	0,42
	SSIM↑	0,69	0,70	0,68

algoritama SfM i MVS, povećanje veličine skupa podataka dovelo je do složenije geometrije rekonstruiranog modela, što je rezultiralo smanjenjem vrijednosti pokazatelja PSNR.

4. Rasprava

4.1. Doprinos istraživanja postojećemu fondu znanja

1. Uspostavljena je kvantitativna referentna osnova za procjenu performansi različitih modela 3D rekonstrukcije oštećenog betona. Kako bi se istražile razlike između eksplicitnih i implicitnih algoritama 3D rekonstrukcije, sustavno su vrednovane ukupne performanse implicitnih metoda (Instant-NGP i NeRF-PyTorch) te eksplicitne metode (MVS-SfM) u rekonstrukciji oštećenih betonskih površina. Rezultati pokazuju da je, na istome skupu slikovnih podataka, Instant-NGP ostvario PSNR = 24,13 dB, LPIPS = 0,43, SSIM = 0,69. Istodobno je cijeli proces treniranja i renderiranja dovršen za samo minutu i 30 sekundi, čime je taj algoritam nadmašio ostale metode kako u pogledu kvalitete rekonstrukcije tako i u pogledu računalne učinkovitosti.
2. Potvrđena je učinkovitost implicitnih algoritama 3D rekonstrukcije za oštećene betonske površine. U usporedbi s rupama u modelu i artefaktima nazubljenih rubova (*edge aliasing*), koji se često pojavljuju kod tradicionalnih eksplicitnih metoda, algoritam NeRF učinkovito rekonstruira visokofrekventne detalje oštećenih područja poput površinskih pora i putanja širenja pukotina. Posebno se ističe Instant-NGP, koji zahvaljujući tehnologiji višerezolucijskog *hash* kodiranja uspješno rekonstruira složene fizičke teksture uz istodobno ostvarivanje brze rekonstrukcije na razini minuta. Osim toga algoritam pokazuje pouzdane performanse i u uvjetima slabog osvjetljenja i ograničene količine podataka.
3. Predložena je izvediva tehnička osnova za preciznu kvantitativnu procjenu oštećenja i modeliranje digitalnih blizanaca. Rezultati istraživanja pokazuju da visokoprecizni 3D modeli generirani implicitnim NeRF okvirom ne zadovoljavaju samo praktične zahtjeve za brzim povratnim informacijama tijekom terenskih inženjerskih pregleda, već pružaju i pouzdanu podatkovnu osnovu za automatsko mjerenje širine pukotina i volumetrijsku kvantifikaciju oštećenja. Ovim istraživanjem potvrđena je izvedivost i prednost NeRF-a u prikazu površinskih oštećenja građevinskih konstrukcija, čime je postavljen pouzdan teorijski temelj i tehnološki okvir za razvoj preciznih digitalnih blizanaca u građevinarstvu [25] te sustava za praćenje stanja konstrukcija (engl. *Structural Health Monitoring* – SHM).

4.2. Ograničenja istraživanja i mogući smjerovi budućih istraživanja

Iako je ovim istraživanjem potvrđena prednost implicitnih neuronskih reprezentacija u rekonstrukciji oštećenih betonskih

površina, i dalje postoje određena ograničenja i mogućnosti za daljnji razvoj:

1. Potreba za geometrijskom kvantifikacijom oštećenja u fizičkome prostoru. U ovome radu performanse 3D rekonstrukcije procijenjene su pomoću pokazatelja poput PSNR-a, čime je potvrđena izvedivost NeRF algoritma. Međutim, neophodna je i geometrijska kvantifikacija oštećenih područja u stvarnome fizičkom prostoru. Zato će buduća istraživanja biti usmjerena na detaljnu analizu rekonstruiranih 3D modela radi mjerenja fizičkih dimenzija oštećenja, korištenje visokoprecizne opreme za lasersko skeniranje kao referentne (*ground-truth*) osnove za provjeru točnosti NeRF algoritma u zadacima geometrijske kvantifikacije.
2. Primjena u stvarnim inženjerskim uvjetima i razvoj lakših modela. U ovome radu predložena je metoda 3D rekonstrukcije oštećenih betonskih uzoraka temeljena na NeRF algoritmu, čime je potvrđena učinkovitost implicitnih neuronskih reprezentacija u renderiranju modela. Buduća istraživanja proširit će se izvan laboratorijskih uvjeta te će obuhvatiti izradu skupova podataka iz stvarnih terenskih okružja kako bi metoda bolje odražavala stvarne dimenzije konstrukcija i složenost okolišnih uvjeta prisutnih na infrastrukturi. Istodobno će se, zbog visokih hardverskih zahtjeva postojećih NeRF algoritama, istraživanja usmjeriti prema razvoju laganijih NeRF arhitektura, pogodnih za primjenu u inženjerskim pregledima na terenu.
3. Integracija s algoritmima segmentacije oštećenja. Ovo istraživanje potvrdilo je učinkovitost NeRF metode u rekonstrukciji detalja površine oštećenih betonskih blokova. Međutim, kako bi se omogućila automatizirana procjena i kvantifikacija oštećenja iz trodimenzionalnog gledišta, budući rad bit će usmjeren na integraciju algoritama za instancijsku segmentaciju oštećenja betona s NeRF okvirom za rekonstrukciju. Planirani pristup uključuje snimanje višeperspektivnih slika stvarnih inženjerskih objekata, izdvajanje dvodimenzionalnih maski oštećenja primjenom algoritama instancijske segmentacije, uključivanje tih maski kao prethodnog znanja (*prior information*) u NeRF model te izgradnju trodimenzionalne reprezentacije koja objedinjuje geometrijska i semantička obilježja. Konačni je cilj ostvariti trodimenzionalno vizualno prepoznavanje oštećenja i precizno kvantitativno mjerenje konstrukcijskih defekata.

5. Zaključak

U ovome radu provedena je usporedna analiza 3D rekonstrukcije oštećenih betonskih površina. Prednosti implicitne reprezentacije koju koristi NeRF potvrđene su sustavnom usporedbom s tradicionalnim eksplicitnim metodama (SfM i MVS).

Pri rekonstrukciji složenih tekstura betonskih uzoraka i u situacijama s ograničenom količinom podataka tradicionalne eksplicitne metode pokazuju zamućenje površina, artefakte nazubljenosti i gubitak pozadinskih informacija. Nasuprot tome,

implicitni algoritam uspješno je prevladao navedena ograničenja, učinkovito uklonio artefakte te omogućio visokovjernu rekonstrukciju površinskih pora i širenja pukotina, pokazujući pritom bolje rezultate u pogledu cjelovitosti modela i vizualne vjernosti prikaza. U sveobuhvatnoj procjeni točnosti i učinkovitosti rekonstrukcije posebno se istaknuo model Instant-NGP, temeljen na višerezolucijskome *hash* kodiranju. Koristeći isti skup slikovnih podataka, model je ostvario PSNR = 24,13 dB, LPIPS = 0,43, SSIM = 0,69 te je cijeli proces treniranja i renderiranja završio za samo minutu i 30 sekundi. Kombinacija visokopreciznog prikaza detalja i vrlo brzog izvođenja omogućuje primjenu ove metode u praktičnim situacijama koje zahtijevaju brzu povratnu informaciju tijekom terenskih građevinskih pregleda.

Iako implicitna metoda rekonstrukcije predložena u ovome istraživanju učinkovito rekonstruira geometrijske detalje oštećenih betonskih uzoraka, trenutačno vrednovanje uglavnom se temelji na kvaliteti vizualne sinteze. Apsolutna geometrijska

kvantifikacija u fizičkome prostoru još nije provedena, niti je metoda u cijelosti integrirana s automatiziranim algoritmima za otkrivanje oštećenja. Zato bi buduća istraživanja trebala biti usmjerena na razvoj modela instancijske segmentacije specijaliziranih za oštećenja betonskih površina te njihovu tijesnu integraciju s NeRF okvirom za rekonstrukciju. Takav pristup omogućio bi automatsko izdvajanje i preciznu kvantitativnu procjenu konstrukcijskih oštećenja iz trodimenzionalnoga prostornog gledišta.

Zahvala

Ovo istraživanje financijski su poduprli Zajednički znanstveno-tehnološki program provincije Liaoning (broj projekta: 2025-BSLH-185) i Nacionalna zaklada za prirodne znanosti Kine (broj projekta: 52408163). Autori zahvaljuju svim sudionicima koji su svojim doprinosom omogućili provedbu ovoga istraživanja.

LITERATURA

- [1] Cha, Y., Choi, W., Büyükköztürk, O.: Deep learning-based crack damage detection using convolutional neural networks, *Computer-Aided Civil and Infrastructure Engineering*, 32 (2017) 5, pp. 361-378, <https://doi.org/10.1111/mice.12263/>
- [2] Kwiatkowska, D., Kluska, P., Reich, A.: Convolutional neural networks for the detection of malignant melanoma in dermoscopy images, *Postepy Dermatol Alergol*, 38 (2021) 3, pp. 412-420, <https://doi.org/10.5114/ada.2021.107927>.
- [3] Kheder, M.Q., Mohammed, A.A.: Real-time traffic monitoring system using IoT-aided robotics and deep learning techniques, *Kuwait Journal of Science*, 51 (2024) 1, pp. 100153, <https://doi.org/10.1016/j.kjs.2023.10.017>.
- [4] Li, J.Q., Zhao, X.F., Zhou, G.G., et al.: Standardized use inspection of workers' personal protective equipment based on deep learning, *Safety Science*, 150 (2022), pp. 105689, <https://doi.org/10.1016/j.ssci.2022.105689>.
- [5] Horn, B.K.P.: *Robot Vision*, MIT Press, Cambridge, 1986.
- [6] Geng, J.: Structured-light 3D surface imaging: a tutorial, *Advances in Optics and Photonics*, 3 (2011) 2, pp. 128-160, <https://doi.org/10.1364/AOP.3.000128>.
- [7] Zhang, Z.: A flexible new technique for camera calibration, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22 (2000) 11, pp. 1330-1334, <https://doi.org/10.1109/34.888718>.
- [8] Snavely, N., Seitz, S.M., Szeliski, R.: Photo tourism: exploring photo collections in 3D, *ACM Transactions on Graphics*, 25 (2006) 3, pp. 835-846, <https://doi.org/10.1145/1141911.1141964>.
- [9] Seitz, S.M., Curless, B., Diebel, J., et al.: A comparison and evaluation of multi-view stereo reconstruction algorithms, 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, New York, 2006: pp. 519-528, <https://doi.org/10.1109/CVPR.2006.19>.
- [10] Besl, P.J., McKay, N.D.: A method for registration of 3-D shapes, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14 (1992) 2, pp. 239-256, <https://doi.org/10.1109/34.121791>.
- [11] Mildenhall, B., Srinivasan, P.P., Tancik, M., et al.: NeRF: Representing scenes as neural radiance fields for view synthesis, *Computer Vision - ECCV 2020*, Cham, 2020: pp. 405-421, https://doi.org/10.1007/978-3-030-58452-8_24.
- [12] Kim, H., Sim, S.H., Spencer, B.F.: Automated concrete crack evaluation using stereo vision with two different focal lengths, *Automation in Construction*, 135 (2022), pp. 104136, <https://doi.org/10.1016/j.autcon.2022.104136>.
- [13] Beckman, G.H., Polyzois, D., Cha, Y.J.: Deep learning-based automatic volumetric damage quantification using depth camera, *Automation in Construction*, 99 (2019), pp. 114-124, <https://doi.org/10.1016/j.autcon.2018.12.006>.
- [14] Liu, C.C., Zhou, L., Wang, W.W., et al.: Concrete surface damage volume measurement based on three-dimensional reconstruction by smartphones, *IEEE Sensors Journal*, 21 (2021) 10, pp. 11349-11360, <https://doi.org/10.1109/JSEN.2021.3067739>.
- [15] Zhu, F.: 3D scene representation: A review of recent achievements in neural radiance fields (NeRF), *Journal of Communication University of China (Science and Technology)*, 29 (2022), pp. 64-77, <https://doi.org/10.16196/j.cnki.issn.1673-4793.2022.05.007>.
- [16] Peng, H.X., Guo, S.K., Zou, X.J., et al.: UAVO-NeRF: 3D reconstruction of orchards and semantic segmentation of fruit trees based on neural radiance field in UAV images, *Computers and Electronics in Agriculture*, 237 (2025), pp. 110631, <https://doi.org/10.1016/j.compag.2025.110631>.
- [17] Wen, X., Sun, K., Chen, T., et al.: A NeRF-based technique combined depth-guided filtering and view enhanced module for large-scale scene reconstruction, *Knowledge-Based Systems*, 316 (2025), pp. 113411, <https://doi.org/10.1016/j.knosys.2025.113411>.
- [18] Horé, A., Ziou, D.: Image quality metrics: PSNR vs. SSIM, 2010 20th International Conference on Pattern Recognition, Istanbul, 2010: pp. 2366-2369, <https://doi.org/10.1109/ICPR.2010.579>.
- [19] Wang, Z., Bovik, A.C., Sheikh, H.R., et al.: Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, 13 (2004) 4, pp. 600-612, <https://doi.org/10.1109/TIP.2003.819861>.

- [20] Zhang, R., Isola, P., Efros, A.A., et al.: The unreasonable effectiveness of deep features as a perceptual metric, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, 2018: pp. 586-595, <https://doi.org/10.1109/CVPR.2018.00068>.
- [21] Mueller, T., Evans, A., Schied, C., et al.: Instant neural graphics primitives with a multiresolution hash encoding, ACM Transactions on Graphics, 41 (2022) 4, pp. 1-15, <https://doi.org/10.1145/3528223.3530127>.
- [22] Schönberger, J.L., Frahm, J.M.: Structure-from-motion revisited, 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: pp. 4104-4113, <https://doi.org/10.1109/CVPR.2016.445>.
- [23] Mildenhall, B., Srinivasan, P.P., Ortiz-Cayon, R., et al.: Local light field fusion: practical view synthesis with prescriptive sampling guidelines, ACM Transactions on Graphics, 38 (2019) 4, pp. 1-14, <https://doi.org/10.1145/3306346.3322941>.
- [24] Tancik, M., Srinivasan, P.P., Mildenhall, B., et al.: Fourier features let networks learn high frequency functions in low dimensional domains, Advances in Neural Information Processing Systems, 33 (2020), pp. 7537-7547.
- [25] Boje, C., Guerriero, A., Kubicki, S., et al.: Towards a semantic construction digital twin: Directions for future research, Automation in Construction, 114 (2020), pp. 103179, <https://doi.org/10.1016/j.autcon.2020.103179>.