

Sveučilište Josipa Jurja Strossmayera u Osijeku
GRAĐEVINSKI I ARHITEKTONSKI FAKULTET OSIJEK

INOVACIJSKI FORUM · 10. ADRIATECH 2026
Hrvatska izložba inovacija u građevinarstvu

IM4StEM

Razvoj inovativne metode za procjenu potresne oštetljivosti zgrada

prof. dr. sc. Marijana Hadzima-Nyarko
Sveučilište Josipa Jurja Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek

Rijeka, 26. 10. 2026.

Co-funded by the European Union

Erasmus+
Enriching lives, opening minds.

Sadržaj

01	Uvod: problem procjene potresne oštetljivosti	3–6
02	Projekt IM4StEM u programu Erasmus+	7–8
03	Konzorcij i pridruženi partneri	9–10
04	Ciljevi i radni paketi projekta	11–12
05	Mobilna aplikacija i web platforma	13–14
06	Prikupljanje podataka i baza zgrada	15–16
07	Pregledi zgrada nakon potresa i baza oštećenja	17–19
08	Strojno učenje na tri razine i metodologija	20–23
09	Predviđanje stupnja potresnog oštećenja	24–28
10	Online model i alat za predviđanje	29–31

Zašto je procjena potresne oštetljivosti važna?

Zagreb, 22. 3. 2020. ML 5,5	**Petrinja, 29. 12. 2020.** ML 6,2	**Turska, 6. 2. 2023.** Mw 7,8 i 7,5
11,5 mlrd €	**5,5 mlrd €**	**34,2 mlrd USD**
procijenjena šteta	*procijenjena šteta*	*izravna šteta (≈ 4 % BDP-a)*
26.197 oštećenih zgrada	**≈ 50.000** pregledanih zgrada	**> 50.000** poginulih
≈ 1.900 neuporabljivih zgrada	**16.105** privremeno ili trajno neuporabljivih	**≈ 1,25 mil.** ljudi privremeno bez doma
27 ozlijeđenih, 2 smrtno stradala	**7** poginulih (+2 tijekom sanacije)	**53 %** štete na stambenim zgradama

Problem
procjene oštetljivosti

- Gubici ovise ponajprije o oštetljivosti postojećih zgrada, a ne samo o jakosti potresa.
- Detaljni pregledi provode se tek nakon potresa – sporo, skupo i uz velik broj stručnjaka.
- Potrebne su brze i pouzdane procjene prije potresa: za planiranje, pojačanja i hitni odgovor.

Izvori: Vlada RH / Svjetska banka – procjene šteta (RDNA 2020.); Grad Zagreb – stanje pregleda zgrada nakon petrinjskog potresa (29. 3. 2022.); Svjetska banka GRADA (2023.)

Potresni rizik i oštetljivost zgrada

$$R = H \times V$$

potresni rizik = opasnost × oštetljivost (Coburn i Spence, 2002)

H

Opasnost (engl .*hazard*)

vjerojatnost pojave potresa određene jakosti na danom području u određenom razdoblju; najčešće se izražava vršnim ubrzanjem temeljnog tla (PGA).

V

Oštetljivost (engl. *vulnerability*)

stupanj gubitka elementa rizika pri danoj razini opasnosti – omjer očekivanog i najvećeg mogućeg gubitka (0 – 1). Višedimenzionalna je i mijenja se tijekom vremena.

R

Rizik (engl. *risk*)

očekivani gubici elementa rizika (zgrade, ljudi, gospodarske aktivnosti) u budućem razdoblju – ljudski, gospodarski i fizički.

Prikaz oštećenja	Opis oštećenja
	**Stupanj 1**: Neznatno (zanemarivo) do malo oštećenje (bez oštećenja konstrukcijskih dijelova, malo nekonstrukcijsko oštećenje). Fine pukotine kod vrlo malog broja zida. Otpadanje samo manjih komada žbuke. Otpadanje labavijih komada kamena iz gornjih dijelova zgrade u malom broju slučajeva.
	**Stupanj 2**: Umjereno oštećenje (malo konstrukcijsko oštećenje, umjereno nekonstrukcijsko oštećenje). Pukotine u mnogim zidovima. Otpadanje prilično velikih komada žbuke. Djelomični slom dimnjaka.
	**Stupanj 3**: Znatno do teško oštećenje (umjereno konstrukcijsko oštećenje, teško nekonstrukcijsko oštećenje). Velike i široke pukotine u većini zida. Odvojen krovni pokrov. Slom dimnjaka u liniji krova; slom pojedinačnih konstrukcijskih elemenata (pregradno, zabatno zide).
	**Stupanj 4**: Vrlo teško oštećenje (teško konstrukcijsko oštećenje; vrlo teško nekonstrukcijsko oštećenje). Ozbiljni slom zida; djelomični konstrukcijski slom krovova i stropova.
	**Stupanj 5**: Rušenje (vrlo teško konstrukcijsko oštećenje). Potpuno ili skoro potpuno rušenje.

Stupnjevi oštećenja zidanih zgrada prema EMS-98 (Grünthal, 1998) – ista ljestvica 1–5 koristi se u IM4StEM bazi

Metode procjene potresne oštetljivosti

Empirijske metode

Statistička obrada opaženih oštećenja zgrada u prošlim potresima.

- Matrice vjerojatnosti oštećenja (DPM)
- Metoda indeksa oštetljivosti (GNDT, RISK-UE)
- Empirijske krivulje oštetljivosti
- Brzi vizualni pregled (RVS, FEMA P-154)

\+ jednostavne, zasnovane na velikom broju stvarnih podataka

– „prosječne" konstrukcije; teško prenosive na drugu gradnju i područja

Hibridne metode

Kombiniraju podatke o opaženim oštećenjima s rezultatima numeričkih modela.

- Hibridne matrice vjerojatnosti oštećenja (Kappos, 1995)
- Hibridne funkcije i krivulje oštetljivosti
- Krivulje temeljene na stručnoj procjeni

\+ model se kalibrira stvarnim podacima; nadomješta manjak podataka za jake potrese

– zahtijevaju usklađivanje različitih izvora podataka

Analitičke metode

Numerički proračun odziva konstrukcije – veza intenziteta i oštećenja ima fizikalno značenje.

- Nelinearni statički proračun (engl. *pushover*), spektar sposobnosti nosivosti (HAZUS)
- Nelinearni dinamički proračun (NLTHA, IDA)
- Metode zasnovane na pomacima i mehanizmu sloma

\+ obuhvaćaju nove tipove zgrada i učinak ojačanja

– puno ulaznih podataka; računalno zahtjevne

Prema: Calvi i dr. (2006), ISET J. Earthquake Technology 43(3); Kassem i dr. (2020), Ain Shams Engineering Journal 11; Hadzima-Nyarko (2022)

Od klasičnih metoda prema IM4StEM pristupu

Idealna metodologija trebala bi (Calvi i dr., 2006):

1	uključiti najnovija saznanja o potresnoj opasnosti
2	eksplicitno obuhvatiti sve izvore nesigurnosti
3	biti prilagodljiva različitoj graditeljskoj praksi, novim tipovima zgrada i pojačanjima
4	uravnotežiti računalnu zahtjevnost, količinu potrebnih podataka i pouzdanost rezultata

Pouzdana procjena oštetljivosti zahtijeva barem dva pristupa koja se međusobno nadopunjuju i provjeravaju.

IM4StEM: empirija + strojno učenje

1.762 zgrade u terenskoj bazi (5 gradova) – standardizirani ulazni podaci

560 zgrada oštećenih u potresima Petrinja (2020.) i Kahramanmaraş (2023.)

≈ 93 % točnost predviđanja stupnja oštećenja (Random Forest) uz SHAP objašnjivost

IM4StEM u programu Erasmus+

Erasmus+ Ključna aktivnost 2 (KA220-HED)
Partnerstva za suradnju u visokom obrazovanju

IM4StEM – Inteligentne metode za konstrukcije, elemente i materijale – partnerski je projekt sufinanciran iz programa Erasmus+.

Povezuje potresno inženjerstvo, digitalne alate i umjetnu inteligenciju s visokoškolskom nastavom:

- nastava kroz terenski rad i stvarne podatke o zgradama
- zajednička međunarodna platforma i baza zgrada
- strojno učenje za procjenu potresne oštetljivosti
- prijenos znanja prema struci i lokalnoj zajednici

Prioriteti Erasmus+ → doprinos IM4StEM

Digitalna transformacija
mobilna i web aplikacija, digitalna baza zgrada

Inovacije u obrazovanju
UI i strojno učenje u nastavi, terenska nastava

Okolišna održivost
reciklirani građevinski materijali, kružno gospodarstvo

Međunarodna suradnja
7 partnera iz 6 zemalja, zajednički terenski rad

Uključivost i otvorenost
digitalne vjerodajnice i javni webinari

Pregled projekta IM4StEM

€400,000	36 mjeseci	Ruj. 2023.	7 partnera
Ukupni proračun	Trajanje	Početak	6 zemalja

Inteligentne metode za konstrukcije, elemente i materijale

Ključne teme

- **Digitalni sadržaji i pedagogija**
- **Prevencija katastrofa i oporavak**
- **Integracija STEM-a i metode UI**
- **Zeleni i digitalni kapaciteti**

Konzorcij i partneri

HR Hrvatska	**Sveučilište Josipa Jurja Strossmayera u Osijeku (GrAFOS + FERIT)**	
RS Srbija	**Sveučilište u Novom Sadu Novi Sad, Srbija**	
ES Španjolska	**Universidad Pablo de Olavide Sevilla, Španjolska**	
PL Poljska	**Politechnika Wrocławska Wrocław, Poljska**	
TR Turska	**Sveučilište Bitlis Eren Bitlis, Turska**	
RO Rumunjska	**Universitatea Transilvania din Brașov Brașov, Rumunjska**	
HR Hrvatska	**Sveučilište u Splitu Split, Hrvatska**	

Pridruženi partneri

19 pridruženih partnera iz 6 zemalja

Hrvatska 6

ALUMNI — Građevinski i arhitektonski fakultet Osijek

Hrvatsko društvo sudskih vještaka i procjenitelja

Hrvatsko društvo za potresno inženjerstvo

Grad Kaštela

Zavod za prostorno planiranje

Graditeljsko-geodetska škola Osijek

Srbija 3

Srpsko udruženje za zemljotresno inženjerstvo (SUZI)

Udruženje inženjera (IZGRADNJA)

Politehnička škola Subotica

Poljska 3

Panterra Grupa

Poljsko udruženje podopolagača

KGHM Metraco S.A.

Španjolska 1

Nacionalni geografski institut

Turska 3

Komora građevinskih inženjera

Grad Bitlis

YALÇIN AÇIKGÖZ

Rumunjska 3

M B Building and Consulting

ROZINI S.R.L.

Udruženje projektanata konstrukcija

19

partnera: ustanove, gradovi, strukovne udruge i tvrtke

Ciljevi projekta

1 Kvalitetnija nastava

Unaprijediti nastavu, istraživanja i praksu digitalizacijom i metodama strojnog učenja

2 Međunarodna suradnja

Ojačati kapacitete za međunarodnu i multidisciplinarnu suradnju putem zajedničke web platforme

3 Digitalni alati na terenu

Razviti alate za prikupljanje podataka na terenu i uključiti studente u terenske aktivnosti

4 UI i strojno učenje

Primijeniti UI/strojno učenje za predviđanje ponašanja konstrukcija i potresne oštetljivosti

5 Održivost

Promicati održivost primjenom recikliranih građevinskih materijala

6 Diseminacija

Diseminirati rezultate široj akademskoj i stručnoj zajednici

Radni paketi

Ruj. 2023. *početak* 2024. 2025. 2026. **Kol. 2026.** *kraj*

36 mjeseci

WP1

Upravljanje projektom; diseminacija i obrazovanje

10 javnih webinara, 600+ educiranih studenata, 2.434 izdane digitalne vjerodajnice, znanstvene publikacije i izlaganja na konferencijama

WP2

Digitalizacija i baza podataka o zgradama

Razvoj digitalnih alata, mobilne aplikacije, QGIS webinari i prikupljanje podataka o zgradama u 5 partnerskih gradova (Osijek, Split, Brașov, Bitlis, Novi Sad)

WP3

Integracija STEM-a kroz UI u građevinarstvu

Primjena metoda strojnog učenja za predviđanje tlačne čvrstoće betona, čvrstoće zidanih zidova i razine potresnih oštećenja zgrada

WP4

Reciklirani građevinski materijali

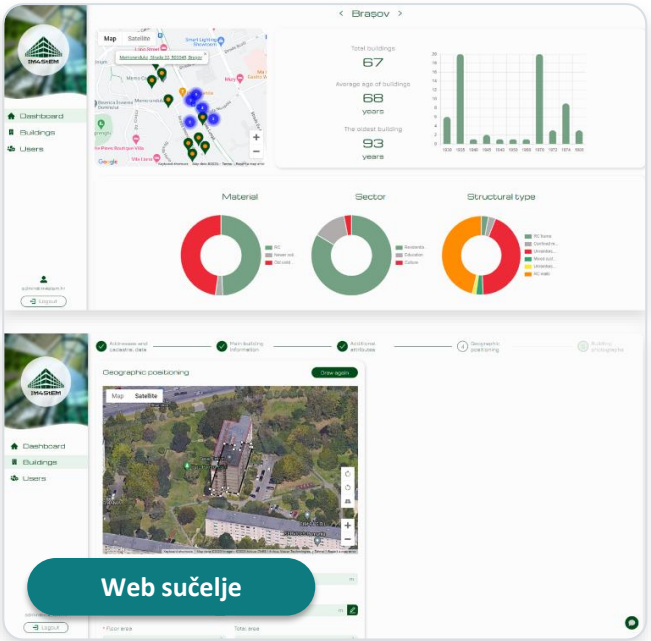
Laboratorijska ispitivanja betona s agregatom od reciklirane opeke; istraživanje biomorta i primjene reciklirane opeke; pristup kružnog gospodarstva

IM4StEM mobilna aplikacija

Digitalno prikupljanje podataka na terenu – mobilno i web sučelje

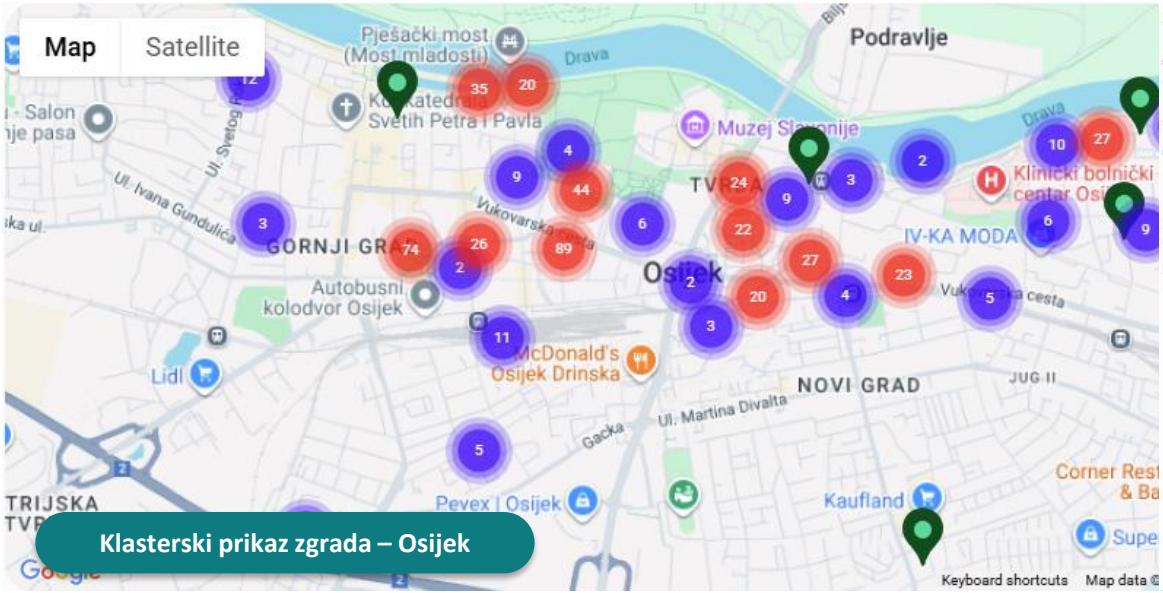


1. **Adresa i katastarski podaci**
2. **Osnovni podaci o zgradi**
   Konstrukcijski sustav, broj katova, starost, namjena, katna visina, materijal, stropna konstrukcija…
3. **Dodatni atributi**
   morfologija tla, održavanje, meki kat
4. **Geopozicioniranje i karta**
5. **Fotodokumentacija i validacija**



IM4StEM web platforma

Svi prikupljeni podaci dostupni su na zajedničkoj interaktivnoj karti



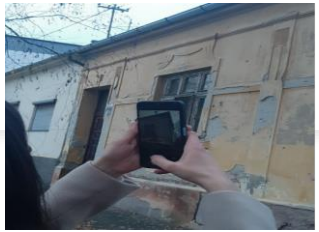
Klasterski prikaz zgrada – Osijek



Pojedinačne zgrade na karti

Prikupljanje podataka

Terenski rad postao je okruženje za učenje



Osijek



Split



Brașov



Novi Sad



Bitlis

Što se promijenilo

Studenti

Terenski rad postao je praktična obuka o potresnom riziku i digitalnom prikupljanju podataka.

Nastavnici

Međunarodni nadzor i zajednički terenski rad omogućili su metodološko usklađivanje i prijenos znanja.

Istraživanje

Prikupljeni podaci poslužili su kao ulaz za procjenu oštetljivosti, GIS analize i studije strojnog učenja.

Stvarni podaci: 1.762 zgrade u 5 gradova

Usklađena baza zgrada partnerskih gradova kao ulaz za modele predviđanja oštetljivosti.



Osijek (HR):
580 zgrada

Brașov (RO):
202 zgrade

Split (HR):
570 zgrada

Novi Sad (RS):
200 zgrada

Bitlis (TR):
210 zgrada

37.002 karakteristike zgrada

Prikupilo ih je više od 140 studenata na terenu – otvorena, standardizirana međunarodna baza potresne oštetljivosti

Pregledi zgrada nakon potresa

Kahramanmaraş, Turska

Potres 6. 2. 2023., M_w 7,8 i 7,5

Pregledi zgrada oštećenih u potresu u Kahramanmarašu.

Obilazak novih stambenih zgrada izgrađenih nakon potresa u pokrajini Hatay.







Pregledi zgrada nakon potresa

Petrinja, Hrvatska

Potres 29. 12. 2020., M_L 6,2

Pregled zgrada oštećenih u potresu na području Petrinje.

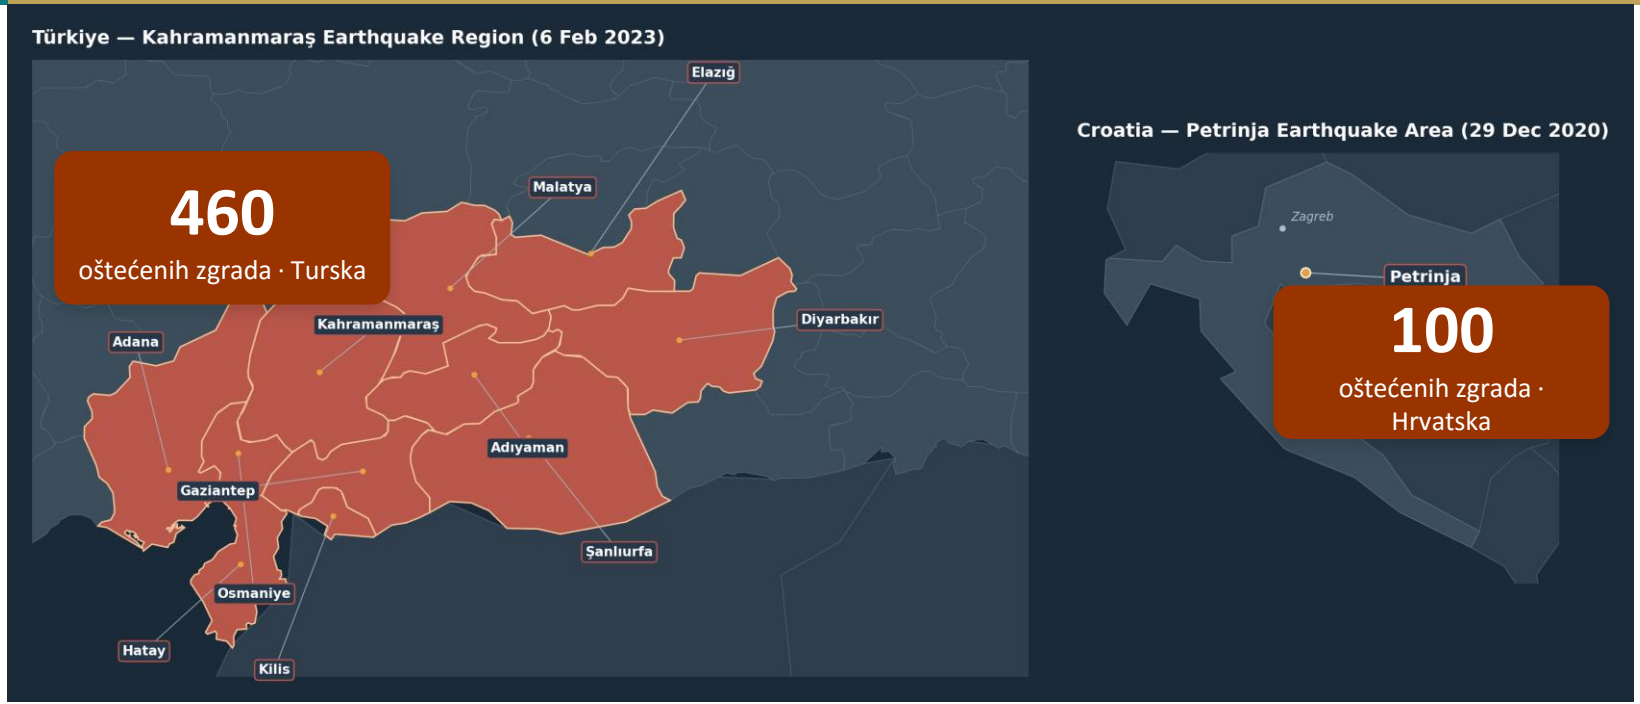
Studenti su, pod stručnim vodstvom, obišli gradilišta obnove zgrada kulturne baštine oštećenih u potresu.








Stvarni podaci: baza od 560 oštećenih zgrada

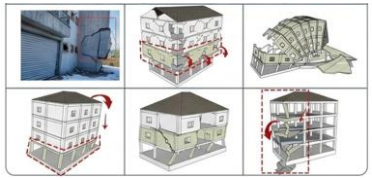


22 atributa po zgradi · 13 kategorijskih · 9 numeričkih

Strojno učenje na tri razine

KONSTRUKCIJA
Potresno oštećenje

560 zgrada oštećenih u potresima u Petrinji i Kahramanmaraşu; 22 ulazna atributa (13 kategorijskih, 9 numeričkih)



Predviđanje razine oštećenja iz karakteristika zgrade + PGA

ML + OBJAŠNJIVOST

ELEMENT
Zidani zid

914 uzoraka zidova: čvrstoća zidnih elemenata f_b, čvrstoća morta f_m i omjer visine i duljine (h/l)

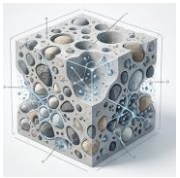


Predviđanje tlačne čvrstoće iz svojstava zida i morta

ML + OBJAŠNJIVOST

MATERIJAL
Beton

363 uzorka analizirana prema 8 parametara: v/c omjer, cement, krupni agregat, sitni agregat, omjer otpadnog i sitnog agregata, omjer otpadnog i krupnog agregata, vrsta uzorka, tlačna čvrstoća



Predviđanje 28-dnevne tlačne čvrstoće iz sastava mješavine

ML + OBJAŠNJIVOST

Metoda: statistička analiza + ansambli stabala odlučivanja i umjetne neuronske mreže, interpretirani metodom SHAP (SHapley Additive exPlanations) kako bi se otvorila „crna kutija".

Tim

Rezultati su nastali zajedničkim radom međunarodnog tima

AT

Angela del Robledo Troncoso García

docentica

Universidad Pablo de Olavide
Sevilla, Španjolska

SC

Sławomir Czarnecki

izvanredni profesor

Politechnika Wrocławska
Wrocław, Poljska

EN

Emmanuel Karlo Nyarko

redoviti profesor

Sveučilište J. J. Strossmayera u Osijeku
Osijek, Hrvatska

Metodologija: od podataka do odluke

IZAZOV

Ponašanje konstrukcija složeno je, nelinearno i ovisi o mnogim međusobno povezanim varijablama.

CILJ

Prediktivni model koji je ne samo **točan**, nego i **interpretabilan**.

ŠTO? *Ne želimo znati samo što će model predvidjeti, nego i zašto.* **ZAŠTO?**

Metodologija: od podataka do odluke

Naš postupak u tri koraka

1 Statistička analiza

najprije smo analizirali podatke kako bismo pronašli korelacije, razdiobe i ključne statističke čimbenike

2 Treniranje modela

primijenili smo raznovrstan skup algoritama strojnog učenja:

Regresijski modeli

linearna regresija, Random Forest, XGBoost, ANN

Klasifikacijski modeli

stabla odlučivanja, Random Forest, ANN

3 Interpretabilnost

koristili smo SHAP (SHapley Additive exPlanations) kako bismo „otvorili crnu kutiju". SHAP analiza točno pokazuje **koja obilježja imaju najveći utjecaj na predviđanja modela**.

Predviđanje stupnja potresnog oštećenja

Cilj: utvrditi atribute zgrade koji utječu na stupanj oštećenja (ljestvica 1 – 5) nakon potresa

560	2	20	1 – 5
zgrada u uzorku	potresa: Petrinja 2020. i Kahramanmaraş 2023.	ulaznih obilježja	stupanj oštećenja (izlaz)

Ulazni atributi

13 kategorijskih: konstrukcija stropa, položaj zgrade u bloku, namjena, materijal…

7 numeričkih: godina izgradnje, širina, visina, duljina, tlocrtna ploština, broj katova, *PGA*

Model **strojnog učenja**

Stupanj oštećenja

1 2 3 4 5

od neznatnog (1) do rušenja (5)

Predviđanje stupnja potresnog oštećenja

Statistička analiza – ključni nalazi

▲ Što povećava rizik?

- Prisutnost „mekog kata”
- Nepravilnost po visini
- Starija godina izgradnje i (iznenađujuće) manji broj katova

→ *povezano s teškim oštećenjima – stupnjevi 4 – 5*

▼ Što štiti zgradu?

- Redovito održavanje
- Pravilnost u tlocrtu

→ *povezano s najnižim stupnjevima oštećenja – 1 i 2*

Predviđanje stupnja potresnog oštećenja

Tri režima treniranja/testiranja – podaci stratificirani prema:

Gradu (NAJBOLJE)	Stupnju oštećenja	Gradu i stupnju oštećenja
92,9 %	**85,7 %**	**89,3 %**
klasifikacija · Random Forest	klasifikacija · Random Forest	klasifikacija · ANN
84,8 %	**84,8 %**	**85,7 %**
regresija · Random Forest	regresija · Gradient Boosting	regresija · Random Forest

Regresijski modeli
linearna regresija, Ridge, Lasso, Random Forest, Gradient Boosting, ANN

Klasifikacijski modeli
logistička regresija, Random Forest, Gradient Boosting, ANN

Predviđanje stupnja potresnog oštećenja

≈ 93 %

Klasifikacija prema gradu je najlakša

Random Forest postiže točnost od gotovo 93 % – obilježja snažno razlikuju gradove.

85 – 86 %

Stupanj oštećenja je najzahtjevniji

Najbolji modeli (Random Forest, Gradient Boosting) – zbog složene i neuravnotežene ciljne varijable.

0,893

Zajednička stratifikacija pogoduje ANN-u

ANN postiže testnu točnost 0,8929 i nadmašuje Gradient Boosting (0,8839).

Grad + stupanj

Preporuka

Stratificirati podatke i prema gradu i prema stupnju oštećenja – model bez pristranosti koji se generalizira na nove lokacije.

Predviđanje stupnja potresnog oštećenja

Što je SHAP?

Metoda koja pokazuje koliko svako ulazno obilježje **pomaže ili odmaže** konačnom predviđanju modela.

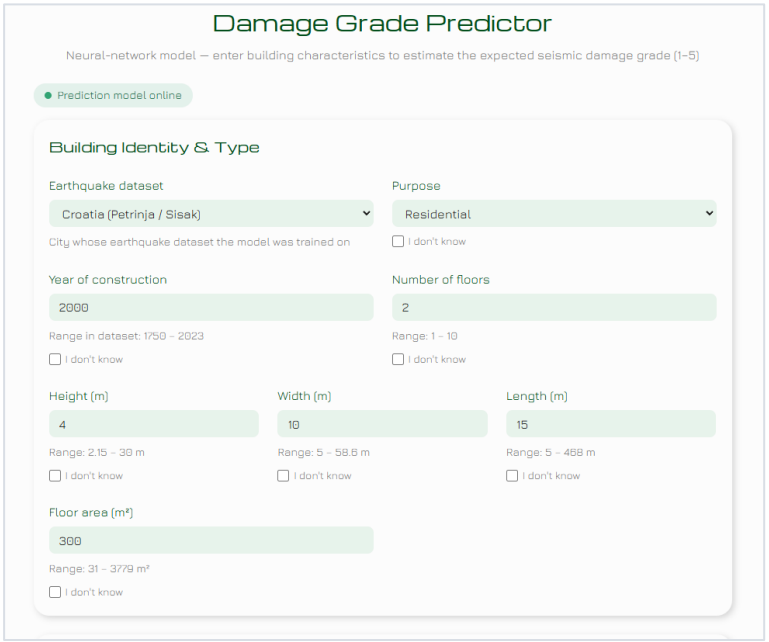
Neovisna je o vrsti modela – primjenjiva na bilo koji model strojnog učenja.

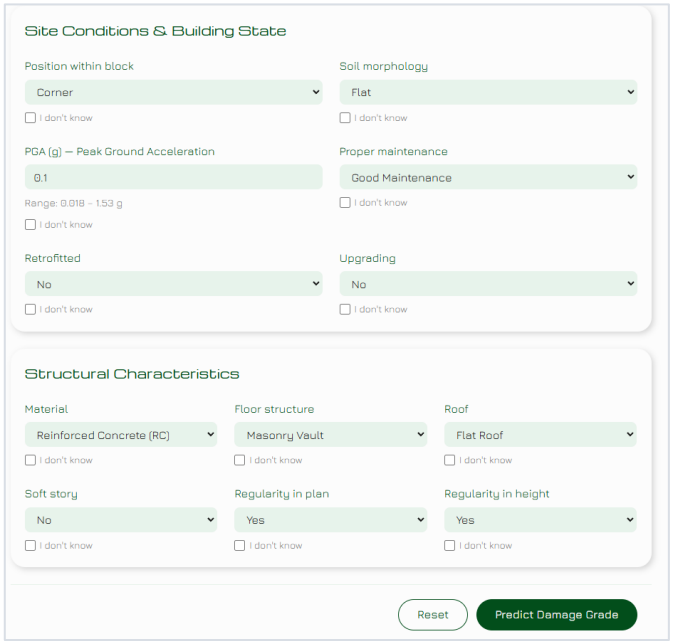
Dominantni čimbenici u predviđanjima

- ***PGA***
  vršno ubrzanje temeljnog tla
- **Lokacija**
  grad / područje
- **Konstrukcija stropa**
  tip stropne konstrukcije
- **Dimenzije zgrade**
  duljina, širina, visina
- **Materijal**
  nosivi materijal zgrade

Predviđanje stupnja potresnog oštećenja

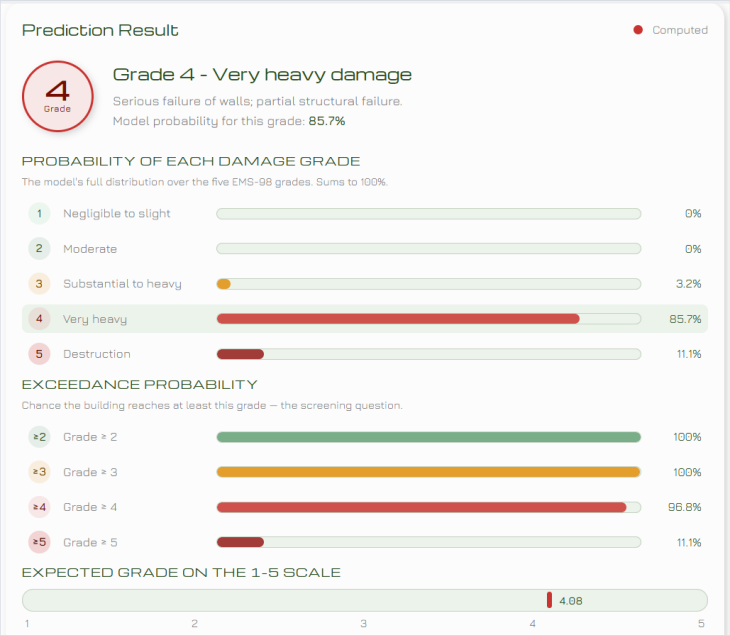
1 Online alat: unos podataka identifikacija zgrade, uvjeti lokacije i konstrukcijske karakteristike

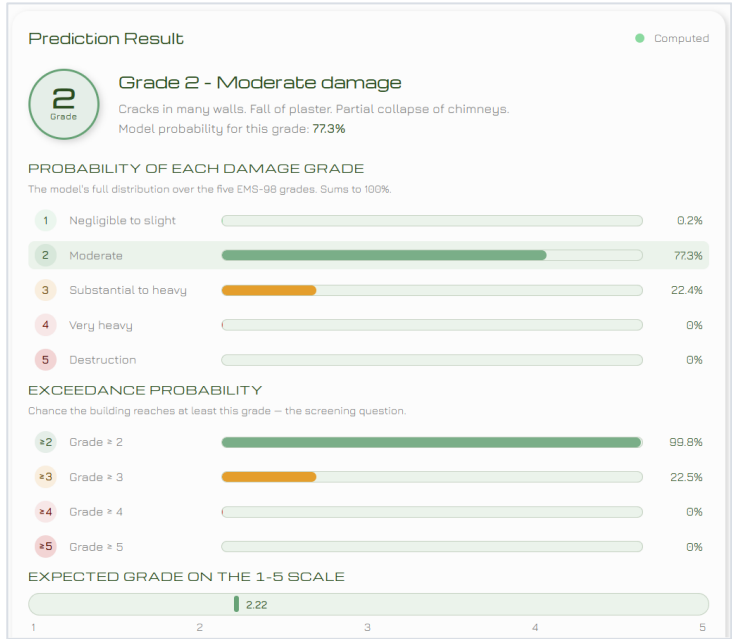




Predviđanje stupnja potresnog oštećenja

2 Rezultat predviđanja vjerojatnost svakog stupnja, vjerojatnost prekoračenja i očekivani stupanj





Hvala!

Pitanja i rasprava

Mrežna stranica projekta: im4stem.eu

Marijana Hadzima-Nyarko
Građevinski i arhitektonski fakultet Osijek
Sveučilište Josipa Jurja Strossmayera u Osijeku
Osijek, Hrvatska

Skeniraj: im4stem.eu

Erasmus+
KA220-HED