

Umjetna inteligencija u višehazardnom ranom upozoravanju kroz prizmu CRISAFE i AI-Warn projekata

Meho Saša Kovačević¹, Mario Bačić¹

¹Sveučilište u Zagrebu Građevinski fakultet, Kačićeva 26, 10000 Zagreb

Sažetak: Rad prikazuje primjenu umjetne inteligencije u višehazardnim sustavima ranog upozoravanja kroz razvojnu liniju UCPM projekata oVERFLOW, CROSScade, CRISAFE i AI-Warn, koje je koordinirao Sveučilište u Zagrebu Građevinski fakultet. Posebna se pozornost daje projektu CRISAFE, u kojem je razvijen i u praksi provjeren sustav CHEWS za praćenje oborine, vodostaja i vibracija, s jedinstvenim tijekom prikupljanja podataka, prikazom stanja i pravilima upozoravanja. Na toj osnovi AI-Warn uvodi sljedeći korak prema AI-om potpomognutom ranom upozoravanju kroz višesenzorsku fuziju satelitskih mjerenja, UAV snimanja i gusto raspoređene IoT mreže senzora te rano prepoznavanje neuobičajenih pojava i pouzdaniju potporu odlučivanju službama civilne zaštite i upraviteljima infrastrukture u pilot područjima Dubrovnika i Bruxellesa. Time AI-Warn potvrđuje potencijal AI-om potpomognutih višesenzorskih sustava ranog upozoravanja u jačanju klimatske otpornosti europskih regija.

Ključne riječi: umjetna inteligencija, višehazardni sustavi ranog upozoravanja, kritična infrastruktura, civilna zaštita, potpora odlučivanju

1. Uvod

Uslijed klimatskih promjena i sve učestalijih ekstremnih pojava, raste potreba za sustavima ranog upozoravanja koji učinkovito povezuju praćenje stanja na terenu, procjenu ranjivosti i konkretno operativno djelovanje [1-3]. To je od presudne važnosti u kaskadnim scenarijima gdje se različiti hazardi vremenski i prostorno preklapaju, čime se dodatno povećava rizik za građane i kritičnu infrastrukturu [4-6]. U takvim okolnostima puko prikupljanje podataka više nije dovoljno. Ključni prioritet postaje njihova pouzdana obrada i transformacija u jasne, primjenjive informacije koje službama civilne zaštite i upraviteljima infrastrukture omogućuju donošenje pravovremenih i utemeljenih odluka.

Razvojni put, dan u ovom radu, može se jasno pratiti kroz projekte oVERFLOW, CROSScade i CRISAFE te kroz daljnji razvoj prema projektu AI-Warn. Svi projekti su financirani kroz program mehanizma civilne zaštite Europske Unije. Projekti oVERFLOW (engl. *Vulnerability assessment of embankments and bridges exposed to flooding hazards*) i CROSScade (engl. *Cross-border cascading risk management for critical infrastructure in the Sava river Basin*) uspostavili su metodološku osnovu kroz procjenu ranjivosti kritične infrastrukture, analizu kaskadnih višehazardnih scenarija te strukturiranje rizika u obliku pogodnom za operativnu primjenu [7, 8]. Projekt CRISAFE (engl. *Critical infrastructure early warning system and population awareness for multi hazard cascading events*) je tu osnovu dodatno razradio i povezo u cjeloviti višehazardni okvir koji obuhvaća kvantificirane hazardne scenarije, procjenu ranjivosti i kaskadnu procjenu rizika [9-12].

Za prijelaz prema sustavu ranog upozoravanja orijentiranom k umjetnoj inteligenciji (AI) posebno je važan CRISAFE-ov razvijeni CHEWS sustav (engl. *Cascading Multi-Hazard Early Warning System*), jer predstavlja operativni sloj koji povezuje rezultate analize hazarda, ranjivosti i rizika s podacima terenskog monitoringa [11, 12]. Na taj način su analitički rezultati prevedeni u operativne razine upozorenja i postupke korisne za svakodnevni nadzor i reagiranje. U sklopu projekta, na zagrebačkom pilot području razvijen je i primijenjen IoT sustav za praćenje oborine, vodostaja i vibracija, s jedinstvenim tijekom prikupljanja, prijenosa, pohrane i prikaza podataka, jasno definiranom logikom upozorenja te praćenjem pouzdanosti sustava i kvalitete podataka u gotovo stvarnom vremenu [12].

Na toj osnovi projekt AI-Warn (engl. *Holistic AI-driven Early Warning System for Climate-Induced Hazards in Critical Infrastructure and Civil Protection*) predstavlja sljedeći razvojni korak prema primjeni umjetne inteligencije u višehazardnim sustavima ranog upozoravanja. U odnosu na CRISAFE, naglasak se proširuje na višesenzorsku fuziju podataka koja povezuje satelitska opažanja Zemlje, snimanja bespilotnom UAV letjelicom i gusto raspoređene IoT mreže geotehničkih i hidroloških senzora. Takva integracija izravno je povezana s AI konceptom jer stvara podatkovnu osnovu za naprednu analitiku, rano prepoznavanje neuobičajenih pojava i robusniju potporu odlučivanju, uz zadržavanje ekspertnih pravila i lokacijski specifičnih pragova upozorenja kao važnog dijela sustava.

U skladu s navedenim kontinuitetom, cilj ovoga rada je prikazati kako se na iskustvima CHEWS sustava razvija primjena umjetne inteligencije u projektu AI-Warn kao sljedećem metodološkom i operativnom koraku. Poseban naglasak stavlja se na komponente već potvrđene u praksi unutar CRISAFE projekta te na komponente koje projekt AI-Warn uvodi kao nadogradnju, s ciljem unaprjeđenja potpore odlučivanju službama civilne zaštite i upraviteljima infrastrukture u uvjetima klimatski uvjetovanih višehazardnih događaja.

2. Razvojni okvir projekata iz mehanizma civilne zaštite Europske Unije

Razvojni okvir prikazan u ovom radu temelji se na kontinuitetu četiri projekta iz mehanizma civilne zaštite Europske Unije (engl. *Union Civil Protection Mechanism – UCPM*) projekta koje je koordinirao Sveučilište u Zagrebu Građevinski fakultet. Taj kontinuitet nije samo administrativan, nego metodološki i operativan: od procjene ranjivosti pojedinih elemenata infrastrukture, preko procjene kaskadnog višehazardnog rizika, do razvoja sustava ranog upozoravanja i planiranog uvođenja metoda umjetne inteligencije u obradu i interpretaciju podataka.

U projektu oVERFLOW naglasak je bio na poplavno ugroženoj infrastrukturi, osobito na nasipima za obranu od poplava i mostovima, te na razvoju probabilističkog pristupa procjeni ranjivosti [7]. Posebno je važan doprinos razvoja krivulja ranjivosti, kojima se povezuje intenzitet opterećenja s vjerojatnošću oštećenja ili sloma. Uz to, projekt je uključivao i praktične elemente pregleda i praćenja stanja infrastrukture, uključujući terenske i bespilotne metode, čime je postavljen temelj za kasnije povezivanje modela i podataka monitoringa.

Projekt CROSScade proširio je taj okvir s razine pojedinačne infrastrukture na razinu kaskadnog višehazardnog rizika i prekogranične suradnje, s fokusom na sliv rijeke Save [8]. Pri tome se razmatrala osjetljivost nasipa za obranu od poplava i mostova na kaskadne seizmičke i poplavne događaje. Ključna vrijednost CROSScade-a bila je u povezivanju tehničkih analiza s organizacijskim i operativnim potrebama. U projektu su razvijani komunikacijski okviri i akcijski planovi koji povezuju službe civilne zaštite i upravitelje infrastrukture u scenarijima složenih događaja. Time je napravljen važan iskorak od inženjerske procjene prema sustavu koji može poduprijeti stvarno donošenje odluka u kriznim situacijama.

CRISAFE je taj razvojni niz dodatno proširio povezivanjem kvantificiranih scenarija opasnosti, procjene ranjivosti kritične infrastrukture i procjene kaskadnog višehazardnog rizika u jedinstven okvir [9-11]. Posebno je važna primjena Bayes-ovih mreža za procjenu rizika u scenarijima koji uključuju nesigurnosti, nedostatke podataka i uzročno-posljedične veze između više događaja. U tom se okviru povezuju rezultati scenarija opasnosti, podaci o izloženosti i infrastrukturi te rezultati procjene ranjivosti, uz uključivanje ekspertnog znanja gdje je to potrebno. Na taj način je uspostavljen analitički okvir koji je po svojoj prirodi kompatibilan s kasnijim AI pristupima, jer se temelji na integraciji heterogenih izvora podataka i ažuriranju procjena kako novi podaci postaju dostupni.

Za temu ovoga rada posebno je važan CHEWS sustav razvijen u okviru CRISAFE projekta, jer predstavlja operativni sloj koji povezuje monitoring kritične infrastrukture i okolišnih uvjeta s upozorenjima namijenjenima službama civilne zaštite

i upraviteljima infrastrukture [12]. CRISAFE nije ostao samo na razini modeliranja scenarija, ranjivosti i rizika, nego je razvio i praktičan okvir za praćenje i uzbunjivanje u gotovo stvarnom vremenu. To je ključna prijelazna točka prema AI nadogradnji razmatranoj u ovom radu.

o uspostavljenoj osnovi daljnji razvoj usmjerava se prema povezivanju više izvora podataka, uključujući satelitska opažanja Zemlje, UAV snimanja i gusto raspoređene IoT mreže geotehničkih i hidroloških senzora, te prema uvođenju metoda umjetne inteligencije za analizu obrazaca, detekciju anomalija i potporu odlučivanju. Zbog toga CRISAFE predstavlja ključan most prema toj sljedećoj fazi: on daje validiranu osnovu monitoringa, scenarija, ranjivosti i rizika na koju se može nadograditi AI-potpomognuta obrada i interpretacija podataka.

3. Projekt CRISAFE kao potvrđena osnova za AI nadogradnju

3.1. Scenariji kaskadnih opasnosti

U okviru projekta CRISAFE definirani su i kvantificirani scenariji opasnosti za dvije studije slučaja, grad Zagreb i grad Rotterdam, pri čemu opasnosti nisu promatrane izolirano, nego kao mogući sljedovi međusobno povezanih procesa s kaskadnim posljedicama za kritičnu infrastrukturu i okolni prostor. U zagrebačkom slučaju naglasak je bio na intenzivnim oborinama, vodnim valovima i potresnom djelovanju na sustav bujičnih retencija Medvednice, dok je u Rotterdamu naglasak bio na poplavnim scenarijima i mehanizmima koji mogu ugroziti sigurnost nasipa, uključujući statičku likvefakciju i druge oblike gubitka stabilnosti. Tako je uspostavljena kvantificirana scenarijska osnova za daljnje korake procjene ranjivosti i rizika [9].

3.2. Procjena ranjivosti kritične infrastrukture

Na tako definirane i kvantificirane scenarije opasnosti nadovezala se procjena ranjivosti kritične infrastrukture, provedena na reprezentativnim zagrebačkim retencijama i na dionici nasipa u području Rotterdama. U toj su procjeni povezani terenski i geotehnički podaci, numeričko modeliranje i probabilističke analize, pri čemu su kao ključan rezultat dobivene krivulje ranjivosti koje povezuju intenzitet opterećenja s vjerojatnošću oštećenja ili otkaza. Tako je uspostavljena veza između scenarija opasnosti i očekivanog ponašanja infrastrukture, što je bilo nužno za kasnije definiranje rizika i pragova upozorenja [10].

3.3. Procjena kaskadnog višehazardnog rizika

Sljedeći korak bila je procjena kaskadnog višehazardnog rizika, razvijena primjenom Bayes-ovih mreža kao prikladnog okvira za rad u uvjetima nesigurnosti, nedostatka podataka i složenih uzročno-posljedičnih veza između više događaja. U tom se pristupu povezuju scenariji opasnosti, procjena ranjivosti, podaci o izloženosti i ekspertno znanje, čime se rizik ne promatra kao statičan rezultat, nego kao strukturirana i ažurirana procjena. Takav okvir posebno je važan za kasniji razvoj sustava ranog upozoravanja jer omogućuje povezivanje analitičkih rezultata s operativnim pravilima i podacima iz monitoringa [11].

Na taj je način u projektu CRISAFE uspostavljen logičan slijed od scenarija opasnosti, preko procjene ranjivosti i procjene rizika, do osnove za operativno upozoravanje. Na toj se potvrđenoj osnovi u sljedećem poglavlju razmatra CHEWS kao operativni IoT temelj sustava ranog upozoravanja, koji predstavlja izravni most prema AI-Warn-u [12].

3.4. CHEWS kao operativni IoT temelj sustava ranog upozoravanja

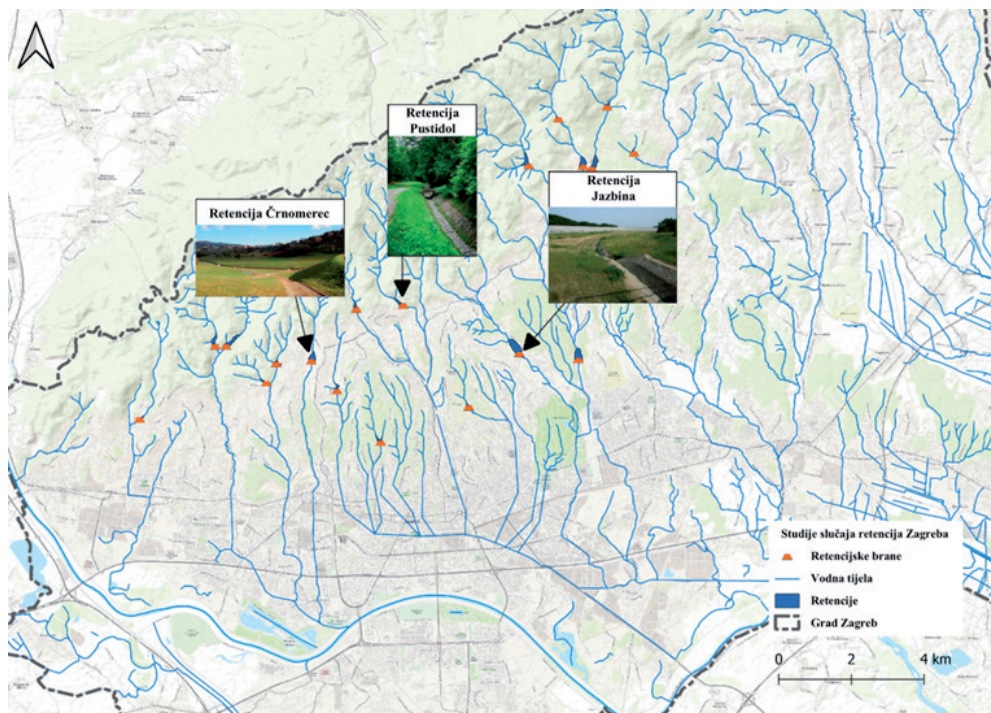
3.4.1. Zagrebački pilot projekt i operativni koncept CHEWS-a

Operativna vrijednost projekta CRISAFE najjasnije se očituje u sustavu CHEWS, kojim su rezultati prethodnih analiza prevedeni u praktičan okvir za monitoring i upozoravanje. Pritom CHEWS nije zamišljen samo kao dodatak modelima hazarda, ranjivosti i rizika, nego kao operativni sloj koji omogućuje njihovu primjenu u svakodnevnom nadzoru i upravljanju.

Zagrebački pilot projekt razvijen je na sustavu retencija na južnim padinama Medvednice iznad grada Zagreba, pri čemu su kao reprezentativne lokacije odabrane retencije Črnomerec, Pusti dol i Jazbina (Slika 1). Odabir tih lokacija omogućio je uspostavu pilot sustava na stvarnoj infrastrukturi koja ima jasno definiranu zaštitnu funkciju u obrani od bujičnih poplava te povezivanje modelskih rezultata iz prethodnih projektnih aktivnosti s konkretnim lokacijama na kojima se mogu pratiti okolišni i infrastrukturni pokazatelji relevantni za rano upozoravanje.

U okviru zagrebačkog pilot projekta razvijena su i ugrađena tri međusobno povezana sustava monitoringa: monitoring oborina, monitoring vodostaja i monitoring vibracija odnosno odziva lokacije na potresno djelovanje. Monitoring oborina daje ranu informaciju o mogućem razvoju bujičnih dotoka, monitoring vodostaja omogućuje neposredno praćenje hidrauličkog odgovora sustava, dok monitoring vibracija omogućuje registriranje potresnog događaja i procjenu potrebe za pojačanim naknadnim nadzorom.

Posebna vrijednost CHEWS-a jest u tome što ta tri sustava nisu razvijena kao odvojena tehnička rješenja, nego kao dijelovi jedinstvenog operativnog okvira usmjerenog na rano upozoravanje i potporu odlučivanju [12].



Slika 1: Odabrane lokacije retencija u gradu Zagrebu za uspostavu CHEWS monitoring sustava

3.4.2 Arhitektura sustava, logika upozorenja i rad u gotovo stvarnom vremenu

Sustav CHEWS razvijen je kao jedinstvena i funkcionalno usklađena arhitektura koja povezuje monitoring oborine, vodostaja i vibracija u zajednički tok prikupljanja, prijenosa, pohrane, obrade i prikaza podataka. Polazna točka sustava su terenski senzorski čvorovi koji prikupljaju podatke i organiziraju ih u standardizirane poruke s identitetom uređaja, vremenskom oznakom i osnovnim informacijama o stanju sustava. Na taj način je već na razini izvora podataka osigurana standardizacija nužna za jedinstven rad cijelog sustava i njegovo buduće proširenje.

Prijenos podataka organiziran je tako da senzorski čvorovi šalju poruke prema središnjem komunikacijskom i poslužiteljskom sloju, gdje se podaci zaprimaju, provjeravaju, pohranjuju i pripremaju za daljnju obradu. Središnji dio arhitekture čine postupci prihvata, pohrane i osnovne obrade podataka, pri čemu se podaci iz različitih skupina senzora prevode u jedinstven oblik prikladan za prikaz i logiku upozoravanja. Time

korisnik više ne mora pratiti više nepovezanih aplikacija ili skupova podataka, nego dobiva objedinjeni prikaz stanja na promatranim lokacijama.

Operativna vrijednost sustava proizlazi iz toga što se mjerni podaci prevode u jasnu i ujednačenu logiku upozorenja. U okviru projekta CRISAFE upozorenja su organizirana kroz tri osnovne razine: informacija, upozorenje i alarm. Sustav pritom razlikuje upozorenja vezana uz oborinu, upozorenja vezana uz vodostaj i promjenu vodostaja, upozorenja vezana uz vibracije i seizmički odziv te kombinirana upozorenja. Za svaku skupinu upozorenja definirani su odgovarajući indikatori i pravila aktivacije, pri čemu se sirovi mjerni podaci najprije prevode u stabilnije i operativno razumljivije pokazatelje. Dodatna stabilnost postiže se pravilima postojanosti uvjeta i histereze, čime se sprječava nepouzdana mijenjanje razina upozorenja zbog šuma, kratkotrajnih oscilacija ili pojedinačnih nerealnih skokova u mjerenju.

Takva arhitektura omogućuje rad u gotovo stvarnom vremenu, pri čemu se podaci nakon mjerenja prenose, zaprimaju i prikazuju s dovoljno malim vremenskim odmakom da mogu služiti kao osnova za operativno upozoravanje. Ujedno se kroz isti sustav omogućuje povezivanje više izvora podataka unutar zajedničke logike upozorenja, uključujući i kombinirane višehazardne situacije. U konačnici je pokazano da se na jedinstvenoj operativnoj arhitekturi može graditi daljnja više-izvorna i AI-potpomognuta nadogradnja [12].

3.4.3 Pouzdanost sustava i kvaliteta podataka kao preduvjet AI nadogradnje

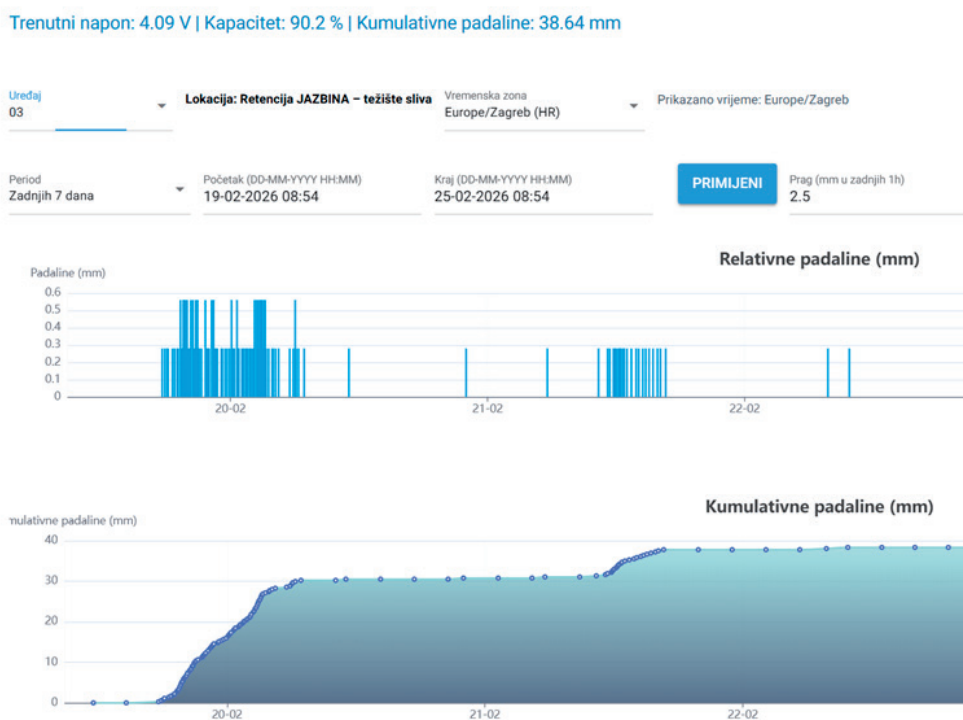
Jedna od najvažnijih značajki CHEWS sustava jest to što pouzdanost sustava i kvaliteta podataka nisu promatrane kao sporedno tehničko pitanje, nego kao sastavni dio same logike ranog upozoravanja. Sustav zato jasno razlikuje stanje u kojem nema opasne pojave od stanja u kojem nema pouzdanih podataka ili sustav ne radi ispravno. Upravo zato su uz fizička upozorenja razvijena i operativno-tehnička upozorenja kojima se prati stanje sustava i vjerodostojnost podatkovnog toka.

Pouzdanost sustava promatra se kroz kontinuitet podatkovnog toka, raspoloživost komunikacije, stanje napajanja, vjerodostojnost mjerenja, cjelovitost zapisa i raspoloživost središnjih servisa. To znači da sustav ne prati samo izmjerene vrijednosti, nego i vrijeme od posljednje poruke, razinu napunjenosti baterije, pojavu nerealnih ili zaglavljenih signala, nepravilnosti u vremenskim oznakama i moguće probleme u prijenosu, bazi podataka ili web-prikazu. Posebno su važna upozorenja povezana s prekidom komunikacije i izostankom podataka, kao i osnovna pravila kontrole kvalitete mjerenja, uključujući provjeru raspona vrijednosti, prepoznavanje nerealnih skokova i prepoznavanje zaglavljenih signala.

Operativna važnost takvog pristupa posebno dolazi do izražaja u korisničkom sučelju, gdje se fizička upozorenja i operativno-tehnička upozorenja prikazuju zajedno,

unutar iste operativne slike sustava (Slika 2). Korisnik pritom mora u vrlo kratkom vremenu moći odgovoriti ne samo na pitanje što se događa, nego i na pitanje koliko je prikazano stanje pouzdano. Takva organizacija nije važna samo za svakodnevni rad sustava, nego i za njegovu buduću AI nadogradnju. Umjetna inteligencija može imati stvarnu operativnu vrijednost samo ako se oslanja na podatke čija je pouzdanost poznata i ako sustav može razlikovati stvarnu anomaliju u ponašanju promatranog procesa od anomalije u samom podatkovnom toku [11, 12].

Kroz projekt CRISAFE pokazano je da višehazardni sustav ranog upozoravanja može biti uspostavljen kao operativno upotrebljiv i tehnički pouzdan okvir koji povezuje kvantificirane scenarije, monitoring, logiku upozorenja i podatkovnu pouzdanost u gotovo stvarnom vremenu. Međutim, CRISAFE je pritom ostao pretežno usmjeren na IoT monitoring i na pravila upozorenja utemeljena na unaprijed definiranim indikatorima i pragovima. U sljedećem poglavlju se razmatra kako se ta potvrđena osnova može proširiti prema višesenzorskoj fuziji podataka, AI-potpomožutoj detekciji anomalija i hibridnoj potpori odlučivanju [12].



Slika 2: Web sučelje za praćenje oborina, koje prikazuje inkrementalnu i kumulativnu količinu oborina na primjeru retencije Jazbina

4. Primjena umjetne inteligencije u projektu AI-Warn

4.1. Potreba za AI nadogradnjom višehazardnih sustava ranog upozoravanja

Sustav CHEWS, razvijen u CRISAFE projektu, ostaje pretežno oslonjen na unaprijed definirane indikatore, pragove i pravila odlučivanja, pri čemu je glavna podatkovna osnova vezana uz IoT monitoring. To je posebno učinkovito u jasno definiranom lokalnom okviru, ali ograničenja sustava postaju izraženija kada se želi obuhvatiti veći broj heterogenih izvora podataka, različite prostorne i vremenske skale hazarda te složenije obrasce razvoja opasnih pojava.

Potreba za takvom nadogradnjom posebno dolazi do izražaja u radu s klimatski uvjetovanim opasnostima različitog karaktera, kao što su ekstremne oborinske nestabilnosti, te s njima povezani odroni i klizišta u strmom i geomorfološki složenom prostoru, odnosno urbane poplave u gusto izgrađenom nizinskom okruženju. Takvi slučajevi zahtijevaju sustav koji može objediniti informacije različitog podrijetla, prostorne pokrivenosti i vremenske razlučivosti te ih prevesti u operativno relevantne pokazatelje za službe civilne zaštite i upravitelje infrastrukture.

Dodatni razlog za AI nadogradnju proizlazi iz same prirode podataka koji se u takvim sustavima koriste. Povezivanje satelitskih opažanja Zemlje, UAV snimanja, ugrađenih IoT senzorskih mreža i postojećih baza podataka otvara mogućnost znatno bogatijeg uvida u razvoj opasnih stanja, ali istodobno postavlja zahtjev za prostornim i vremenskim usklađivanjem, čišćenjem, harmonizacijom i zajedničkom interpretacijom podataka. Ta potreba za radom nad velikim brojem heterogenih i međusobno zavisnih podataka čini umjetnu inteligenciju prirodnim sljedećim korakom u razvoju sustava.

Važan razlog za primjenu umjetne inteligencije jest i činjenica da su višehazardni sustavi ranog upozoravanja često podatkovno bogati, ali stvarnim događajima siromašni. Drugim riječima, na raspolaganju je velik broj mjerenja i snimaka, ali je stvarnih opasnih događaja relativno malo, a njihovo označavanje često je nepotpuno ili neujednačeno. U takvim uvjetima klasični pristupi koji se oslanjaju na velike skupove unaprijed označenih primjera imaju ograničenu primjenjivost.

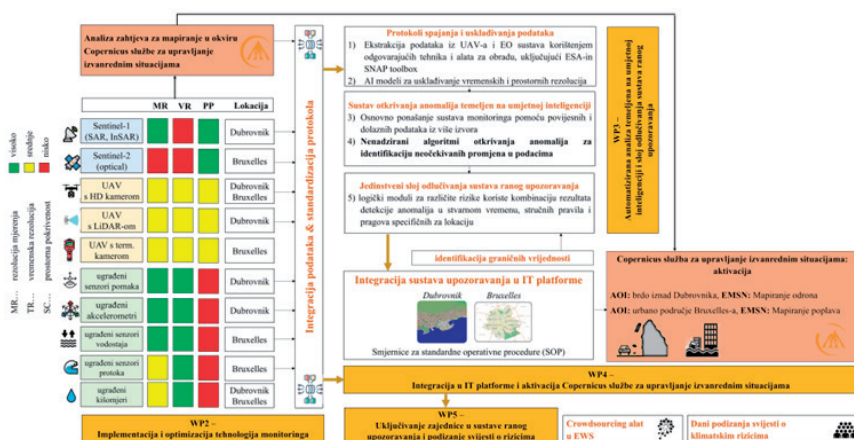
Istodobno, umjetna inteligencija u ovom se radu ne promatra kao zamjena za ekspertna pravila i inženjersko znanje, nego kao njihova nadogradnja. Cilj takvog pristupa nije zamijeniti postojeću logiku sustava ranog upozoravanja, nego povećati njegovu osjetljivost na rane signale, poboljšati povezivanje višeizvornih podataka i ojačati potporu odlučivanju u složenim višehazardnim situacijama.

4.2. Višesenzorska fuzija podataka kao osnova za AI analitiku

Jedna od temeljnih novosti AI nadogradnje u odnosu na CRISAFE jest prijelaz s pretežno IoT usmjerenog sustava na višesenzorsku fuziju podataka. Dok je u CRISAFE-u naglasak bio na povezivanju terenskog monitoringa, pravila upozorenja i procjene pouzdanosti podataka unutar jedinstvene operativne arhitekture, ovdje se taj okvir proširuje uključivanjem satelitskih opažanja Zemlje, UAV snimanja, gusto raspoređenih IoT mreža geotehničkih i hidroloških senzora te postojećih informacijskih sustava relevantnih za upravljanje rizicima.

Takav pristup posebno je važan zato što različiti tipovi opasnosti i različiti prostorni konteksti zahtijevaju i različite tipove podataka. IoT senzori omogućuju kontinuirano lokalno praćenje stanja tla, konstrukcije i hidroloških uvjeta, ali njihova je prostorna pokrivenost ograničena na mjesta ugradnje. Satelitska opažanja Zemlje daju širi prostorni pregled i omogućuju praćenje promjena na razini padina, koridora infrastrukture i urbanih područja, ali s drukčijom vremenskom razlučivošću i drukčijim ograničenjima interpretacije. UAV snimanja pružaju vrlo detaljan lokalni prikaz i mogu popuniti jaz između kontinuiranog terenskog monitoringa i šireg satelitskog promatranja. Zato se pouzdaniji uvid u razvoj opasnih stanja može dobiti tek kada se ti izvori promatraju zajedno, a ne odvojeno.

Višesenzorska fuzija pritom ne znači samo tehničko objedinjavanje različitih nizova podataka u istu bazu. Ona podrazumijeva prostorno i vremensko usklađivanje podataka, njihovu harmonizaciju, čišćenje, provjeru kvalitete i prevođenje u zajednički analitički oblik prikladan za daljnju obradu. Bez takvog koraka umjetna inteligencija ne bi radila na stvarno usporedivim i logično povezanim ulazima, nego na međusobno nepovezanim skupovima podataka ograničene operativne vrijednosti. U tom kontekstu višesenzorska fuzija predstavlja preduvjet, a ne dodatak AI analitici (Slika 3).



Slika 3: Metodološki okvir projekta AI-Warn s višesenzorskom fuzijom podataka, AI analizom i povezivanjem prema sustavu ranog upozoravanja i potpori odlučivanju

4.3. AI-potpomognuta detekcija anomalija i hibridna logika odlučivanja

Nakon uspostave višesenzorske podatkovne osnove sljedeći ključni korak jest razvoj AI-potpomognute detekcije anomalija i njezino povezivanje s logikom odlučivanja u sustavu ranog upozoravanja. Pritom je važno naglasiti da se umjetna inteligencija ne uvodi radi zamjene postojećih pravila upozorenja, nego radi njihove nadogradnje u uvjetima u kojima broj izvora podataka, njihova heterogenost i složenost promatranih procesa nadilaze mogućnosti klasičnog pristupa utemeljenog samo na unaprijed definiranim pragovima.

Posebna vrijednost takvog pristupa jest u tome što je usmjeren na nenadziranu detekciju anomalija. To znači da sustav ne ovisi o velikim skupovima unaprijed označenih opasnih događaja, nego najprije uči uobičajeno ponašanje promatranog sustava na temelju povijesnih i pristiglih podataka, a zatim prepoznaje odstupanja od naučenog obrasca. To je pogodno za višehazardne sustave ranog upozoravanja, jer su stvarni opasni događaji relativno rijetki, a njihova potpuna i pouzdana klasifikacija često nije raspoloživa.

Na taj način umjetna inteligencija ne traži samo prelazak pojedinačnog praga, nego prepoznaje da se sustav ponaša drukčije od očekivanog, što može biti važan rani signal razvoja opasnog stanja. U tome leži njezina glavna operativna vrijednost: uočavanje promjena koje još ne moraju biti vidljive kroz klasična pravila upozorenja, ali mogu upućivati na potrebu pojačanog nadzora ili dodatne provjere.

Međutim, na taj način se ne ostaje na razini izdvojenog AI rezultata, nego podrazumijeva hibridnu logiku odlučivanja u kojoj se AI uvidi kombiniraju s ekspertnim pravilima i lokacijski specifičnim pragovima. Podatkovno vođena analitika se povezuje s fizičkim značenjem opasnosti, ranjivosti infrastrukture i postojećim operativnim pravilima sustava ranog upozoravanja.

4.4. Potpora odlučivanju službama civilne zaštite i upraviteljima infrastrukture

Konačna vrijednost primjene umjetne inteligencije ne očituje se samo u naprednijoj obradi podataka, nego prije svega u kvalitetnijoj potpori odlučivanju službama civilne zaštite i upraviteljima infrastrukture. U sustavima ranog upozoravanja takvi korisnici ne trebaju samo dodatne podatke ili složenije grafove, nego pouzdane i pravodobne informacije koje omogućuju procjenu situacije, određivanje razine pripravnosti i odabir odgovarajućih operativnih postupaka.

Ključna prednost takvog pristupa jest u tome što objedinjeni sustav može povezati višeizvorne podatke, rezultate detekcije anomalija, ekspertna pravila i lokacijski spe-

cifične pragove upozorenja u jedinstvenu operativnu sliku stanja. Ovakvim pristupom korisnicima se ne prenose samo pojedinačni signali ili nepovezani pokazatelji, nego interpretirani rezultati koji upućuju na to razvija li se opasna situacija, koliko je pouzdana takva procjena i zahtijeva li ona pojačani nadzor, dodatnu provjeru ili aktiviranje unaprijed definiranih postupaka.

Za službe civilne zaštite važna je sposobnost sustava da na vrijeme prepozna razvoj situacije i pruži podlogu za procjenu mogućih posljedica i prioriteta djelovanja. Za upravitelje infrastrukture važna je i dodatna razina informacija koja se odnosi na stanje promatranog sustava, potrebu pojačanog nadzora, eventualne znakove degradacije i mogućnost pravodobnog preventivnog djelovanja.

5. Konceptija prijelaza od CHEWS-a sustava do AI-Warn-a

Prijelaz od CHEWS-a sustava do AI-Warn-a može se najjasnije sagledati kroz usporedbu komponenti koje se zadržavaju i onih koje se nadograđuju. AI-Warn ne predstavlja prekid s prethodno razvijenim sustavom, nego njegov metodološki i operativni nastavak prema složenijem višeizvornom i AI-potpomognutom okviru.

5.1. Komponente preuzete iz CHEWS-a

Projekt AI-Warn iz CHEWS-a preuzima logiku povezivanja monitoringa, upozorenja i potpore odlučivanju unutar jedinstvenog digitalnog okvira, kao i na standardizirani tok podataka od senzorskog čvora do baze podataka i operativnog prikaza. Kroz CHEWS je već uspostavljen okvir u kojem monitoring ne služi samo prikazu mjerenja, nego i operativnoj interpretaciji stanja sustava [12].

Iz CHEWS-a se preuzimaju stabilizirana logika upozorenja, povezivanje fizičkih i tehničkih upozorenja te pristup u kojem se podaci uvijek tumače zajedno s procjenom njihove pouzdanosti. Jednako je važna i činjenica da je CRISAFE već uspostavio vezu između scenarija opasnosti, procjene ranjivosti, procjene rizika i operativne logike upozoravanja. Razvijen je okvir u kojem se podaci iz monitoringa ne promatraju izolirano, nego u vezi s prethodno definiranim mehanizmima opterećenja, otkaza i posljedica [9-12].

5.2. Komponente nadograđene u AI-Warn-u

Na tako uspostavljenoj osnovi AI-Warn uvodi tri ključne nadogradnje: višesenzorsku fuziju podataka, AI-potpomognutu detekciju anomalija i objedinjeni sloj potpore od-

lučivanju. U odnosu na CRISAFE, koji je bio pretežno usmjeren na IoT monitoring, pravila upozorenja i operativnu logiku sustava, ovdje se podatkovna osnova proširuje na satelitska opažanja Zemlje, UAV snimanja i druge izvore te se uvodi dodatni analitički sloj za rano prepoznavanje odstupanja.

Pritom se postojeća pravila ne zamjenjuju, nego nadograđuju hibridnim pristupom koji povezuje AI rezultate s ekspertnim pravilima i lokacijski specifičnim pravilima. Ovako se ne mijenja temeljna logika ranog upozoravanja uspostavljena u CRISAFE-u, nego se proširuju podatkovni i analitički kapaciteti sustava. Zadržavaju se potreba za preglednim operativnim prikazom, jasnim pravilima aktivacije upozorenja i stalnim praćenjem pouzdanosti podataka, ali se otvara mogućnost ranijeg prepoznavanja neuobičajenih pojava i boljeg povezivanja višeizvornih informacija.

5.3. Studije slučaja u Dubrovniku i Bruxellesu i operativna primjenjivost

Praktična vrijednost takve nadogradnje posebno dolazi do izražaja u pilot-primjenama u Dubrovniku i Bruxellesu. Te dvije lokacije predstavljaju dva različita klimatski uvjetovana hazardna i operativna konteksta: Dubrovnik, kao strm i geomorfološki složen prostor izložen padinskim nestabilnostima, odronima i klizištima, često potaknutim ekstremnim oborinama, te Bruxelles, kao gusto izgrađeno nizinsko urbano područje osjetljivo na intenzivne oborine i urbane poplave. Izbor tih pilot područja pokazuje da cilj AI nadogradnje nije razvoj sustava za jednu vrstu opasnosti, nego razvoj okvira koji se može prilagoditi različitim uvjetima (Slika 4).



Slika 4: Pilot područja projekta AI-Warn u Dubrovniku i Bruxellesu kao reprezentativni primjeri različitih višehazardnih i operativnih konteksta

U oba slučaja naglasak je na povezivanju monitoringa, procjene ranjivosti, lokacijski specifičnih pragova i sustava potpore odlučivanju u oblik koji je primjenjiv službama civilne zaštite i upraviteljima infrastrukture. Operativna primjenjivost dodatno se pojačava time što se rezultati nastoje uključiti u postojeće informacijske platforme korisnika, umjesto razvoja izdvojenog sustava koji bi djelovao izvan njihovih radnih okruženja. To je značajno zato što povećava vjerojatnost stvarne uporabe sustava u svakodnevnim postupcima praćenja, procjene i reagiranja.

Pilot-primjene u Dubrovniku i Bruxellesu tako pokazuju da prijelaz od CHEWS-a do AI-Warn-a prije svega znači prijelaz od potvrđenog operativnog IoT sustava prema višesenzorskom i AI-potpomognutom okviru prilagođenom različitim hazardnim i operativnim kontekstima. U tome se ujedno vidi i glavna logika ovog rada: umjetna inteligencija ne uvodi se kao izdvojena tehnološka novost, nego kao sljedeći razvojni korak na već potvrđenoj osnovi monitoringa, upozoravanja i potpore odlučivanju.

6. Rasprava

Primjena umjetne inteligencije u višehazardnim sustavima ranog upozoravanja ima svoje opravdanje samo ako se razvija na već strukturiranoj osnovi scenarija opasnosti, procjene ranjivosti, procjene rizika, monitoringa i operativne logike upozoravanja. AI-Warn je važan jer pokušava povezati višeizvorne podatke, rano prepoznavanje odstupanja i potporu odlučivanju bez napuštanja postojećih operativnih pravila.

Glavna mogućnost koja se ovim pristupom otvara jest sposobnost obrade većeg broja heterogenih i međusobno povezanih podataka nego što je to moguće u sustavu koji se oslanja isključivo na fiksne pragove i unaprijed definirana pravila. To je osobito važno u slučajevima kao što su Dubrovnik i Bruxelles, gdje se ne promatra samo jedan dominantan indikator, nego složen skup signala različite prostorne i vremenske razlučivosti. U takvim uvjetima umjetna inteligencija može imati stvarnu vrijednost u ranom prepoznavanju odstupanja, povezivanju više signala u logičnu operativnu sliku te smanjenju opterećenja korisnika količinom podataka koju bi inače morali tumačiti ručno.

Istodobno, postoje i jasna ograničenja. U višehazardnim sustavima ranog upozoravanja najčešće ne postoje veliki i reprezentativni skupovi označenih opasnih događaja na kojima bi se mogli graditi klasični nadzirani modeli. Dodatno, podaci dolaze iz izvora različite kvalitete, različite učestalosti i različite razine interpretabilnosti. Zbog toga je razumno što se ne polazi od ambicije potpune automatizacije odlučivanja, nego od pristupa u kojem umjetna inteligencija služi kao dodatni analitički sloj, a ne kao jedini izvor zaključivanja. Takvo postavljanje umjetne inteligencije kao alata za pojačavanje osjetljivosti sustava, a ne za zamjenu cjelokupne logike upozoravanja, čini se posebno prikladnim za sustave civilne zaštite i upravljanja infrastrukturom. U

tim je sustavima važna ne samo sposobnost ranog otkrivanja odstupanja, nego i transparentnost procjene, mogućnost njezina objašnjenja i povjerenje korisnika u način na koji je upozorenje generirano.

Ključno pitanje nije može li umjetna inteligencija prepoznati anomaliju, nego kako takav rezultat pretvoriti u inženjerski i operativno smislen zaključak. Zbog toga stručno znanje u višehazardnim sustavima ranog upozoravanja ne može biti zamijenjeno, nego mora ostati temelj na koji se AI nadograđuje. U prethodnim poglavljima pokazano je da su scenariji opasnosti, procjena ranjivosti i procjena kaskadnog višehazardnog rizika u CRISAFE-u izgrađeni na geotehničkom, hidrotehničkom i probabilističkom razumijevanju procesa. Bayes-ove mreže dodatno pokazuju da se rizik može modelirati na način koji uključuje i kvantitativne podatke i ekspertno znanje te omogućuje ažuriranje procjena kada se uvedu nova opažanja. To je blisko logici hibridnog pristupa u kojem se podatkovno vođena analitika koristi za rano prepoznavanje odstupanja, ali se rezultati tumače zajedno s ekspertno definiranim pravilima, pragovima i fizičkim razumijevanjem ponašanja infrastrukture i opasnosti.

Hibridni pristup ima dvije važne prednosti. Prvo, povećava robusnost sustava jer smanjuje ovisnost o jednoj vrsti ulaznih podataka ili o jednom analitičkom mehanizmu. Drugo, povećava prihvatljivost sustava za krajnje korisnike, jer se upozorenja i preporuke mogu povezati s poznatim indikatorima, razumljivim pragovima i postojećim operativnim postupcima. To je osobito važno u kontekstu civilne zaštite i upravljanja infrastrukturom, gdje korisnici moraju moći razumjeti zašto je određena razina upozorenja aktivirana i na čemu se takva procjena temelji.

Iz dosadašnje analize proizlazi nekoliko jasnih smjernica za daljnji razvoj. Prvo, validacija AI nadogradnje ne bi smjela biti ograničena samo na točnost AI modula, nego mora obuhvatiti cjelokupni lanac od ulaznih podataka do operativne odluke. To uključuje kvalitetu i pouzdanost podataka, stabilnost višesenzorske fuzije, interpretabilnost anomalijских pokazatelja, dosljednost hibridne logike upozorenja i stvarnu upotrebljivost rezultata u radnim okruženjima službi civilne zaštite i upravitelja infrastrukture.

Drugo, trebalo bi posebno provjeravati kako se sustav ponaša u degradiranim uvjetima, kada su pojedini izvori podataka privremeno nedostupni, jer se u takvim situacijama često testira stvarna operativna vrijednost sustava. Treće, važan dio validacije mora biti i integracija u postojeće platforme korisnika, budući da se stvarna vrijednost sustava ne potvrđuje samo kroz analitičku točnost, nego i kroz njegovu sposobnost da postane dio svakodnevnih operativnih postupaka.

U konačnici, daljnji razvoj treba biti usmjeren na provjeru koliko sustav može pouzdano povezati višeizvorne podatke, rano prepoznati relevantna odstupanja i takve rezultate pretvoriti u operativno upotrebljivu potporu odlučivanju. Tek će cjelovita validacija pokazati stvarnu vrijednost umjetne inteligencije u višehazardnim sustavima ranog upozoravanja.

7. Zaključak

Razvojna linija od projekata oVERFLOW i CROSScade preko CRISAFE-a do AI-Warn-a pokazuje da se primjena umjetne inteligencije u višehazardnim sustavima ranog upozoravanja ne može promatrati izdvojeno od prethodno razvijenih metodoloških i operativnih osnova. U tom je slijedu oVERFLOW uspostavio važan okvir za procjenu ranjivosti infrastrukture, CROSScade proširio pristup prema kaskadnom višehazardnom riziku i operativnoj suradnji, a CRISAFE povezo scenarije opasnosti, procjenu ranjivosti, procjenu rizika i sustav ranog upozoravanja (CHEWS) u jedinstven sustav usmjeren prema upozoravanju i potpori odlučivanju.

CRISAFE je u ovom radu potvrđen kao ključni most prema AI nadogradnji. Razvoj CHEWS-a pokazao je da je moguće uspostaviti operativno upotrebljiv IoT sustav monitoringa i upozoravanja u gotovo stvarnom vremenu, s jasno definiranom logikom upozorenja, kombiniranim pravilima, praćenjem pouzdanosti sustava i kontrolom kvalitete podataka. Time je stvorena potvrđena digitalna i operativna osnova na koju se može nadograditi složeniji višeizvorni sustav ranog upozoravanja.

Na toj osnovi AI-Warn predstavlja sljedeći razvojni korak kroz višesenzorsku fuziju satelitskih opažanja Zemlje, UAV snimanja, IoT mreža i drugih raspoloživih izvora podataka, uz AI-potpomognutu detekciju anomalija i hibridnu logiku odlučivanja. Glavna vrijednost takvog pristupa nije u zamjeni postojećih inženjerskih i ekspertnih pravila, nego u njihovoj nadogradnji dodatnim slojem analitike koji omogućuje ranije prepoznavanje neuobičajenih pojava, bolje povezivanje heterogenih izvora podataka i pouzdaniju potporu odlučivanju službama civilne zaštite i upraviteljima infrastrukture.

Zaključno, najveća vrijednost AI-Warn-a jest u tome što primjenu umjetne inteligencije razvija na već potvrđenoj osnovi scenarija opasnosti, procjene ranjivosti, procjene rizika, monitoringa i operativne logike upozoravanja. Umjetna inteligencija u višehazardnim sustavima ranog upozoravanja pokazuje se ne kao samostalna tehnološka inovacija, nego kao logično utemeljen i operativno usmjeren sljedeći korak prema jačanju klimatske otpornosti europskih regija.

Zahvala

Ovo je istraživanje financirano od strane Mehanizma civilne zaštite Europske unije, u okviru poziva UCPM-2025-KAPP-PVPP, Grant Agreement 101254083, AI-Warn projekt (Holistic AI-driven Early Warning System for Climate-Induced Hazards in Critical Infrastructure and Civil Protection).

8. Literatura

- [1] Basher, R.: Global early warning systems for natural hazards: systematic and people-centred, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **364** (2006) 1845, 2167-2182, <https://doi.org/10.1098/rsta.2006.1819>
- [2] WMO: *Multi-hazard Early Warning Systems: A Checklist*, World Meteorological Organization, Geneva, 2018.
- [3] UNISDR: *Developing Early Warning Systems: A Checklist*, Third International Conference on Early Warning (EWC III), Bonn, 2006.
- [4] Kappes, M. S.; Keiler, M., von Elverfeldt, K., Glade, T.: Challenges of analyzing multi-hazard risk: a review, *Natural Hazards*, **64** (2012) 2, 1925-1958, <https://doi.org/10.1007/s11069-012-0294-2>.
- [5] Pescaroli, G.; Alexander, D.: Critical infrastructure, panarchies and the vulnerability paths of cascading disasters, *Natural Hazards*, **82** (2016) 1, 175-192, <https://doi.org/10.1007/s11069-016-2186-3>
- [6] Rinaldi, S. M.; Peerenboom, J. P., Kelly, T. K.: Identifying, understanding, and analyzing critical infrastructure interdependencies, *IEEE Control Systems Magazine*, **21** (2001) 6, 11-25, <https://doi.org/10.1109/37.969131>.
- [7] Bačić, M.; Kovačević, M. S., Jurić Kačunić, D., Librić, L., Car, M., Gavin, K., Stipanović, I., Reale, C.: Classification of a flood protection infrastructure based on its vulnerability to various loads: example of the oVERFLOW project, u: *Proceedings of the 7th International Conference on Road and Rail Infrastructure*, Pula, 11-13 May 2022, str. 611-618, <https://doi.org/10.5592/CO/cetra.2022.1471>.
- [8] Skarić Palić, S.; Stipanović, I., Ganić, E.: *CROSScade Deliverable 4.1: Risk assessment methodology for cross-border cascading hazard scenarios*, 2023.
- [9] Rossi, N.; Bačić, M., Gavin, K., Kovačević, M. S.: *CRISAFE Deliverable 2.1: Current and future cascading multi-hazard scenarios*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [10] Gavin, K.; Reale, C., Rossi, N., Bačić, M., Kovačević, M. S.: *CRISAFE Deliverable 2.2: Vulnerability Assessment of the Critical Infrastructure Subjected to Multi-Hazards*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [11] Pekćec, M.; Stipanović, I.: *CRISAFE Deliverable 3.1: Cascading multi-hazard risk assessment methodology*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [12] Kovačević, M. S.; Bačić, M.: *CRISAFE Deliverable 4.2: Report on the sensors and monitoring of the CHEWS alerts*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.