

D1.2.2

OPTIMIZIRANA DODELITEV VIROV: SMERNICE IN PRIPOROČILA POLITIK ZA UPORABO NAPOVEDNIH MODELOV

KARST FIREWALL 5.0

Verzija 1.0

Avtor - Infordata Sistemi Srl
Notranja recenzija: ZRC SAZU, IUAV

Inovativno ekosistemsko-zasnovano prilagajanje podnebnim spremembam na Krasu. Spodbujanje požarno odporne
gmajne s podporo industrije 5.0

DELIVERABLE INFORMAZIONI / INFORMACIJE

Acronimo del progetto / Akronim projekta:	KARST FIREWALL 5.0
Titolo del progetto / Naslov projekta:	Adattamento innovativo al cambiamento climatico basato sugli ecosistemi nella regione del Carso. Promuovere una silvicoltura resistente agli incendi con il supporto di Industria 5.0 Inovativno ekosistemsko-zasnovano prilagajanje podnebnim spremembam na Krasu. Spodbujanje požarno odporne gmajne s podporo industrije 5.0
Area prioritaria / Prednostno področje:	Un'Europa più verde e a basse emissioni di carbonio, che si muove verso un'economia a zero emissioni di carbonio e resiliente Bolj zelena, nizkoogljična Evropa, ki prehaja na gospodarstvo z ničelno stopnjo neto emisij ogljika in je odporna
Obiettivo specifico del programma / Specifični cilj programa:	SO4: Promuovere l'adattamento ai cambiamenti climatici e la prevenzione del rischio di catastrofi e la resilienza, tenendo conto degli approcci ecosistemici. SO4: Spodbujanje prilagajanja podnebnim spremembam in preprečevanja tveganja nesreč ter odpornosti ob upoštevanju ekosistemskih pristopov
URL del sito web del progetto / URL spletne strani projekta:	www.ita-slo.eu/karst-firewall-50
Numero del documento / Številka dokumenta:	KFW50-D122
Titolo del documento / Naslov dokumenta:	OPTIMIZIRANA DODELITEV VIROV: SMERNICE IN PRIPOROČILA POLITIK ZA UPORABO NAPOVEDNIH MODELOV
Work Package:	1
Attività / Aktivnost:	2.2
Partner responsabili (autori) / Odgovorni partnerji (avtorji):	Infodata Sistemi (Elazem, Abdelhamid; Petelin, Marko; Zidaric, Samuel; Zuccato, Nicola)
Partner coinvolti / Sodelujoči partnerji:	ZRC-SAZU (Čonč, Špela; Breg Valjavec, Mateja; Ciglič, Rok)
Luogo e data di pubblicazione / Kraj in datum objave:	Trst, 15/10/2025

KRATICE	4
1 POVZETEK	5
2 CILJ IN OZADJE	6
2.1 Cilj	6
2.2 Ozadje	6
3 SMERNICE IN PRIPOROČILA ZA OPTIMIZACIJO VIROV Z UPORABO	8
NAPOVEDNIH MODELOV	
3.1 Kronološki razvoj orodij za napovedovanje gozdnih požarov	8
3.2 Smernice za dodelitev virov na podlagi napovednih modelov	12
3.2.1 Dodelitev virov za preprečevanje	13
3.2.2 Dodelitev virov za odziv	14
3.2.3 Implementacija podpore pri odločanju	15
3.2.4 Čezmejno deljenje virov	16
3.3 Priporočila politik za preprečevanje in upravljanje gozdnih požarov	16
3.3.1 Priporočila za tehnično implementacijo	17
3.3.2 Strategije organizacijske uporabe	19
3.3.3 Priporočila politik in upravljanja	20
3.3.4 Etični in operativni vidiki	20
3.4 Okvir čezmejnega sodelovanja	21
3.4.1 Enotno deljenje informacij	21
3.4.2 Usklajeni odzivni mehanizmi	21
3.4.3 Harmonizacija politik	22
4 VIRI	24

ABBREVIAZIONI

AI	Artificial Intelligence
AHP	Analytic Hierarchy Process
ARPA FVG	Regionalna agencija za varstvo okolja Furlanije-Juljske krajine
ARSO	Agencija Republike Slovenije za okolje (Slovenian Environment Agency)
CFFDRS	Canadian Forest Fire Danger Rating System
DMC	Duff Moisture Code
EU	European Union
FFMC	Fine Fuel Moisture Code
FBP	Fire Behaviour Prediction
FWI	Fire Weather Index
GIS	Geographic Information System
MCDA	Multi-Criteria Decision Analysis
ML	Machine Learning
TPI	Topographic Position Index
TWI	Topographic Wetness Index
XGBOOST	eXtreme Gradient Boosting
ZGS	Zavod za gozdove Slovenije (Slovenian Forest Service)
BUI	Build Up Index
DC	Drought Code
ISI	Initial Spread Index

1 POVZETEK

To poročilo zagotavlja napredne smernice in priporočila politik za optimizirano dodelitev virov pri preprečevanju in upravljanju gozdnih požarov v čezmejni regiji slovensko-italijanskega Krasa. Na podlagi rezultatov naprednih napovednih modelov, razvitih v okviru projekta Karst Firewall 5.0 (D1.2.1) in ocen nevarnosti in ranljivosti zaradi požarov v naravi (D1.1.2), dokument poudarja transformativno vlogo tehnologije (s poudarkom na umetni inteligenci; AI) pri izboljšanju pripravljenosti, odzivanju in učinkovitosti virov. Medtem ko trenutna orodja, kot so droni, sateliti, infrardeče kamere in mreže IoT senzorjev, že igrajo kritično vlogo pri nadzoru požarov v realnem času, so nedavni napredki v kognitivni AI, strojnem učenju in globokem učenju omogočili novo dobo napovednega upravljanja gozdnih požarov.

Te smernice zagotavljajo gozdarskim oddelkom in reševalcem enotni okvir za:

- Dodelitev virov na podlagi podatkov z uporabo dinamičnih napovedi tveganja.
- Protokole čezmejnega sodelovanja in priporočila politik.
- Odločitvene delovne tokove, integrirane z AI.

Rešitve, ki jih poganja AI (vključno z eXtreme Gradient Boosting (XGBoost), arhitekturami globokega učenja in bayesovsko analizo) so pokazale pomembne izboljšave pri napovedovanju obnašanja požarov z integracijo dinamičnih vremenskih podatkov, zgodovinskih zapisov o požarih in značilnostih območja, kot sta geomorfologija in vegetacijska pokritost. Ti modeli, podprti z orodji kot je kanadski Prometheus simulator rasti požarov, ponujajo napovedi v realnem času in podrobne napovedi nevarnosti vžiga in širjenja požara, kar omogoča odločevalcem, da razporedijo vire na podlagi prioritete, vodenih s podatki.

Dokument opisuje praktične pragove za integracijo AI modelov (npr. >70% verjetnosti vžiga sproži stopnjevanje nadzora) in uvaja harmoniziran čezmejni upravljavski okvir s poudarkom na standardiziranih ravneh opozoril, deljenju podatkov, skladnem z GDPR, in integriranih vajah. Ključna priporočila politik zagovarjajo institucionalno sprejetje sistemov za podporo odločanju, ki temeljijo na AI, razvoj interoperabilnih infrastruktur za čezmejno sodelovanje in vzpostavitev regulativnih okvirov, ki zagotavljajo transparentnost, človeški nadzor in etično uporabo napovednih tehnologij.

Namenjen javnim organom, gasilskim enotam in načrtovalcem za izredne razmere ta rezultat deluje kot strateški vodnik za posodobitev upravljanja gozdnih požarov preko napovedne dodelitve virov, s čimer povečuje odpornost kraške pokrajine v kontekstu spreminjajočega se podnebja.

2 CILJ IN OZADJE

2.1 CILJ

Primarni cilj tega dokumenta je zagotoviti celovite smernice in priporočila politik za optimizirano dodelitev virov pri preprečevanju in upravljanju gozdnih požarov za gozdarske oddelke, gasilske službe in reševalce na čezmejnem slovensko-italijanskem območju na Krasu. Specifično ta rezultat cilja na:

- Vzpostavitev praktičnih smernic za integracijo napovednih modelov v odločitve o dodelitvi virov.
- Opredelitev priporočil za sprejetje AI v politikah preprečevanja in upravljanja gozdnih požarov.
- Predstavitev okvira za čezmejno sodelovanje pri deljenju virov in skupnem odzivu.
- Dokumentiranje evolucije orodij za napovedovanje gozdnih požarov in njihovih posameznih prispevkov.

2.2 OZADJE

Planota Kras, ki se razteza na približno 1.000 km² (30% v Italiji, 70% v Sloveniji), predstavlja edinstveno ekološko in administrativno pokrajino, ki jo zaznamuje apnenčasta površina, raznoliki vegetacijski vzorci in mešanica sredozemskega in kontinentalnega podnebja. Ta čezmejna regija se spopada z naraščajočimi tveganji gozdnih požarov zaradi več dejavnikov:

- Vplivi podnebnih sprememb: Analiza zgodovinskih podatkov razkriva povišanje povprečne temperature za 1,4°C med letoma 1993 in 2023, kjer se italijanske postajese segrevajo s +0,0606°C/leto, in slovenske s +0,0591°C/leto (ARPA FVG, 2023; ARSO, 2023). Ta trend segrevanja spremlja povišano sončno sevanje (+0,6320 W/m²/leto v Italiji in +0,4873 W/m²/leto v Sloveniji), kar prispeva k povečani dovzetnosti za gozdne požare.
- Spremembe v rabi zemljišč: Opuščanje tradicionalnih suhih pašnikov in pogozdovanje iz 19. stoletja, zlasti s črnim borom, so ustvarile pokrajine, bogate z gorivom, ki so nagnjene k širjenju ognja (Projekt Karst Firewall 5.0, Rezultat 1.1.2, 2024).
- Antropogeni dejavniki: Analiza zgodovinskih podatkov o gozdnih požarih kaže, da se je 67,4% požarov vnelo na razdalji 50 metrov od cest, kar izpostavlja človeško dejavnost kot pomemben vir vžiga (Projekt Karst Firewall 5.0, Rezultat 1.1.2, 2024). Porazdelitev vzrokov se razlikuje med državami, z večjo prevalenco podtikanja v Sloveniji (18,1%) v primerjavi z Italijo (4,5%).

Prejšnji rezultati v projektu Karst Firewall 5.0 so vzpostavili kritične temelje za to delo:

- Rezultat 1.1.2 je izvedel celovite analize nevarnosti in ranljivosti zaradi gozdnih požarov z uporabo modeliranja MaxEnt in večkriterijske odločitvene analize s postopkom analitične

hierarhije (MCDA/AHP). Rezultati so pokazali, da trenutno 16% območja (predvsem obalna območja in naselja) kaže pomembno ali izjemno visoke ravni nevarnosti. Ocena ranljivosti je klasificirala 93% regije z zelo visoko ranljivost (67% pomembno visoko, 25% izjemno visoko).

- Rezultat 1.2.1 je razvil napovedne AI algoritme za oceno tveganja gozdnih požarov z integracijo zgodovinskih podatkov o gozdnih požarih (1990-2024), meteoroloških zapisov in komponent meteorološkega indeksa požarne ogroženosti (FWI). Model eXtreme Gradient Boosting (XGBoost) je dosegel 90% natančnost pri napovedovanju dogodkov vžiga, kar pomeni, da je pravilno klasificiral dneve z ali brez požarov v 9 od 10 primerov med validacijo. Model je dosegel 81% priklic z uporabo tritedenskega zgodovinskega vremenskega okna, kjer je spremenljivke temperatura, hitrost vetra, vlažnost in sončno sevanje identificiral kot najpomembnejše pri napovedovanju (Projekt Karst Firewall 5.0, Rezultat 1.2.1, 2025).

Te analize zagotavljajo znanstveno podlago za smernice optimizacije virov, predstavljene v tem poročilu. Z upoštevanjem teh vpogledov, podprtih s podatki, lahko gozdarski oddelki in gasilske službe strateško dodelijo vire za preprečevanje in odziv, da maksimizirajo učinkovitost in izboljšajo regionalno odpornost proti grožnjam gozdnih požarov.

3 SMERNICE IN PRIPOROČILA ZA OPTIMIZACIJO VIROV Z UPORABO NAPOVEDNIH MODELOV

Tehnološka inovacija je že postala nepogrešljiva pri preprečevanju gozdnih požarov in odzivu na izredne razmere, z orodji kot so droni, infrardeče kamere, satelitske slike in mreže IoT senzorjev, ki omogočajo hitrejšo zaznavanje, izboljšano situacijsko ozaveščenost in učinkovitejšo razporeditev virov. Vendar pa je v zadnjih letih umetna inteligenca (AI)—in zlasti strojno učenje—postala transformativna sila, sposobna predefinirati tradicionalne prakse gašenja požarov. AI tehnologije zdaj ponujajo neprimerljive zmožnosti v napovedni analitiki, modeliranju obnašanja in podpori odločanjem, kar omogoča organom napovedovanje tveganja pred požari z naraščajočo prostorsko in časovno natančnostjo. Preko integracije zgodovinskih podatkov o požarih, meteoroloških zapisov in geolokacijskih vnosov—vključno s topografijo terena, vegetacijo in klimatskimi trendi—napredni modeli kot so XGBoost, globoke nevronske mreže in bayesovski sistemi sklepanja omogočajo tisto, kar imenujemo kognitivno upravljanje gozdnih požarov. Ti modeli ne izboljšajo le natančnost napovedi, ampak se tudi dinamično prilagajajo spreminjajočim se razmeram, saj ponujajo navodila v realnem času tako za preprečevanje kot za hiter odziv. To poglavje predstavlja kronološki pregled evolucije orodij za napovedovanje gozdnih požarov (Poglavje 4.1), ki mu sledijo praktične smernice (Poglavje 4.2) o tem, kako te napovedne zmožnosti lahko optimizirajo dodelitev virov—pred, med in po dogodkih gozdnih požarov. Razprava odraža prehod od statičnega kartiranja nevarnosti do dinamičnih, z AI okrepljenih odločitvenih okvirov, ki so bistvenega pomena za podnebno odporno in čezmejno upravljanje gozdnih požarov.

3.1 KRONOLOŠKI RAZVOJ ORODIJ ZA NAPOVEDOVANJE GOZDNIH POŽAROV

Razvoj orodij za napovedovanje gozdnih požarov se je skozi čas pomembno razvil, pri čemer vsak nov pristop gradi na prejšnjih metodologijah in jih izboljšuje. Razumevanje te evolucije zagotavlja dragocen kontekst za smernice, predstavljene v tem dokumentu:

Zgodnji opazovalni sistemi (pred letom 1970)

- Ročne table nevarnosti požarov: Sistemi pred računalniki, ki uporabljajo ročno zapisane vremenske podatke in opazovanja vlažnosti goriva za izračun lokalnega tveganja.
- McArthur merilniki nevarnosti gozdnih požarov (1960., Avstralija): Prenosne naprave z drsnim pravilom za oceno nevarnosti požara z uporabo temperature, vlažnosti, vetra in dejavnikov suše.

Prispevek: Postavili so temelje za standardizirane metrike nevarnosti požara, vendar jim je primanjkovalo skalabilnosti.

Tradizionalni sistemi ocenjevanja nevarnosti požarov (1970-1990)

- Kanadski meteorološki indeks požarne ogroženosti (FWI): Razvit v 1970., FWI zagotavlja numerične ocene relativnega požarnega potenciala na podlagi vremenskih opazovanj. Sistem uporablja temperaturo, relativno vlažnost, hitrost vetra in padavine za izračun več komponent (FFMC, DMC, DC, ISI, BUI, FWI), ki predstavljajo vsebnost vlage različnih plasti goriva in potencialno obnašanje ognja (Kanadska gozdarska služba, 2009).
- Ameriški nacionalni sistem ocenjevanja nevarnosti požarov (NFDRS, 1972): Uvedel je modele vlažnosti goriva in indeks gorenja (BI) za ZDA, dopolnjujoč FWI z regionalno specifičnostjo, ter pokazal potrebo po regionalno prilagojenih sistemih.

Prispevek: Vzpostavili so standardizirane metrike za oceno nevarnosti požara, ki ostajajo temeljne za sodobne sisteme. Vendar pa je tem zgodnjim sistemom primanjkovalo prostorske specifičnosti in poleg vremena niso upoštevali lokalnih okoljskih dejavnikov.

Prostorska analiza na podlagi GIS (1990-2000)

- Kartiranje verjetnosti požara: Kombinacija topografskih spremenljivk (naklon, ekspozicija) s klasifikacijami vegetacije za ustvarjanje prostorskih predstav požarnega tveganja.
- Model rasti požara FARSITE (1990., ZDA): Razširil je prostorsko modeliranje z integracijo Huygensovega načela širjenja ognja s podatki o pokrajini, ter omogočil je kompleksne simulacije vzorcev gorenja, vendar je zahteval visokoresolucijske vhodne podatke.

Prispevek: Uvedeli so prostorske dimenzije v oceno požarnega tveganja, omogočajoč dodelitev virov, specifičnih za območje. Ti pristopi so bili omejeni s statičnimi vnosi, ki se niso prilagajali spreminjajočim se razmeram.

Integracija daljinskega zaznavanja (2000-2010)

- Zaznavanje požarov na podlagi satelitov: Sistemi kot MODIS in pozneje sateliti Sentinel so omogočili zaznavanje in spremljanje požarov skoraj v realnem času.
- VIIRS (Visible Infrared Imaging Radiometer Suite): Visokoločljivostno (375m) zaznavanje požarov kot MODIS, operativno od 2011.
- EFFIS (Evropski informacijski sistem gozdnih požarov): Platforma na ravni EU, ki kombinira satelitske podatke, vremenske napovedi in karte ranljivosti (lansirana v 2000.), ki je zagotovil spremljanje tveganja na kontinentalni ravni, vendar mu je primanjkovalo napovedne podrobnosti.

Prispevek: Izboljšala je zmožnosti zgodnjega zaznavanja in zagotavljanje podatkov za analizo po požaru, vendar je ponujala omejene napovedne zmožnosti.

Deterministični modeli širjenja ognja (2000-2010)

- Model rasti požara Prometheus: Razvit v Kanadi in sprejet mednarodno, Prometheus simulira širjenje ognja na podlagi vremena, topografije in značilnosti goriva (Kanadska gozdarska služba, 2009).
- BehavePlus (ZDA, 2000.): Odprtokodni sistem, ki modelira obnašanje ognja (hitrost širjenja, dolžina plamena) pod različnimi pogoji.
- FIRETEC (ZDA, 2010.): Model, ki temelji na fiziki, simulira turbulence in interakcije ognja z atmosfero na majhnih lestvicah, ter napredoval je mehanistično razumevanje dinamike ognja, vendar je bil omejen na raziskovalne aplikacije.

Prispevek: Omogočili so simulacijo obnašanja ognja pod različnimi scenariji, podpirajoč taktično načrtovanje odziva. Omejeni so z računskimi zahtevami in poenostavitvami kompleksne dinamike ognja.

Statistični pristopi strojnega učenja (2010)

- Modeliranje MaxEnt: Kot je implementirano v Rezultatu 1.1.2, MaxEnt uporablja podatke samo o prisotnosti za napovedovanje prostorskih porazdelitev verjetnosti gozdnih požarov (Projekt Karst Firewall 5.0, Rezultat 1.1.2, 2024).
- Večkriterijska odločitvena analiza (MCDA): Integrirala je več dejavnikov preko tehtanih kombinacij za oceno ranljivosti.
- Logistična regresija in SVM: Zgodnje ML aplikacije za binarne napovedi požar/brez požara, ter pokazal je potencial ML, vendar se je soočil z neuravnoteženimi nabori podatkov o gozdnih požarih.


Prispevek: Izboljšali so prostorsko oceno tveganja s sistematično integracijo več spremenljivk in strokovnega znanja. Predvsem statičen po naravi, ki je zahteval ročne posodobitve z novimi podatki.

Dinamični AI/ML modeli (2020)

- Modeli Random Forest in Decision Tree: Zgodnje aplikacije strojnega učenja, ki so izboljšale natančnost napovedi z identificiranjem nelinearnih odnosov med spremenljivkami.
- Model XGBoost: Kot je implementiran v Rezultatu 1.2.1, ta napreden pristop ansambel učenja je dosegel 90% natančnost pri napovedovanju dogodkov vžiga (pravilno klasificiranje dni požar/brez požara v 9 od 10 primerov) z izkoriščanjem zgodovinskih vremenskih in požarnih podatkov (Projekt Karst Firewall 5.0, Rezultat 1.2.1, 2025).
- Globoko učenje (CNN/RNN): Uporabljeno za analizo satelitskih slik za napovedovanje širjenja ognja iz zgodovinskih vzorcev gorenja.
- Hibridni ansambel modeli: Kombinirali so ML s simulacijami, ki temeljijo na fiziki, ter izboljšali so natančnost pri napovedovanju redkih dogodkov, vendar so povišali računske stroške.

Prispevek: Pomembno so izboljšali natančnost napovedi in omogočili dinamično oceno tveganja na podlagi spreminjajočih se pogojev, vendar so zahtevali obsežne zgodovinske podatke za usposabljanje.

Slika 1 - Primerjava metrik natančnosti pri napovedovanju tveganja požarov (stolpični diagram).



Nastajajoča orodja (2020 - sedanjost)

- AI-podprto spremljanje družbenih omrežij: Orodja kot analiza Twitter (X) API za zgodnje zaznavanje požarov preko poročil iz množice.
- Digitalni dvojniki: virtualne replike pokrajin za testiranje scenarijev „kaj bi bilo, če“ v realnem času (npr. Siemens Xcelerator). Prispevek: zapolnil je vrzel med človeškim in tehnološkim zaznavanjem, vendar je sprožil zaskrbljenost glede zasebnosti.

Integrirani čezmejni sistemi (2025): Karst Firewall 5.0 (Italija-Slovenija, 2024)

Integracija: Kombinira napovedi XGBoost (Rezultat 1.2.1), zgodovinske podatke in spremljanje vremena v realnem času v enotni portal za podporo pri odločanju.

Inovacija: Prvi sistem, ki operacionalizira AI napovedi s čezmejnim koordiniranjem virov, obravnavajoč vrzeli v:

- Prostorska ločljivost: Specifičnost mreže 500m v primerjavi s tradicionalnimi 10km FWI conami.
- Časovna dinamika: Posodablja napovedi tveganja urno v primerjavi z dnevnimi

posodobitvami v prejšnjih sistemih.

- Politična uskladitev: Harmonizira italijanske in slovenske protokole odziva preko skupnih pragov.

Učinkovitost: Zmanjša lažno negativne rezultate za 22% v primerjavi s samostojnimi XGBoost modeli, kot je bilo potrjeno v pilotnih uvozih 2023-2024.

Prispevek: Predstavlja najsodobnejše orodje pri napovedovanju gozdnih požarov s sintezo 50 let tehnoloških napredkov (FWI metrike, ML in čezmejno deljenje podatkov) v enoten okvir. Neposredno obravnava edinstvene izzive kraške regije, vključno z:


- Kompleksnostjo čezmejnega upravljanja.
- Tveganjem vžiga v bližini cest (67,4% požarov).
- Podnebno pogojenim sušenjem goriva (+1,4°C od 1993).

Ta evolucija odraža napredovanje od generičnih, na vremenu temelječih pristopov do vse bolj sofisticiranih, podatkovno vodenih sistemov, ki integrirajo več virov podatkov in metodologij. Trenutni sistem Karst Firewall 5.0 predstavlja najsodobnejše v tej evoluciji, kombinirajoč moči prejšnjih pristopov, medtem ko obravnava njihove omejitve preko integracije in čezmejnega sodelovanja.

3.2 SMERNICE ZA DODELITEV VIROV NA PODLAGI NAPOVEDNIH MODELOV

Naslednje smernice so zasnovane za pomoč ekipam za upravljanje gozdnih požarov pri optimizaciji dodelitve virov z uporabo napovednih modelov in orodij, razvitih v projektu Karst Firewall 5.0:

Slika 2 - Metrike učinkovitosti optimizacije virov (2023) (%).




3.2.1 DODELITEV VIROV ZA PREPREČEVANJE

Prostorska prioritizacija na podlagi kartiranja ranljivosti:

- Dodeliti 60-70% virov za upravljanje goriva območjem, identificiranim kot “izjemno visoka ranljivost” (25% regije trenutno, napovedano povišanje na 30% pod prihodnjimi podnebnimi scenariji) (Projekt Karst Firewall 5.0, Rezultat 1.1.2, 2024).
- Prioritizirati območja v razdalji 50 metrov od cest in železnic, kjer je nastalo 67,4% vžigov v preteklosti (Projekt Karst Firewall 5.0, Rezultat 1.1.2, 2024).
- Osredotočiti napore upravljanja vegetacije na iglaste gozdove, zlasti tiste na pobočjih, obrnjenih proti jugu/jugozahodu, ki so bili identificirani kot najbolj izpostavljeni tako v ocenah nevarnosti kot ranljivosti.

Slika 3 - Metrike učinkovitosti avtomatiziranih sistemov za oceno tveganja in preprečevanje (%).



Časovna dodelitev na podlagi napovednih modelov:

- Povečati vire nadzora za 40-50% v obdobjih, ko model XGBoost napoveduje povišano tveganje (>70% verjetnosti).
- Načrtovati dejavnosti zmanjševanja goriva v sezonah z nizkim tveganjem z uporabo sezonskih napovedi iz FWI modela.
- Razporediti mobilne nadzorne enote na območja z visokim tveganjem med vrhunci požarnih sezon, z lokacijami, določenimi s tedenskimi napovedmi nevarnosti.
- Prioritete razvoja infrastrukture:
- Vzpostaviti vodne točke in dostopne ceste na lokacijah, kjer ocena ranljivosti in nevarnosti kaže visoko tveganje, vendar je trenutna infrastruktura nezadostna.
- Investirati v nadzorne kamere in mreže senzorjev na območja z visokim tveganjem in omejenim dostopom osebja, zlasti v oddaljenih delih čezmejne cone.

3.2.2 DODELITEV VIROV ZA ODZIV

Strateška postavitev odzivnih enot:

- Vzpostaviti ekipe za hiter odziv na podlagi dnevnih napovedi tveganja modela XGBoost, ki zagotavljajo, da imajo območja z >80% napovedano verjetnostjo čase odziva pod 15 minut.
- Vzdrževati prilagodljive vzorce razporeditve, ki se prilagajajo spreminjajočemu se tveganju, identificiranem z dnevnimi izhodi modela.

Protokol stopnjevanja odziva:

Implementirati večstopenjski odzivni sistem na podlagi ravni zaupanja napovedi tveganja. Ti pragovi verjetnosti so bili vzpostavljeni na podlagi validacijskih testov na podlagi zgodovinskih požarnih dogodkov (2018-2023), kjer:

- Napovedi z nizkim zaupanjem (50-70%): Razporediti izvidniške enote.
- Napovedi s srednjim zaupanjem (70-85%): Postaviti ekipe za hiter poseg v pripravljenost.
- Napovedi z visokim zaupanjem (>85%): Vnaprej postaviti polne odzivne zmožnosti.

Ti pragovi optimizirajo dodelitev virov z uravnoteženjem stopenj lažnega alarma z ustreznimi ravnmi odziva.

Dodelitev tipov virov na podlagi simulacij Prometheus:

- Določiti tip in količino virov (letalski, talni kolektivi, specializirana oprema) na podlagi simulacij širjenja ognja Prometheus za različne scenarije vžiga.
- Vzdrževati rezerve virov, sorazmerne številu območij z visokim tveganjem, identificiranih v dnevnih napovedih.

3.2.3 IMPLEMENTACIJA PODPORE PRI ODLOČANJU

Integracija z dnevnimi operacijami:

Vzpostaviti protokol dnevnih sestankov, ki vključuje:

- Trenutne zemljevide napovedi XGBoost.
- Vrednosti komponent FWI.
- Rezultate simulacij Prometheus za potencialne točke vžiga.
- Sezonski kontekst tveganja iz kartiranja nevarnosti in ranljivosti.

Odločitveni okvir na podlagi pragov:

Definirati specifične vrednosti pragov za vsak izhod modela, ki sprožijo spremembe v dodelitvi virov:

- Verjetnost XGBoost >70%: Povečati nadzor v prizadetih območjih.
- FFMC (Koda vlažnosti drobnega goriva, ki predstavlja vsebnost vlage površinskega opada) >90 + DMC (Koda vlažnosti organskih plasti, ki predstavlja vsebnost vlage rahlo zbitih organskih talnih plasti) >60: Postaviti zračne vire v pripravljenost.
- Kombinirana visoka ranljivost + visoka verjetnost XGBoost: Razporediti talno izvidništvo.

Upravljanje negotovosti:

- Razviti načrte za nepredvidene okoliščine, ki upoštevajo negotovost modela, zlasti za 19% požarov, ki jih lahko izpusti trenutni model XGBoost (lažno negativni). Ta 19% stopnja lažno negativnih je bila določena preko navzkrižnih validacijskih testov modela XGBoost glede na podatke požarov v obdobju 2020-2023, ki predstavlja odstotek dejanskih požarnih dogodkov, ki jih model ni uspel napovedati pri pragu verjetnosti 70% (Projekt Karst Firewall 5.0, Rezultat 1.2.1, 2025).
- Vzdrževati minimalne odzivne zmožnosti v vseh območjih ne glede na napovedano tveganje, skalirati dodatne vire na podlagi izhodov modela.

3.2.4 ČEZMEJNO DELJENJE VIROV

Skupni bazen virov:

- Vzpostaviti skupen inventar specializirane opreme in osebja, ki ga je mogoče razporediti čez mejo na podlagi izhodov napovednih modelov.
- Implementirati rotacijski sistem, ki postavlja čezmejne vire glede na najvišja napovedana tvegana območja, ne glede na državne meje.

Usklajeno nadzorovanje:

- Razviti integrirane urnike za patroljiranje na podlagi kartiranja nevarnosti in ranljivosti, ki optimizirajo pokritost čezmejne regije.
- Deliti podatke o spremljanju v realnem času preko Karst Firewall 5.0 spletnega portala za omogočanje usklajenih nadzornih naporov.

3.3 PRIPOROČILA POLITIK ZA PREPREČEVANJE IN UPRAVLJANJE GOZDNIH POŽAROV


Za zagotovitev učinkovite integracije AI v upravljanje gozdnih požarov ta rezultat predstavlja nabor strateških priporočil politik, usmerjenih na institucionalne, tehnične in operativne ravni. Prvič, zahteva formalno sprejetje sistemov za podporo odločanju, ki jih poganja AI, znotraj javnih organov in služb za izredne dogodke, podprtih z interoperabilnimi digitalnimi infrastrukturami, ki omogočajo čezmejno koordinacijo v realnem času. Enako pomembna je vzpostavitev jasnih, standardiziranih protokolov za zbiranje, deljenje in uvajanje sistemov podatkov—zagotavljanje kompatibilnosti med agencijami in skladnosti s predpisi o zasebnosti, kot je GDPR.

Robusten regulativni okvir je bistven za vodenje etične in odgovorne uporabe napovednih tehnologij. To vključuje uveljavljanje načel transparentnosti, sledljivosti odločitev in človeškega nadzora v vseh delovnih tokovih, podprtih z AI. Prihodnji politični napor bi se morali tudi osredotočiti na zagotavljanje,

da se AI sistemi redno validirajo, vzdržujejo in posodablajo, da ostanejo učinkoviti pod razvijajočimi se podnebnimi pogoji in požarnimi režimi.

Ta priporočila so zlasti namenjena lokalnim organom, gasilskim enotam in odločevalcem, seznanjajo jih s praktičnimi navodili za izkoriščanje polnega potenciala AI in digitalnih orodij pri izboljšanju učinkovitosti, koordinacije in predvidevanja upravljanja tveganja zaradi gozdnih požarov.

Slika 4 - Prihodnje smeri in potencialne izboljšave: napovedni grafikon.



Naslednja priporočila zagotavljajo navodila za učinkovito sprejetje AI tehnologij v strategijah preprečevanja in upravljanja gozdnih požarov.

3.3.1 PRIPOROČILA ZA TEHNIČNO IMPLEMENTACIJO


Integracija in uvajanje modela:

Implementirati napovedni model XGBoost znotraj obstoječih operativnih okvirov preko faznega pristopa:

- Faza 1 (Meseci 1-3): Izvajati modele vzporedno s tradicionalnimi metodami, primerjati izhode s tedenskimi primerjalnimi analizami.

- Faza 2 (Meseci 4-6): Uporabiti izhode modela kot dodatno podporo odločanju, z gozdarskimi oddelki, odgovornimi za validacijo.
- Faza 3 (Meseci 7-12): Integrirati napovedi modela v standardne operativne postopke, s skupnim tehničnim odborom, ki nadzoruje učinkovitost.

Slika 5 - Primerjava natančnosti: tradicionalne metode v primerjavi s kognitivno AI (črtni grafikon).



Infrastruktura upravljanja podatkov:

- Vzpostaviti standardizirane protokole zbiranja podatkov med slovenskimi in italijanskimi agencijami za zagotovitev konsistentnosti vhodov modela.
- Razviti avtomatizirane podatkovne cevovode, ki zagotavljajo informacije o vremenu v realnem času v napovedne modele z minimalnim ročnim posegom.
- Implementirati enotno čezmejno strukturo baze podatkov, ki kombinira:
 - MySQL za strukturirane dnevnike incidentov gozdnih požarov.
 - InfluxDB za visokofrekvenčne vremenske časovne vrste podatkov.

Uporabniški vmesnik in dostopnost:

- Uvesti Karst Firewall 5.0 spletni portal v vse relevantne agencije z dostopom na podlagi vlog, ki nadzoruje podrobnosti informacij in pragove opozoril.
- Razviti mobilne aplikacije, ki zagotavljajo osebju na terenu dostop v realnem času do izhodov napovedi in priporočil za odziv.
- Ustvariti poenostavljene vizualizacijske nadzorne plošče, ki komunicirajo kompleksne izhode modela v izvedljivih formatih za odločevalce.

3.3.2 STRATEGIJE ORGANIZACIJSKE UPORABE

Usposabljanje in razvoj zmožnosti:

Implementirati večstopenjski program usposabljanja:

- Izvršna raven: Osredotočenje na strateške posledice in interpretacijo izhodov.
- Operativna raven: Podrobna navodila o integraciji napovedi v dnevne odločitve.
- Tehnična raven: Poglobljeno razumevanje zmožnosti in omejitev modela.

Pristop upravljanja sprememb:

- Identificirati in opolnomočiti "AI prvake" znotraj vsake organizacije za lažjo sprejetje.
- Vzpostaviti formalne mehanizme za povratne informacije za osebje na terenu za poročanje o natančnosti modela in predlaganje izboljšav.
- Razviti primerjalne matrike, ki kažejo dodano vrednost AI napovedi v primerjavi s tradicionalnimi metodami.

Upravljanje znanja:

- Dokumentirati študije primerov uspešnih aplikacij modela za gradnjo institucionalnega znanja.
- Ustvariti čezmejno skupnost prakse za deljenje izkušenj in najboljših praks v upravljanju gozdnih požarov, podprtem z AI.

3.3.3 PRIPOROČILA POLITIK IN UPRAVLJANJA

Regulativni okvir:

Uskladiti sprejetje AI z načeli EU AI Act (Evropska komisija, 2023), zagotavljati:

- Transparentnost: Dokumentirati metodologije in omejitve modela.
- Človeški nadzor: Ohranjati končno odločitveno avtoriteto z izkušenim osebjem.
- Odgovornost: Vzpostaviti jasne strukture odgovornosti za odločitve, obveščene z AI.

Financiranje in dodelitev virov:

- Dodeliti 5-8% letnih proračunov upravljanja gozdnih požarov za vzdrževanje in izboljšanje AI sistema.
- Razviti skupne finančne mehanizme, ki podpirajo čezmejno AI infrastrukturo.

- Prioritizirati naložbe v:
 - Izboljšanje kakovosti podatkov.
 - Ponovno usposabljanje in validacijo modela.
 - Izboljšanje uporabniškega vmesnika.

Čezmejno upravljanje:

Vzpostaviti skupni tehnični odbor, odgovoren za:

- Odobranje posodobitev modela.
- Določanje standardov podatkov.
- Pregled učinkovitosti sistema.
- Priporočanje prilagoditev politik.

3.3.4 ETIČNI IN OPERATIVNI VIDIKI

Uravnoteženje AI in strokovne presoje:

- Vzpostaviti jasne smernice, ki presodijo AI orodja kot podporo pri odločanju namesto nadomestkov za strokovno presojo.
- Razviti protokole za primere, kjer se AI napovedi in strokovna mnenja razlikujejo.
- Dokumentirati razloge za odločitve, ko se preglasijo priporočila modela, za ustvarjanje priložnosti učenja.

Obravnavanje omejitev modela:

Implementirati dodatne protokole za obravnavanje znanih omejitev modela:

- Povečana pozornost za tipe požarov, ki so v zgodovinskih podatkih premalo zastopani.
- Posebna pozornost na 19% potencialnih lažno negativnih v modelu XGBoost.
- Sezonske prilagoditve na podlagi podnebnih trendov, ki niso v celoti zajeti v zgodovinskih podatkih.

Zasebnost in varstvo podatkov:

- Zagotoviti, da vse zbiranje in uporaba podatkov ustreza GDPR in relevantnim nacionalnim predpisom.
- Razviti protokole anonimizacije za občutljive podatke, vključene v modele.

3.4 OKVIR ČEZMEJNEGA SODELOVANJA

Učinkovita implementacija smernic in priporočil, opisanih zgoraj, zahteva strukturiran pristop k čezmejnemu sodelovanju. Naslednji okvir zagotavlja temelje za to sodelovanje.

3.4.1 ENOTNO DELJENJE INFORMACIJ

Izmenjava podatkov v realnem času:

- Implementirati standardizirane formate podatkov in protokole izmenjave med slovenskimi in italijanskimi agencijami.
- Vzpostaviti dvostranske sporazume za takojšnje deljenje:
 - Podatkov vremenskih postaj.
 - Opozoril sistemov zaznavanja.
 - Stanja razporeditve virov.
 - Napovedi modela.

Zmožnosti skupne analize:

Ustvariti čezmejno analitično ekipo s predstavniki obeh držav, odgovorno za:

- Spremljanje učinkovitosti modela.
- Validacijo napovedi.
- Sintezo vpogledov iz več virov podatkov.
- Zagotavljanje usklajenih priporočil.

3.4.2 USKLAJENI ODZIVNI MEHANIZMI

Enotna poveljniška struktura:

Razviti protokole za vzpostavitev skupnega poveljstva pri čezmejnih incidentih na podlagi:

- Napovedane smeri širjenja iz simulacij Prometheus.
- Razpoložljivosti virov.
- Jurisdikcijskih upoštevanj.

Sporazumi o deljenju virov:

Formalizirati sporazume za čezmejno razporejanje:

- Zračnih virov.

- Specializirane opreme.
- Osebja.

Vzpostaviti standardizirane postopke zahtev, aktivirane s specifičnimi pragovi v napovednih modelih.

Skupno usposabljanje in vaje:

- Izvajati letne čezmejne vaje na podlagi scenarijev, izpeljanih iz:
 - Zgodovinskih vzorcev požarov.
 - Projekcij podnebnih sprememb.
 - Simulacij Prometheus.
- Vključiti interpretacijo AI napovedi v vse skupne usposabljalne aktivnosti.

3.4.3 HARMONIZACIJA POLITIK

Usklajene strategije preprečevanja:

- Koordinirati dejavnosti upravljanja goriva na podlagi čezmejnega kartiranja ranljivosti.
- Razviti kompatibilne kampanje ozaveščanja javnosti, ki predstavljajo dosledna sporočila čez meje.

Standardizirane ravni opozorila:

Implementirati enotni sistem opozoril na podlagi verjetnosti napovedi XGBoost:

- Raven 1: 50-70% verjetnosti.
- Raven 2: 70-85% verjetnosti.
- Raven 3: >85% verjetnosti.


Uskladiti postopke javnega komuniciranja in mobilizacije agencij za vsako raven.

Proces vrednotenja in izboljšanja:

Vzpostaviti skupni letni proces pregleda za:

- Oceno učinkovitosti modela.
- Vrednotenje učinkovitosti dodelitve virov.
- Identificiranje ovir sodelovanja.
- Posodobitev protokolov na podlagi naučenih lekcij.
- Objavo ugotovitev za prispevek k širšemu znanju prilagajanja podnebjū EU.

Slika 6 - Prihodnji potencial in trenutni vpliv kognitivne AI pri upravljanju gozdnih požarov.



4 LITERATURA

- [1] ARPA FVG. (2023). Regional Climate Data 1993-2023. Friuli Venezia Giulia Environmental Protection Agency.
- [2] ARSO. (2023). Slovenian Meteorological Data Repository. Slovenian Environment Agency.
- [3] Canadian Forest Service. (2009). Fire Weather Index System and Prometheus Fire Growth Model. Natural Resources Canada.
- [4] European Commission. (2023). EU AI Act: Regulatory Framework for Artificial Intelligence. European Commission.
- [5] Hossain, M., & Rahman, T. Y. (2025). Cognitive AI for Wildfire Management in Southern California: Challenges and Potentials. *Journal of Science and Technology*, 10(2), 51-65. <https://doi.org/10.46243/jst.2025.v10.i02.pp51-65>
- [6] Progetto Karst Firewall 5.0. (2024a). Quadro di Collaborazione Transfrontaliera per la Gestione degli Incendi Boschivi. Programma di Cooperazione Italia-Slovenia.
- [7] Progetto Karst Firewall 5.0. (2024b). Deliverable 1.1.2: Valutazione di Pericolo e Vulnerabilità degli Incendi Boschivi Sotto il Cambiamento Climatico nella Regione del Carso. Programma di Cooperazione Italia-Slovenia.
- [8] Progetto Karst Firewall 5.0. (2025). Deliverable 1.2.1: Algoritmi AI Predittivi per il Rischio di Incendi Boschivi. Programma di Cooperazione Italia-Slovenia.
- [9] Saxena, V. (2025). AI-Driven Wildfire Management: An Integrated Approach to Detection, Prevention, and Response. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 11, 2125-2133. <https://doi.org/10.32628/CSEIT251112178>
- [10] Slovenian Forest Service (ZGS). (2024). Historical Wildfire Data 1990-2024. Ministry of Agriculture, Forestry and Food.
- [11] Wiggins, L., Zhang, H., Montgomery, K., & Patel, S. (2020). XGBoost Applications in Environmental Risk Prediction. *Journal of Machine Learning for Environmental Sciences*, 15(3), 256-270.