

D1.2.1

MODELI NAPOVEDNIH ALGORITMOV

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-D121
Titolo del documento / Naslov dokumenta:	MODELI NAPOVEDNIH ALGORITMOV
Work Package:	1
Attività / Aktivnost:	2.1
Partner responsabili (autori) / Odgovorni partnerji (avtorji):	Infordata 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

1 OKRAJŠAVE	4
2 CILJI IN OZADJE	5
2.1 Literatura in razpoložljivi modeli	5
2.2 Meteorološki indeks požarne ogroženosti	5
2.3 Modeli strojnega učenja za napovedovanje	6
2.3.1 Modeli, ki temeljijo na vozliščih ML	6
2.3.2 Model rasti požara Prometheus	8
2.4 Povezava z D1.1.2	9
3 ANALIZA, NAČRTOVANJE IN RAZVOJ	11
3.1 Kontekst analize	11
3.2 Eksperimentalni rezultati	13
3.2.1 Pomembnost značilnosti	15
3.2.2 Razprava in prihodnje delo	15
4 REZULTATI DODATNIH ANALIZ IZ ZGODOVINSKIH PODATKOV	17
5 INTEGRACIJA V SPLETNI PORTAL KARST FIREWALL 5.0	22
5.1 Meteorološki nabori podatkov na portalu Karst Firewall	22
5.2 Zbrani parametri	24
5.3 Sistem aktivacije obvestil	26
6 SKLICI	32
7 DODATEK A	33

ABBREVIAZIONI	
ARPA	Regionalna agencija za varstvo okolja, Italija
ARSO	Agencija RS za okolje, Slovenija
Corpo Forestale	Gozdarska služba dežele Furlanija-Juljska krajina, Italija
EU AI Act	Zakon EU o umetni inteligenci je okvir, ki določa harmonizirana pravila za razvoj, dajanje na trg in uporabo sistemov umetne inteligence (UI) v Evropski uniji (EU)
FWI	Meteorološki indeks požarne ogroženosti
XGBoost Model	eXtreme Gradient Boosting je distribuirana odprtokodna knjižnica strojnega učenja, ki uporablja odločitvena drevesa z gradientnim povečevanjem
K-Nearest Neighbors	algoritem strojnega učenja, uporabljen tako za klasifikacijo kot za regresijsko nalogo
IUAV	Univerza IUAV v Benetkah, Italija
INFOR	Infordata Sistemi Srl, Italija
ML	Strojno učenje (ang. Machine Learning)
Random Forest	Naključni gozdovi so metoda strojnega učenja za klasifikacijo, regresijo in druge naloge
ZGS	Zavod za gozdove Slovenije, Slovenija
ZRC SAZU	Znanstveno raziskovalni center Slovenske akademije znanosti in umetnosti, Slovenija

1 POVZETEK

V okviru čezmejnega projekta Karst Firewall 5.0 — , osredotočenega na podnebno odporno gozdno gospodarjenje v kraški regiji — izroček D1.2.1 predstavlja razvoj, testiranje in validacijo napovednih modelov za oceno tveganja gozdnih požarov. Požari predstavljajo eno najbolj uničujočih naravnih nesreč na svetovni ravni, ki jih pogojujejo zapletena medsebojna delovanja med gorivi, topografijo in vremenskimi razmerami, kot so temperatura, vlažnost, hitrost in smer vetra ter padavine, zabeležene v obravnavanem obdobju. Raziskave in analize, opravljene za razvoj novih algoritmov, so razkrile jasno korelacijo med vremenskimi razmerami in širjenjem gozdnih požarov. Poleg tega so pokazale tudi druge pomembne podatke, kot je povišanje povprečne temperature v čezmejni kraški regiji med letoma 1993 in 2023 za 1,4 °C.

V tem dokumentu so opisan pristop, metodologija in rezultati, pridobljeni z algoritmi umetne inteligence za napovedovanje tveganja gozdnih požarov. Čeprav trenutni rezultati kažejo obetavno natančnost, je treba za nadaljnje izboljšanje učinkovitosti vključiti še številne druge kompleksnejše spremenljivke. Dejavnosti implementacije in optimizacije teh algoritmov se bodo nadaljevale do konca projekta, vodene z novimi vhodnimi informacijami, pridobljenimi med delom. Ko bodo na voljo novi podatki in se bodo uvedle naprednejše analitične tehnike, se bodo modeli strojnega učenja nenehno posodabljali in izboljševali, kar bo zagotovilo, da bo sistem ostal prilagodljiv, natančen in odziven skozi čas.

Preizkušenih je bilo več razredov algoritmov, vključno z linearnimi modeli, verjetnostnimi modeli, modeli K-najbližjih sosedov in drevesnimi modeli. Med njimi sta se kot najučinkovitejši izkazali metodi, ki temeljita na odločitvenih drevesih, Random Forest in XGBoost. Ta modela sta pokazala odlične rezultate pri zajemanju zapletenih nelinearnih interakcij med okoljskimi in antropogenimi spremenljivkami, ki vplivajo na pojav gozdnih požarov.

Modeli so temeljili na uporabi podatkov meteoroloških služb ARPA FVG in ARSO, ter na podatkih o preteklih požarih, ki jih zagotavljata postaja Gozdarske službe Duino-Aurisina in Zavod za gozdove Slovenije (ZGS). Napovedna natančnost se je bistveno izboljšala, ko so vhodni podatki pokrivali tridnevno časovno okno pred požarnimi dogodki. XGBoost je pokazal visoko odpornost na razredni neravnotežje in zagotovil vpogled v relativni pomen značilnosti.

Pomembno je poudariti, da se uporaba umetne inteligence (UI) v tem kontekstu strogo drži etičnih standardov in se usklajuje z načeli zakona EU o UI, vključno s preglednostjo, človeškim nadzorom in odgovornostjo. Čeprav rezultati modela ponujajo natančne napovedi, niso namenjeni nadomeščanju človeške strokovnosti. Namesto tega napovedi služijo kot orodja za podporo odločanju, ki jih morajo razlagati in validirati usposobljeni strokovnjaki, kot so gozdarji, agenti civilne zaščite in lokalne oblasti.

To delo podpira širše cilje projekta Karst Firewall 5.0: izboljšanje pripravljenosti na gozdne požare prek tehnoloških inovacij, čezmejnega sodelovanja in strategij prilagajanja, ki temeljijo na ekosistemi. Napovedni modeli, razviti v tem dokumentu, so namenjeni integraciji v sistem zgodnjega opozarjanja v okviru čezmejne digitalne platforme, ki se trenutno razvija v okviru delovnega paketa 2.

2 CILJI IN OZADJE

Cilj izročka 1.2.1 “Napovedovanje požarne ogroženosti” v okviru projekta Karst Firewall je razviti natančnejše in zanesljivejše orodje za napovedovanje tveganja gozdnih požarov z uporabo nedavnega napredka na področju umetne inteligence in strojnega učenja. Z združevanjem meteorološkega indeksa požarne ogroženosti (FWI), zgodovinskih podatkov o gozdnih požarih zadnjih 20 let na italijanskem in slovenskem Krasu ter dolgoročnih meteoroloških podatkov iz meteoroloških postaj, postavljenih na čezmejnem kraškem območju, projekt razvija nov algoritem umetne inteligence, ki bo lahko z večjo natančnostjo identificiral območja in pogoje visokega tveganja požarne ogroženosti. Rezultati bodo deljeni z javnimi oblastmi in znanstveno skupnostjo kot podpora sistemom zgodnjega opozarjanja in strategijam za zmanjševanje tveganja, medtem ko bo sam algoritem integriran v spletni portal Karst Firewall 5.0 za zagotovitev široke dostopnosti in operativne uporabe.

2.1 LITERATURA IN RAZPOLOŽLJIVI MODELI

Za razvoj napovednih algoritmov za tveganje gozdnih požarov smo preučili več publikacij, metodologij in obstoječih algoritmov, ki so se že ukvarjali s tem problemom. Naš pristop se je specifično osredotočil na matematično modeliranje, tesno usklajeno z glavnimi kompetencami našega podjetja. V okviru kontekstualne analize je bilo upoštevanih več ključnih publikacij, vključno z [1] Development and Structure of Prometheus: the Canadian Wildland Fire Growth Simulation Model, odličnim orodjem za simulacijo širjenja gozdnih požarov [3], Mapping Variable Wildfire Source Areas Through Inverse Modeling, študijo, ki uporablja pristop inverznega modeliranja za sledenje virov požara z retrogradno analizo vetrnih vzorcev, in [6] Machine Learning based Wildfire Area Estimation Leveraging Weather Forecast Data, ki je še posebej navdihnilo naše delo. Dodatne relevantne reference so na voljo v poglavju 6: Reference.

Izroček D1.1.1 skupaj s prispevki naših tehničnih partnerjev IUAV in ZRC SAZU je bil temeljnega pomena za usmerjanje naših dejavnosti. Podatki, uporabljeni za to analizo, izvirajo iz Gozdarske službe Duino (podatki o gozdnih požarih v regiji FVG) in Zavoda za gozdove Slovenije (ZGS) (<https://prostor.zgs.gov.si/pregledovalnik/>). Meteorološki podatki so bili pridobljeni iz zgodovinskih arhivov ARPA FVG (<https://www.osmer.fvg.it/archivio.php?ln=&p=dati>) in ARSO (<https://meteo.arso.gov.si/met/sl/app/webmet>); vzporedno je bil razvit tudi programski vmesnik za pridobivanje podatkov v realnem času iz meteoroloških postaj, razpršenih po italijanskem in slovenskem kraškem ozemlju.

2.2 METEOROLOŠKI INDEKS POŽARNE OGROŽENOSTI

Meteorološki indeks požarne ogroženosti (FWI) je sistem numeričnega ocenjevanja, ki ocenjuje potencialno intenzivnost gozdnih požarov na podlagi prevladujočih vremenskih razmer. Prvotno ga je razvila kanadska gozdarska služba, FWI pa je postal standardno orodje za oceno požarne ogroženosti, ki ga uporabljajo nacionalne in regionalne meteorološke agencije po vsem svetu, vključno z Evropo.

Sistem FWI vključuje več meteoroloških spremenljivk za modeliranje vsebnosti vlage v gozdnih gorivih in vpliva vetra na obnašanje požarov. Natančneje, uporablja štiri ključne dnevne meteorološke parametre:

- Temperatura.
- Relativna vlažnost.
- Hitrost in smer vetra.
- Padavine v zadnjih 24 urah.

Te vhodne parametre se obdela preko serije podindeksov, ki zajemajo različne komponente suhosti goriva in požarnega potenciala, kot sta vlažnost finega goriva (FFMC) in vlažnost humusa (DMC). Končni rezultat, vrednost FWI, kombinira te parametre za zagotovitev ene vrednosti, ki predstavlja indeks požarne ogroženosti. Višje vrednosti FWI predstavljajo večjo požarno ogroženost in večjo intenzivnost požara.

2.3 MODELI STROJNEGA UČENJA ZA NAPOVEDOVANJE

V okviru analize zahtev smo preučili vrsto modelov strojnega učenja za obravnavo napovedne analize, vključno z:

- Linearni modeli: učinkoviti, ko linearna kombinacija značilnosti lahko loči razrede, vendar manj primerni za zapletene in nelinearne pojave, kot so gozdni požari.
- K-najbližji sosedji (KNN): temelji na bližini v naboru podatkov. Deluje dobro z majhnimi in dobro porazdeljenimi nabori podatkov, vendar postane počasen z velikimi nabori podatkov in mu manjka jasna interpretabilnost.
- Verjetnostni modeli: predpostavljajo neodvisnost med značilnostmi, predpostavka, ki redko velja za meteorološke podatke, kjer so spremenljivke močno korelirane.
- Drevesni modeli: uporabljajo odločitvena drevesa za rekurzivno razdeljevanje nabora podatkov na progresivno manjše podmnožice, idealni za zajemanje nelinearnih razmerij in zapletenih interakcij med spremenljivkami.
- Med njimi so se drevesni modeli izkazali kot najbolj primerni za naše cilje. Naslednji modeli so bili izbrani za poglobljeno analizo:
- Odločitvena drevesa: enostavna za interpretacijo, vendar nagnjeni k prekomernemu prileganju.
- Random Forest: kombinira več odločitvenih dreves za izboljšanje robustnosti, zmanjšanje prekomerne prileganja in izboljšanje posploševanja.
- XGBoost: visokoperformančni model povečevanja, ki iterativno popravlja prejšnje napake in učinkovito upravlja neuravnotežene nabore podatkov in manjkajoče podatke.


2.3.1 MODELI, KI TEMELJIJO NA VOZLIŠČIH ML

Drevesni modeli, kot so odločitvena drevesa, Random Forest in XGBoost, so še posebej primerni za naše cilje napovedovanja gozdnih požarov in ponujajo vrsto prednosti:

- Upravljanje tabelarnih in nelinearnih podatkov: dinamike gozdnih požarov so zapletene in pod vplivom več spremenljivk. Drevesni modeli lahko naravno zajemajo nelinearne interakcije, ne da bi zahtevali eksplisitne transformacije značilnosti, za razliko od linearnih modelov.
- Robustnost in interpretabilnost: odločitvena drevesa ponujajo pregledne odločitvene procese, vendar lahko kažejo prekomerno prileganje, zlasti s podatki, ki imajo veliko šuma. Random Forest to zmanjšuje z agregiranjem odločitev iz več dreves in dosega boljše posploševanje. XGBoost to izboljšuje z gradnjo dreves v zaporedju, popravljanjem napak prejšnjih iteracij ter ponuja visoko natančnost, integrirano upravljanje manjkajočih vrednosti in nizko občutljivost na šum.
- Izbira značilnosti in upravljanje zapletenosti: z bogatim naborom meteoroloških in zgodovinskih spremenljivk lahko Random Forest in XGBoost samodejno identificirata najpomembnejše značilnosti, izboljšata napovedno uspešnost brez potrebe po obsežnem ročnem uglaševanju.
- Upravljanje neuravnoteženih naborov podatkov: gozdni požari nastanejo redko. XGBoost odlično identificira redke dogodke zaradi prilagojenih funkcij izgube in tehnik uravnoteženja razredov, povečuje priklicno sposobnost, ne da bi žrtvoval splošno natančnost.
- Računska učinkovitost: XGBoost je optimiziran za hitrost in učinkovitost pomnilnika, kar omogoča obdelavo velikega nabora podatkov. Podpira paralelizacijo in GPU pospešitev, kar omogoča hitrejšo usposabljanje v primerjavi s tradicionalnimi algoritmi povečevanja.

2.3.2 MODEL RASTI POŽARA PROMETHEUS

Slika 1 - Primer napovedi rasti gozdnih požarov modela Prometheus (vir: <https://firegrowthmodel.ca>).



Prometheus je napredni sistem simulacije rasti gozdnih požarov, razvit v Kanadi, ki se uporablja predvsem za modeliranje širjenja in obnašanja gozdnih požarov v naravnih pokrajinah (Slika 1). Zasnovan je za podporo tako operativnemu odločanju med aktivnimi gozdnimi požari kot strateškemu načrtovanju za preprečevanje in upravljanje požarov.

Ključne komponente

Temelji na kanadskem sistemu napovedovanja obnašanja požarov (FBP): Prometheus simulira rast gozdnih požarov z uporabo empiričnih enačb kanadskega FBP sistema, ki napoveduje hitrost širjenja, intenzivnost in druge značilnosti požara na podlagi goriva, vremenskih razmer in topografije.

Integracijameteorološkega indeksa požarne ogroženosti (FWI): ta indeks pomaga pri ocenjevanju požarne ogroženosti z vključevanjem podatkov o temperaturi, vlažnosti, vetru in padavinah.

Prometheus Mathematical: modelira rast obsega požara kot elipse z uporabo pristopa, ki temelji na širjenju valov (Huygensova teorija). Vsaka točka na robu požara oddaja nov val front, kar prispeva k simulaciji širjenja požara skozi čas v specifičnih pogojih.

Integracija podatkov zahteva vhodne podatke o:

- Vrste goriv (vegetacija).
- Topografija (naklon, izpostavljenost, nadmorska višina).
- Vremenske razmere (tako zgodovinske kot napovedane).

Rezultati so:

- Obsegi požarov na osnovi časa.
- Hitrost in smer širjenja.
- Intenzivnost požarne linije.
- Karte verjetnosti požarov.

Prilagodljivost: čeprav je bil razvit za kanadske ekosisteme, je bil Prometheus uspešno prilagojen tudi v drugih državah, kot je Nova Zelandija, kar dokazuje njegovo modularnost in prilagodljivost.

Prometheus je odličen izbor za uporabo tudi na območju Krasa in na splošno v Evropi. Čeprav je bil razvit v Kanadi, je Prometheus odprtokoden in prilagodljiv, kar omogoča integracijo z evropskimi GIS sistemi, nabori podnebnih podatkov (npr. Copernicus) in lokalnimi modeli goriv. Njegova uporaba bi zagotovila znanstveno validirane projekcije, izboljšala čezmejno izmenjavo podatkov in načrtovanje ter podprla odločanje v fazah krize in preprečevanja.

Projekt Karst Firewall 5.0, ki si prizadeva razviti čezmejne strategije preprečevanja in upravljanja gozdnih požarov za italijansko-slovensko kraško regijo, bi lahko zelo koristil od integracije modela rasti požarov Prometheus. Prometheus bi okrepil znanstveno in tehnološko zmogljivost projekta z omogočanjem simulacije čezmejnega širjenja požarov, pomagal bi oblastem napovedati, kako bi se požar, ki, bi izbruhnil v Sloveniji, lahko širil v Italijo in obratno. Podpira simulacije scenarijev tako v realnem času kot za prihodnost, kar je idealno za sisteme zgodnjega opozarjanja in usposabljanje reševalcev. Poleg tega lahko integrira obstoječe modele MaxEnt in MCDA/AHP z zagotavljanjem dinamičnih in specifičnih izhodov za obnašanje požarov ter omogoča testiranje strategij upravljanja goriv, kot sta čiščenje grmovja in ponovno pogozdovanje. Simulacije Prometheus so lahko uporabne tudi za usposabljanje in javno izobraževanje, vključno z delavnicami in vajami za gašenje požarov. Nazadnje je mogoče njegove rezultate integrirati v digitalno platformo Karst Firewall 5.0, ki zagotavlja interaktivne karte in vizualizacije širjenja požarov na osnovi časa za informirano odločanje in vključevanje skupnosti.

2.4 POVEZAVA Z D1.1.2

Izroček D1.1.2 z naslovom "Ocena tveganja in ranljivosti gozdnih požarov v zvezi s podnebnimi spremembami v kraški regiji" zagotavlja temeljne osnove za razvoj napovednih algoritmov,

predstavljenih v tem izročku (D1.2.1); rezultati in cilji bodo uporabljeni v prihodnjem obdobju za nadaljevanje izboljševanja in optimizacije napovednih algoritmov. Posebej z uporabo modeliranja maksimalne entropije (MaxEnt) in večkriterijske odločitvene analize (MCDA/AHP) D1.1.2 ponuja strukturirano in visokoresolucijsko kartiranje verjetnosti požarne nevarnosti in ranljivosti na čezmejnem kraškem območju. Te analize neposredno informirajo in razširjajo obseg napovednega modeliranja, razvitega v D1.2.1, na več ključnih načinov:

- Zagotavljanje vhodnih podatkov in spremenljivk: Pojasnjevalne spremenljivke, uporabljene in obdelane v D1.1.2 — ki obsegajo antropogene, okoljske, podnebne in topografske značilnosti — predstavljajo glavni nabor značilnosti za usposabljanje napovednih modelov. Njihova kalibracija, harmonizacija in ponovno vzorčenje na visoki prostorski ločljivosti (3 m × 3 m) zagotavlja kompatibilnost z zahtevami strojnega učenja za natančne prostorske napovedi.
- Osnova za validacijo modela: Validirane karte nevarnosti gozdnih požarov in kategorizacija razredov ranljivosti iz D1.1.2 predstavljajo merilo, na podlagi katerega lahko testiramo napovedno uspešnost algoritmov, razvitih v D1.2.1. To vključuje tako trenutne kot prihodnje podnebne scenarije, kar omogoča robustno oceno časovnega posploševanja v napovednem modeliranju.
- Izboljšanje usposabljanja algoritmov in uspešnosti: Nabori podatkov o točkah vžiga, prečiščeni in s kontrolirano kakovostjo, uporabljeni v D1.1.2, omogočajo nepristranske in dobro porazdeljene podatke za usposabljanje, kar izboljšuje kakovost učenja algoritmov, kot je MaxEnt, in podpira prihodnjo integracijo alternativnih modelov, kot so Random Forest ali klasifikatorji globokega učenja.
- Podpora za načrtovanje sistemov za podporo odločanju: Konceptualni okvir, razvit v D1.1.2, podpira integracijo napovednih algoritmov v odločitvena orodja. Njegova strukturirana ocena dejavnikov prek analize AHP in GIS podpira logiko tehtanja, integrirano v bolj zapletene modele, ki temeljijo na umetni inteligenci, razvite v okviru D1.1.2.

Povzetek: rezultati D1.1.2 zagotavljajo empirične, metodološke in prostorske osnove, ki bodo prispevale k izvedljivosti, relevantnosti in robustnosti algoritmičnega modeliranja D1.2.1 v kontekstu načrtovanja preprečevanja in odziva na tveganje gozdnih požarov na območju Krasa.

3 ANALIZA, NAČRTOVANJE IN RAZVOJ

3.1 KONTEKST ANALIZE


Za razvoj napovednega modela za gozdne požare na Krasu smo raziskali več algoritmov strojnega učenja za identifikacijo najbolj učinkovite rešitve. Nabor podatkov je vseboval zgodovinske meteorološke podatke (npr. temperatura, vlažnost, hitrost vetra, padavine), kombinirane s podatki o preteklih požarih, kar nam je omogočilo strukturiranje zanesljive osnove za učenje in ocenjevanje modela. Po skrbni fazi predprocesiranja smo uporabili tehnike inženirstva značilnosti za izbiro najbolj relevantnih spremenljivk in zmanjšanje dimenzionalnosti problema. Ta optimizacijska faza je bila namenjena izboljšanju natančnosti modela ob minimalizaciji računskih stroškov. Za učenje modelov smo uporabili meteorološke podatke za dneve, ko so bili požari prisotni, vključno s temperaturo, vlažnostjo, padavinami, vetrom, zračnim tlakom in sončnim sevanjem, izmerjene na najbližji meteorološki postaji kraju požara.

Tabela 1 - Seznam meteoroloških postaj, uporabljenih za učenje algoritmov ML in spremljanje v realnem času.

ITALY - ARPA	SLOVENIA - ARSO
Gorizia Aeroporto	Ajdovščina - Dolenje
Monfalcone Pluvio	Bilje
Trieste Ist. Nautico	Boja Zora
Sgonico-Zgonik	Debeli rtic
Trieste molo F.lli Bandiera	Godnje
Borgo Grotta Gigante	Koper Kap
Gradisca	Koper Luka
	Nova Gorica
	Piran
	Podnanos
	Škocjan
	Vedrijan

Nabor podatkov je bil ustvarjen z uvozom, harmonizacijo in obdelavo več kot 8 milijonov zgodovinskih meteoroloških podatkov iz italijanskih in slovenskih postaj, lociranih na Krasu, vseboval pa je tudi 38.500 lokacij gozdnih požarov. Dodatne informacije o lokacijah in značilnostih postaj so na voljo v dodatku A.

Slika 2 - Primerjava parov parametrov. Zgoraj: meteorološki podatki do tri ure pred gozdnimi požari. Spodaj: podatki, ki niso povezani z gozdnimi požari. Ti grafi poudarjajo korelacije med obravnavanimi parametri.



Glede na značilnosti prej opisanih modelov smo se sprva odločili uporabiti model strojnega učenja, ki temelji na odločitvenem drevesu, za pridobitev prve ocene učinkovitosti te vrste analize. Z obširno podatkovno bazo zgodovinskih meteoroloških podatkov (povezanih z zapisi gozdnih požarov v regiji) smo ustvarili več naborov podatkov z različno časovno pokritostjo. Ti so vsebovali meteorološke podatke, zabeležene eno uro pred gozdnim požarom, in podatke, ki so segali do enega meseca pred požarom. Ta pristop nam je omogočil učenje modela odločitvenega drevesa za prepoznavanje vzorcev v času, ki bi lahko bili relevantni za napovedovanje gozdnih požarov. Ker je odločitveno drevo najpreprostejši od modelov na osnovi vozlišč, smo nato razširili našo oceno na naprednejša modela Random Forest in XGBoost. Ti so zagotovili večjo napovedno natančnost in ponudili dragocen

vpogled v relativni pomen (ali "težo") različnih parametrov, kot so vlažnost, temperatura, hitrost vetra k prispevanju za napovedovanje požarov. Preliminarni rezultati so pokazali, da so ti modeli sposobni zajeti glavne okoljske vzorce, ki se pojavijo pred požari. Spodbujeni s temi ugotovitvami smo nadaljevali z nadaljnjim izpopolnjevanjem modela, raziskali dodatne tehnike za izboljšanje napovedne uspešnosti.

3.2 EKSPERIMENTALNI REZULTATI

Za ocenjevanje uspešnosti različnih modelov smo uporabili različne metrike. Med njimi sta se dve merili izkazali še posebej relevantni za našo aplikacijo:

- **Natančnost:** meri splošno pravilnost modela tako pri primerih požarov kot pri primerih brez požarov.
- **Priklic:** kvantificira sposobnost modela za pravilno identifikacijo dejanskih gozdnih požarov, kar je še posebej pomembno v kontekstu napovedovanja požarov.

Naslednja tabela povzema rezultate natančnosti in priklica, pridobljene s testiranjem začetnega modela na naborih podatkov, ki pokrivajo različne časovne intervale pred požari.

Tabela 2 - Rezultati, pridobljeni z uporabo treh klasifikacijskih modelov na treh različicah nabora podatkov, poimenovanih 1 DAN, 1 TEDEN in 1 MESEC, ki ustrezajo časovnemu intervalu pred gozdnim požarom (oziroma: 1 dan, 1 teden, 1 mesec).

Modeli	Parametri	1 DAN	1 TEDEN	1 MESEC
Odločitveno drevo	Natančnost	0.68	0.66	0.65
	Priklic	0.59	0.52	0.47
Random forest	Natančnost	0.73	0.70	0.67
	Priklic	0.65	0.58	0.53
XGBoost	Natančnost	0.75	0.70	0.68
	Priklic	0.69	0.65	0.61


Čeprav splošna uspešnost še ni optimalna, zlasti glede priklica, se je pojavil jasen trend: z naraščanjem velikosti nabora podatkov naprednejši modeli, kot je XGBoost, konstantno presegajo preprostejše. Posebej XGBoost kaže trdno natančnost in boljši priklic, kar dokazuje večjo sposobnost zaznavanja pozitivnih primerov (požari). To obetavno obnašanje je motiviralo nadaljnjo optimizacijo in uglaševanje modela.

Z uporabo različnih strategij strojnega učenja smo izpopolnili učenje, izboljšali kakovost nabora podatkov in optimizirali model XGBoost. Kritičen vidik, ki smo ga obravnavali med razvojem modela, je bil neravnovesje v naboru podatkov z bistveno večjim številom primerov, ki niso povezani s požari, v primerjavi z dejanskimi dogodki gozdnih požarov. To neravnovesje lahko močno vpliva na model v smeri napovedovanja večinskega razreda, s čimer zmanjšuje njegov priklic. Za ublažitev tega

problema smo uporabili tehnike tehtanja razredov in testirali strategije ponovnega vzorčenja, da bi zagotovili, da je model bolje opremljen za zaznavanje redkih, vendar ključnih pozitivnih primerov.

Najboljši rezultati so bili doseženi z uporabo meteoroloških podatkov, ki pokrivajo triurno časovno okno pred pojavom gozdnih požarov. V tej konfiguraciji je model XGBoost dosegel 90% natančnost in 81% priklic, kar potrjuje njegovo robustnost pri napovedovanju dogodkov gozdnih požarov z zmanjševanjem lažno negativnih rezultatov. Nastala izboljšava je prikazana prek matrike konfuzije, ki zagotavlja podroben razčlen napovednih sposobnosti modela. Matrika predstavlja porazdelitev resničnih pozitivnih (TP), lažnih pozitivnih (FP), resničnih negativnih (TN) in lažnih negativnih (FN) dogodkov, kar potrjuje, da model XGBoost dosega najvišjo natančnost med testiranimi modeli. Posebej je model uspešno identificiral večino gozdnih požarov (razred 1), čeprav nezanemarljivo število lažnih negativnih (FN) še vedno kaže, da nekateri požari niso bili zaznani. Ta analiza poudarja tako prednosti kot preostale izzive trenutnega pristopa.


Slika 3 - Matrika konfuzije, ki prikazuje najuspešnejši model XGBoost.



3.2.1 POMEMBNOST ZNAČILNOSTI

Ena glavnih prednosti uporabe drevesnih modelov je možnost določitve pomembnosti vsake značilnosti. Razumevanje, katere meteorološke spremenljivke vodijo odločitve modela, je ključno za operativno uporabo. Naslednji graf prikazuje najpomembnejše značilnosti po modelu XGBoost. Te značilnosti bistveno prispevajo k napovedovanju gozdnih požarov. Kot prikazuje graf, so najbolj vplivne značilnosti za napovedovanje gozdnih požarov temperatura, hitrost vetra, vlažnost in sevanje, kar se ujema s splošnim meteorološkim razumevanjem obnašanja gozdnih požarov.

Slika 4 - Razvrstitev pomembnosti značilnosti iz modela XGBoost.



3.3.2 RAZPRAVA IN PRIHODNJE DELO


Čeprav je XGBoost zagotovil najboljše rezultate glede na splošno uspešnost, obstajajo še vedno možnosti za izboljšanje. Še posebej smo opazili večje število lažno negativnih rezultatov v razredu gozdnih požarov, kar kaže, da je model konzervativen pri napovedovanju požarnih dogodkov. Čeprav model dosega trden priklic 81%, bi se prihodnje delo lahko osredotočilo na upravljanje teh lažno negativnih rezultatov, ki so ključni za izboljšanje zanesljivosti modela v scenarijih napovedovanja dejanskih požarov. Pomembno je poudariti, da se bodo modeli še naprej razvijali skozi čas, koristili pa bodo ne le bolj naprednim tehnikam strojnega učenja, temveč tudi vključevanju

izvedenih meteoroloških indeksov. Parametri, kot so FPMC (vlažnost finega goriva), DMC (vlažnost humusa) ali DC (suša), ponujajo dodatne ravni razumevanja pogojev požarne ogroženosti in se bodo postopoma vključevali v napovedni okvir za nadaljnje izpopolnjevanje njegove natančnosti in odzivnosti.

4 REZULTATI DODATNIH ANALIZ IZ ZGODOVINSKIH PODATKOV

Poleg glavnih rezultatov, povezanih z napovednim modeliranjem, je analiza zgodovinskih vremenskih vzorcev in podatkov o gozdnih požarih na Krasu prinesla več pomembnih komplementarnih ugotovitev. Ti posredni rezultati, še posebej poglobljena analiza temperaturnih trendov v različnih meteoroloških postajah, zagotavljajo dodatni kontekst dinamiki požarne ogroženosti in ranljivosti na območju ter podpirajo izpopolnjevanje napovednih algoritmov. Analiza temperature razkriva značilne trende segrevanja v celotni regiji, z statistično pomembnim povišanjem za 0,57 °C na desetletje v zadnjih 30 letih (1993-2023) (slika 5).


Slika 5 - Splošni trend temperature (1993-2023). Časovna vrsta povprečnih letnih temperatur (°C), izračunanih za vse meteorološke postaje od 1993 do 2023. Oranžna črta prikazuje letna povprečja z indikatorji, ki označujejo podatkovne točke. Črtkana rdeča črta predstavlja trend linearne regresije. Oranžno senčeno območje označuje podatkovni razpon. (vir podatkov: ARSO, ARPA).



Primerjalna analiza podnebnih kazalnikov med italijanskimi in slovenskimi postajami razkriva različne trende tako za osončenost kot za temperaturo (slika 6). Za meritve osončenosti italijanske postaje kažejo strmejši naraščajoči trend (naklon 0,6320 W/m²/leto) v primerjavi s slovenskimi postajami (naklon 0,4873 W/m²/leto), kar kaže na diferencialno intenzifikacijo izpostavljenosti soncu v čezmejni regiji. Podobno podatki o temperaturi kažejo vzporedne trende segrevanja, pri čemer italijanske


postaje dosledno beležijo višje vrednosti (povprečno za 0,9 °C toplejše) v primerjavi s slovenskimi v 30-letnem obdobju. Stopnja segrevanja je nekoliko bolj izrazita na italijanski strani (naklon 0,0606 °C/leto) v primerjavi s slovensko stranjo (naklon 0,0591 °C/leto). Te ugotovitve poudarjajo prostorsko heterogenost vplivov podnebnih sprememb na Krasu z možnimi posledicami za diferencialno oceno tveganja gozdnih požarov čez nacionalne meje.

Slika 6 - Zgoraj: raztreseni diagram, ki prikazuje povprečne letne vrednosti sevanja od 1993 do 2023. Italijanske postaje so predstavljene z rdečo, slovenske pa z modro barvo. Za vsako skupino držav so prikazane črte linearne regresije (rdeča črta za italijanske postaje, modra črta za slovenske postaje) z ustreznimi 95% intervali zaupanja, predstavljenimi s senčenimi območji. Spodaj: raztreseni diagram, ki prikazuje povprečne letne temperature od 1993 do 2023, s podatkovnimi točkami italijanskih postaj (rdeča barva) in slovenskih postaj (modra barva). Vsaki skupini držav je priložena barvna regresijska črta (rdeča za italijansko, modra za slovensko) s 95% intervali zaupanja, predstavljenimi s senčenimi območji okoli vsake črte.




Specifični podatki po postajah potrjujejo te ugotovitve, saj vse postaje razen ene kažejo trende segrevanja. Povprečno segrevanje na vseh postajah je 1,56 °C, pri čemer so nekatere lokacije zabeležile še večje segrevanje: postaje 2, 8 in 11 so zabeležile temperaturno povišanje nad 3 °C.

Slika 7 - Temperaturne spremembe po postajah. Vodoravni stolpčni graf, ki prikazuje celotno temperaturno spremembo (°C) na vsaki meteorološki postaji med ustreznimi obdobji merjenja. Stolpci so razvrščeni glede na velikost spremembe, od največje (zgoraj) do najmanjše (spodaj). Vsaka postaja je označena z ustreznim obdobjem merjenja v letih. Črčkana rdeča črta označuje povprečno spremembo vseh postaj.




Pri primerjavi desetletij so bila leta 2020 povprečno za 1,38 °C toplejša v primerjavi z devetdesetimi leti na petih reprezentativnih postajah z najpopolnejšimi zgodovinskimi zapisi.

Slika 8 - Primerjava temperatur prvega in zadnjega desetletja. Skupinski vodoravni stolpčni graf, ki primerja povprečne temperature med prvim desetletjem (modri stolpci) in zadnjim desetletjem (oranžni stolpci) obdobja merjenja za vsako postajo. Postaje so razporejene navpično s temperaturnimi vrednostmi, prikazanimi na vodoravni osi. Zelene vrednosti označujejo temperaturno razliko med desetletji.



Te empirične meritve ne potrjujejo le intenzifikacije učinkov podnebnih sprememb na lokalne požarne režime, temveč poudarjajo tudi prostorsko heterogenost v vzorcih segrevanja na Krasu. Prostorsko-časovna analiza gozdnih požarov poleg tega razkriva jasne vzorce v pogostosti vžiga in geografski porazdelitvi, ki se ujemajo z opaženimi temperaturnimi gradienti. Ta vpogled ne validira le pomembnosti podnebnih in antropogenih dejavnikov, uporabljenih pri modeliranju, temveč ponuja tudi dragocene informacije za dolgoročno spremljanje in načrtovanje strategij preprečevanja požarov.

Slika 9 - Toplotna karta s koncentracijo gozdnih požarov na Krasu od 1995 do 2025.



5 INTEGRACIJA V SPLETNI PORTAL KARST FIREWALL 5.0

Zgodovinski nabori podatkov, obdelani v okviru aktivnosti WP2, bodo integrirani v spletni portal Karst Firewall 5.0, ki je trenutno še v fazi razvijanja. Ta digitalna platforma je zasnovana tako, da deluje kot centralizirano vozlišče za analizo požarne ogroženosti, podporo odločanju in spremljanje v realnem času. V tem poglavju je opisano, kako se napovedni algoritmi uporabljajo v digitalnem sistemu za upravljanje in opozarjanje pred gozdnimi požari.

Za zagotovitev učinkovitega dostopa in naprednih funkcij poizvedovanja se zapisi gozdnih požarov shranjujejo v strukturi bazi podatkov MySQL, kar omogoča hitre operacije vrtenja, filtriranja in korelacije med spremenljivkami, kot so čas, lokacija in vzrok. Meteorološki podatki, ki vključujejo velike količine informacij (npr. temperatura, vlažnost, padavine), se shranjujejo v InfluxDB, bazi podatkov, optimizirani za časovne vrste, kar je še posebej primerno za upravljanje podatkov iz visokofrekvenčnih senzorjev.

Ta dvojna arhitektura baze podatkov podpira tako analitično globino kot tudi zmogljivost, kar omogoča napovednim algoritmom, razvitim v tem dokumentu, povezavo s pretoki podatkov v realnem času in preteklosti. Posledično je portal Karst Firewall 5.0 namenjen temu, da postane temeljno operativno orodje za čezmejno pripravljenost in odzivanje na gozdne požare na Krasu.

5.1 METEOROLOŠKI NABORI PODATKOV NA PORTALU KARST FIREWALL

Ta portal zbira in shranjuje meteorološke podatke iz izbranih meteoroloških postaj, navedenih na sledeči strani: <https://karst.way.to.it/weather-station>

Slika 10 - Posnetek zaslona nabora meteoroloških podatkov na platformi Karst Firewall.

#	ID	Name	Station Code	Latitude	Longitude	Altitude	City	Province	Region	Country	Active	Options
1	1	Ayrolle - Dolina	AJDOL-DOLINA	45.888200	13.907300	85	Ayrolle	Ayrolle	Dolina	Slovenia	Yes	 
2	2	Biše	NOVA-GORILLA	45.891800	13.824000	55	Biše	Mura-Kostanjevica	Dolina	Slovenia	Yes	 
3	3	Debeli rti	TRZAS-ZAL	45.801600	13.535200	9	Trzask	Trzask	Obalno-Kraška	Slovenia	Yes	 
4	4	Biše Zora	DEBEL-RTI	45.803200	13.671300	9	Trzask	Trzask	Obalno-Kraška	Slovenia	Yes	 
5	5	Gedige	GOORLE	45.754700	13.843300	320	Gedige	Sežana	Obalno-Kraška	Slovenia	Yes	 
6	6	Koper Kap	KOPER-KAPET-LA	45.548100	13.724600	4	Koper	Koper	Obalno-Kraška	Slovenia	Yes	 
7	7	Koper Luka	KOPER-LUKA	45.564300	13.744800	2	Koper	Koper	Obalno-Kraška	Slovenia	Yes	 

V primeru, da se doda novo postajo, je treba zagotoviti naslednje podrobnosti:

- Ime postaje.
- Koda postaje (uporabljena za edinstveno identifikacijo: pomembno je, da jo vnesete pravilno).
- Koordinate.
- Država.
- Mesto.
- Regija/pokrajina (lahko tudi kot "upravna regija").

Koda postaje je ključnega pomena za identifikacijo postaje v sistemu, zato je pri vnosu potrebno skrbno preveriti ali so vse informacije pravilno navedene, da ne prihaja do napak. V kolikor postaja ni več potrebna, je ni potrebno izbrisati, ampak se jo lahko preprosto označi kot neaktivno, hkrati pa to omogoča, da se ohranijo zgodovinski podatki in doslednost sistema.

Slika 11 - Posnetek zaslona definicije meteorološke postaje na platformi Karst Firewall.



Zbrani podatki se shranjujejo v bazi podatkov časovnih vrst InfluxDB. Uporaba InfluxDB ponuja več prednosti za shranjevanje in poizvedovanje podatkov časovnih vrst:

- Visoka zmogljivost: InfluxDB je optimiziran za podatke s časovnimi žigi, kar omogoča hitro branje in pisanje, tudi z velikimi količinami podatkov.
- Učinkovito shranjevanje: učinkovito stiska podatke, kar omogoča dolgoročno hranjenje zgodovinskih podatkov brez visokih stroškov shranjevanja.

- Analiza v realnem času: idealen za nadzorne plošče in opozorila, kjer so posodobljene informacije ključne.
- Skalabilnost: InfluxDB lahko upravlja podatke iz več naprav ali senzorjev hkrati ne da bi to vplivala na hitrost izvedbe.

5.2 ZBRANI PARAMETRI

Vsaka meteorološka postaja zbira in prenaša vrsto okoljskih parametrov, ki lahko vključujejo naslednje parametre:

- Temperatura.
- Vlažnost.
- Padavine.
- Hitrost vetra.
- Maksimalna hitrost vetra.
- Smer vetra.
- Smer maksimalnega vetra.
- Osončenost.
- Atmosferski tlak (hPa).

Opomba: vse postaje ne zagotavljajo popolnega nabora parametrov. Razpoložljivost podatkov se lahko razlikuje glede na postajo.

Podatki se berejo iz vsake postaje vsaj enkrat na uro. Običajno večina postaj prenaša podatke vsako uro, kar zagotavlja redne posodobitve za spremljanje in analizo, ki sta skoraj v realnem času.

Možno je ogledati zgodovinske podatke vseh meteoroloških postaj na naslednji strani: <https://karst.way.to.it/weather-station-log>

Ta vmesnik omogoča:

- Izbiro časovnega razpona.
- Izbiro specifične meteorološke postaje.
- Ogled podrobnih vremenskih informacij za izbrano obdobje.

kar zagotavlja priročen način za analizo preteklih vremenskih razmer in spremljanje dolgoročnih okoljskih trendov.

Slika 12 - Posnetek zaslona zgodovinskih meteoroloških zapisov na platformi Karst Firewall.

Date Range
2025-04-16 00:00:00 to 2025-04-16 23:59:59
Visualizza 1-20 di 438 elementi.

#	ID	Weather Station	Datetime TT	Temperature	Humidity	Precipitation	Wind Speed	Wind Max Speed	Wind Direction	Wind Direction Max	Radiation	Pressure Hpa	Options
1	8300511	Podnanos	16/04/2025 10:30:00	17.5	74	0	7	12			0	0	
2	8300512	Vodijan	16/04/2025 10:30:00	16	67	0	5	8			330	0	
3	8300505	Biše	16/04/2025 10:30:00	18.9	67	0	2	6			357	1015.1	
4	8300507	Biše Zana	16/04/2025 10:30:00	17.7	64	0	5	8			0	0	
5	8300508	Geolige	16/04/2025 10:30:00	16	64	0	4	11			318	0	

in podrobne vremenske informacije za specifično postajo v izbranem času.

Slika 13 - Posnetek zaslona trenutnih metrik meteorološke postaje na platformi Karst Firewall.


ID	8300505
Weather Station	Biše
Datetime	16/04/2025 10:30:00
Temperature	18.9
Humidity	67
Precipitation	0
Wind Speed	2
Wind Max Speed	6
Wind Direction	45
Wind Direction Max	74
Radiation	357
Pressure Hpa	1015.1

5.3 SISTEM AKTIVACIJE OBVESTIL


Učinkovit sistem upravljanja zaradi tveganja pred gozdnimi požari se ne opira le na natančno zaznavanje, temveč tudi na pravočasno in ciljno komunikacijo ogroženosti. To poglavje opisuje sistem aktivacije obvestil, ki je bil zasnovan za samodejno generiranje, distribucijo in sledenje opozoril, ko modeli umetne inteligence, okoljski senzorji ali nadzorne kamere identificirajo potencialno ogroženost zaradi gozdnih požarov. S prednostno razvrstitvijo opozoril glede na resnost in njihovo posredovanje ustreznim zainteresiranim stranem, vključno z vladnimi agencijami in službami za ukrepanje v nujnih primerih, sistem zagotavlja hitro mobilizacijo in strukturirano odzivanje na incidente. Vključuje konfiguracijske elemente, kot so matrika opozoril, samodejno ustvarjanje incidentov in celovit dnevnik obvestil, ki omogočajo popolno sledljivost in odgovornost skozi celoten proces opozarjanja in odzivanja.

Ko modeli umetne inteligence, senzorji ali kamere identificirajo potencialna tveganja zaradi gozdnih požarov, sistem ustvari opozorilo, ki podrobno opisuje naravo grožnje (npr. "Zaznan požar"), čas zaznave in njeno resnost, pri čemer so opozorila razvrščena glede na raven grožnje. Ta opozorila se samodejno posredujejo zainteresiranim stranem, vključno z vladnimi agencijami in službami za ukrepanje v nujnih primerih, za omogočanje hitre mobilizacije virov, kot so gasilske enote ali droni za oceno situacije. Ob prejemu opozorila, odzivne enote takoj ukrepajo za ublažitev grožnje, gašenje požarov, ustvarjanje požarnih pasov ali izvršujejo druge ukrepe za zaježitev. Vsaka dejanja se zabeleži v sistem za analizo in pregled po incidentu. Za omogočitev avtomatiziranega upravljanja tveganja gozdnih požarov se sistem opozarjanja najprej konfigurira prek vmesnika matrike opozoril, kot prikazuje posnetek zaslona. Ta konfiguracija vključuje opredelitev opisa opozorila, frekvence in pogojev aktivacije, kot so incidenti, zaznani z UI, senzorji ali kamerami. Možno je vključiti ali izključiti specifične lokacije in dodeliti prejemnike ali vloge za zagotovitev, da opozorila dosežejo pravilne zainteresirane strani prek določenih komunikacijskih kanalov. Ta fleksibilna matrika zagotavlja pravočasne in ciljne odzive na pred grožnjami zaradi gozdnih požarov.

Slika 14 - Posnetek zaslona orodja matrike opozoril na platformi Karst Firewall.



Slika 15 - Posnetek zaslona konfiguracije matrike opozoril na platformi Karst Firewall.



Create Alert Matrix

Home > Alert Matrix > Create Alert Matrix

Create Alert Matrix

Base Alert Matrix Data

Description *

Cms Page *

Select ...

Active

No

Frequency, (min)

Trigger Incident

Off

Included Locations


Select ...

Excluded Locations

Select ...

Ko so opozorila aktivirana in obvestila poslana, se samodejno zabeležijo v dnevnik obvestil, kot prikazuje posnetek zaslona. Ta razdelek ponuja pregled vsakega obvestila, ki ga je mogoče iskati in filtrirati, vključno s podrobnostmi, kot so ID opozorila, uporabnik prejema, komunikacijski kanal, naslov e-pošte, časovni žig pošiljanja in status dostave. Ta dnevnik zagotavlja popolno sledljivost komunikacij opozarjanja, kar podpira preverljivost in preglednost sistema.

Slika 16 - Posnetek zaslona dnevnika obvestil za opozorila na platformi Karst Firewall.



Za opozorila, ki zahtevajo aktivacijo incidenta, je sistem nastavljen tako, da samodejno ustvari incident, ko se takšno opozorilo aktivira. Ta novoustvarjeni incident označuje začetek strukturiranega odzivnega procesa, ki vključuje:

- Incident: Ustvarjen takoj po aktivaciji opozorila.
- Intervencija: Dejanja, ki se izvedejo kot odziv na incident.
- Vključeno osebje: Seznam oseb, zadolženih za upravljanje incidenta.
- Oprema: Viri in orodja, uporabljena med intervencijo.

Ta delovni tok zagotavlja, da se kritični dogodki ne le zabeležijo, temveč jim sledijo tudi sistematični in sledljivi odzivi, ki vključujejo potrebne človeške in materialne vire.

Slika 17 - Posnetek zaslona nadzorne plošče za spremljanje incidentov, ki jih povzročajo gozdni požari na platformi Karst Firewall.



Slika 18 - Seznam posnetkov zaslona gozdnih požarov na platformi Karst Firewall.

Incidents
Dashboards

Create

Visualizzo 1-20 di 38.580 elementi.

#	ID FF	Code	Us ID	Status	Opzioni
				Select ...	
1	48579	2020_11981205_SMALL PINES	(nessun valore)		 
2	48578	2020_11981111_FOOT PRINT	(nessun valore)		 
3	48577	2020_11981035_DUBOIS	(nessun valore)		 
4	48576	2020_11980985_BIG SNAG	(nessun valore)		 
5	48575	2020_11980913_SWITCHBACK	(nessun valore)		 
6	48574	2020_11980821_COW CREEK	(nessun valore)		 
7	48573	2020_11980770_LITTLE CHIEF	(nessun valore)		 
8	48572	2020_11980587_CREEK 5	(nessun valore)		 
9	48571	2020_11980528_ROCK STATION	(nessun valore)		 
10	48570	2020_11980510_LEFT FIELD	(nessun valore)		 
11	48569	2020_11980377_COUNTY ROAD 205	(nessun valore)		 

Slika 19 - Posnetek zaslona povzetka upravljanja incidentov na platformi Karst Firewall.

Update Incident: 48579 [Dashboards](#)

[Home](#) • [Incidents](#) • [Update](#)

[General](#) [Characteristics](#) [Interventions](#) [Damage](#)

Basic Information

Report Date:

Year:

Day Of Week:

Time and Location

Fire Start:


Fire End:

Total Fire Duration, (min):

Forest:

Location:

Expected Containment Location:



6 SKLICI

[1] Development and Structure of Prometheus: the Canadian Wildland Fire Growth Simulation Model
https://spyd.com/fgm.ca/Prometheus_Information_Report_NOR-X-417_2010.pdf

[2] COM Documentation for Programmers <https://firegrowthmodel.ca/resources/com/PrometheusCOM/index.html>

[3] Mapping Variable Wildfire Source Areas Through Inverse Modeling - DOI: 10.3390/fire7120454
https://www.researchgate.net/publication/386399479_Mapping_Variable_Wildfire_Source_Areas_Through_Inverse_Modeling

[4] Adversarial Robustness for Deep Learning-Based Wildfire Prediction Models - DOI 10.3390/fire8020050 https://www.researchgate.net/publication/388448962_Adversarial_Robustness_for_Deep_Learning-Based_Wildfire_Prediction_Models

[5] Atmospheric Modeling for Wildfire Prediction - DOI 10.3390/atmos16040441 https://www.researchgate.net/publication/390678489_Atmospheric_Modeling_for_Wildfire_Prediction

[6] Machine Learning based Wildfire Area Estimation Leveraging Weather Forecast Data - DOI: 10.5815/ijitcs.2025.01.01 https://www.researchgate.net/publication/388820171_Machine_Learning_based_Wildfire_Area_Estimation_Leveraging_Weather_Forecast_Data

[7] Predicting Wildfires Using Machine Learning Methods - DOI: 10.55525/tjst.1063284 - https://www.researchgate.net/publication/363225926_Predicting_Wildfires_Using_Machine_Learning_Methods

[8] Seber, G. A. in Lee, A. J., "Linear Regression Analysis", Vol. 329, John Wiley & Sons, 2012.

[9] Trucchia, A.; Meschi, G.; Fiorucci, P.; Gollini, A.; Negro, D. Definition of Wildfire Susceptibility Maps in Italy to Understand Seasonal Wildfire Regimes at the National Level. Fire 2022, 5, 30.
<https://doi.org/10.3390/fire5010030>

7 DODATEK A

Analiza, predstavljena v tej študiji, temelji na podatkih, zbranih iz 21 meteoroloških postaj, razpršenih na Krasu. Tabela A.1 zagotavlja popolne informacije o vsaki postaji, vključno z geografskimi koordinatami, nadmorsko višino in identifikacijsko kodo. Tabela A.2 prikazuje porazdelitev postaj po regiji.

Slika 20 - Položaji meteoroloških postaj, upoštevanih za zgodovinske meteorološke podatke.




Tabela A1 - Seznam meteoroloških postaj ARPA (Italija) in ARSO (Slovenija), uporabljenih v okviru projekta.

ID	IME	DRŽAVA	LATITUDA	LONGITUDA	NADM. VIŠINA
1	Ajdovščina - Dolenje	Slovenija	45.866200	13.901300	86
2	Bilje	Slovenija	45.895600	13.624000	55
3	Debeli rtic	Slovenija	45.591600	13.705200	0
4	Boja Zora	Slovenija	45.603200	13.671300	0
5	Godnje	Slovenija	45.754700	13.843300	320
6	Koper Kap	Slovenija	45.548100	13.724600	4
7	Koper Luka	Slovenija	45.564500	13.744800	2
8	Nova Gorica	Slovenija	45.955600	13.652400	112
9	Piran	Slovenija	45.548100	13.545400	0
10	Podnanos	Slovenija	45.804500	13.965900	153
11	Škocjan	Slovenija	45.663800	13.993100	420
12	Vedrijan	Slovenija	46.013100	13.541000	232
13	Gorizia Aeroporto	Italija	45.910390	13.595497	68
14	Monfalcone Pluvio	Italija	45.780471	13.536554	0
15	Sgonico-Zgonik	Italija	45.738004	13.742056	268
16	Trieste Ist. Nautico	Italija	45.647393	13.764540	30
17	Trieste molo F.lli Bandiera	Italija	45.649996	13.752242	1
18	Borgo Grotta Gigante	Italija	45.709385	13.764681	275
19	Gradisca	Italija	45.889791	13.481807	29