Napovedovanje na podlagi scenarijev in blaženje okoljskih tveganj

Učni izidi

Po zaključku te teme bodo študenti znali:

- Razložiti koncept scenarijskega napovedovanja pri analizi okoljskih in podnebnih podatkov.
- Opisati postopek agregiranja časovnih vrst okoljskih podatkov v letne podnebne kazalnike in razložiti njegovo vlogo pri analizi dolgoročnih tveganj.
- Uporabiti metodo nenadzorovanega strojnega učenja (k-sredin) za razvrščanje podnebnih let v gruče glede na njihove splošne značilnosti.
- Razložiti dobljene gruče kot različne podnebne scenarije
- Razpravljati o tem, kako lahko rezultati scenarijske analize podprejo odločanje

Uvod

Sodobni sistemi za spremljanje okolja so vse bolj odvisni od neprekinjenega zbiranja podatkov iz različnih virov, med katerimi so omrežja senzorjev, vremenske postaje, satelitska opazovanja in odprte ekološke zbirke podatkov. Ti sistemi redno ustvarjajo velike količine podatkov in zagotavljajo podlago za spremljanje stanja okolja v daljših časovnih obdobjih.

V nasprotju s tradicionalnimi analitičnimi metodami, ki pogosto temeljijo na statičnih ali omejenih zbirkah podatkov, je spremljanje okolja dinamičen proces, pri katerem se podatki neprekinjeno zbirajo in posodabljajo. V takem okolju strojno učenje ne obsega le razvoja posameznih modelov, temveč tudi vzdrževanje stalnega analitičnega pristopa za obravnavo časovno strukturiranih podatkov in izvajanje dolgoročnih analiz.

Najpomembnejše okoljske spremenljivke, kot so ravni onesnaževal zraka, temperatura, padavine ali morska gladina, so naravno organizirane kot časovne vrste. Ti podatki izkazujejo sezonskost, kratkoročna nihanja in dolgoročne trende, zato so potrebne metode, ki analizirajo spreminjanje razmer skozi čas in se ne omejujejo le na opazovanje trenutnega stanja.

V tem okviru strojno učenje ponuja metode za spremljanje trendov in odkrivanje anomalij v okoljskih podatkih. Da bi bile te metode praktično uporabne v operativnih sistemih, jih je treba vključiti v širši okvir upravljanja ekoloških podatkov in jih ne uporabljati kot ločena analitična

orodja. Tako lahko podpirajo premišljene in odgovorne okoljske odločitve, kot so zgodnje odkrivanje težav s kakovostjo zraka, ocenjevanje tveganja izrednih vremenskih dogodkov ali spremljanje dolgoročnih sprememb morske gladine.

Od neprekinjenega spremljanja okolja do podnebnih scenarijev

Pri dolgoročnem spremljanju okolja je opiranje zgolj na posamezne meritve ali kratka časovna obdobja pogosto nezadostno. Za odkrivanje pomembnih sprememb, povezanih s podnebnimi tveganji, se podatki praviloma povzamejo za daljša obdobja, na primer po letih. Ta metoda omogoča, da posamezno leto predstavlja celovit posnetek okoljskih razmer in ne le skupek ločenih meritev.

Poleg povprečnih vrednosti so pri analizi okoljskih tveganj ključni tudi izredni dogodki, kot so vročinski valovi ali sušna obdobja. Njihov pomen ne izhaja le iz njihove intenzivnosti, temveč tudi iz pogostosti pojavljanja in trajanja. Zato analiza poleg povprečnih temperatur in padavin upošteva tudi pogostost, trajanje in kombinacije škodljivih razmer.

Če te kazalnike obravnavamo skupaj, lahko vsako leto opišemo z naborom značilk, ki skupaj določajo njegov podnebni profil. Nato je mogoče s tehnikami strojnega učenja ugotoviti podobnosti med leti in jih razvrstiti v gruče glede na njihove skupne značilnosti.

Algoritem gručenja z metodo k-sredin v okviru okoljskih podatkov

Metoda k-sredin [1], [2], [3] je preprost in široko uporabljen algoritem gručenja za ugotavljanje podobnosti v velikih zbirkah podatkov. Njena osnovna zamisel je razdeliti podatke v določeno število gruč, pri čemer vsaka gruča vsebuje zapise, ki so si glede na opazovane značilke najbolj podobni. Pri tej metodi je vsako leto predstavljeno z naborom številskih značilk, algoritem pa vse značilke obravnava hkrati in išče splošno podobnost med zapisi, namesto da bi jih primerjal le po eni spremenljivki.

V praksi algoritem začne z začetnimi ocenami središč gruč. Nato jih večkrat prilagodi, da zmanjša razdaljo med vsakim zapisom in središčem njegove gruče. Postopek se nadaljuje, dokler se razporeditev zapisov med gručami ne ustali. Rezultat so gruče, ki predstavljajo skupne vzorce v podatkih.

Pri okoljskih analizah metoda k-sredin razvršča različna časovna obdobja, na primer posamezna leta, v gruče glede na njihov celotni podnebni profil in ne le glede na eno spremenljivko. Ta metoda pomaga prepoznati stabilne, prehodne in izredne podnebne razmere, ne da bi se pri tem opirala na vnaprej določene pragove ali pravila.

Predstavljajmo si, da vsako leto spremljamo nekaj preprostih kazalnikov, kot so povprečna temperatura, število zelo vročih dni in število dni brez dežja. Če te kazalnike obravnavamo ločeno, se vsako leto zdi edinstveno, zato jih je težko jasno opisati.

Ko pa vse kazalnike obravnavamo skupaj, nekatera leta izkazujejo zelo podobne vzorce, kot prikazuje slika 5.1. Nekatera leta imajo na primer lahko zmerne temperature, redke vročinske valove in dovolj padavin. V drugi polovici leta so temperature navadno višje, vročinski valovi pogostejši, sušna obdobja pa daljša.

V tem primeru algoritem k-sredin števila gruč ne določi vnaprej, temveč samodejno zazna gruče med seboj najbolj podobnih let glede na vse opazovane kazalnike. Vsako dobljeno gručo lahko razložimo kot značilen podnebni vzorec.

Ena gruča lahko predstavlja stabilnejša in zmernejša leta, druga lahko ustreza izrazitemu toplotnemu stresu, tretja pa je lahko povezana z izredno vročino in sušo. Pri analizi nove zbirke podatkov lahko vsako leto primerjamo s temi vzorci in ga na podlagi njegovih značilnosti uvrstimo v gručo, ki ji je najbolj podobno.

Spodaj opisana študija primera temelji na tem konceptu. Z uporabo dolgoročnih meteoroloških časovnih vrst razvrščа dejanska podnebna leta in jih analizira v okviru podnebnih tveganj.

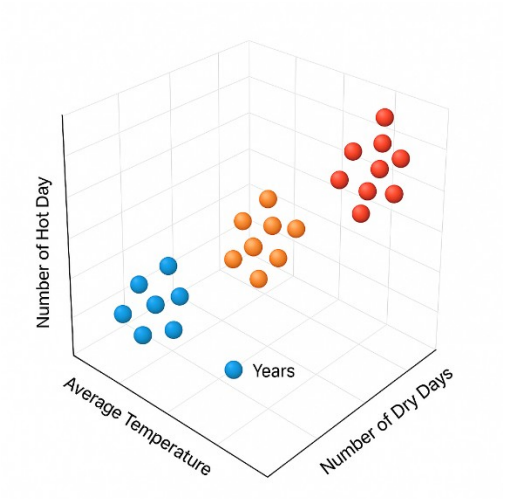

Slika 5.1 Ponazoritveni primer gručenja letnih podnebnih profilov

Prevod napisov na sliki: Osi prikaza: povprečna temperatura, število suhih dni in število vročih dni; točke predstavljajo leta.

Študija primera: analiza podnebnih tveganj na podlagi meteoroloških časovnih vrst

Vir podatkov Open-Meteo

V tej študiji primera je platforma Open-Meteo [4] uporabljena kot referenčni vir vremenskih podatkov. Open-Meteo prek javno dostopnega programskega vmesnika (API) omogoča brezplačen dostop do zgodovinskih vremenskih podatkov za katero koli lokacijo na svetu, pri čemer lahko uporabniki izberejo časovno obdobje in nabor vremenskih spremenljivk. Zgodovinski podatki segajo v leto 1940, najnovejši zapisi pa so na voljo z manjšim zamikom (do enega dneva).

Čeprav je osnovni dostop do podatkov brezplačen, Open-Meteo brezplačni model uporabe omejuje s številom klicev API in razpoložljivostjo naprednih funkcij. Poklicnim in poslovnim uporabnikom so na voljo razširjeni paketi API, ki ponujajo višje omejitve, več zbirk podatkov in zanesljivejšo infrastrukturo.

Podatki platforme Open-Meteo izvirajo iz javnih virov, med katerimi so državne meteorološke agencije in podnebne reanalize. Zagotovljeni so pod licenco Creative Commons Attribution 4.0 (CC BY 4.0), kar pomeni, da morajo uporabniki navesti njihov vir. Ta licenca dovoljuje uporabo podatkov pri izobraževalnem in raziskovalnem delu ter hkrati spodbuja preglednost in ponovljivost analize.

Prenos je treba izvesti prek preprostega spletnega vmesnika, v katerem se določijo geografska lokacija, časovno obdobje (slika 5.2), časovna ločljivost (urna ali dnevna) in izbrane meteorološke spremenljivke. Ta metoda zagotavlja natančno in dosledno zbiranje podatkov za različne lokacije ter scenarije analize.

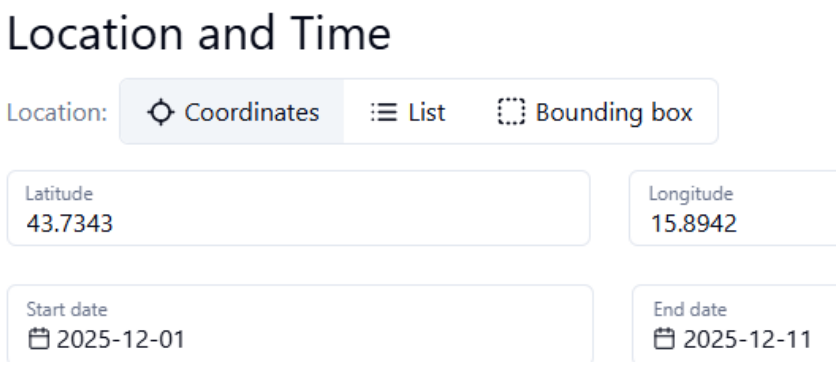

Slika 5.2 Izbira lokacije podatkov in časovne vrste na platformi Open-Meteo

Prevod napisov na sliki: Lokacija in čas: izberete lahko koordinate, seznam ali omejitveni okvir; zemljepisna širina 43.7343, zemljepisna dolžina 15.8942; začetni datum 1. 12. 2025 in končni datum 11. 12. 2025.

Primer gručenja podnebnih let

Za analizo podnebnih tveganj je pomembno izbrati le spremenljivke, ki so neposredno povezane z dolgoročnimi spremembami in okoljskim stresom ter katerih pomen je jasno razumljiv. V tem okviru bo poudarek na spremenljivkah, ki opisujejo toplotne razmere, hidrološko bilanco in izredne vremenske dogodke.

Osnovni kazalniki toplotnega stresa vključujejo povprečno dnevno temperaturo zraka na višini 2 metrov (povprečna temperatura (2 m) – temperature_2m_mean) in najvišjo dnevno temperaturo zraka (najvišja temperatura (2 m) – temperature_2m_max). Te meritve bodo pomagale spremljati dolgoročne trende segrevanja in prepoznavati obdobja izredne vročine. Poleg tega bo za natančnejšo oceno toplotne obremenitve ljudi in okolja uporabljena povprečna občutena temperatura na višini 2 metrov (apparent_temperature_mean), ki upošteva učinke vlažnosti in vetra.

Za ocenjevanje hidrološkega in sušnega stresa bodo izbrane spremenljivke, ki opisujejo razpoložljivost in izgubo vode v okolju. Skupna dnevna količina padavin (vsota padavin – precipitation_sum) bo uporabljena za oceno vnosa vode v sistem, referenčna evapotranspiracija (referenčna evapotranspiracija – et0_fao_evapotranspiration) pa bo predstavljala morebitno izgubo vode zaradi izhlapevanja in transporta. Povprečna vlažnost tal v plasti od 0 do 100 cm (povprečna vlažnost tal (0–100 cm) – soil_moisture_0_100cm_mean) bo kazalnik dejanske razpoložljivosti vode v tleh in dolgotrajnega sušnega stresa.

Kot dopolnilne spremenljivke, ki zagotavljajo širši meteorološki okvir in pomagajo pri razlagi rezultatov, bodo uporabljene največja hitrost vetra (največja hitrost vetra (10 m) – wind_speed_10m_max), povprečna relativna vlažnost (povprečna relativna vlažnost (2 m) –

relative_humidity_2m_mean) in povprečni zračni tlak, preračunan na morsko gladino (povprečni tlak na morski gladini – pressure_msl_mean). Čeprav te spremenljivke niso osrednji del analize, bodo izboljšale razumevanje razmer, v katerih se podnebna tveganja razvijajo in spreminjajo.

Obdobje opazovanja in časovni obseg analize

Za analizo podnebnih tveganj bodo uporabljeni zgodovinski meteorološki podatki od 1. januarja 1950 do 31. decembra 2024. Izbrano obdobje zagotavlja dovolj dolgo časovno vrsto za prepoznavanje dolgoročnih sprememb toplotnih in hidroloških razmer, obenem pa ohranja razmeroma visoko in stabilno kakovost podatkov, ki je bistvena za natančno analizo in razlago.

Podatki bodo preneseni v dnevni časovni ločljivosti, ki zagotavlja ravnovesje med časovno podrobnostjo in stabilnostjo časovne vrste. Dnevna ločljivost pomaga spremljati sezonske vzorce in spremembe pogostosti neugodnih razmer ter hkrati zmanjšuje šum in kratkoročna nihanja, značilna za podatke z višjo časovno ločljivostjo.

Analitični potek dela in uporaba metod strojnega učenja

Pri analizi toplotnih in hidroloških kazalnikov poudarek ne bo zgolj na ugotavljanju prisotnosti pričakovanih in dobro znanih sezonskih vzorcev (na primer poletnih sušnih obdobij), temveč na tem, kako se njihove značilnosti spreminjajo v daljših časovnih obdobjih. Analiza bo posebej preučila spremembe pogostosti, trajanja in intenzivnosti neugodnih razmer ter morebitne spremembe časa njihovega pojavljanja znotraj leta.

Pri hidrološkem stresu se bo analiza osredotočila na obdobja, v katerih se razpoložljivost vode v tleh zmanjšuje več zaporednih let, hkrati pa se povečuje evapotranspiracija. Ocenila bo tudi, ali se ta obdobja v sezoni pojavljajo prej, trajajo dlje ali so intenzivnejša kot v prejšnjih letih. Take spremembe kažejo na večje tveganje suše, četudi sezonski vzorec pojava ostaja nespremenjen.

Podobno kazalniki vročine ne bodo spremljali le poletnih najvišjih vrednosti, temveč tudi spremembe števila vročih dni, trajanja vročinskih obdobij in pogostosti visokih temperatur zunaj običajnih sezonskih razponov. Tako je mogoče razlikovati med naravnimi sezonskimi vzorci in dolgoročnimi premiki, ki neposredno vplivajo na podnebna tveganja.

Uvoz podatkov v podatkovno skladišče Oracle

Preneseni meteorološki podatki se uvozijo prek vgrajenega vmesnika Data Load v podatkovnem skladišču Oracle Autonomous Data Warehouse [5]. Vmesnik omogoča nalaganje

podatkov iz lokalnih datotek .xlsx in njihovo samodejno pretvorbo v relacijske tabele v zbirki podatkov, kot prikazuje slika 5.3.

Med nalaganjem se določi ime ciljne tabele, stolpci Excelove datoteke pa se preslikajo v ustrezne podatkovne tipe zbirke podatkov. Datumski zapisi se shranijo kot časovni atributi, številske meteorološke spremenljivke pa se naložijo kot številske vrednosti, primerne za nadaljnjo analizo, kot prikazuje slika 5.4.

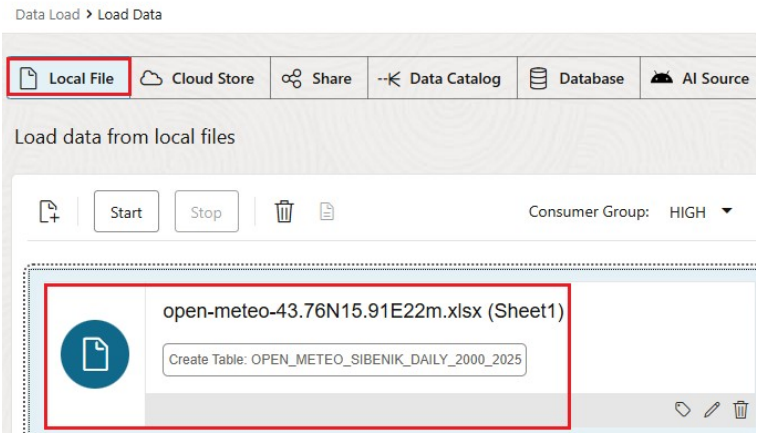

Slika 5.3 Vmesnik Data Load za uvoz meteoroloških podatkov v obliki XLSX

Prevod napisov na sliki: Nalaganje podatkov: lokalna datoteka, shramba v oblaku, skupna raba, katalog podatkov, podatkovna zbirka ali vir umetne inteligence. Drugi napisi: naloži podatke iz lokalnih datotek; zaženi, ustavi; potrošniška skupina – visoka; ustvari tabelo.

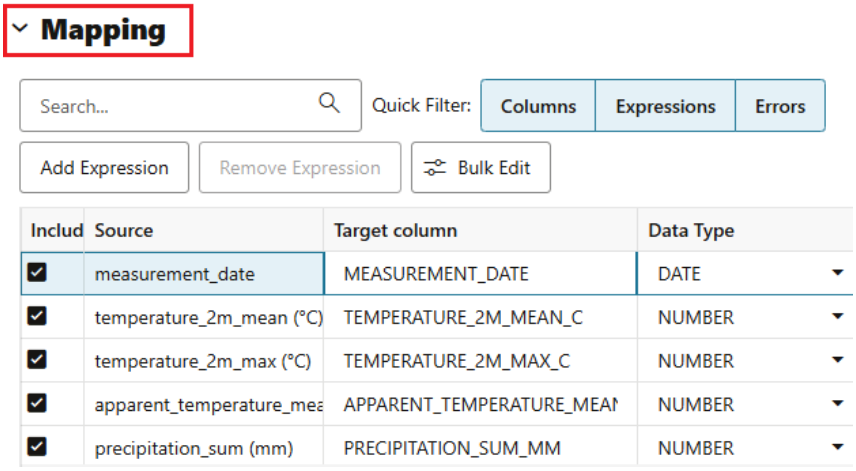

Slika 5.4 Preslikava stolpcev iz Excelove datoteke v podatkovne tipe zbirke podatkov med uvozom

Prevod napisov na sliki: Preslikava: iskanje; hitri filter – stolpci, izrazi, napake; dodaj izraz, odstrani izraz, množično urejanje. Glave tabele: vključi, vir, ciljni stolpec in podatkovni tip.

Rezultat tega postopka je strukturirana tabela z dnevnimi časovnimi vrstami izbranih meteoroloških spremenljivk za opazovano lokacijo (Šibenik) in določeno obdobje (od 1. 1. 1940 do 31. 12. 2024), kot prikazuje slika 5.5.

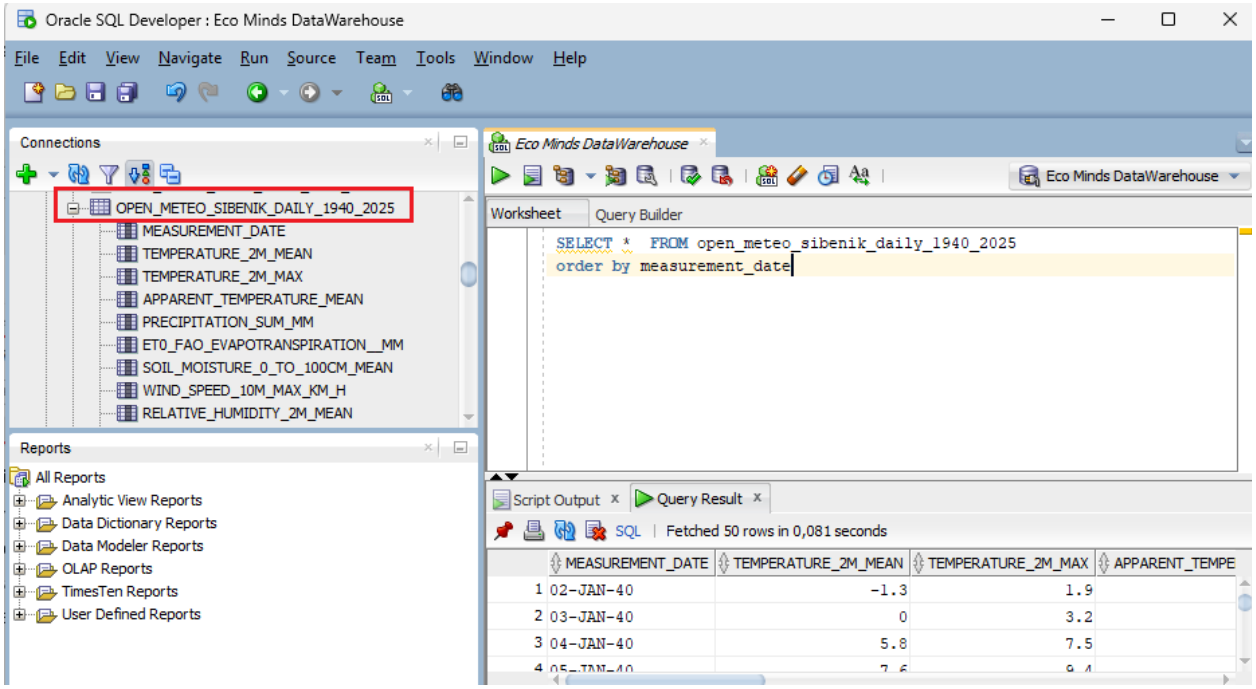

Slika 5.5 Struktura tabele OPEN_METEO_SIBENIK_DAILY_1940_2025 z dnevnimi meteorološkimi podatki

Prevod napisov na sliki: Oracle SQL Developer – podatkovno skladišče Eco Minds. Meniji: datoteka, urejanje, pogled, krmarjenje, zaženi, izvorna koda, ekipa, orodja, okno in pomoč. Plošče: povezave; poročila – vsa poročila, poročila analitičnih pogledov, podatkovnega slovarja, modelirnika podatkov, OLAP, TimesTen in uporabniško določena poročila; delovni list; graditelj poizvedb; izhod skripta; rezultat poizvedbe. Pridobljenih 50 vrstic v 0,081 sekunde.

Agregiranje podatkov in oblikovanje značilk

Po uvozu dnevnih meteoroloških meritev v relacijsko zbirko podatkov je naslednji korak agregiranje podatkov in oblikovanje letnih vhodnih značilk (nabora značilk). Ker je cilj analize prepoznati dolgoročne vzorce in tipe podnebnih let, se dnevni zapisi pretvorijo v letne povzetke, ki toplotne, hidrološke in izredne razmere posameznega leta opišejo kot en sam večrazsežni zapis.

Agregiranje se izvede s poizvedbo SQL, ki uporablja več skupnih izrazov tabel (CTE). Vsak del izračuna določen nabor kazalnikov, rezultati pa se združijo v eno tabelo letnih značilk.

V bloku yearly_temps se letni toplotni profil oblikuje s statističnimi merami temperature zraka na višini 2 metrov in temperature površine. Za vsako leto se izračunajo:

- povprečje in mediana povprečne dnevne temperature (AVG, PERCENTILE_CONT(0.5)), ki skupaj zajemata »značilno« temperaturo in robustno mero, manj občutljivo na skrajne vrednosti,
- najmanjše in največje vrednosti (MIN, MAX), pri čemer se največja vrednost določi iz temperature_2m_max, da se bolje zajame izredna toplotna obremenitev,
- podobne mere občutene temperature (apparent_temperature_mean) kot kazalnik dejanskega toplotnega stresa, ki vključuje vpliv vlažnosti in vetra,
- poleg tega se kot kontekstualna spremenljivka izračuna povprečna relativna vlažnost, ki pomaga razložiti razlike med »suho vročino« in obdobji povečane toplotne obremenitve zaradi vlažnosti.

Izredni vročinski dogodki se ocenijo z merili za vročinske valove. V razdelku heatwave se najprej prepoznajo zaporedni dnevi, ko temperature_2m_max presega 30 °C. Zaporednost se določi z združevanjem zaporednih datumov na podlagi razlike med datumom in zaporedno številko. Kot vročinski valovi se razvrstijo samo obdobja, ki trajajo vsaj 5 dni (HAVING COUNT(*) >= 5). Na podlagi teh obdobij heatwave_stats izračuna letne skupne vrednosti.

- število vročinskih valov v letu,
- povprečno, najkrajše in najdaljše trajanje vročinskega vala.

Poleg same ravni temperature se tako zajame tudi struktura izrednih dogodkov (na primer njihova pogostost in trajanje), kar je bistveno za razumevanje podnebnega tveganja.

Za celovito opredelitev sušnega tveganja, ki ne temelji zgolj na padavinah, je bil v zbirki podatkov **yearly_drought** uveden sestavljeni kazalnik »dan s tveganjem za sušo«. Tak dan je opredeljen kot sočasna izpolnitev treh pogojev:

- zelo malo padavin (precipitation_sum_mm<1),
- visoka referenčna evapotranspiracija (et0_fao_evapotranspiration__mm>4),
- nizka vlažnost tal (soil_moisture_0_to_100cm_mean <0,20).

Poleg tega se ločeno določijo dnevi z visoko evapotranspiracijo in nizko vlažnostjo tal, kar omogoča razlikovanje med leti, v katerih prevladuje »atmosferska potreba po vodi«, in leti, v katerih je glavna težava dolgotrajno pomanjkanje vode v tleh. Tako sušni stres ni pretirano poenostavljen na en sam signal, temveč je modeliran kot funkcija vnosov (padavine), izgub (ET0) in dejanske razpoložljivosti vode (vlažnost tal).

Blok **yearly_wind** razširi opis izrednih vetrovnih razmer z naslednjima kazalnikoma:

- največja hitrost vetra, zabeležena v letu,
- število dni z močnim vetrom (prag 50 km/h).

Ti kazalniki niso osrednji predmet analize toplotno-hidrološkega tveganja, vendar pomagajo pri razumevanju izrednih dogodkov, pomembnih za operativno spremljanje in upravljanje tveganj.

Končni SELECT združi vse izračunane nabore letnih značilk v en rezultat. Za kazalnike, ki niso nujno prisotni v vsakem letu (na primer vročinski valovi), uporabi LEFT JOIN, manjkajoče vrednosti pa nadomesti z nič (COALESCE). Rezultat je letna zbirka vhodnih značilk, v kateri je vsako leto en zapis z več dejavniki okoljskega stresa: vročino, padavinami, sušo in vetrom. Ta matrika značilk predstavlja vhodni podatkovni prostor za nadaljnjo uporabo metod nenadzorovanega strojnega učenja (na primer metode k-sredin).

```
WITH yearly_temps AS (
  SELECT
    EXTRACT(YEAR FROM measurement_date) AS year,

    -- Statistika temperature zraka
    ROUND(AVG(temperature_2m_mean), 1) AS avg_year_temp,
    ROUND(
      PERCENTILE_CONT(0.5)
      WITHIN GROUP (ORDER BY temperature_2m_mean),
      1
    ) AS median_year_temp,
    MIN(temperature_2m_mean) AS min_year_temp,
    MAX(temperature_2m_max) AS max_year_temp,

    -- Občutena temperatura (toplotni stres)
    ROUND(AVG(apparent_temperature_mean), 1) AS avg_apparent_temp,
    ROUND(
      PERCENTILE_CONT(0.5)
      WITHIN GROUP (ORDER BY apparent_temperature_mean),
      1
    ) AS median_apparent_temp,
    MIN(apparent_temperature_mean) AS min_apparent_temp,
    MAX(apparent_temperature_mean) AS max_apparent_temp,

    -- Relativna vlažnost
    ROUND(AVG(relative_humidity_2m_mean), 1) AS avg_relative_humidity

  FROM open_meteo_sibenik_daily_1940_2025
  WHERE measurement_date BETWEEN
        DATE '1950-01-01' AND DATE '2024-12-31'
  GROUP BY EXTRACT(YEAR FROM measurement_date)
```

```
),
yearly_hydrology AS (
  SELECT
    EXTRACT(YEAR FROM measurement_date) AS year,

    -- Hidrološki kazalniki
    COUNT(CASE WHEN precipitation_sum_mm < 1 THEN 1 END) AS dry_days,
    COUNT(CASE WHEN precipitation_sum_mm >= 1 THEN 1 END) AS rainy_days,
    MAX(precipitation_sum_mm) AS max_daily_precipitation_mm

  FROM open_meteo_sibenik_daily_1940_2025
  WHERE measurement_date BETWEEN
        DATE '1950-01-01' AND DATE '2024-12-31'
  GROUP BY EXTRACT(YEAR FROM measurement_date)
),
heatwaves AS (
  SELECT
    grp,
    MIN(measurement_date) AS start_date,
    COUNT(*) AS duration_days
  FROM (
    SELECT
      measurement_date,
      measurement_date
        - ROW_NUMBER() OVER (ORDER BY measurement_date) AS grp
    FROM open_meteo_sibenik_daily_1940_2025
    WHERE measurement_date BETWEEN
          DATE '1950-01-01' AND DATE '2024-12-31'
      AND temperature_2m_max > 30
  )
  GROUP BY grp
  HAVING COUNT(*) >= 5
),
heatwave_stats AS (
  SELECT
    EXTRACT(YEAR FROM start_date) AS year,

    -- Kazalniki vročinskih valov
    COUNT(*) AS heatwave_count,
    ROUND(AVG(duration_days), 1) AS heatwave_avg_duration_days,
    MIN(duration_days) AS heatwave_min_duration_days,
    MAX(duration_days) AS heatwave_max_duration_days

  FROM heatwaves
  GROUP BY EXTRACT(YEAR FROM start_date)
),
yearly_drought AS (
  SELECT
    EXTRACT(YEAR FROM measurement_date) AS year,

    -- Kombinirano tveganje za sušo (izpolnjeni vsi pogoji)
    COUNT(
      CASE
```

```
        WHEN precipitation_sum_mm < 1
         AND et0_fao_evapotranspiration__mm > 4
         AND soil_moisture_0_to_100cm_mean < 0.20
        THEN 1
      END
    ) AS drought_risk_days,

    -- Posamezni pogoji, povezani s sušo
    COUNT(
      CASE
        WHEN et0_fao_evapotranspiration__mm > 4
        THEN 1
      END
    ) AS high_et0_days,

    COUNT(
      CASE
        WHEN soil_moisture_0_to_100cm_mean < 0.20
        THEN 1
      END
    ) AS low_soil_moisture_days

  FROM open_meteo_sibenik_daily_1940_2025
  WHERE measurement_date BETWEEN
        DATE '1950-01-01' AND DATE '2024-12-31'
  GROUP BY EXTRACT(YEAR FROM measurement_date)
),
yearly_wind AS (
  SELECT
    EXTRACT(YEAR FROM measurement_date) AS year,

    -- Ekstremne vrednosti vetra
    MAX(wind_speed_10m_max_km_h) AS max_wind_speed_km_h,
    COUNT(
      CASE
        WHEN wind_speed_10m_max_km_h > 50
        THEN 1
      END
    ) AS strong_wind_days_50kmh

  FROM open_meteo_sibenik_daily_1940_2025
  WHERE measurement_date BETWEEN
        DATE '1950-01-01' AND DATE '2024-12-31'
  GROUP BY EXTRACT(YEAR FROM measurement_date)
)
SELECT
  t.year,

  -- Kazalniki vročinskih valov
  COALESCE(h.heatwave_count, 0) AS heatwave_count,
  COALESCE(h.heatwave_avg_duration_days, 0) AS heatwave_avg_duration_days,
  COALESCE(h.heatwave_min_duration_days, 0) AS heatwave_min_duration_days,
  COALESCE(h.heatwave_max_duration_days, 0) AS heatwave_max_duration_days,
```

```
  -- Temperatura zraka
  t.avg_year_temp,
  t.median_year_temp,
  t.min_year_temp,
  t.max_year_temp,

  -- Občutena temperatura
  t.avg_apparent_temp,
  t.median_apparent_temp,
  t.min_apparent_temp,
  t.max_apparent_temp,

  -- Relativna vlažnost
  t.avg_relative_humidity,

  -- Hidrologija
  y.dry_days,
  y.rainy_days,
  y.max_daily_precipitation_mm,

  -- Sušni stres
  COALESCE(d.drought_risk_days, 0) AS drought_risk_days,
  COALESCE(d.high_et0_days, 0) AS high_et0_days,
  COALESCE(d.low_soil_moisture_days, 0) AS low_soil_moisture_days,

  -- Veter
  w.max_wind_speed_km_h,
  w.strong_wind_days_50kmh

FROM yearly_temps t
LEFT JOIN heatwave_stats h ON t.year = h.year
JOIN yearly_hydrology y ON t.year = y.year
LEFT JOIN yearly_drought d ON t.year = d.year
LEFT JOIN yearly_wind w ON t.year = w.year
ORDER BY t.year;
```

Analiza in vizualizacija agregiranih letnih kazalnikov

Na podlagi letnih agregiranih vrednosti, izračunanih s poizvedbo SQL, opisano v prejšnjem podpoglavju, je bila izvedena vizualna analiza ključnih toplotnih in hidroloških kazalnikov. Ta je dopolnilno analitično orodje za razumevanje dolgoročnih vzorcev in spremljanje spreminjanja podnebnih razmer skozi čas.

Slika 5.6 prikazuje povprečno letno temperaturo zraka v Šibeniku med letoma 1950 in 2024, izračunano kot letno povprečje dnevne povprečne temperature zraka na višini 2 m (temperature_2m_mean).

Vizualizacija potrjuje dolgoročni trend naraščanja temperatur z izrazito medletno spremenljivostjo. Zlasti od začetka 21. stoletja so povprečne temperature višje od preteklih večletnih povprečij, v zadnjih letih pa so se pojavljala tudi obdobja občutno povišanih temperatur.

Ta trend ne kaže le na postopno segrevanje, temveč tudi na premik v porazdelitvi letnih toplotnih razmer, kar je ključno za nadaljnjo analizo vročinskih valov in razvrščanje podnebnih let v gruče z metodami strojnega učenja.

Slika 5.7 prikazuje letno število vročinskih valov, opredeljenih kot obdobja najmanj petih zaporednih dni z najvišjo dnevno temperaturo nad 30 °C, skupaj z njihovim povprečnim trajanjem. Na začetku časovne vrste so vročinski valovi redki in večinoma kratki. V zadnjih letih pa se je njihova pogostost povečala, trajanje posameznih dogodkov pa občutno podaljšalo.

Ta vzorec kaže spremembo vpliva toplotnega stresa: namesto občasnih izrednih dogodkov so v zadnjih letih vse pogostejša daljša obdobja visokih temperatur, ki pomembno vplivajo na zdravje ljudi, ekosisteme in rabo virov.

Slika 5.8 prikazuje letno število suhih in deževnih dni, pri čemer so suhi dnevi opredeljeni kot dnevi z manj kot 1 mm padavin. Graf razkriva precejšnjo medletno spremenljivost, v zadnjem obdobju pa trend večjega števila suhih in manjšega števila deževnih dni.

Ta sprememba v porazdelitvi padavinskih dni ne pomeni nujno zmanjšanja skupne letne količine padavin. Kaže pa na večjo zgoščenost padavinskih dogodkov in daljša sušna obdobja, kar je pomembno za razvoj sušnega stresa.

Slika 5.9 prikazuje letno število dni, ki izpolnjujejo merila za izrazito tveganje za sušo, za katero so značilne zelo majhna količina padavin, povečana referenčna evapotranspiracija in zmanjšana vlažnost tal. V večjem delu opazovanega obdobja ti pogoji niso izpolnjeni hkrati, v zadnjih letih pa je bilo takih sušnih dni opazno več.

Pojav večdesetletnih obdobij s kombiniranim sušnim stresom kaže na spremembo medsebojnega delovanja atmosferskih in hidroloških dejavnikov, pri čemer suša ni več le posledica pomanjkanja padavin, temveč tudi povečane izgube vode in zmanjšane vlažnosti tal.

Pomembno je upoštevati, da se neugodne značilnosti ne pojavijo nujno vsako leto; njihove kombinacije in stopnja izraženosti se med leti razlikujejo. Večrazsežnost letnih podnebnih značilk poudarja potrebo po metodi, ki lahko hkrati analizira več kazalnikov in zazna naravne vzorce njihovega pojavljanja.

Naslednji korak analize je zato uporaba metod nenadzorovanega strojnega učenja, ki letne zapise obravnavajo kot celovite podnebne profile. Ta pristop omogoča združevanje let glede na njihovo splošno podobnost, kar pomaga prepoznati različne tipe podnebnih let in jih razložiti z vidika podnebnih tveganj.

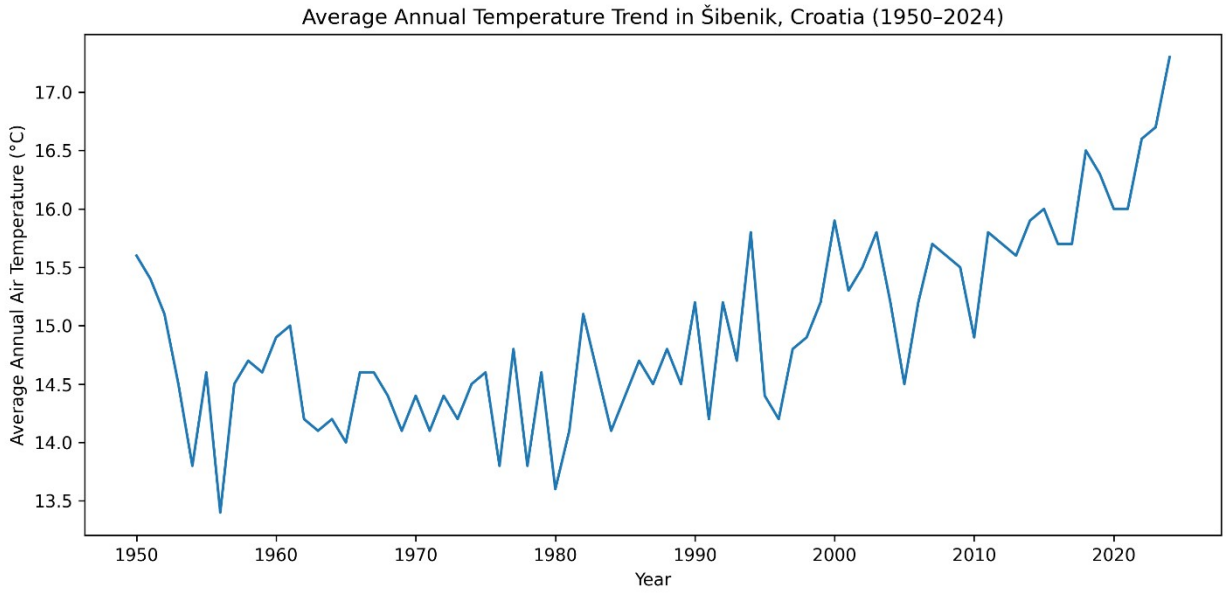

Slika 5.6 Povprečna letna temperatura zraka v Šibeniku (1950–2024)

Prevod napisov na sliki: Trend povprečne letne temperature v Šibeniku na Hrvaškem (1950–2024). Osi: leto in povprečna letna temperatura zraka (°C).

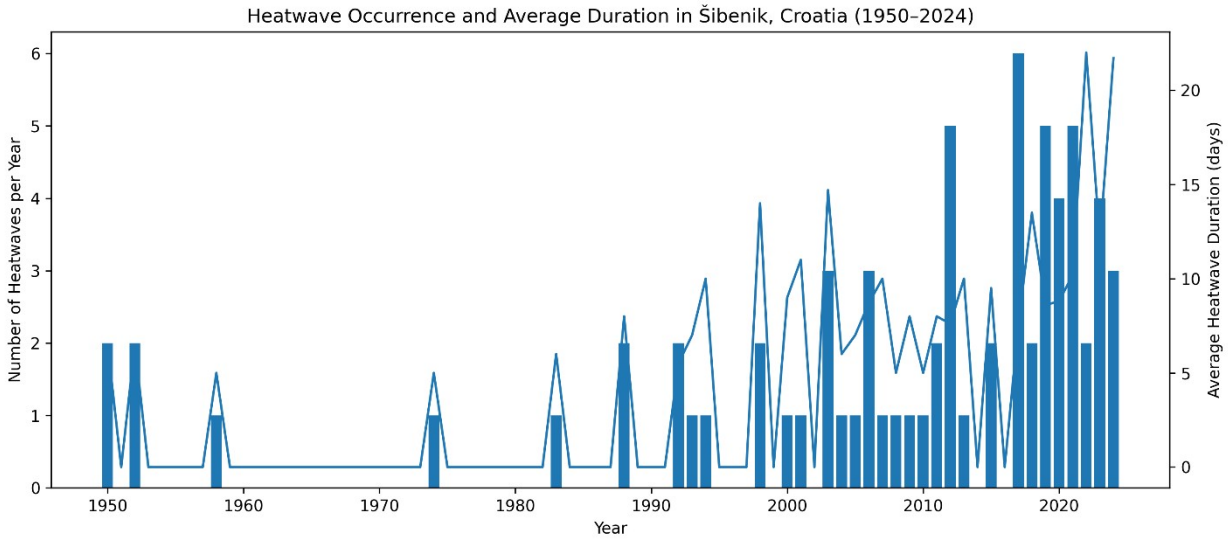

Slika 5.7 Pogostost in povprečno trajanje vročinskih valov v Šibeniku (1950–2024)

Prevod napisov na sliki: Pojavljanje in povprečno trajanje vročinskih valov v Šibeniku na Hrvaškem (1950–2024). Osi: leto, število vročinskih valov na leto in povprečno trajanje vročinskega vala (dni).

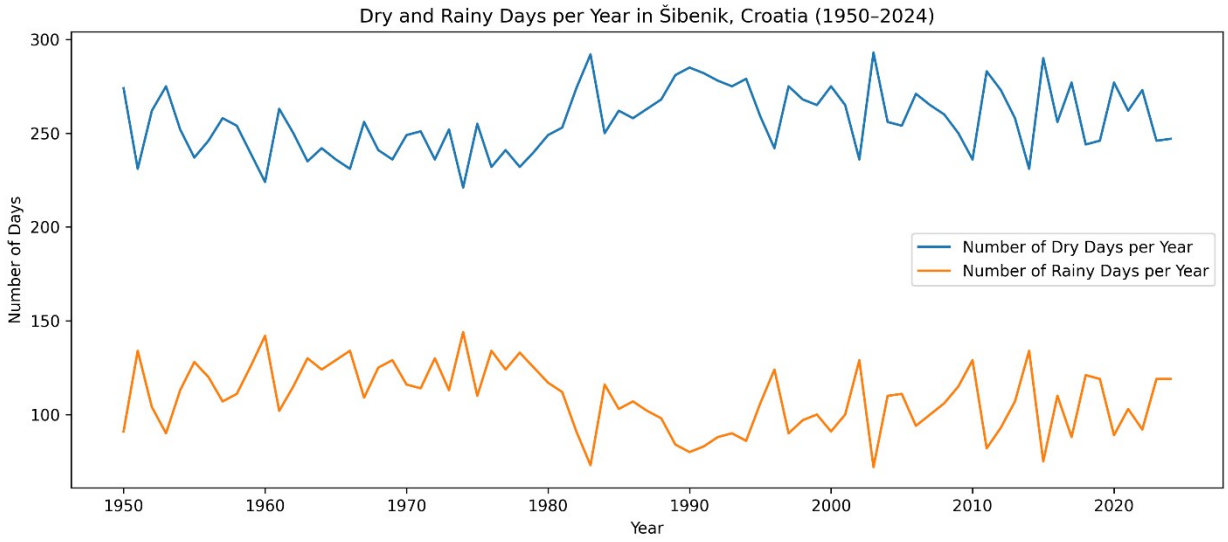

Slika 5.8 Število suhih in deževnih dni na leto v Šibeniku (1950–2024)

Prevod napisov na sliki: Suhi in deževni dnevi na leto v Šibeniku na Hrvaškem (1950–2024). Osi: leto in število dni. Legenda: število suhih dni na leto; število deževnih dni na leto.

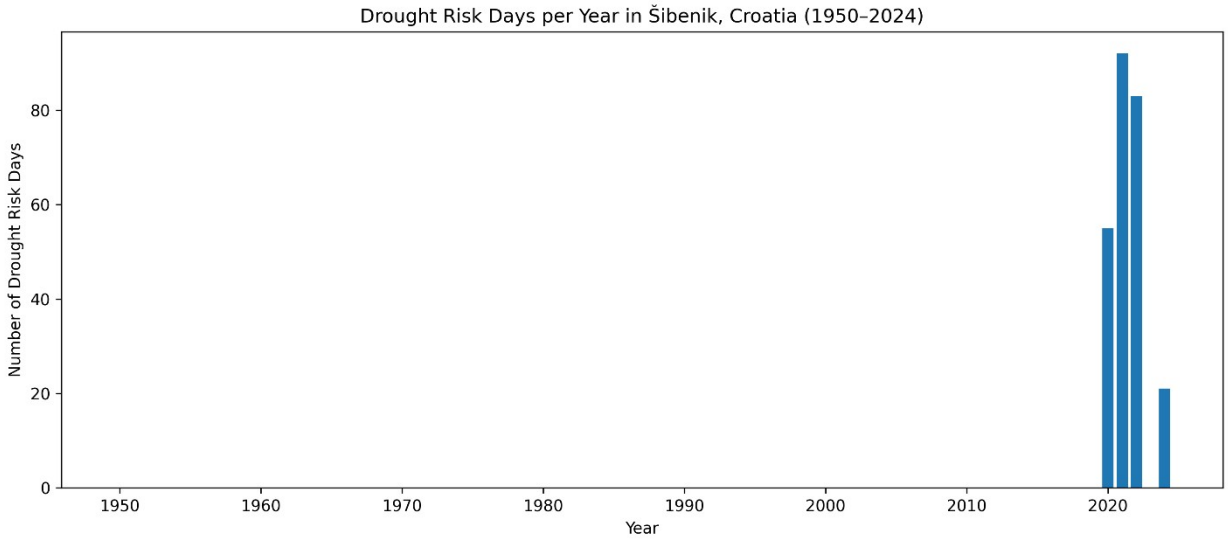

Slika 5.9 Število dni, ki izpolnjujejo merilo izrazitega tveganja za sušo v Šibeniku (1950–2024)

Prevod napisov na sliki: Dnevi s tveganjem suše na leto v Šibeniku na Hrvaškem (1950–2024). Osi: leto in število dni s tveganjem suše.

Nenadzorovano strojno učenje za razvrščanje letnih podnebnih profilov v skupine

Po agregiranju dnevnih meteoroloških meritev v letne nabore značilk je bilo v podatkovnem prostoru izvedeno gručenje z metodo k-sredin. Analiza je bila izvedena neposredno v podatkovnem skladišču Oracle z vgrajenim paketom DBMS_DATA_MINING [6], ki omogoča povezovanje priprave podatkov, modeliranja in razlage rezultatov v enotnem relacijskem okviru.

Model je opredeljen kot model gručenja (CLUSTERING), uporabljen na tabeli CLIMATE_YEARLY_FEATURES_SIBENIK, ki je neposredni rezultat agregatne poizvedbe SQL, opisane v prejšnjem podpoglavju. Tabela vsebuje po en zapis za vsako leto s pripadajočim naborom letnih agregiranih značilk, vključno s toplotnimi, hidrološkimi, sušnimi in vetrnimi kazalniki.

Število gruč je v tabeli parametrov modela nastavljeno na 3 (CLUS_NUM_CLUSTERS = 3). Ta izbira omogoča uravnoteženo razčlenitev letnih podnebnih profilov na manjše število razumljivejših tipov brez pretiranega drobljenja rezultatov.

Model gručenja z metodo k-sredin je bil naučen z uporabo vseh razpoložljivih letnih značilk, vhodne spremenljivke pa so bile v okviru Oracle Data Mining samodejno normalizirane in standardizirane. Tako spremenljivke z večjimi številskimi razponi (na primer število dni ali skrajne vrednosti) ne prevladajo v postopku gručenja.

Po izdelavi modela je bilo vsako leto z vgrajeno funkcijo CLUSTER_ID dodeljeno določeni gruči. Rezultati kažejo, da so leta razvrščena v tri različne gruče z različnimi časovnimi vrstami in podnebnimi značilkami, kot prikazuje preglednica 1.

Ena gruča (ID = 4), ki jo lahko razumemo kot **stabilni podnebni scenarij** (označen z zeleno), vključuje največ let ter jo zaznamujejo najnižje povprečne temperature, skoraj popolna odsotnost vročinskih valov in sušnega stresa ter največje število deževnih dni. Ta gruča zajema leta z razmeroma stabilnim in zmernim podnebjem. Slika 5.10 prikazuje, da ta gruča prevladuje v večjem delu opazovanega obdobja, zlasti v drugi polovici 20. stoletja.

Drugo gručo (ID = 5), ki predstavlja **prehodni podnebni scenarij** (označen z modro), zaznamujejo višje povprečne temperature, pogostejši vročinski valovi, več suhih in manj deževnih dni. Ta kombinacija kaže na povečan toplotni in hidrološki stres, čeprav ne dosega skrajnih vrednosti sušnega kazalnika. Slika 5.10 kaže, da se leta iz te gruče v prejšnjih obdobjih pojavljajo občasno, po letu 2000 pa so veliko pogostejša.

Tretja gruča (ID = 3), ki predstavlja **neugodni (ekstremni) podnebni scenarij** in je označena z oranžno, sicer vključuje manj let, vendar jo jasno zaznamujejo najvišje povprečne temperature, največ vročinskih valov in izjemno veliko število dni s kombiniranim sušnim stresom. Kot prikazuje slika 5.10, se ta gruča pojavlja skoraj izključno v najnovejšem obdobju opazovanja, kar kaže na kvalitativni premik v podnebnih značilnostih in ne zgolj na postopno spreminjanje posameznih spremenljivk.

Preglednica 1. Rezultati gručenja podnebnih kazalnikov za Šibenik z metodo k-sredin

ID gruče	Število let v gruči	Povprečna letna temperatura (°C)	Povprečna občutena temperatura (°C)	Povprečno število vročinskih valov na leto	Povprečno število dni s tveganjem za sušo	Povprečno število suhih dni na leto	Povprečno število deževnih dni na leto	Povprečna največja hitrost vetra (km/h)
3	**4**	**16,5**	**15**	**3,5**	**62,8**	**264,8**	**100,8**	**44,5**
4	46	14,5	12,7	0,1	0	249,4	115,8	53,7
5	25	15,5	13,9	2,1	0	268,1	97,2	51,8

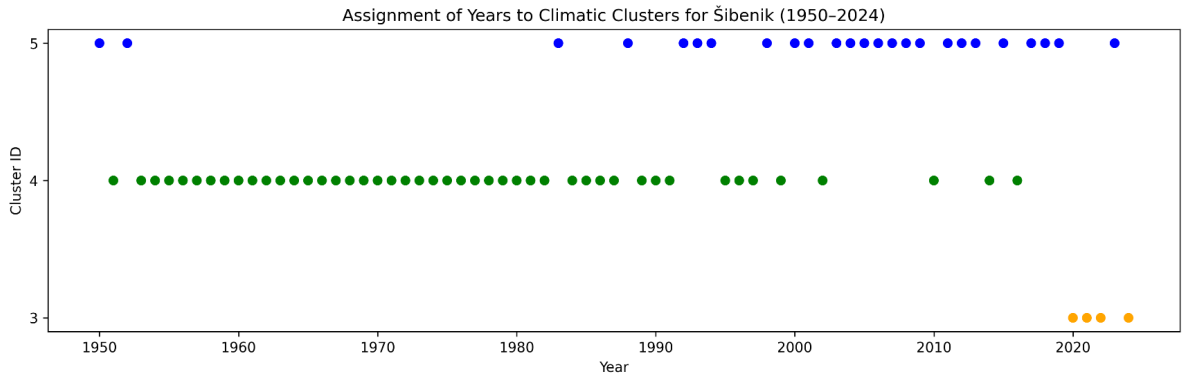

Slika 5.10 Razvrstitev let v podnebne gruče v Šibeniku (1950–2024)

Prevod napisov na sliki: Razvrstitev let v podnebne gruče za Šibenik (1950–2024). Osi: leto in ID gruče.

```
-- ========================================================
-- Gručenje letnih podnebnih profilov z metodo k-sredin
-- --------------------------------------------------------
-- Ta skript izvaja nenadzorovano strojno učenje
-- neposredno v podatkovnem skladišču Oracle Autonomous Data Warehouse.
-- Vhodna tabela CLIMATE_YEARLY_FEATURES_SIBENIK
-- vsebuje po eno vrstico za vsako leto z agregiranimi podnebnimi
-- kazalniki, izpeljanimi iz dnevnih meteoroloških podatkov.
--
-- Cilj analize je razvrstiti leta s
-- podobnimi podnebnimi značilnostmi v skupine z metodo
-- k-sredin.
-- ========================================================

-- --------------------------------------------------------
-- 1. korak: določitev nastavitev za model k-sredin
-- --------------------------------------------------------
-- Ustvarimo tabelo nastavitev, ki jo Oracle Data Mining uporablja
-- za konfiguracijo algoritma gručenja.

CREATE TABLE KMEANS_SETTINGS (
  setting_name  VARCHAR2(30),
  setting_value VARCHAR2(30)
);

-- Določimo število gruč (K = 3)
INSERT INTO KMEANS_SETTINGS
VALUES ('CLUS_NUM_CLUSTERS', '3');


-- --------------------------------------------------------
-- 2. korak: izdelava modela gručenja z metodo k-sredin
-- --------------------------------------------------------
-- Učenje modela poteka neposredno v podatkovni zbirki
-- z uporabo paketa DBMS_DATA_MINING.
```

```
-- Vsaka vrstica predstavlja eno leto (primer),
-- vsi preostali stolpci pa se uporabijo kot vhodne značilnosti.

BEGIN
  DBMS_DATA_MINING.CREATE_MODEL(
    model_name          => 'CLIMATE_KMEANS_SIBENIK',
    mining_function     => DBMS_DATA_MINING.CLUSTERING,
    data_table_name     => 'CLIMATE_YEARLY_FEATURES_SIBENIK',
    case_id_column_name => 'YEAR',
    settings_table_name => 'KMEANS_SETTINGS'
  );
END;


-- ------------------------------------------------------
-- 3. korak: preverjanje, ali je bil model uspešno ustvarjen
-- ------------------------------------------------------

SELECT model_name, mining_function
FROM user_mining_models
WHERE model_name = 'CLIMATE_KMEANS_SIBENIK';


-- ------------------------------------------------------
-- 4. korak: dodelitev vsakega leta gruči
-- ------------------------------------------------------
-- Funkcija CLUSTER_ID vrne gručo,
-- ki ji pripada posamezni letni podnebni profil.

SELECT
  year,
  CLUSTER_ID(CLIMATE_KMEANS_SIBENIK USING *) AS cluster_id
FROM CLIMATE_YEARLY_FEATURES_SIBENIK
ORDER BY year;


-- ------------------------------------------------------
-- 5. korak: opis gruč s povprečnimi vrednostmi značilk
-- ------------------------------------------------------
-- Ta poizvedba povzema podnebne značilnosti
-- posamezne gruče z izračunom povprečnih vrednosti
-- izbranih kazalnikov.

SELECT
  CLUSTER_ID(CLIMATE_KMEANS_SIBENIK USING *) AS cluster_id,
  COUNT(*) AS years_in_cluster,

  -- Temperaturne značilnosti
  ROUND(AVG(avg_year_temp), 1) AS avg_temp,
  ROUND(AVG(avg_apparent_temp), 1) AS avg_apparent_temp,

  -- Kazalniki toplotnega stresa
  ROUND(AVG(heatwave_count), 1) AS avg_heatwaves,
```

```
  -- Kazalniki, povezani s sušo
  ROUND(AVG(drought_risk_days), 1) AS avg_drought_days,
  ROUND(AVG(dry_days), 1) AS avg_dry_days,

  -- Značilnosti padavin
  ROUND(AVG(rainy_days), 1) AS avg_rainy_days,

  -- Ekstremne vrednosti vetra
  ROUND(AVG(max_wind_speed_km_h), 1) AS avg_max_wind

FROM CLIMATE_YEARLY_FEATURES_SIBENIK
GROUP BY CLUSTER_ID(CLIMATE_KMEANS_SIBENIK USING *)
ORDER BY cluster_id;
```

Potrditev prepoznanih podnebnih vzorcev z uporabo novejših podatkov

Rezultati študije primera za območje Šibenika (Hrvaška) kažejo, da se podnebne spremembe jasno odražajo ne le v postopnem zviševanju temperatur, temveč tudi v premikih v strukturi podnebnih let in pogostejših neugodnih kombinacijah toplotnih in hidroloških razmer. Vizualna analiza letnih kazalnikov razkriva povečanje pogostosti in trajanja vročinskih valov ter pojavljanje let z izrazitim kombiniranim sušnim stresom.

Rezultati analize gruč z metodo k-sredin so pokazali, da se je od leta 2020 na opazovanem območju pojavil poseben tip podnebnega leta z najizrazitejšim toplotnim in sušnim stresom. To gručo odlikujejo visoke povprečne in najvišje temperature, pogostejši in daljši vročinski valovi ter daljša obdobja kombiniranega sušnega stresa; v časovni vrsti se pojavlja skoraj izključno v najnovejšem obdobju analize.

Vpogled v skoraj popolne meteorološke podatke za leto 2025, predstavljene v preglednici 2 (do vključno 12. decembra 2025), kaže, da so značilnosti tega leta zelo skladne s predhodno prepoznanim vzorcem. Zabeleženi so bili štirje vročinski valovi s povprečnim trajanjem več kot 13 dni, izjemno visoka najvišja dnevna temperatura 38,4 °C in več kot 100 dni s kombiniranim sušnim stresom, medtem ko se je število deževnih dni zmanjšalo. Ta kombinacija toplotnih in hidroloških kazalnikov se ujema s profilom najbolj ekstremne gruče, prepoznane pri analizi zgodovinskih podatkov.

To potrjuje, da uporabljena analiza z metodo k-sredin ni le retrospektivni opis preteklih razmer, temveč tudi orodje za odkrivanje strukturnih sprememb v podnebni dinamiki sistema. Leto 2025 zato ni osamljen skrajni pojav, temveč del vzorca, ki se je začel na začetku dvajsetih let 21. stoletja, kar poudarja pomen tega pristopa za zgodnje prepoznavanje neugodnih scenarijev in ocenjevanje okoljskih tveganj.

Preglednica 2 Ključni podnebni kazalniki za leto 2025 (Šibenik)

Kazalnik	Vrednost
Število vročinskih valov	4
Povprečno trajanje vročinskega vala (dni)	13,5
Najvišja dnevna temperatura (°C)	38,4
Povprečna letna temperatura zraka (°C)	17
Povprečna občutena temperatura (°C)	15,3
Suhi dnevi	252
Število deževnih dni	94
Število dni s kombiniranim sušnim stresom	101
Število dni s povečano evapotranspiracijo	128
Najvišja hitrost vetra (km/h)	48,4

Pomen za blaženje okoljskih tveganj na podlagi scenarijev

Na območju Šibenika prepoznane podnebne gruče predstavljajo z dokazi podprte scenarije, ki ponazarjajo različne ravni okoljskega tveganja. Leta z razmeroma stabilnimi podnebnimi razmerami so izhodiščni scenarij. Ena gruča pa je zaznamovana z izrazitim toplotnim in sušnim stresom, zato predstavlja neugoden, najslabši možni scenarij. Naraščajoča pogostost takšnih let v zadnjih desetletjih skupaj s skoraj popolnimi podatki za leto 2025 kaže, da te skrajne razmere postajajo običajen pojav v lokalnem podnebju in ne več redek dogodek.

V praksi povečana pogostost let z neugodnimi podnebnimi značilnostmi poudarja potrebo po boljšem upravljanju vodnih virov, zlasti med dolgimi sušnimi obdobji in turistično sezono, ko se potreba po vodi poveča. Naraščajoča pogostost in trajanje vročinskih valov poudarjata pomen preventivnih ukrepov na področju javnega zdravja, prilagajanja mest in rabe energije, zlasti na gosto poseljenih območjih in v poletnih mesecih. Poleg tega lahko razumevanje prehoda od stabilnejših k bolj tveganim podnebnim tipom pomaga pri razvoju lokalnih sistemov zgodnjega opozarjanja in načrtov prilagajanja podnebnim spremembam.

Razširitev analize na dodatna mesta

Za preverjanje uporabnosti predlaganega pristopa so bile izvedene dodatne analize za tri mesta v različnih geografskih in podnebnih regijah: Rim (Italija), Skopje (Severna Makedonija) in Kijev (Ukrajina).

Za vsako mesto je bil uporabljen enak analitični postopek kot za Šibenik, vključno z izbiro meteoroloških spremenljivk, agregiranjem dnevnih meritev v letne podatke in uporabo metode

k-sredin. Vendar je bil model naučen ločeno z uporabo podatkov, značilnih za posamezno lokacijo. To zagotavlja, da prepoznane gruče predstavljajo lokalne podnebne vzorce in povezave med kazalniki v posameznem mestu.

Rezultati analize gruč za Rim, Skopje in Kijev so predstavljeni v pripadajočih preglednicah, ki prikazujejo povprečja ključnih podnebnih kazalnikov po gručah (preglednice 3–5), ter na slikah, ki ponazarjajo razporeditev podnebnih let po gručah za obdobje 1950–2024 (slike 5.11–5.13). Čeprav je metodologija v vseh primerih dosledna (tako kot prej za Šibenik), se dobljene gruče razlikujejo po značilnostih in časovnih trendih, kar potrjuje, da se podnebni vzorci in tveganja razlikujejo glede na regionalni kontekst.

Preglednica 3 Rezultati gručenja podnebnih kazalnikov z metodo k-sredin za Rim

ID gruče	Število let v gruči	Povprečna letna temperatura (°C)	Povprečna občutena temperatura (°C)	Povprečno število vročinskih valov na leto	Povprečno število dni s tveganjem za sušo	Povprečno število suhih dni na leto	Povprečno število deževnih dni na leto	Povprečna najvišja hitrost vetra (km/h)
3	20	16	15,3	3	40,3	268,7	96,6	35,3
4	21	15,4	14,8	2,8	15,1	255,5	109,8	34,4
5	34	14,7	14	1,2	5	250,1	115,1	34,4

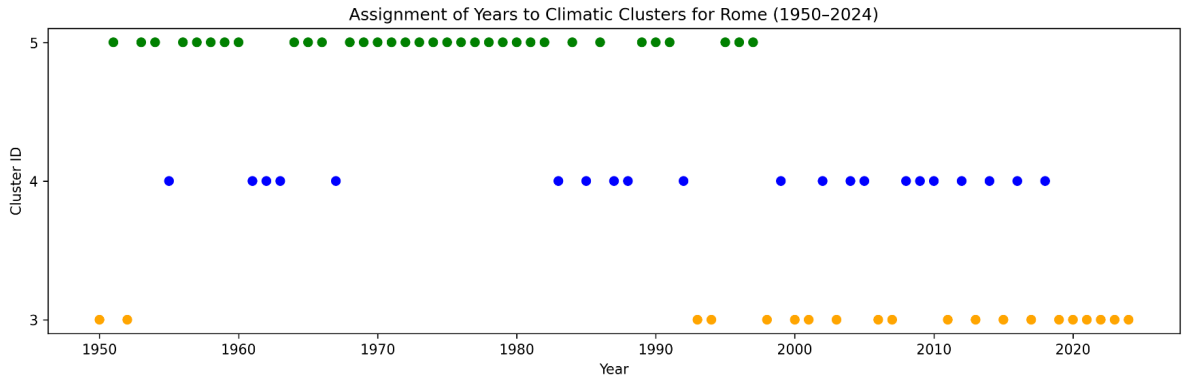

Slika 5.10. Razvrstitev let v podnebne gruče v Rimu (1950–2024)

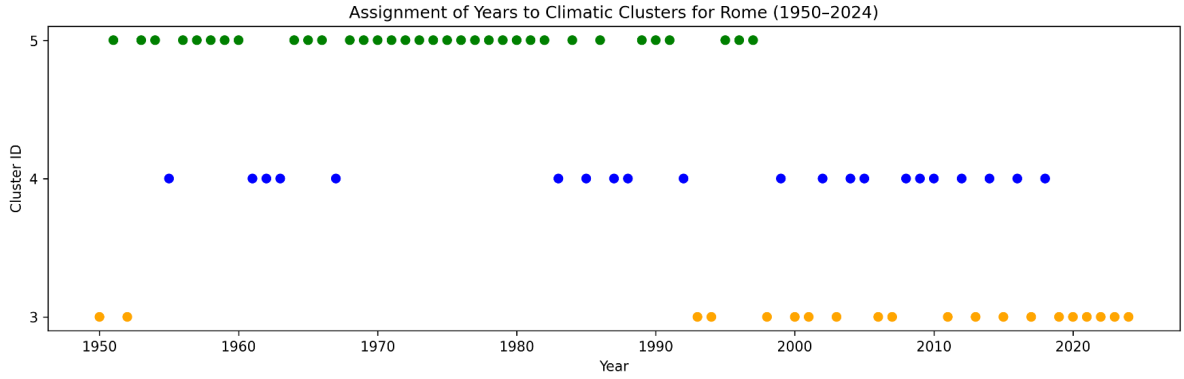

Prevod napisov na sliki: Razvrstitev let v podnebne gruče za Rim (1950–2024). Osi: leto in ID gruče.

Preglednica 4 Rezultati gručenja podnebnih kazalnikov z metodo k-sredin za Skopje

ID gruče	Število let v gruči	Povprečna letna temperatura (°C)	Povprečna občutena temperatura (°C)	Povprečno število vročinskih valov na leto	Povprečno število dni s tveganjem za sušo	Povprečno število suhih dni na leto	Povprečno število deževnih dni na leto	Povprečna najvišja hitrost vetra (km/h)
2	45	12,6	11,1	2,6	36,6	269,8	95,4	26,7
4	3	13,1	11,4	2,3	66,7	301,3	64	31
5	27	14,1	12,6	4,6	78,2	285,1	80,1	26,2

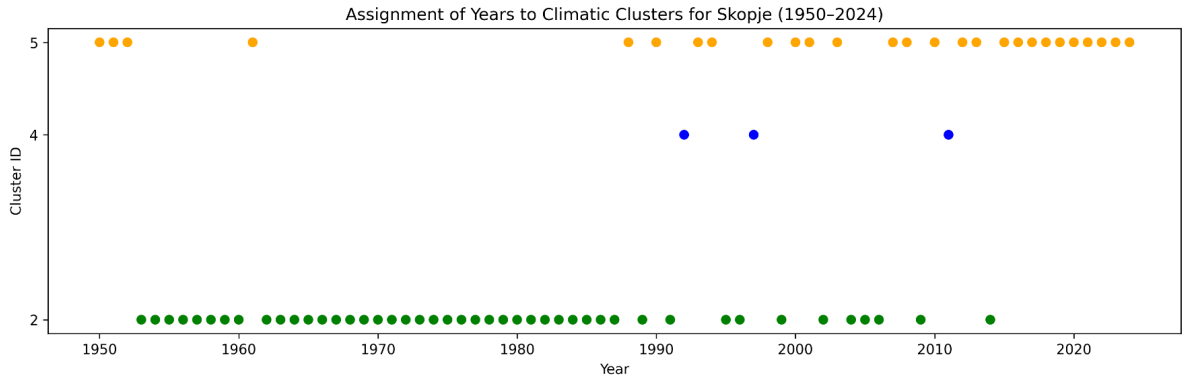

Slika 5.11 Razvrstitev let v podnebne gruče v Skopju (1950–2024)

Prevod napisov na sliki: Razvrstitev let v podnebne gruče za Skopje (1950–2024). Osi: leto in ID gruče.

Preglednica 5 Rezultati gručenja podnebnih kazalnikov z metodo k-sredin za Kijev

ID gruče	Število let v gruči	Povprečna letna temperatura (°C)	Povprečna občutena temperatura (°C)	Povprečno število vročinskih valov na leto	Povprečno število dni s tveganjem za sušo	Povprečno število suhih dni na leto	Povprečno število deževnih dni na leto	Povprečna najvišja hitrost vetra (km/h)
3	2	7	4,1	0	0	248	117,5	52,5
4	63	7,7	4,8	0	0	243,2	122	39,6
5	10	8,9	6,1	1,2	0	255,6	109,6	37,1

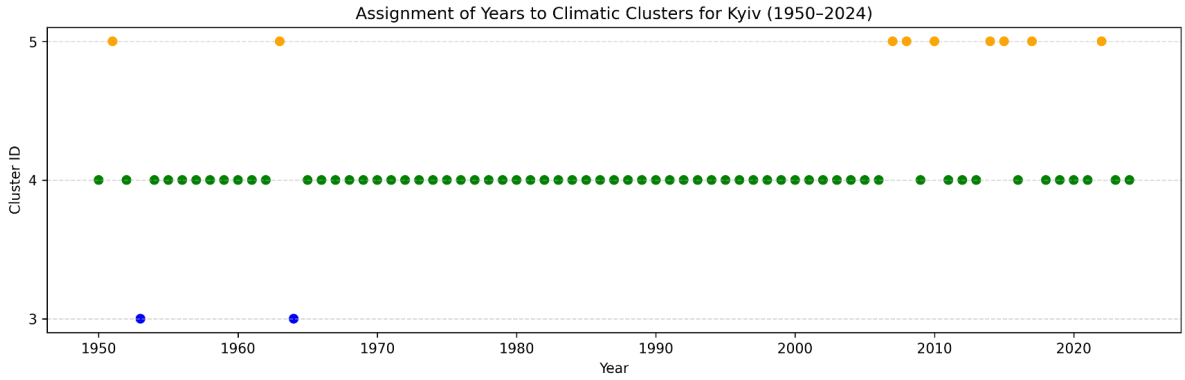

Slika 5.11 Razvrstitev let v podnebne gruče v Kijevu (1950–2024)

Prevod napisov na sliki: Razvrstitev let v podnebne gruče za Kijev (1950–2024). Osi: leto in ID gruče.

Analiza dodatnih mest kaže, da je v Rimu, Skopju in Kijevu v zadnjem času prišlo do premika k letom z izrazitejšimi skrajnimi podnebnimi značilnostmi. Vendar se ti vzorci med seboj razlikujejo. V vseh treh mestih se je pogostost let z višjimi temperaturami in večjim toplotnim

stresom povečala. Nasprotno pa se stabilnejši podnebni vzorci pogosteje pojavljajo v starejšem delu podatkovne časovne vrste.

Posebej opazno je, da so od začetka 21. stoletja, še zlasti pa po letu 2010, v celinskih mestih, kot sta Skopje in Kijev, postale pogostejše gruče, ki predstavljajo bolj skrajne razmere. To kaže na širjenje toplotnega stresa zunaj značilnih sredozemskih območij. Čeprav se intenzivnost in kombinacije skrajnih razmer razlikujejo od tistih v obalnih mestih, ugotovitve kažejo na strukturni premik v podnebnih vzorcih tudi na teh območjih.

Te ugotovitve potrjujejo, da prepoznani vzorci niso le lokalne anomalije, temveč del širšega trenda podnebnih sprememb, pri katerem se ekstremni scenariji postopoma pojavljajo v različnih podnebnih pasovih, kar poudarja potrebo po lokalno prilagojenih, vendar dosledno uporabljenih analitičnih metodah.

Naloge za vajo

- Prenesite zgodovinske dnevne vremenske podatke za izbrano lokacijo (npr. z API-jem Open-Meteo)
- Dnevne meteorološke podatke agregirajte v letne podnebne kazalnike (npr. povprečna temperatura, število zelo vročih dni, število suhih dni).
- Na podlagi izbranih kazalnikov oblikujte letne podnebne profile.
- Z metodo k-sredin razvrstite podnebna leta v skupine glede na njihove značilnosti.
- Vsako leto dodelite ustrezni gruči in rezultate prikažite v preglednici ali grafično.
- Dobljene gruče razložite kot različne podnebne scenarije (stabilne, prehodne, neugodne).
- Novejše podatke primerjajte s predhodno prepoznanimi gručami in ocenite, kateremu tipu podnebnega leta pripadajo.

Preverjanje znanja

Kaj je glavni cilj uporabe algoritma k-sredin v predstavljeni študiji primera?

A. Numerično napovedovanje prihodnjih temperatur
B. Razvrščanje podnebnih let v skupine glede na medsebojno podobnost
C. Izračun sezonskih povprečij meteoroloških spremenljivk
D. Odkrivanje posameznih ekstremnih dni

Kaj je namen agregiranja dnevnih meteoroloških podatkov na letno raven?

A. Zmanjšati obseg podatkov brez izgube informacij
B. Olajšati prepoznavanje dolgoročnih vzorcev in podnebnih tipov
C. Odstraniti sezonskost iz podatkov
D. Pripraviti podatke za nadzorovano učenje

Kateri nabor kazalnikov najbolje opisuje neugodni (ekstremni) podnebni scenarij, prepoznan v študiji primera?

A. Visoke temperature, veliko deževnih dni in šibek veter
B. Zmerne temperature in redki vročinski valovi
C. Visoke temperature, pogosti vročinski valovi in veliko število dni s kombiniranim sušnim stresom
D. Velika količina padavin in kratkotrajni ekstremi

Zakaj gruča, prepoznana po letu 2020 v primeru mesta Šibenik, velja za kazalnik strukturnih sprememb podnebnih razmer?

A. Ker temelji samo na enem ekstremnem letu
B. Ker vključuje nove kombinacije toplotnega in hidrološkega stresa
C. Ker se pojavlja skoraj izključno v novejšem obdobju
D. Ker jo vnaprej določajo pragovi

Katera trditev najbolje opisuje vlogo algoritma k-sredin pri scenarijskem napovedovanju okoljskih tveganj?

A. Algoritem k-sredin prihodnje podnebne razmere neposredno napoveduje kot scenarije
B. Algoritem k-sredin prepoznava značilne vzorce, ki jih je mogoče razlagati kot scenarije
C. Algoritem k-sredin kot scenarije uporablja klasične meteorološke analize
D. Algoritem k-sredin se uporablja za kratkoročne napovedi

Dodatni viri

[1] G. James, D. Witten, T. Hastie in R. Tibshirani, An Introduction to Statistical Learning: With Applications in R, 2. izd. New York, NY, ZDA: Springer, 2021 [spletno]. Dostopno na: https://hastie.su.domains/ISLR2/ISLRv2_website.pdf, dostop: 15. dec. 2025

[2] Lindholm, N. Wahlström, F. Lindsten in T. B. Schön, Machine Learning – A First Course for Engineers and Scientists. Cambridge, Združeno kraljestvo: Cambridge University Press, 2022 [spletno]. Dostopno na: http://smlbook.org/book/sml-book-draft-latest.pdf, dostop: 15. dec. 2025

[3] O. Simeone, A brief introduction to machine learning for engineers, predobjava arXiv, arXiv:1709.02840, 2017. [spletno]. Dostopno na: https://arxiv.org/pdf/1709.02840.pdf, dostop: 15. dec. 2025

[4] Historical Weather API Documentation, 2024. Dostopno na: https://open-meteo.com/en/docs/historical-weather-api, dostop: 15. dec. 2025.

[5] Oracle, Autonomous AI Lakehouse. [spletno]. Dostopno na: https://www.oracle.com/autonomous-database/autonomous-ai-lakehouse, dostop: 15. dec. 2025.

[6] Oracle, DBMS_DATA_MINING Package Reference, Oracle Database 19c Documentation. [spletno]. Dostopno na: https://docs.oracle.com/en/database/oracle/oracle-database/19/arpls/DBMS_DATA_MINING.html, dostop: 15. dec. 2025.