Tema 6: Duboko učenje za analizu utjecaja na okoliš

Kolegij: Strojno učenje za primjene u okolišu

Ishodi učenja

Nakon završetka ove nastavne cjeline studenti će moći:

- Objasniti koncept i ulogu neuronskih mreža u primjenama u području okoliša.
- Objasniti temeljne ideje dubokog učenja (DL) te kako su neuronske mreže strukturirane i kako se treniraju.
- Opisati kako se konvolucijske i rekurentne neuronske mreže upotrebljavaju u analizi utjecaja na okoliš.
- Primijeniti osnovni model dubokog učenja za analizu okolišnih podataka (npr. onečišćenja, zemljišnog pokrova ili temperaturnih trendova).
- Interpretirati rezultate modela dubokog učenja i raspraviti njihovu ulogu u podupiranju održivih odluka.
- Razviti jednostavne prototipove ili analize scenarija koje demonstriraju primjene dubokog učenja za održivost.
- Raspraviti kako DL može pomoći donositeljima odluka u procjeni ekološkog rizika.

Uvod

Duboko učenje (DL) grana je strojnog učenja koja se koristi umjetnim neuronskim mrežama za učenje složenih obrazaca u podacima. Za razliku od tradicionalnih algoritama, modeli dubokog učenja mogu automatski izdvajati važne značajke, što ih čini osobito korisnima za velike i složene skupove okolišnih podataka. Ovo predavanje uvodi temeljne ideje dubokog učenja i pokazuje kako te metode podupiru prilagodbu klimatskim promjenama, ekološku zaštitu i održivo donošenje odluka.

Definicija i razlikovanje: strojno učenje naspram dubokog učenja

Umjetna inteligencija nastala je 1950-ih godina, kada je nekoliko pionira iz tada novonastalog područja računarstva počelo postavljati pitanje mogu li se računala navesti da „misle” - pitanje čije posljedice istražujemo i danas [1]. Sažeto, AI se može opisati kao nastojanje automatizacije intelektualnih zadataka koje inače obavljaju ljudi. Kao takva, AI je opće područje koje obuhvaća

strojno učenje i duboko učenje, ali uključuje i mnogo drugih pristupa koji ne moraju uključivati nikakvo učenje. Tri ugniježđena ovala koja prikazuju odnos između umjetne inteligencije, strojnog učenja i dubokog učenja prikazana su na slici 6.1.

Strojno učenje način je programiranja računala tako da mogu učiti iz podataka i poboljšavati svoju učinkovitost bez zadavanja točnog pravila za svaku situaciju. U klasičnom strojnom učenju ljudi obično biraju koje su ulazne karakteristike (značajke) važne, primjerice „prosječna temperatura", „količina oborina" ili „vlažnost tla", a zatim treniraju algoritam da na temelju tih značajki izrađuje predviđanja ili donosi odluke. Ovaj pristup dobro funkcionira kada su podaci relativno mali, strukturirani u tablicama i kada je važno zadržati modele jednostavnima i lakima za objašnjenje.

Duboko učenje posebna je vrsta strojnog učenja koja se koristi višeslojnim umjetnim neuronskim mrežama za učenje izravno iz sirovih podataka kao što su slike, zvuk ili duge vremenske serije. Umjesto da ljudi ručno oblikuju značajke, duboka neuronska mreža automatski uči korisne obrasce korak po korak u svojim slojevima, primjerice od piksela preko oblika do objekata na slici. Duboko učenje obično zahtijeva znatno više podataka i računalne snage, ali je vrlo uspješno u rješavanju složenih zadataka kao što su prepoznavanje slika, prepoznavanje govora i razumijevanje prirodnog jezika.

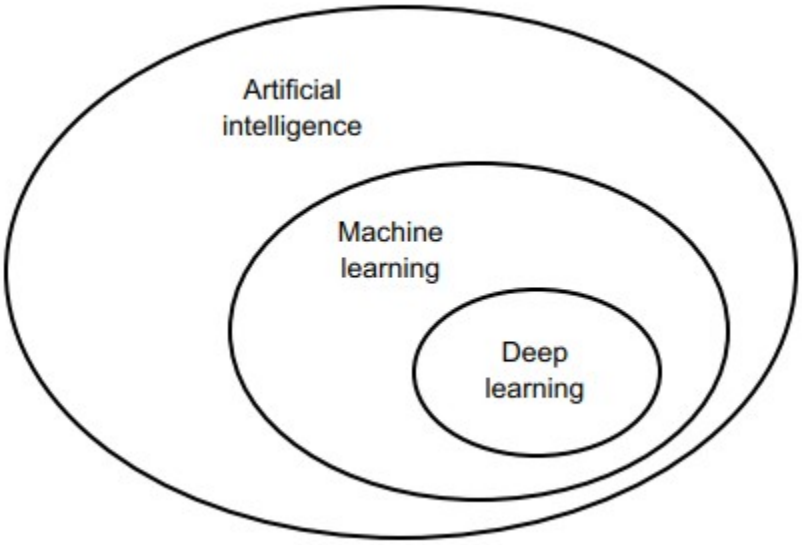

Slika 6.1 Razine umjetne inteligencije

Ključna je razlika u tome što je strojno učenje šira porodica metoda, u kojoj ljudi tipično definiraju značajke, a modeli su često manji i lakši za interpretaciju, dok je duboko učenje podskup koji se oslanja na duboke neuronske mreže kako bi automatski učilo značajke i obrasce iz velikih količina podataka. U praksi se strojno učenje često koristi sa strukturiranim okolišnim podacima u proračunskim tablicama ili bazama podataka, dok se duboko učenje preferira pri radu sa satelitskim snimkama, mrežama senzora ili drugim visokodimenzionalnim signalima. Za ovaj kolegij studenti trebaju zapamtiti jednostavno pravilo: svako duboko učenje jest strojno učenje, ali nije svako strojno učenje duboko učenje.

Eksplozija okolišnih podataka: sateliti, dronovi, IoT senzori, klimatski modeli

Suvremena znanost o okolišu otišla je daleko izvan jednostavnih ručnih mjerenja; danas imamo globalnu mrežu digitalnih „očiju" i „ušiju" koje prate Zemlju. Sateliti svakodnevno snimaju planet u visokoj razlučivosti, prateći promjene poput topljenja leda ili urbanog rasta, dok dronovi kartiraju šume i obale u 3D-u. Istodobno, milijuni senzora Interneta stvari (IoT) smještenih u oceanima, tlu i gradovima neprekidno šalju podatke o temperaturi, onečišćenju i vlažnosti. Time nastaje golema, neuredna knjižnica informacija - često nazvana „nestrukturiranim podacima" - koja je prevelika da bi je ljudi analizirali ručno.

Uz opažanja iz stvarnog svijeta, znanstvenici se oslanjaju na složene klimatske modele koji se izvode na superračunalima kako bi simulirali vremenske obrasce desetljećima unaprijed. Kada te

simulacije kombiniramo sa satelitskim snimkama i tokovima podataka sa senzora, dobivamo skupove podataka koji sadržavaju milijune varijabli, odnosno „visokodimenzionalne" podatke. Tradicionalne metode strojnog učenja ovdje često imaju poteškoća jer zahtijevaju da ljudi najprije ručno pojednostave podatke (inženjering značajki). S obzirom na samu količinu podataka koju danas proizvodimo, ručno stvaranje pravila za svaku satelitsku fotografiju ili očitanje senzora nije moguće.

Duboko učenje postaje ključno. Za razliku od starijih algoritama koji se nakon određene točke prestaju poboljšavati, modeli dubokog učenja zapravo postižu bolje rezultate kada se hrane većom količinom podataka. Jedinstveno su sposobni obraditi ovu „eksploziju podataka" - koristeći konvolucijske neuronske mreže (CNN) da „vide" obrasce na satelitskim fotografijama i rekurentne neuronske mreže (RNN) da „pamte" trendove u zapisima klimatskih senzora. Automatiziranjem analize ovih složenih podataka duboko učenje pretvara poplavu sirovih informacija u djelotvorne uvide za zaštitu našeg planeta.

Zašto je duboko učenje važno: obrada složenih, nelinearnih i visokodimenzionalnih podataka

Duboko učenje ključno je za znanost o okolišu jer priroda rijetko slijedi ravnu crtu; umjesto toga, ekološki odnosi izrazito su nelinearni, što znači da mala promjena jednog čimbenika (poput temperature) može pokrenuti nerazmjerno velike ili složene učinke (poput oluje). Dok tradicionalni algoritmi teško „crtaju" te složene krivulje, modeli dubokog učenja koriste aktivacijske funkcije kako bi učinkovito aproksimirali bilo koji kontinuirani, zakrivljeni odnos pronađen u prirodi. Nadalje, okolišni podaci često su visokodimenzionalni i sastoje se od golemih ulaza kao što su satelitske slike s milijunima piksela ili istodobna očitanja tisuća meteoroloških senzora. Dok starije metode često bivaju preplavljene samom količinom informacija - problemom poznatim kao „prokletstvo dimenzionalnosti" - arhitekture dubokog učenja posebno su oblikovane za obradu tih velikih, nestrukturiranih skupova podataka, automatski razdvajajući šum kako bi pronašle smislene obrasce bez potrebe da ljudi najprije pojednostave podatke. Primjeri DL-a u održivosti uključuju:

- Kartiranje krčenja šuma. Konvolucijske neuronske mreže (CNN) analiziraju satelitske snimke područja kao što je Amazonija kako bi automatski otkrile gdje je šuma posječena ili degradirana, pomažući nadležnim tijelima da brže reagiraju i planiraju mjere zaštite.
- Prognoziranje poplava. Rekurentni ili hibridni modeli dubokog učenja uče iz prethodnih oborina, razina rijeka i vlažnosti tla kako bi predvidjeli kada i gdje će se rijeke vjerojatno izliti, dajući zajednicama više vremena za pripremu i smanjenje šteta.

- Klasifikacija koraljnih grebena. Modeli dubokog učenja trenirani na tisućama podvodnih fotografija mogu prepoznati različite vrste koralja i otkriti izbjeljivanje ili bolesti, čime pomažu morskim biolozima da prate zdravlje grebena mnogo brže nego ručnim pregledima.
- Predviđanje emisija. Modeli dubokog učenja mogu koristiti podatke o potrošnji energije, prometu i industrijskoj aktivnosti za procjenu dnevnih ili budućih emisija ugljikova dioksida, pomažući vladama i tvrtkama da prate napredak prema klimatskim ciljevima.

Osnove dubokih neuronskih mreža

Ovaj modul uspostavlja teorijski i praktični okvir dubokog učenja (DL), potpodručja umjetne inteligencije koje je revolucioniralo način na koji interpretiramo složene skupove podataka. DL pomiče paradigmu s tradicionalnog statističkog modeliranja prema automatiziranom inženjeringu značajki.

Dok se tradicionalne statističke metode, poput linearne regresije, uvelike oslanjaju na ručni odabir značajki - pri čemu istraživači moraju identificirati i predobraditi određene varijable kako bi odredili njihov utjecaj - duboke neuronske mreže (DNN) osmišljene su za autonomno učenje tih reprezentacija. Kroz niz skrivenih slojeva DNN razlaže sirove podatke na više razina apstrakcije.

- **Početni slojevi: hvataju jednostavne obrasce ili značajke „niske razine”.**
- **Dublji slojevi: kombiniraju te obrasce kako bi identificirali složene strukture visoke razine unutar podataka.**

Ova sposobnost hijerarhijskog učenja osobito je važna za okolišnu analitiku. Prirodnim sustavima rijetko upravljaju jednostavni, aditivni odnosi; umjesto toga, definiraju ih varijable - poput vlažnosti, atmosferskog tlaka i lebdećih čestica - koje međudjeluju na nelinearne i vrlo složene načine.

Tradicionalni modeli često imaju poteškoća s tim „kaotičnim” interakcijama, ali DNN-ovi su izvrsni u:

- **Prepoznavanju obrazaca: identificiranje suptilnih pomaka u klimatskim podacima koji prethode ekstremnim vremenskim događajima,**
- **Višedimenzionalnoj korelaciji: mapiranje načina na koji se različiti okolišni čimbenici (poput vlažnosti tla i brzine vjetra) spajaju kako bi utjecali na lokalne ekosustave,**

- **Prediktivnoj točnosti: pružanje robusnijih prognoza hvatanjem nelinearnog „šuma" koji bi jednostavniji modeli mogli odbaciti kao stršeće vrijednosti.**

Usvajanjem ovih temelja istraživači mogu prijeći s pukog opažanja podataka na izgradnju prediktivnih alata sposobnih nositi se s razmjerom i promjenjivošću našeg planeta koji se mijenja.

Arhitektura neuronskih mreža: koncept slojeva

Neuronska mreža može se shvatiti kao matematička funkcija koja preslikava neki skup ulaznih vrijednosti u izlazne vrijednosti.

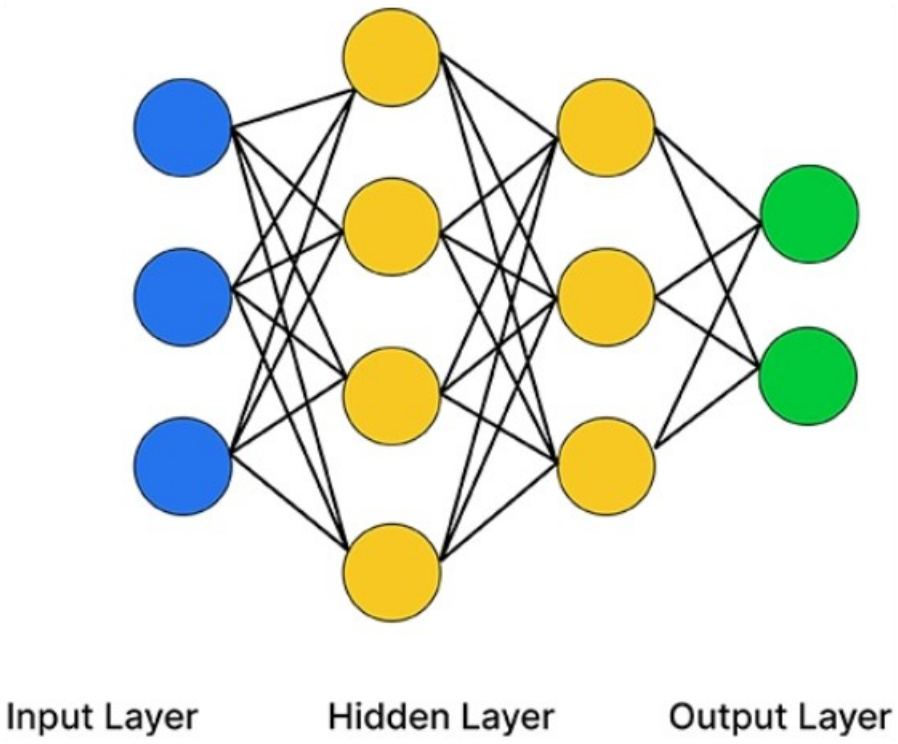

Slika 6.2 Arhitektura neuronskih mreža

Duboka unaprijedna mreža [1], odnosno višeslojni perceptron (MLP), sastoji se od triju vrsta slojeva (slika 6.2):

- **Ulazni sloj:**
  Ovaj sloj prima sirove okolišne podatke. Ne obavlja nikakvo računanje. Broj neurona u ovom sloju točno odgovara broju značajki u skupu podataka.

- *Okolišni kontekst: Ako analiziramo kvalitetu zraka, ulazni neuroni mogu predstavljati određena očitanja senzora, primjerice: .*

- **Skriveni slojevi:**
  Ti slojevi nalaze se između ulaznog i izlaznog sloja. Nazivaju se „skrivenima" jer se njihove vrijednosti ne opažaju u podacima za treniranje.
  - **Heaton objašnjava da, kako podaci prolaze kroz te slojeve, mreža izračunava ponderirane zbrojeve ulaza. „Duboko" učenje jednostavno se odnosi na mrežu koja ima više od jednog skrivenog sloja.**
  - *Funkcija: Ti slojevi djeluju kao ekstraktori značajki. Rani slojevi mogu otkriti jednostavne obrasce (npr. dnevne temperaturne cikluse), dok dublji slojevi te obrasce kombiniraju kako bi otkrili složene pojave (npr. specifične uvjete koji prethode toplinskom valu).*
- **Izlazni sloj:**
  Završni sloj proizvodi predviđanje (slika 6.3).
  - *Regresija: jedan neuron daje kontinuiranu vrijednost (npr. predviđenu količinu oborine u mm).*
  - *Klasifikacija: više neurona predstavlja vjerojatnosti za različite razrede (npr. razred 0: „Siguran zrak", razred 1: „Opasan zrak").*

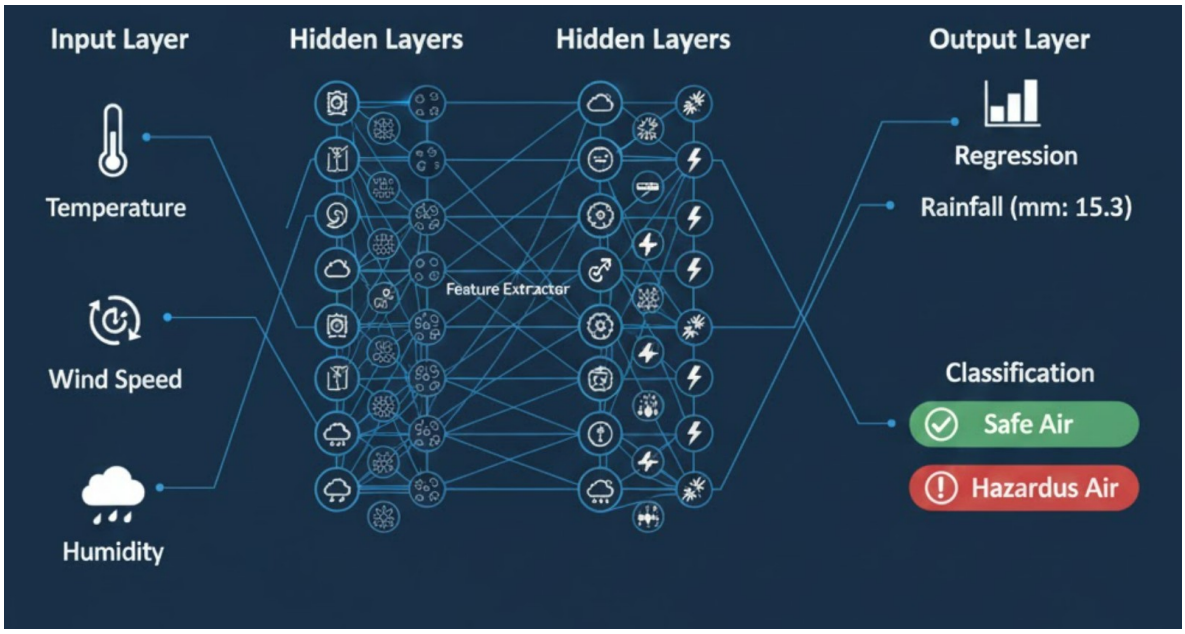

Slika 6.3 Slojevi neuronskih mreža

Aktivacijske funkcije: uvođenje nelinearnosti

Kada bi se neuronska mreža sastojala samo od ponderiranih zbrojeva i dodavanja pristranosti, ostala bi linearan model - u biti velika jednadžba regresije - bez obzira na to koliko slojeva imala. U takvom sustavu kompozicija linearnih funkcija i sama je linearna funkcija, što znači da mreža nikada ne bi mogla zahvatiti zamršene, „nazubljene" ili zakrivljene odnose prisutne u stvarnim podacima.

Za modeliranje složenih okolišnih pojava - poput nelinearnih stopa rasta bakterija ili kaotičnog praga olujne ćelije - moramo uvesti matematičkog „vratara" u svaki neuron. To je uloga aktivacijske funkcije (slika 6.4).

- **ReLU (Rectified Linear Unit): definirana kao , matematička funkcija koja jednostavno propušta pozitivne signale, ali potpuno blokira negativne.**
  - Rectified Linear Unit trenutačni je „zlatni standard" za skrivene slojeve u dubokom učenju,
  - Logika: propušta pozitivne signale nepromijenjene, ali potpuno blokira negativne signale,

- Računalna učinkovitost: za razliku od složenih eksponencijalnih funkcija, ReLU zahtijeva samo jednostavnu provjeru praga, što je čini iznimno brzom za izračun tijekom treniranja,
- Ublažavanje iščezavajućih gradijenata: u vrlo dubokim mrežama gradijenti (signali koji se koriste za „poučavanje" mreže) imaju tendenciju postajati sve manji dok mreža ne prestane učiti. ReLU[1] pomaže to spriječiti održavanjem konstantnog gradijenta za sve pozitivne ulaze,
- Rijetkost: vraćanjem nule za sve negativne ulaze ReLU stvara „rijetke" reprezentacije u kojima je u bilo kojem trenutku aktivan samo podskup neurona. To oponaša biološku učinkovitost ljudskog mozga.

• Sigmoid

- Binarna klasifikacija: budući da njezin izlaz ostaje u rasponu (0,1), idealan je izbor za izlazni sloj modela koji predviđa binarni ishod. Primjer: predviđanje vjerojatnosti „poplave" (>0.5) naspram „nema poplave" (<0.5).
- Povijesni kontekst: iako se nekoć koristila u skrivenim slojevima, ondje ju je uvelike zamijenio ReLU jer se sigmoid „zasićuje" (krajevi krivulje postaju vrlo ravni), što može zaustaviti učenje.

- **Softmax:**
  - Dok sigmoid obrađuje „A naspram B", Softmax je namijenjen međusobno isključivim kategorijama,
  - Distribucija vjerojatnosti: Softmax uzima vektor sirovih rezultata iz završnog sloja i sažima ih u distribuciju vjerojatnosti. Ključno je svojstvo da svi izlazi zbrojem daju točno 1.0 (100 %),
  - Primjena u okolišu: ako klasificirate zemljišni pokrov iz satelitskih snimki, Softmax osigurava da model ne kaže samo da je piksel „uglavnom šuma", nego daje preciznu raščlambu: 85 % šuma, 10 % urbano područje, 5 % voda,
  - Donošenje odluka: razred s najvećom vjerojatnošću tipično se odabire kao konačno predviđanje modela.

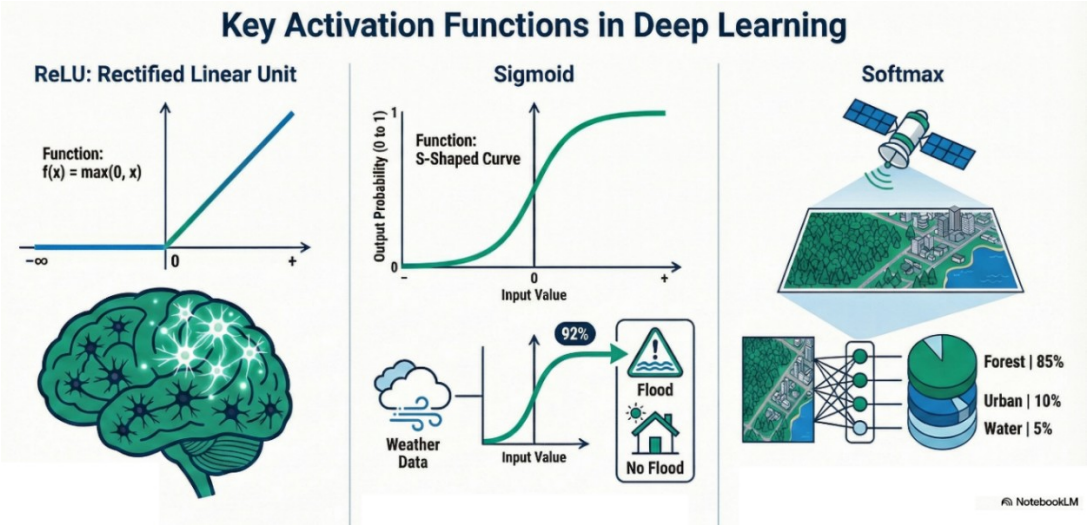

Slika 6.4 Ključne aktivacijske funkcije

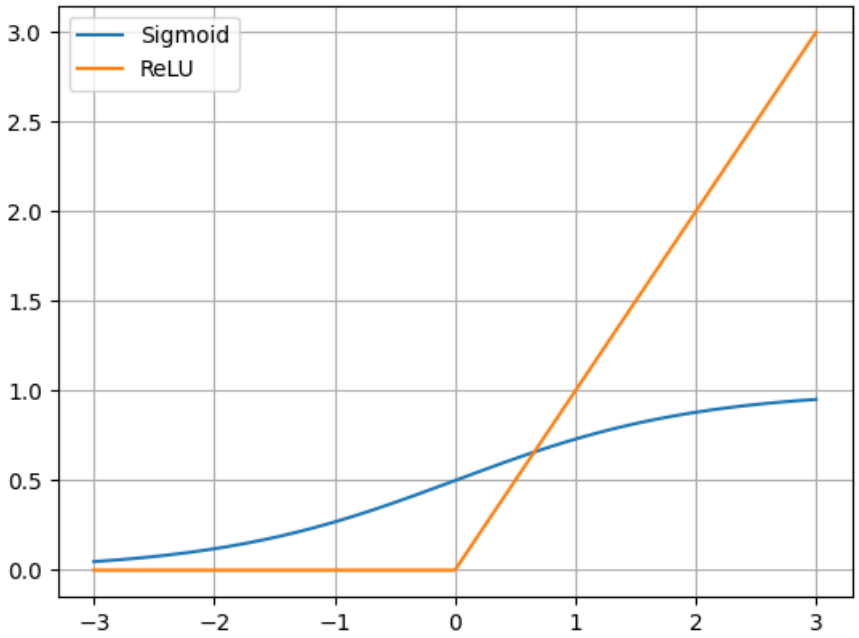

Slika 6.5 Primjer aktivacijskih funkcija sigmoid i ReLU

Slika 6.5 prikazuje grafove aktivacijskih funkcija sigmoid i ReLU.

Treniranje i optimizacija

Učenje u neuronskoj mreži nije jednokratan događaj, nego kontinuirani ciklus pokušaja i pogrešaka. Kako bi ovladala složenim okolišnim podacima, mreža slijedi postupak od tri koraka:

propagaciju unaprijed (izrada procjene), izračun gubitka (mjerenje pogreške) i propagaciju unatrag (ispravljanje unutarnjih težina).

- **Funkcija gubitka (ciljna funkcija):**

  Prije nego što se mreža može poboljšati, potrebna joj je matematička definicija „pogrešnog”. To je funkcija gubitka (naziva se i ciljna funkcija). Djeluje kao jedna skalarna vrijednost koja predstavlja udaljenost između predviđanja mreže i stvarnih, referentnih podataka.

  - **Srednja kvadratna pogreška (MSE): idealna za regresijske zadatke, kao što su predviđanje točne koncentracije CO2 u atmosferi ili temperature za sljedeći dan. Kvadrira razlike, čime se velike pogreške kažnjavaju snažnije od malih.**
  - **Unakrsna entropija gubitka: tipično se koristi za klasifikacijske zadatke (npr. „Je li ovaj satelitski piksel šuma ili urbano područje?”). Mjeri koliko se dobro predviđena distribucija vjerojatnosti podudara sa stvarnom oznakom.**

- **Propagacija unatrag (konceptualni pregled): Nakon što se gubitak izračuna, mreža mora odrediti koje su specifične težine i pristranosti najviše pridonijele pogrešci. To se postiže propagacijom unatrag.**

  Informacija teče unatrag od izlaznog sloja prema ulazu[2]. Koristeći matematička načela, algoritam točno određuje koliko je svaka pojedina težina pridonijela konačnoj pogrešci.

  - Gradijent je u biti vektor koji pokazuje u smjeru najvećeg porasta pogreške.
  - Izračunavanjem tih gradijenata mreža uči točno koliko bi neznatno povećanje ili smanjenje određene težine utjecalo na konačno predviđanje.

- **Gradijentni spust:**
  S dostupnim gradijentima mreža koristi optimizator za ažuriranje svojih težina. Najčešća metafora za to jest gradijentni spust.

  Zamislite da stojite na maglovitoj planini („krajobraz gubitka”), a cilj vam je doći do najniže doline (točke minimalne pogreške). Ne možete vidjeti dolinu, ali možete osjetiti nagib pod nogama.

  - **Gradijent: govori vam koji je smjer „uzbrdo”.**

- **Korak: kako biste smanjili pogrešku, napravite korak u suprotnom smjeru od gradijenta (nizbrdo),**
- **Stopa učenja: određuje veličinu vašeg koraka. Ako je korak prevelik, mogli biste preskočiti dolinu; ako je premalen, putovanje će trajati beskonačno dugo.**

- **Uobičajeni optimizatori**

  Iako je osnovni gradijentni spust temelj, moderno duboko učenje koristi sofisticiranije „planinare" za pronalaženje dna brda:

  - **Stohastički gradijentni spust (SGD): umjesto promatranja cijelog skupa podataka odjednom, izračunava gradijente koristeći male „minigrupe" podataka, čineći proces bržim i dinamičnijim.**
  - **Adam (Adaptive Moment Estimation): trenutačno najpopularniji optimizator. Automatski prilagođava stopu učenja za svaku težinu, usporavajući kada se približi rješenju i ubrzavajući kada je put jasan.**

Prenaučenost i generalizacija u okolišnim podacima

Kritičan izazov u treniranju neuronskih mreža jest prenaučenost. Prenaučenost nastaje kada model nauči podatke za treniranje predobro, uključujući slučajni šum ili anomalije specifične za taj skup podataka, umjesto temeljnih fizikalnih zakonitosti. Heaton naglašava da će prenaučen model imati malu pogrešku na podacima za treniranje, ali veliku pogrešku na novim, neviđenim podacima (loša generalizacija).

Posljedica za okoliš: Prenaučen model treniran na vremenskim podacima iz razdoblja 2010. - 2020. mogao bi zapamtiti specifične oluje iz tih godina. Ako se primijeni 2025., mogao bi ne uspjeti predvidjeti sušu jer traži točne obrasce iz 2010., a ne opće klimatske pokazatelje.

Strategije ublažavanja:

- **Dropout: tehnika pri kojoj se nasumično odabrani neuroni zanemaruju (isključuju) tijekom treniranja. To prisiljava mrežu da uči robusne značajke umjesto da se oslanja na specifične putanje.**

- **Rano zaustavljanje: praćenje učinkovitosti modela na zasebnom „validacijskom skupu” i zaustavljanje treniranja odmah kada se validacijska pogreška počne povećavati, čak i ako se pogreška treniranja i dalje smanjuje.**

Modeliranje nizova: od MLP-a do LSTM-a

Za razliku od tradicionalnih algoritama ili osnovnih unaprijednih mreža koje podatkovne točke uglavnom tretiraju neovisno, okolišni podaci inherentno su sekvencijalni. Za učinkovitu obradu takvih podataka koristimo mrežu Long Short-Term Memory (LSTM) [2].

LSTM je specijalizirana rekurentna neuronska mreža (RNN) osmišljena da „pamti” dugoročne trendove i riješi matematičke izazove zadržavanja informacija kroz duga razdoblja (poznato kao problem „iščezavajućeg gradijenta”). Zamislite pokretnu traku koja ide paralelno s nizom koji obrađujete. Informacija iz prošlosti može skočiti na tu pokretnu traku, biti prenesena kroz mnogo vremenskih koraka i sići netaknuta kada je potrebna. LSTM-ovi koriste sustav naučivih vrata (ulazna, izlazna i zaboravna vrata) koja reguliraju taj tok, odlučujući točno koje informacije zadržati, a koje odbaciti.

Budući da je idealno prilagođena okolišnim primjenama, ova arhitektura omogućuje dublju analizu od jednostavne regresije. Umjesto da za predviđanje današnjeg stanja koristi samo jučerašnje podatke, LSTM model promatra niz od prethodnih 14 dana kako bi prije izrade prognoze identificirao trendove zagrijavanja ili hlađenja.

Temeljne arhitekture dubokog učenja u području okoliša

Ovaj odjeljak istražuje temeljne arhitekture neuronskih mreža koje se koriste za modeliranje okolišnih sustava. Umjesto usredotočivanja na složene matematičke izvode, usmjeravamo se na intuiciju iza tih modela: razumijevanje kada upotrijebiti određenu arhitekturu na temelju strukture okolišnih podataka (npr. tablična očitanja senzora, satelitske snimke ili povijesne vremenske serije).

Unaprijedne mreže (FFN): temelj

Unaprijedna mreža, često nazvana višeslojnim perceptronom (MLP), temeljni je model dubokog učenja. U tim mrežama informacija teče u jednom smjeru - od ulaznih čvorova, kroz skrivene slojeve, do izlaznih čvorova - bez petlji.

Kako funkcionira: FFN-ovi aproksimiraju funkcije preslikavanjem ulaznih vektora u izlazne ciljne vrijednosti. Izvrsni su u učenju globalnih obrazaca u tabličnim podacima.

Primjena u okolišu: FFN-ovi su prikladni za statičke prediktivne zadatke u kojima redoslijed podatkovnih točaka nije važan ili su vremenske ovisnosti slabe.

Primjer: predviđanje trenutačne razine onečišćenja na određenoj lokaciji na temelju presjeka trenutačne brzine vjetra, temperature i gustoće prometa.

Ograničenje: FFN-ovi nemaju „memoriju". Svaki ulaz obrađuju neovisno, što ih čini manje učinkovitima za podatke u kojima je redoslijed važan, kao što su dugotrajni toplinski valovi ili sezonski trendovi.

Konvolucijske neuronske mreže: obrada prostornih podataka

Dok FFN-ovi ulazne značajke tretiraju neovisno, okolišni podaci često imaju topologiju nalik rešetki, poput satelitskih slika ili radarskih karata. CNN-ovi su specijalizirani za obradu takvih podataka.

Kako funkcionira: umjesto povezivanja svakog neurona sa svakim drugim neuronom, CNN-ovi koriste male „filtre" (kernele) koji klize preko ulazne slike kako bi otkrili lokalne obrasce poput rubova, tekstura ili oblika. To omogućuje modelu da prepozna značajku (npr. stablo ili zgradu) bez obzira na to gdje se pojavljuje na slici (translacijska invarijantnost).

Primjena u okolišu: CNN-ovi su standard za daljinska istraživanja. Primjer: analiza satelitskih snimki za kartiranje krčenja šuma u Amazoniji ili klasifikacija zdravlja koraljnih grebena iz podvodnih fotografija.

Rekurentne arhitekture (RNN, LSTM, GRU): analiza vremenskih serija

Okolišni podaci inherentno su sekvencijalni; poznavanje jučerašnje temperature ključno je za predviđanje današnje temperature. Rekurentne neuronske mreže (RNN) rješavaju to uvođenjem unutarnje petlje koja omogućuje postojanost informacija.

Standardni RNN-ovi: te mreže održavaju „stanje" koje sadržava informacije povezane s onime što su do tada vidjele. Međutim, standardni RNN-ovi pate od „problema iščezavajućeg gradijenta", zbog čega ne mogu pamtiti informacije kroz duge nizove (npr. povezati oborinski događaj od prije dva tjedna s današnjim razinama rijeka).

Long Short-Term Memory (LSTM): za rješavanje problema memorije uvedeni su LSTM-ovi sa specijaliziranom unutarnjom strukturom koja uključuje „vrata" (ulazna, zaboravna i

izlazna vrata). Ta vrata omogućuju mreži da eksplicitno nauči što treba zapamtiti, a što zaboraviti tijekom dugih razdoblja.

Gated Recurrent Unit (GRU): pojednostavljena varijanta LSTM-a koja se često trenira brže, a pritom nudi usporedivu učinkovitost za mnoge okolišne zadatke vremenskih serija. Primjena u okolišu: ove su arhitekture ključne za prognoziranje.

Primjer: predviđanje rizika od poplava na temelju niza podataka o oborinama i vlažnosti tla tijekom prethodnih 14 dana ili modeliranje klimatskih trendova u kojima povijesni kontekst određuje buduća stanja.

Odgovorna umjetna inteligencija: prenaučenost i etika

Primjena dubokog učenja u stvarnom svijetu zahtijeva više od same visoke točnosti; zahtijeva pouzdanost i etičku odgovornost.

Izbjegavanje prenaučenosti: česta je zamka stvaranje modela koji memorira podatke za treniranje (npr. specifične vremenske anomalije iz 2010.), ali se ne uspijeva generalizirati na budućnost. Koristimo tehnike poput Dropouta (nasumično zanemarivanje neurona tijekom treniranja kako bi se spriječilo oslanjanje na specifične putanje) i ranog zaustavljanja (prekid treniranja kada se validacijska učinkovitost pogorša) kako bismo osigurali robusnost modela.

Etička i interpretabilna AI: modeli dubokog učenja često se kritiziraju kao „crne kutije". U okolišnoj politici moramo težiti transparentnosti. Tehnologija nikada nije neutralna; tehnički izbori ujedno su i etički izbori. Kada modeli utječu na odluke - poput raspodjele vode ili odgovora na katastrofe - ključno je provjeriti da ne održavaju pristranosti prisutne u povijesnim podacima te da njihove predikcije mogu interpretirati stručnjaci iz domene.

Od dubokog učenja do klimatski prilagodljivog donošenja odluka

Nakon što je model dubokog učenja istreniran i validiran, fokus se pomiče s tehničke optimizacije na operativni učinak. Postizanje niske stope pogreške (primjerice, pomoću metrika kao što su srednja apsolutna pogreška ili korijen srednje kvadratne pogreške) tehnička je prekretnica, ali krajnji je cilj prevođenje tih numeričkih predviđanja u smislene, klimatski prilagodljive akcije. Prediktivno modeliranje pokreće tri ključna stupa održivosti:

- **Proaktivno planiranje. Korištenje dugoročnih prognoza za projektiranje otporne infrastrukture (npr. dimenzioniranje sustava odvodnje na temelju predviđenog intenziteta oborina).**
- **Smanjenje rizika: implementacija sustava ranog upozoravanja u kojima izlazi modela izravno aktiviraju sigurnosne protokole.**
- **Raspodjela resursa: optimizacija raspodjele vode ili energije na temelju očekivanih okolišnih uvjeta.**

Prediktivno modeliranje za prilagodbu klimatskim promjenama

Duboko učenje zamjenjuje spore fizikalne simulacije brzim podatkovno utemeljenim modelima, omogućujući prilagodbu klimatskim promjenama u stvarnom vremenu u ključnim područjima:

- Prognoziranje ekstremnih vremenskih obrazaca (toplinski valovi, oluje, suše)
- Predviđanje hidroloških promjena (poplave, varijabilnost riječnih protoka, nestašica vode)
- Modeliranje vjerojatnosti i širenja šumskih požara
- Predviđanje pogoršanja kvalitete zraka i utjecaja na ljudsko zdravlje.

Ti modeli omogućuju klimatski pametno planiranje, kao što su razvoj otporne infrastrukture, sustavi ranog upozoravanja i spremnost za hitne intervencije. Predviđanja dubokog učenja omogućuju preciznu prilagodbu klimatskim promjenama povezivanjem izlaza modela sa specifičnim okidačima politika i mjerama otpornosti. U nastavku su prošireni primjeri strukturirani kao (otkrivanje -> akcija), s pojedinostima o mehanici modela, stvarnim primjenama i ishodima prilagodbe preuzetima iz etabliranih studija slučaja.

Primjeri scenarija klimatski prilagodljivih primjena:

- **Primjene predviđanja poplava**
  - **(Otkrivanje) CNN-LSTM modeli obrađuju satelitske snimke i podatke mareografa kako bi prognozirali 48-satne vjerojatnosti obalnih poplava, postižući 20 % veću točnost od tradicionalnih modela u scenarijima porasta razine mora. -> (Akcija) Općine aktiviraju prilagodljive obrane obalne linije poput obnove mangrova i podizanja kritične infrastrukture; rana upozorenja smanjuju ekonomske gubitke za 30 - 50 % prethodnim postavljanjem vreća s pijeskom i preusmjeravanjem prometa [5],**

- **(Otkrivanje) Prostorno-vremenske LSTM mreže integriraju radarske oborine i podatke vodomjernih postaja za kartiranje dubine urbanih poplava u stvarnom vremenu s razlučivošću od jednog sata. -> (Akcija) Hitne službe uvode dinamične aplikacije za upozoravanje stanovnika, optimiziraju rad crpnih stanica i ažuriraju urbane zone za standarde gradnje otporne na poplave [6].**

- **Upravljanje rizikom od šumskih požara**
  - **(Otkrivanje) Ansambl CatBoost-RNN modela analizira vegetacijske indekse, obrasce vjetra i temperaturu iz MODIS satelitskih podataka kako bi predvidio dnevnu vjerojatnost izbijanja šumskog požara na područjima od 10 000 km². -> (Akcija) Šumarske službe planiraju kontrolirana paljenja u razdobljima niskog rizika, izdaju stupnjevane naloge za evakuaciju putem SMS-a i preventivno raspoređuju zračne cisterne s vodom, smanjujući troškove gašenja za 25 %. [7],**
  - **(Otkrivanje) Hibridni CNN-BiLSTM okviri simuliraju brzine širenja požara koristeći VIIRS detekcije aktivnih požara i topografske podatke za gotovo stvarnovremensko prognoziranje perimetra. -> (Akcija) Zajednice postavljaju mreže senzora za rano otkrivanje dima, proširuju protupožarne prosjeke autohtonom vegetacijom i obučavaju dobrovoljne brigade za brzu intervenciju [8].**

- **Strategije za sušu i toplinske valove**
  - **(Otkrivanje) Hibridni QRNN+wavelet modeli dubokog učenja prognoziraju indeks hidrološke suše Streamflow Drought Index (SDI-3, SDI-6, SDI-12) za Stockholm u Švedskoj, integrirajući dekompoziciju vremenskih serija za višeskalnu točnost. -> (Akcija) Vodne vlasti uvode ograničenja 3 - 12 mjeseci unaprijed, revidiraju dugoročne ugovore o opskrbi i prilagođavaju rad hidroelektrana kako bi ublažile projicirane manjkove riječnog protoka [9],**
  - **(Otkrivanje) Duboko i ansambl učenje iz europskih klimatskih simulacija izdvajaju epizode ekstremne vrućine i suše koje pojačavaju toplinske valove u južnoj i zapadnoj Europi, naglašavajući glavne klimatske pokazatelje. -> (Akcija) Gradovi poput Lisabona i Atene aktiviraju „planove za hitne situacije zbog vrućine”: centre za rashlađivanje, zabrane rada na otvorenom i ciljane SMS obavijesti za starije stanovništvo [10].**

Studija slučaja: predviđanje toplinskih valova pomoću dubokih neuronskih mreža

Izvor podataka Open-Meteo

Za ovu studiju slučaja platforma Open-Meteo koristi se kao referenca za vremenske podatke. Open-Meteo pruža besplatan pristup povijesnim vremenskim podacima za bilo koju lokaciju u svijetu putem javno dostupnog API-ja, omogućujući korisnicima odabir vremenskog raspona i skupa vremenskih varijabli.

Za treniranje modela dubokog učenja sposobnog za predviđanje toplinskih valova potrebne su nam specifične varijable koje pokreću toplinski stres. Preuzimanje treba provesti preko mrežnog sučelja, uz navođenje geografske lokacije (geografske širine i dužine), vremenske razlučivosti (dnevno) i odabranih meteoroloških varijabli.

U ovoj vježbi usredotočit ćemo se na ključnu varijablu temperature_2m_max - to je ciljna varijabla koju želimo predvidjeti kako bismo identificirali događaje ekstremne vrućine.

Podaci se izravno uvoze u Python okruženje pomoću biblioteke Pandas, koja parsira CSV odgovor API-ja u strukturirani skup podataka prikladan za strojno učenje.

Primjer dubokog učenja

U ovoj praktičnoj vježbi prelazimo s jednostavne statistike na moderno duboko učenje. Izgradit ćemo sustav koji ne kaže samo „danas je vruće”, nego aktivno upozorava na približavanje opasnih toplinskih valova analizom klimatske dinamike kroz vrijeme.

Da bismo to postigli, koristimo LSTM (Long Short-Term Memory) mrežu - vrstu umjetnog mozga sposobnu za pronalaženje uzročno-posljedičnih odnosa u vremenu.

Vodič korak po korak: kako pokrenuti simulaciju

Koristit ćemo Google Colab, besplatnu platformu u oblaku koja vam omogućuje pokretanje ovog AI modela izravno u pregledniku bez instaliranja ikakvog softvera.

1. **Otvorite Google Colab:**
    - U web-pregledniku otvorite colab.research.google.com,
    - Prikazat će se prozor „Welcome to Colaboratory”.
2. **Prenesite bilježnicu:**

- Kliknite karticu Upload u skočnom prozoru,
- Povucite i ispustite datoteku “ML_DL.ipynb” u okvir (ili kliknite „Choose File” kako biste je odabrali s računala).

3. **Pokrenite kod:**
   - Nakon što se bilježnica učita, pogledajte gornju traku izbornika,
   - Kliknite Runtime i odaberite Run all (ili pritisnite Ctrl+F9),
   - *Napomena: možda ćete vidjeti upozorenje „Notebook requires high RAM” ili „Author not trusted” - jednostavno kliknite Run anyway.*
4. **Interakcija:**
   - Pomičite se prema dolje dok se kod izvršava. Vidjet ćete učitavanje tablica podataka, pomicanje traka napretka treniranja i na kraju pojavu interaktivnih grafova.

Tehnički preduvjeti

Implementacija se izvodi u Pythonu pomoću sljedećih specijaliziranih Python biblioteka:

- **TensorFlow/Keras: za izgradnju i treniranje LSTM (Long Short-Term Memory) neuronske mreže,**
- **Scikit-learn: za normalizaciju podataka (skaliranje) i izračun metrika učinkovitosti (MAE, RMSE),**
- **Pandas/NumPy: za obradu podataka vremenskih serija i izvođenje numeričkih izračuna,**
- **Folium/Plotly/Seaborn: za izradu interaktivnih grafova prognoze i geoprostornih karata za potporu odlučivanju.**

Izvor podataka

Platformu Open-Meteo koristimo kao naš „vremenski stroj”. Ona pruža povijesne vremenske podatke za bilo koju lokaciju na Zemlji. Za treniranje naše AI odabrali smo ključnu varijablu „Maksimalna temperatura (2 m)” - ciljnu varijablu koju želimo predvidjeti.

Tijek bilježnice: razumijevanje programskog koda

Dostavljena bilježnica “ML_DL.ipynb” cjelovit je, potpuno funkcionalan radni tok spreman za pokretanje. Unaprijed je konfigurirana za automatsko preuzimanje podataka, treniranje

neuronske mreže i generiranje interaktivnih izvješća. Za prikaz rezultata nije potrebno dodatno programiranje.

Kako bi simulaciju prilagodili različitim gradovima ili scenarijima, studenti trebaju izmijeniti samo Blok 1 (Configuration & Libraries). Blokove 2 do 8 nije potrebno mijenjati i oni sadržavaju temeljnu logiku (obrada podataka, treniranje LSTM-a, vizualizacija). Ti su blokovi automatizirani i treba ih jednostavno izvršavati redom.

Praktični rad podijeljen je u 8 logičkih blokova:

1. Configuration & Libraries. U ovom prvom koraku postavljamo „upravljačku ploču" za naš eksperiment. Prije pokretanja AI-ja studenti mogu izmijeniti određene varijable kako bi simulaciju prilagodili različitim gradovima ili scenarijima:

- **Geografska lokacija: LATITUDE & LONGITUDE: koordinate ciljnog grada (prema zadanim postavkama Kijev, Ukrajina: 50.45, 30.52). Njihovom promjenom možete testirati kako se model ponaša u potpuno različitim klimama, poput kišnog Šibenika (Hrvatska) ili suhog Rima (Italija), Skoplja (Sjeverna Makedonija).**
- **Postavke vremenskog stroja (raspon podataka): START_DATE & END_DATE. Povijesno razdoblje koje se koristi za treniranje AI-ja (npr. "2010-01-01" do "2025-12-31"). Veći broj godina povijesti općenito pomaže modelu da bolje nauči obrasce.**
- **Raspon „memorije" AI-ja: LOOKBACK_DAYS. Veličina „kliznog prozora" (zadano 14 dana). Određuje koliko daleko u prošlost model gleda kako bi izradio predviđanje.**
- **Kontrole vizualizacije: DISPLAY_START_DATE & DISPLAY_END_DATE. One kontroliraju razinu zumiranja glavnog interaktivnog grafa (korak 6). Umjesto prikaza svih 15 godina, možemo se usredotočiti na određenu zanimljivu godinu (npr. 2025.).**
- **Sigurnosni pragovi (sustav odlučivanja):**
  - HEATWAVE_WARNING: temperaturni prag (npr. 27.0°C) koji aktivira „narančasto" savjetodavno upozorenje za javnost.
  - CRITICAL_EMERGENCY: ekstremna temperatura (npr. 31.0°C) koja aktivira „crveno" kritično upozorenje za hitne službe.
- **Razdoblje analize prognoze: DISPLAY_FORECAST_START_DATE & DISPLAY_FORECAST_END_DATE. Specifični raspon (npr. kolovoz 2025.) koji se**

koristi u koraku 7 za testiranje je li sustav upozoravanja ispravno identificirao toplinske valove tijekom određenog mjeseca.

2. Load Data. Kod se automatski povezuje s Open-Meteo API-jem i preuzima povijest vremena za posljednjih 15 godina. Studenti mogu promatrati kako se „sirovi" podaci pretvaraju u strukturiranu Pandas tablicu (slika 6.6).

```
Fetching data from Open-Meteo...
Data loaded: 5844 records.
```

	Date	MaxTemp	SolarRad
0	2010-01-01	-6.2	1.83
1	2010-01-02	-6.2	2.66
2	2010-01-03	-11.4	3.29
3	2010-01-04	-12.4	3.87
4	2010-01-05	-8.7	3.60

Slika 6.6 Dohvaćeni podaci iz Open-Meteo

3. Preprocessing: The "Sliding Window". To je ključna razlika u odnosu na klasične algoritme. Umjesto da model učimo na temelju obrasca „Jučer je bilo toplo -> danas će biti toplo", stvaramo klizni prozor (razdoblje pogleda unatrag) od 14 dana. Model promatra niz (dan 1 ... dan 14) kako bi predvidio dan 15. Zašto: to omogućuje neuronskoj mreži da opaža inerciju klime - kako se toplina postupno nakuplja prije vrhunca.

4. Build and Train LSTM Model (slika 6.7). Konstruiramo „mozak" našeg sustava:

- Koristimo LSTM sloj, koji djeluje kao memorija sustava, zadržavajući važne trendove i odbacujući slučajni šum.
- Dodaje se mehanizam Dropout kako bi se spriječila prenaučenost - situacija u kojoj model jednostavno memorira prošle godine, ali ne razumije opće vremenske zakonitosti.

```
117/117 ━━━━━━━━━━━━━━━━━━━━ 1s 9ms/step - loss: 0.0029 - mae: 0.0414 - val_loss: 0.0025 - val_mae: 0.0388
Epoch 38/50
117/117 ━━━━━━━━━━━━━━━━━━━━ 1s 8ms/step - loss: 0.0030 - mae: 0.0423 - val_loss: 0.0025 - val_mae: 0.0388
Epoch 39/50
117/117 ━━━━━━━━━━━━━━━━━━━━ 1s 9ms/step - loss: 0.0029 - mae: 0.0413 - val_loss: 0.0025 - val_mae: 0.0389
Epoch 40/50
117/117 ━━━━━━━━━━━━━━━━━━━━ 1s 9ms/step - loss: 0.0030 - mae: 0.0423 - val_loss: 0.0025 - val_mae: 0.0389
Epoch 40: early stopping
Restoring model weights from the end of the best epoch: 35.
Training complete.
```

Slika 6.7 Treniranje LSTM-a s ranim zaustavljanjem

5. Vizualizacija učinkovitosti treniranja. Prikazujemo „krivulju učenja".

Cilj: želimo da obje linije s vremenom idu prema dolje. To znači da se pogreška modela (gubitak) smanjuje.

- **Plava linija (Train Loss): koliko dobro model uči iz „materijala za učenje" (povijesni podaci),**
- **Crvena linija (Validation Loss): koliko dobro model odgovara na „nova pitanja" koja prije nije vidio.**

Na što obratiti pozornost na slici 6.8:

- **Dobar rezultat: obje linije idu prema dolje i ostaju blizu jedna drugoj.**
- **Prenaučenost: ako plava linija ide prema dolje, ali crvena počne ići prema gore, model memorira podatke umjesto da uči obrasce.**

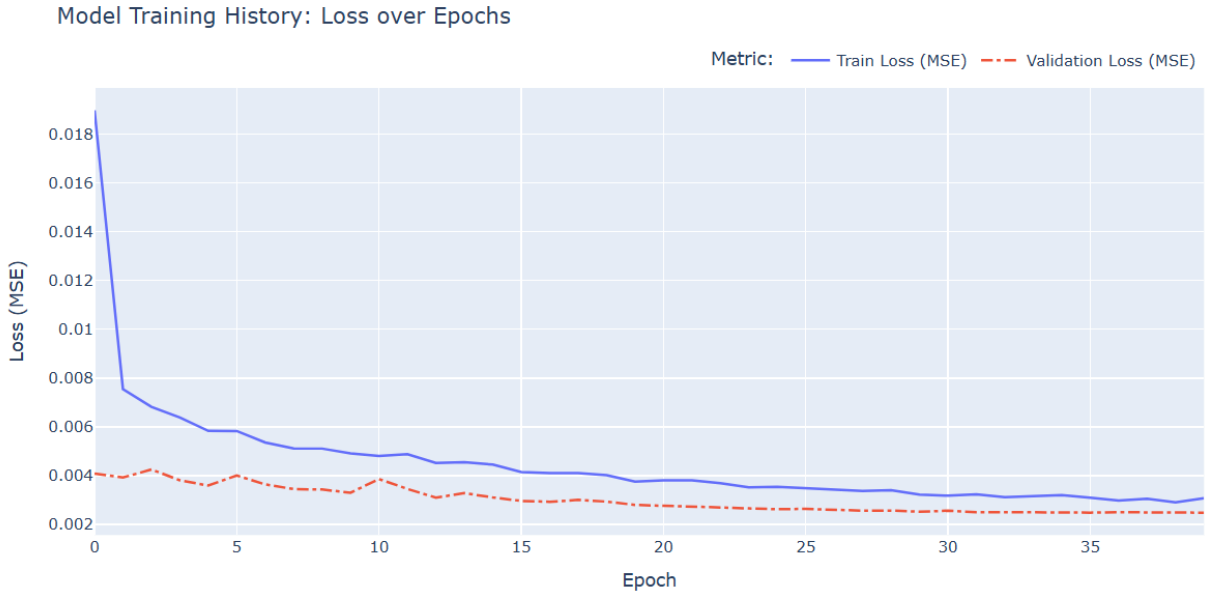

Slika 6.8 Povijest treniranja modela: gubitak kroz epohe

6. Evaluacija i interaktivna prognoza. Koristimo biblioteku Plotly za generiranje interaktivnog grafa.

6a. Izvještajna kartica modela (metrike):

Prije gledanja grafova izračunavamo matematičku ocjenu modela (slika 6.9).

- **MAE (srednja apsolutna pogreška): prosječni „promašaj" u stupnjevima (npr. ako model obično griješi za 1.5°C).**
- **RMSE (korijen srednje kvadratne pogreške): metrika koja velike pogreške kažnjava snažnije od malih.**
- **R2 (mjera točnosti): postotni rezultat (0.0 do 1.0) koji pokazuje koliko temperaturne varijacije model uspješno objašnjava.**

```
--- 📊 WEATHER MODEL REPORT CARD ---

1. Average Error (MAE): 2.14°C
   👉 Explanation: On average, the model's prediction is off by about 2.1°C.
--------------------------------------------------
2. Penalty for Big Mistakes (RMSE): 2.74°C
   👉 Explanation: This metric punishes large errors more heavily.
      If this number is much higher than the Average Error, the model occasionally makes big misses.
--------------------------------------------------
3. Accuracy Score (R²): 0.93 (or 93.1%)
   👉 Explanation: How much of the temperature variation does the model explain?
      (1.0 = Perfect, 0.0 = Useless, Negative = Worse than guessing)
   ✅ Quality: High Confidence.
--------------------------------------------------
```

Slika 6.9 Izvještajna kartica vremenskog modela

6b. Predviđanja (interaktivna prognoza)

Time se generira dinamički graf vremenske serije pomoću Plotlyja (slika 6.10).

- **Crvena linija: temperatura koju je predvidjela AI,**
- **Plava isprekidana linija: stvarno zabilježena temperatura,**
- Interaktivni klizač: nalazi se na dnu i omogućuje studentima zumiranje određenih tjedana ili mjeseci kako bi vidjeli prati li crvena linija točno nagle skokove toplinskog vala.

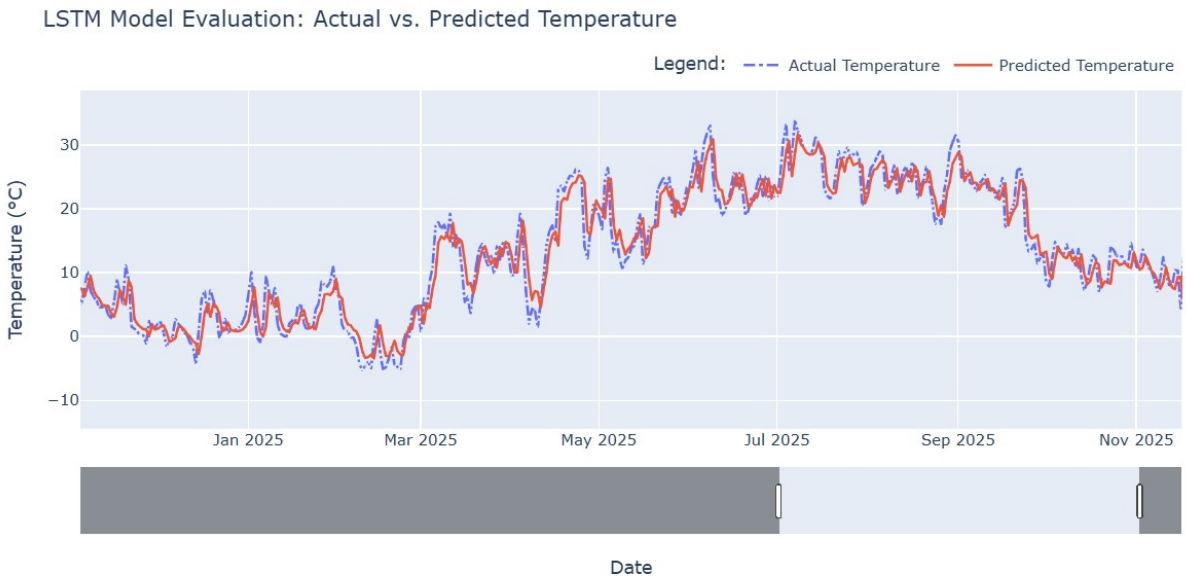

Slika 6.10 Evaluacija LSTM modela: stvarna naspram predviđene temperature

6c. Stvarno naspram predviđenog (dobrota prilagodbe)

Time se generira dijagram raspršenja za provjeru pristranosti.

- **Os X: stvarna temperatura.**
- **Os Y: predviđena temperatura.**
- **„Linija savršenstva": dijagonalna crvena isprekidana linija. Kada bi model bio savršen, svaka plava točka ležala bi točno na toj crvenoj liniji. Ova vizualizacija pomaže nam vidjeti precjenjuje li model dosljedno (točke iznad linije) ili podcjenjuje (točke ispod linije) toplinu.**

6d. Graf reziduala

Time se generira graf koji prikazuje reziduale (odnosno pogreške) kroz vrijeme.

- **Nulta linija: predstavlja savršeno predviđanje (0 pogreške),**
- **Svrha: tražimo nasumičnost. Ako točke izgledaju kao nasumični „šum" oko nulte linije, model je zdrav. Ako vidimo jasne ponavljajuće valne obrasce, to znači da modelu nedostaje ključan čimbenik (poput sezonalnosti).**

7. Klimatski prilagodljiv sustav odlučivanja

U ovom bloku modeliramo rad sustava ranog upozoravanja. Umjetna inteligencija ne predviđa samo temperaturu; djeluje kao „digitalni savjetnik" gradske uprave, signalizirajući kada je potrebno aktivirati sigurnosne protokole.

Sustav radi prema načelu semafora, uspoređujući prognozu AI-ja sa sigurnosnim pragovima (THRESHOLDS) koje smo definirali u Bloku 1.

- 🟢 Razina „Normalno" (zeleno)
  - Uvjet: predviđena temperatura ispod je praga upozorenja (primjerice < 30°C).
  - Akcije zajednice:
    - Rutinsko praćenje vremenskih uvjeta,
    - Standardni rad komunalnih službi,
    - *Objašnjenje: situacija je sigurna; intervencija nije potrebna.*
- 🟠 Razina „Savjetodavno / upozorenje" (naranČasto)
  - Uvjet: temperatura prelazi prvu granicu (primjerice ≥ 30°C, varijabla HEATWAVE_WARNING),
  - Akcije zajednice:
    - Komunikacija: slanje SMS upozorenja ranjivim skupinama stanovništva (starijim osobama, osobama s kroničnim bolestima),
    - Zdravstvo: stavljanje hitne medicinske pomoći u stanje povećane pripravnosti,
    - Socijalne službe: socijalni radnici provode dodatne posjete izoliranim starijim stanovnicima.
- 🔴 Razina „Kritična izvanredna situacija" (crveno)
  - Uvjet: temperatura doseže ekstremne vrijednosti (primjerice ≥ 35°C, varijabla CRITICAL_EMERGENCY).
  - Akcije zajednice:
    - Infrastruktura: otvaranje gradskih „centara za rashlađivanje" - klimatiziranih prostora u knjižnicama, školama ili društvenim centrima otvorenima za javnost,
    - Zaštita na radu: ograničavanje ili zabrana teškog rada na otvorenom (gradnja, popravak cesta) tijekom sati najjačeg sunca,
    - Opskrba vodom: postavljanje mobilnih stanica za distribuciju pitke vode na gradskim trgovima,

- Energetska mreža: priprema za moguća rotacijska isključenja električne energije zbog preopterećenja mreže uzrokovanog klima-uređajima.

```
--- HEATWAVE EARLY WARNING SYSTEM (LSTM) ---
Analyzing forecast for the period: 2025-08-01 to 2025-08-31
Date: 2025-08-01 | Forecast=22.2°C | Actual=24.3°C | Error=-2.1°C
  [ACTION]: 🟢 Status Normal.
------------------------------------------------------------
Date: 2025-08-02 | Forecast=24.7°C | Actual=26.4°C | Error=-1.7°C
  [ACTION]: 🟢 Status Normal.
------------------------------------------------------------
Date: 2025-08-03 | Forecast=26.1°C | Actual=27.0°C | Error=-0.9°C
  [ACTION]: 🟢 Status Normal.
------------------------------------------------------------
Date: 2025-08-04 | Forecast=26.3°C | Actual=28.1°C | Error=-1.8°C
  [ACTION]: 🟢 Status Normal.
------------------------------------------------------------
Date: 2025-08-05 | Forecast=27.1°C | Actual=29.0°C | Error=-1.9°C
  [ACTION]: 🟠 ADVISORY. Issue elderly warnings.
------------------------------------------------------------
Date: 2025-08-06 | Forecast=27.7°C | Actual=28.4°C | Error=-0.7°C
  [ACTION]: 🟠 ADVISORY. Issue elderly warnings.
------------------------------------------------------------
Date: 2025-08-07 | Forecast=27.0°C | Actual=23.0°C | Error=4.0°C
  [ACTION]: 🟠 ADVISORY. Issue elderly warnings.
------------------------------------------------------------
```

Slika 6.11 Sustav ranog upozoravanja na toplinske valove

8. Geoprostorna vizualizacija

U ovom završnom bloku našu vremensku prognozu pretvaramo u geoprostorni alat za potporu odlučivanju. Točke na karti mijenjaju boju (plava/narančasta/crvena) ovisno o predviđenoj razini opasnosti. To pokazuje kako gradski službenici mogu pratiti pojedine gradske četvrti. Statičke karte obično prikazuju trenutni presjek, ali ova animirana karta prikazuje priču.

Primjena u zajednici: kada bi se ovaj model proširio na mrežu senzora (npr. središte grada, predgrađa, industrijska zona), gradski bi upravitelji mogli vidjeti koje se konkretne četvrti pregrijavaju (učinak urbanog toplinskog otoka) i poslati cisterne s vodom samo u ta konkretna susjedstva, štedeći resurse.

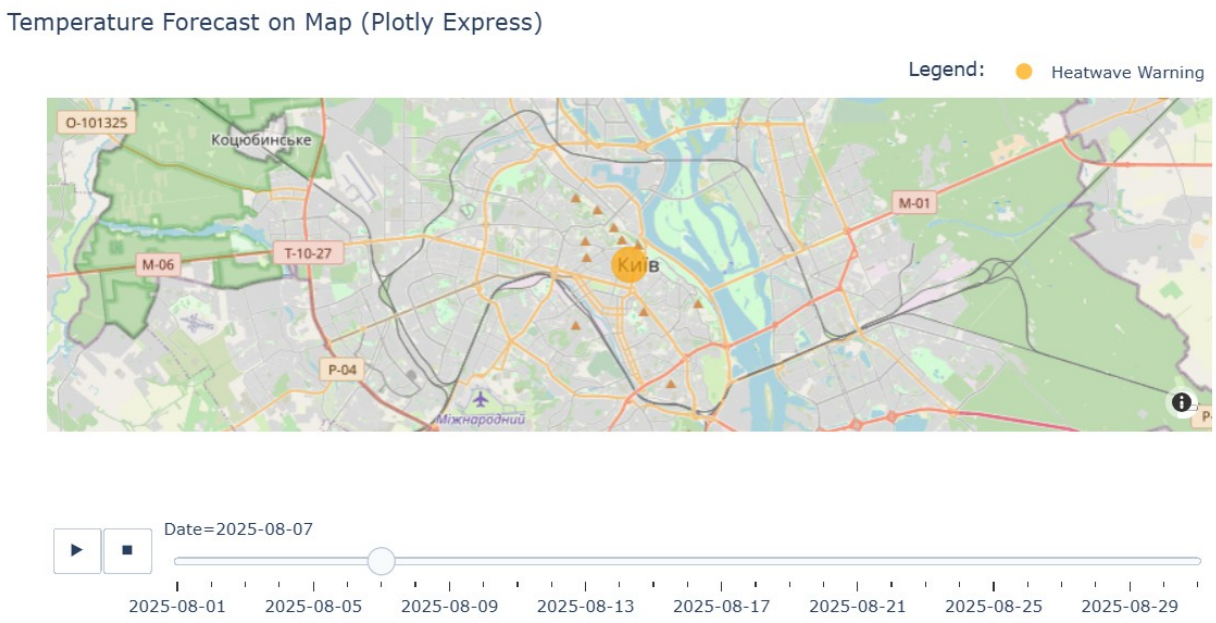

Slika 6.12 Vizualizacija karte na temelju parametara CRITICAL_EMERGENCY i HEATWAVE_WARNING

Zadaci za vježbu

U ovoj ćete vježbi upotrijebiti duboko učenje za predviđanje ekstremnih vremenskih obrazaca u gradu po vlastitom izboru. Zatim ćete te rezultate upotrijebiti za raspravu o praktičnim rješenjima za zaštitu gradske infrastrukture i stanovništva.

Zadatak 1: geografska prilagodba

- **Otvorite datoteku bilježnice dostavljenu u Google Colabu.**
- **Pronađite varijable LATITUDE i LONGITUDE u Bloku 1.**
- **Promijenite te koordinate u grad po vlastitom izboru (npr. svoj rodni grad ili vruću lokaciju poput Rima, Atene itd.).**
- **Pokrenite bilježnicu kako biste generirali nova predviđanja.**
- **Analizirajte rezultate sustava odlučivanja u Bloku 7:**
  - Ispisuje li sustav previše poruka „CRITICAL ALERT” (crveno)? (To sugerira da su pragovi preniski za ovu vruću klimu, što potencijalno uzrokuje „zamor od alarma”).
  - Ili nema nikakvih upozorenja unatoč vrućem vremenu? (To sugerira da su pragovi možda previsoki).

- **Vizualizacija karte (Blok 8): pomaknite se prema dolje do interaktivne karte. Vidite li CRVENE ili NARANČASTE točke? Odgovara li vizualna distribucija „zona opasnosti" vašim očekivanjima za ovaj grad?**
- **Kalibrirajte: vratite se u Blok 1 i prilagodite varijable HEATWAVE_WARNING i CRITICAL_EMERGENCY kako bi bolje odgovarale klimi odabranog grada.**
- **Ponovno pokrenite bilježnicu.**

Pitanje: kako je promjena pragova poboljšala korisnost sustava ranog upozoravanja za ovu specifičnu lokaciju? Koju biste politiku urbanog planiranja predložili za to konkretno područje kako bi se rizik od vrućine smanjio u sljedećih 5 godina? (npr. sadnja više drveća, postavljanje zelenih krovova).

Zadatak 2: testiranje „memorije" (ugađanje hiperparametara)

- **Pronađite varijablu LOOKBACK_DAYS = 14 u Bloku 1. Ona predstavlja „raspon memorije" AI-ja (koliko prošlih dana analizira).**
- **Promijenite vrijednost s 14 na 3 dana.**
- **Ponovno pokrenite cijelu bilježnicu (Runtime -> Run all) kako biste ponovno istrenirali model s ovom „kratkoročnom memorijom".**
- **Pomaknite se prema dolje do evaluacijskog grafa u Bloku 6b.**

Pitanje: usporedite ponašanje crvene linije (predviđanje) sada u odnosu na prethodno pokretanje s 14 dana:

- **Učinak kašnjenja: pomiče li se crvena linija udesno? (tj. shvaća li model da je vruće tek nakon što je temperatura već porasla?)**
- **Točnost vrhunca: ne uspijeva li model dosegnuti najviše temperaturne vrhove (podcjenjujući vrućinu)?**
- **Hipoteza: toplinski valovi ne nastaju trenutačno. Zašto AI mora vidjeti posljednjih 14 dana kako bi ih predvidio, umjesto samo posljednja 3 dana?**

Zadatak 3 (⚠️ napredni i neobvezni zadatak): preokretanje scenarija (test „zimskog anticiklona")

Kontekst: klimatske promjene ne donose samo toplinske valove, nego i ekstremne hladne prodore (npr. prodore polarnog vrtloga). Vaš je trenutačni sustav „slijep" za hladnoću jer traži samo visoke temperature.

- **Korak 1 (putovanje kroz vrijeme): u Bloku 1 promijenite DISPLAY_FORECAST_START_DATE i DISPLAY_FORECAST_END_DATE na poznato hladno zimsko razdoblje (npr. "2012-01-15" do "2012-02-15"). Promijenite LATITUDE i LONGITUDE na sjeverni grad poznat po oštrim zimama (npr. Helsinki, Oslo ili Winnipeg). Savjet: koordinate možete pronaći pomoću Google Maps.**
- **Korak 2 (pragovi): u Bloku 1 promijenite CRITICAL_EMERGENCY na vrijednost smrzavanja, primjerice -15.0 (°C).**
- **Korak 3 (inverzija logike): idite u Blok 7 (sustav odlučivanja).**
    - Pronađite redak koda: if forecast_temp >= CRITICAL_EMERGENCY:
    - **Akcija: promijenite operator iz >= (veće ili jednako) u <= (manje ili jednako).**
    - *Napomena: sada sustav aktivira upozorenje samo kada temperatura padne ispod granice smrzavanja.*
- **Pokrenite: izvršite Blok 7.**

Pitanje: označava li sustav sada ispravno najhladnije dane kao „CRITICAL ALERTS”? Raspravite zašto je prilagodba logike AI-ja jednako važna kao i dobri podaci pri suočavanju s različitim vrstama klimatskih rizika.

Zadatak 4: rasprava

Interpretirajte rezultate zadataka 1 - 3 u okolišnom kontekstu. Na temelju učestalosti i distribucije upozorenja (Blok 7, Blok 8) predložite odgovarajuću politiku urbanog planiranja za ublažavanje identificiranih rizika.

Provjera znanja

Koja je primarna svrha korištenja LSTM (Long Short-Term Memory) modela umjesto jednostavnog izračuna prosjeka za predviđanje toplinskih valova?

A. Izgladiti dnevne fluktuacije i izraditi čist godišnji graf temperature.
B. Identificirati tehničke pogreške i šum u sirovim podacima senzora.
C. Uhvatiti složene vremenske obrasce i „učinak akumulacije” topline kroz vrijeme.
D. Zamijeniti potrebu za fizičkim meteorološkim postajama u udaljenim područjima.

Koja je najvjerojatnija negativna posljedica smanjenja „memorije” AI-ja (Lookback Days) s 14 dana na samo 3 dana?

A. Model će postati osjetljiviji na šum i proizvoditi česte lažne alarme.
B. Model će patiti od „učinka kašnjenja”, shvaćajući da se toplinski val događa tek nakon što je temperatura već dosegnula vrhunac.
C. Model će se automatski prebaciti s dubokog učenja na linearnu regresiju.
D. Model se neće moći pokrenuti jer skup podataka postaje premalen za obradu.

U okolišnom prognoziranju, koji je glavni rizik „prenaučenog” modela dubokog učenja?

A. Proizvodi predviđanja koja su previše generalizirana i zanemaruju lokalne vremenske specifičnosti.
B. Memorira specifične povijesne događaje (šum) i ne uspijeva točno predvidjeti kada se pojave novi, neviđeni vremenski obrasci.
C. Zahtijeva znatno više računalne snage nego što hardver dopušta.
D. Ne može obraditi nelinearne podatke poput vlažnosti ili brzine vjetra.

Iz perspektive upravljanja gradom, koja je primarna strateška prednost korištenja ovog prediktivnog AI sustava u usporedbi s tradicionalnim „reaktivnim” pristupom?

A. Omogućuje mobilizaciju hitnih resursa (npr. centara za rashlađivanje, popravaka mreže) nekoliko dana prije nego što kriza nastupi, smanjujući štetu za stanovništvo.
B. Jamči 100 % točnost, potpuno uklanjajući mogućnost lažnih alarma ili propuštenih događaja.
C. Uklanja potrebu za ljudskim donošenjem odluka, omogućujući da gradom u potpunosti upravljaju računalni algoritmi bez nadzora.
D. Automatski snižava fizičku temperaturu grada optimizacijom semafora.

Koja pojava najbolje objašnjava zašto bi AI model mogao predvidjeti znatno više temperature za gradsko središte s puno betona u usporedbi s obližnjom šumom, iako su geografski blizu?

A. Učinak urbanog toplinskog otoka (UHI), pri kojem umjetne površine zadržavaju i ponovno zrače više topline nego prirodna vegetacija.
B. Lokalizirana anomalija atmosferskog tlaka koja se često formira iznad visokih zgrada.
C. Kalibracijska pristranost satelitskih senzora koja precjenjuje refleksiju staklenih površina.
D. „Učinak kašnjenja” uzrokovan velikom gustoćom prometa koja odgađa protok zraka.

Literatura / dodatno čitanje

[1] F. Chollet, Deep Learning with Python, 2. izd. Shelter Island, NY, SAD: Manning Publications, 2021. [Mrežno]. Dostupno: https://sourestdeeds.github.io/pdf/Deep%20Learning%20with%20Python.pdf, pristupljeno: 15. prosinca 2025.

[2] A. Zhang, Z. C. Lipton, M. Li i A. J. Smola, Dive into Deep Learning. arXiv:2106.11342, 2021. [Mrežno]. Dostupno: https://arxiv.org/abs/2106.11342, pristupljeno: 15. prosinca 2025.

[3] Goodfellow, Y. Bengio i A. Courville, Deep Learning. Cambridge, MA, SAD: MIT Press, 2016. [Mrežno]. Dostupno: http://www.deeplearningbook.org, pristupljeno: 15. prosinca 2025.

[4] J. Heaton, Applications of Deep Neural Networks. arXiv:2009.05673, 2020. [Mrežno]. Dostupno: https://arxiv.org/abs/2009.05673, pristupljeno: 15. prosinca 2025.

[5] Bilal Hassan, Areg Karapetyan, Aaron Chung Hin Chow i Samer Madanat. Climate Adaptation-Aware Flood Prediction for Coastal Cities Using Deep Learning. arXiv:2510.26017 [cs.CV], 2025. [Mrežno]. Dostupno: https://arxiv.org/abs/2510.26017, pristupljeno: 15. prosinca 2025.

[6] Qianqian Zhou, Shuai Teng, Zuxiang Situ, Xiaoting Liao, Junman Feng, Gongfa Chen, Jianliang Zhang i Zonglei Lu. A deep-learning-technique-based data-driven model for accurate and rapid flood predictions in temporal and spatial dimensions. Hydrol. Earth Syst. Sci., 27, 1791-1808, 2023. [Mrežno]. Dostupno: https://hess.copernicus.org/articles/27/1791/2023/hess-27-1791-2023.pdf, pristupljeno: 15. prosinca 2025.

[7] M. Nasourinia i K. Passi, “Wildfire Prediction in British Columbia Using Machine Learning and Deep Learning Models: A Data-Driven Framework,” Big Data and Cognitive Computing, sv. 9, br. 11, str. 290, 2025. [Mrežno]. Dostupno: https://doi.org/10.3390/bdcc9110290, pristupljeno: 15. prosinca 2025.

[8] Hyunglok Seo i Yeonjoo Kim. Enhancing Alaskan wildfire prediction and carbon flux estimation: a two-stage deep learning approach within a process-based model. Environ. Res. Lett., 19, 124040, 2024. [Mrežno]. Dostupno: https://iopscience.iop.org/article/10.1088/1748-9326/ad8bdc, pristupljeno: 15. prosinca 2025.

[9] Babak Mohammadi, Mohammed Abdallah, Rachid Oucheikh, Okan Mert Katipoğlu i Majid Cheraghalizadeh. Enhancing streamflow drought prediction: integrating wavelet

decomposition with deep learning and quantile regression neural network models. Earth Sci. Inform., 18, 232, 2025. [Mrežno]. Dostupno: https://link.springer.com/article/10.1007/s12145-025-01736-w, pristupljeno: 15. prosinca 2025.

[10] Elisa Felsche i Ralf Ludwig. Applying machine learning for drought prediction in a perfect model framework using data from a large ensemble of climate simulations. Nat. Hazards Earth Syst. Sci., 21, 3679-3691, 2021. [Mrežno]. Dostupno: https://nhess.copernicus.org/articles/21/3679/2021/nhess-21-3679-2021.pdf, pristupljeno: 15. prosinca 2025.