

Sinoptičari, umjetna inteligencija, modeli: Kako nastaje prognoza vremena

Bojan Lipovšćak



Screenshot (DHMZ)

Prognoza vremena nije jednostavno očitavanje jedne karte niti prepisivanje rezultata računalnog modela. Ona je rezultat složenog procesa u kojem se povezuju meteorološka mjerenja i motrenja, razumijevanje fizike atmosfere, numerički modeli za prognozu vremena, iskustvo meteorologa i procjena vjerojatnosti različitih mogućih razvoja vremenske situacije.

Rad sinoptičara počinje prikupljanjem i analizom što većeg broja podataka. Promatraju se mjerenja s meteoroloških postaja, radiosondažna mjerenja, radarske i satelitske snimke, podaci s brodova i zrakoplova te analize trenutačnog stanja atmosfere.

Ti podaci omogućuju meteorologu da rekonstruira trodimenzionalnu sliku atmosfere: gdje se nalaze fronte, ciklone i anticiklone, kakva je raspodjela tlaka, temperature i vlage te gdje se razvijaju nestabilna područja.

Nakon toga sinoptičar uspoređuje izlaze različitih numeričkih prognostičkih modela. Uobičajeno je da modeli ne daju potpuno jednaku prognozu. Jedan može predviđati prolazak fronte u jutarnjim satima, drugi nekoliko sati kasnije, dok treći može davati drukčiju količinu oborine ili drukčiji smjer i brzinu vjetrova.

Zašto se prognostički modeli razlikuju

Sinoptičar tada ne bira model mehanički, nego pokušava razumjeti zašto se modeli razlikuju. Pritom uzima u obzir:

- trenutačno stanje atmosfere i kvalitetu početnih podataka;

- rezoluciju i fizikalne postupke pojedinog modela;
- ponašanje modela u sličnim vremenskim situacijama;
- lokalne osobitosti reljefa, obale, otoka i urbanih područja;
- razvoj situacije u prethodnim prognostičkim terminima;
- rezultate ansambala, odnosno skupova prognoza s malo izmijenjenim početnim uvjetima.

Iskusan meteorolog s vremenom razvija svojevrstu mentalnu bazu podataka. Zna, primjerice, da određeni model u nekim okolnostima može precijeniti količinu oborine, da drugi bolje prikazuje buru, ali slabije procjenjuje razvoj konvektivnih pljuskova, ili da model u određenoj dolini sustavno daje previsoku temperaturu.

Prognoza zato nije samo prosjek izračuna numeričkog modela. Ona je interpretacija modelskih rezultata u kontekstu stvarne atmosfere.

Sinoptičar mora odlučiti koji je scenarij najvjerojatniji, ali i prepoznati situacije u kojima postoji povećan rizik da se vrijeme razvije drukčije od najčešće prognozirano scenarija.

To je osobito važno kod opasnih vremenskih pojava. Kod grmljavinskih oluja, tuče, naglih udara vjetra, obilne oborine ili magle mala razlika u položaju fronte ili lokalnoj konvergenciji može značiti veliku razliku između mirnog vremena i ozbiljnog meteorološkog događaja.

Što umjetna inteligencija donosi prognozi

Umjetna inteligencija ne bi trebala zamijeniti sinoptičara, nego mu pomoći da brže i sustavnije obradi količinu podataka koja je čovjeku teško dostupna. Njezina je najveća vrijednost u prepoznavanju obrazaca, procjeni pogrešaka i prilagodbi prognoze lokalnim uvjetima.

Sustav može kontinuirano uspoređivati prognozirano i ostvareno vrijeme. Za svaki model i svaki prognostički parametar može se izračunati odstupanje:

Pogreška = prognozirana vrijednost – ostvarena vrijednost

Ako neki model u određenom području tijekom južnog strujanja redovito daje previsoku temperaturu ili premalo oborine, sustav to može prepoznati. U takvim se okolnostima modelu ne mora uvijek pridavati jednaka važnost. Veću težinu može dobiti model koji je u usporedivim situacijama pokazao manju pogrešku.

Takav sustav može raditi u nekoliko koraka:

- prikuplja prognoze više modela;
- uspoređuje ih s mjerenjima i analizama stvarnog stanja;
- izračunava pogreške za pojedine lokacije, parametre i vremenske situacije;
- prepoznaje sustavna i lokalna odstupanja;
- procjenjuje koji su modeli u određenim okolnostima pouzdaniji;
- izrađuje prilagođenu i, po mogućnosti, probabilističku prognozu.

Raspon mogućih ishoda umjesto jedne vrijednosti

Umjesto jedne vrijednosti, korisniku se može prikazati raspon mogućih ishoda. Primjerice, nije dovoljno navesti da će temperatura biti 22 °C. Korisnije je prikazati da je najvjerojatnija temperatura između 21 i 23 °C, uz određenu vjerojatnost da će zbog povećane naoblake ili hladnog prodora ostati niža.

Umjetna inteligencija može prepoznati i složenije, nelinearne odnose. Primjerice, model može griješiti samo kada se istodobno pojave južno strujanje, visoka vlažnost i orografsko dizanje zraka. Takvu kombinaciju uvjeta klasična statistička korekcija teže prepoznaje, dok algoritam strojnog učenja može

povezati velik broj varijabli i izdvojiti obrazac koji se ponavlja.

Ograničenja umjetne inteligencije

Važno je naglasiti i ograničenja. Sustav umjetne inteligencije uči iz povijesnih podataka, pa može biti manje pouzdan u izvanrednim i rijetkim situacijama kojih u bazi podataka nema dovoljno.

Kod rekordnih toplinskih valova, neuobičajenih putanja ciklona ili ekstremnih konvektivnih događaja ljudsko razumijevanje fizike atmosfere i dalje je nužno.

Suradnja fizike, statistike i umjetne inteligencije

Najbolji pristup nije izbor između čovjeka i umjetne inteligencije, nego njihova suradnja. Fizikalni modeli opisuju razvoj atmosfere na temelju poznatih zakona, statističke metode ispravljaju sustavna odstupanja, a metode strojnog učenja mogu prepoznati složene obrasce i pomoći u lokalnoj prilagodbi prognoze.

Sinoptičar pritom provjerava fizičku smislenost rezultata, procjenjuje rizik i pretvara složene podatke u jasnu informaciju za korisnike.

Takav se pristup može prikazati na sljedeći način:

- fizikalni modeli daju osnovu prognoze;
- statističke metode ispravljaju poznate sustavne pogreške;
- strojno učenje prepoznaje složenije obrasce u podacima;
- višemodelski sustavi uspoređuju rezultate različitih modela;
- sinoptičar provjerava rezultate i procjenjuje moguće posljedice.

NBM kao primjer naprednog pristupa

Dobar primjer takvog razvoja je National Blend of Models, odnosno NBM. Riječ je o sustavu američke Nacionalne meteorološke službe NOAA/NWS koji kombinira prognoze većeg broja globalnih i regionalnih modela te ih dodatno statistički prilagođava stvarnim mjerenjima. Njegov je cilj smanjiti ovisnost o samo jednom modelu i dobiti stabilniju i bolje kalibriranu prognozu.

NBM koristi izlaze različitih modela, a zatim ih uspoređuje s opaženim stanjem vremena. Na temelju prethodnih pogrešaka sustav može korigirati pojedine izlaze i različitim modelima dodijeliti različite težine. NBM, dakle, nije samo običan prosjek prognoziranih vrijednosti na nekom mjestu.

Usporedba prognoze s ostvarenim vremenom

Važna je povratna veza između ostvarenog i prognoziranog vremena. Bez nje bi sustav samo spajao rezultate različitih modela, ali ne bi mogao sustavno procjenjivati njihovu uspješnost.

Usporedbom s mjerenjima moguće je utvrditi je li neki model pretopao, prehladan, presuh, previše kišan ili slabiji u prikazu vjetera na određenom području.

U toj se fazi mogu primjenjivati metode poput korekcije sustavnog odstupanja, kvantilnog mapiranja i ponderiranja prema pogrešci. Jednostavno rečeno, model koji je u usporedivim situacijama uspješniji za temperaturu na određenom području može dobiti veći utjecaj u konačnoj prognozi, dok se utjecaj manje pouzdanog modela smanjuje.

NBM se temelji ponajprije na višemodelskom pristupu i statističkoj postprocesnoj obradi. Zbog toga ga nije najpreciznije opisivati jednostavno kao „AI-prognozu”.

Točniji je opis da je riječ o kombinaciji fizikalnih modela, statistike, mjerenja, modelskog ansambla i automatizirane obrade podataka. Suvremeni prognostički sustavi pritom se sve više povezuju i s metodama strojnog učenja.

Meteocentar i primjena novih tehnologija

U tom je kontekstu vrijedan primjer Hrvatski Meteocentar i njegova meteorološka aplikacija. Primjenom pristupa koji se oslanja na objedinjavanje različitih modelskih izvora, njihovu obradu i prikaz korisniku, Meteocentar pokazuje kako se napredne prognostičke metode mogu približiti široj javnosti.

Takva je primjena važna zato što korisniku ne nudi samo jednu sirovu izlaznu vrijednost modela, nego nastoji objединiti složene prognostičke podatke u razumljiv i praktičan prikaz. Time se premošćuje razlika između znanstveno-tehničke pozadine prognoze i svakodnevnih potreba građana, poljoprivrednika, pomoraca, izletnika i drugih korisnika.

Meteocentar se može promatrati kao primjer domaće primjene višemodelskog pristupa i suvremenih digitalnih alata u prezentaciji vremenske prognoze.

Pritom ipak treba jasno razlikovati tri razine:

- sirovu prognozu pojedinog numeričkog modela;
- obrađenu i kalibriranu prognozu dobivenu kombiniranjem više izvora;
- konačnu meteorološku interpretaciju koju u složenim i opasnim situacijama treba provjeriti stručnjak.

Čovjek ostaje ključan

Umjetna inteligencija može obrađivati mnogo više podataka, prepoznavati pogreške na velikom broju lokacija i brže prilagođavati prognozu novim informacijama. No ona ne razumije atmosferu na isti način kao meteorolog koji povezuje fizikalni proces, lokalne uvjete, nesigurnost prognoze i moguće posljedice za ljude.

Uloga sinoptičara zato se ne gubi, nego se mijenja. Meteorolog sve više postaje tumač i nadzornik složenog prognostičkog sustava: procjenjuje je li automatski rezultat fizički smislen, prepoznaje situacije u kojima model može zakazati, odlučuje kada je potrebno izdati upozorenje i prevodi brojke u jasnu informaciju za javnost.

Najbolja prognoza budućnosti bit će ona u kojoj će fizikalni modeli dati osnovu, statistika i metode umjetne inteligencije obaviti velik dio obrade, a sinoptičar povezati sve rezultate u smislenu i odgovornu procjenu.

NBM i slični sustavi pokazuju smjer razvoja suvremene prognoze vremena, dok Meteocentar predstavlja primjer kako se takvi pristupi mogu razvijati u hrvatskom okruženju i približiti krajnjem korisniku.