

# ► ANET1: poprocesiranje ansambelskih vremenskih napovedi s pomočjo nevronskih mrež

Peter Mlakar<sup>1, 2</sup>, Janko Merše<sup>1</sup>, Jana Faganeli Pucer<sup>2</sup>

<sup>1</sup>Agencija Republike Slovenije za okolje, Vojkova cesta 1b, 1000 Ljubljana

<sup>2</sup>Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, 1000 Ljubljana

peter.mlakar@gov.si, janko.merse@gov.si, jana.faganeli@fri.uni-lj.si

## Izvleček

Poprocesiranje ansambelskih napovedi igra ključno vlogo pri tvorjenju natančnejših verjetnostnih napovedi vremena. Pogosto uporabljene metode za poprocesiranje verjetnostne napovedi ustvarijo ločeno za vsako lokacijo ali časovno obdobje. V tem delu predlagamo nov pristop, imenovan ANET1, ki temelji na nevronskih mrežah, ki združno tvori verjetnostne napovedi za vse lokacije in časovna obdobja. ANET1 posamično poprocesira člane ansambelske napovedi ter te uporabi za oceno parametrov normalne porazdelitve. Za učenje ter evalvacijo naše metode smo uporabili podatkovno zbirko napovedi temperatur, EUPPBench. Rezultati nakazujejo, da ANET1 izboljša delovanje obstoječih metod, predvsem v zahtevnih gorskih regijah. Prav tako zmanjša variabilnost napake napovedi tekom dnevnega hoda. V primerjavi z dvema drugim najboljšima pristopoma, EMOS in DVQR, ANET1 prinaša opazne izboljšave v umerjenosti porazdelitve napovedi glede na več evalvacijskih kriterijev.

**Ključne besede:** strojno učenje, umetna inteligenco, ansambelska vremenska napoved, poprocesiranje

## ANET1: Post-processing of ensemble weather forecasts using neural networks

### Abstract

Ensemble forecast post-processing plays a crucial role in generating more accurate probabilistic weather forecasts. Traditional methods estimate parameters of a parametric distribution separately for each location or lead time while assuming the target distribution of the post-processed weather variable. We propose a novel, neural network-based approach, denoted as ANET1, that produces forecasts jointly for all locations and lead times. Our model post-processes individual ensemble members and uses their latent encodings to estimate the parameters of a predictive normal distribution. To evaluate our method, we conduct temperature forecast post-processing for stations in a sub-region of western Europe using the EUPPBench benchmark. Our results demonstrate that ANET1 showcases state-of-the-art performance, improving upon existing methods in challenging mountainous regions. Compared to the two best methods, EMOS and DVQR, ANET1 exhibits better continuous ranked probability score and quantile loss, resulting in tangible improvements in the calibration of the forecast.

**Keywords:** Machine learning, artificial intelligence, ensemble weather forecast, post-processing

### 1 UVOD

Poprocesiranje vremenskih napovedi je ključno pri tvorjenju natančnejših vremenskih napovedi, saj numerične vremenske napovedi (NWP) vsebujejo napake. Te napake so posledica približkov v začetnih atmosferskih pogojih in računskih poenostavitev [1, 28, 12]. S povečanjem časa napovedi se napake dodatno akumulirajo ter povzročajo vse bolj netoč-

ne napovedi. Zaradi teh omejitev je vremenska napoved po naravi vse bolj negotova. Centri za napovedovanje vremena, kot je npr. Evropski center za srednjeročne vremenske napovedi (ECMWF) [7], za ocenjevanje te negotovosti, napovedi izdajajo v obliki ansamblov. Ansabelska napoved je tako sestavljena iz mnogih različnih vremenskih napovedi, kjer vsaka izraža potencialno edinstveno prihodnjo vremensko

situacijo. Žal pa so napake v napovedi prisotne tudi v ansamblih.

Z namenom, da bi omilili te napake in tako tvorili bolj umerjene napovedne porazdelitve vremena [8], ponudniki vremenskih napovedi pogosto uporabljajo tehnike poprocesiranja ansambelskih napovedi [28]. Metode za poprocesiranje so lahko preproste ali kompleksne, toge [10, 22, 25, 21] ali pa prilagodljive [16, 14, 20, 27] in obsegajo širok spekter statističnih pristopov [28].

Pred kratkim so se na področju poprocesiranja začeli uporabljati pristopi, ki temeljijo na nevronskega mrežah [18, 17, 3, 26, 29, 2, 11, 24, 23, 6, 9]. Algoritem opisan v [23] je pokazal zelo dobre rezultate pri napovedovanju temperatur v Nemčiji v primerjavi s konvencionalnimi tehnikami poprocesiranja. S pomočjo povprečja in variance ansambla napovedi ter v kombinaciji z opisniki lokacij so [23] ustvarili nevronskega mrežo, ki oceni parametre normalne porazdelitve za vsak čas napovedi (termini napovedi v prihodnosti, od zagona modela). Negativna lastnost tega pristopa je, da je potrebno implementirati nov model za vsak čas napovedi, kar drastično poveča potrebeno število modelov. Podoben pristop lahko opazimo v [2], kjer s pomočjo nevronskega mrež, osnovane na [23], avtorji ocenijo koeficiente Bernsteinovih polinomov, s katerimi tvorijo porazdelitev napovedane količine (npr. temperature). Število potrebnih modelov tako pogosto narašča s številom lokacij ter časov napovedi [28]. Napovedovanje po posameznih lokacijah in časih predstavlja omejitve učenja modela saj ne izkoristi informacij iz drugih lokacij.

V našem delu predlagamo nov pristop, Atmosphere NETwork 1 (ANET1). ANET1 je osnovan na nevronskega mrežah in je zmožen hkratnega verjetnostnega napovedovanja vremena za vse lokacije ter čase napovedi. Ravno slednja lastnost ga dodatno razlikuje od ostalih metod poprocesiranja [5]. ANET1 je v primerjavi z drugimi pristopi pokazal zelo dobre rezultate na podatkovni zbirki EUPP Bench [5].

V nadaljevanju v poglavju 2 predstavimo model ANET1 ter opišemo njegovo delovanje ter učni proces. Temu sledijo rezultati evalvacije (poglavju 3) na podatkovni zbirki [5]. Primerjamo ANET1 z metodo ansambelskih statistik (EMOS) [10] ter metodo kvantilne regresije s pomočjo D-vine kopul (DVQR) [20]. Ključne ugotovitve povzamemo v poglavju 4.

## 2 ANET1

### 2.1 ANET1: arhitektura mreže

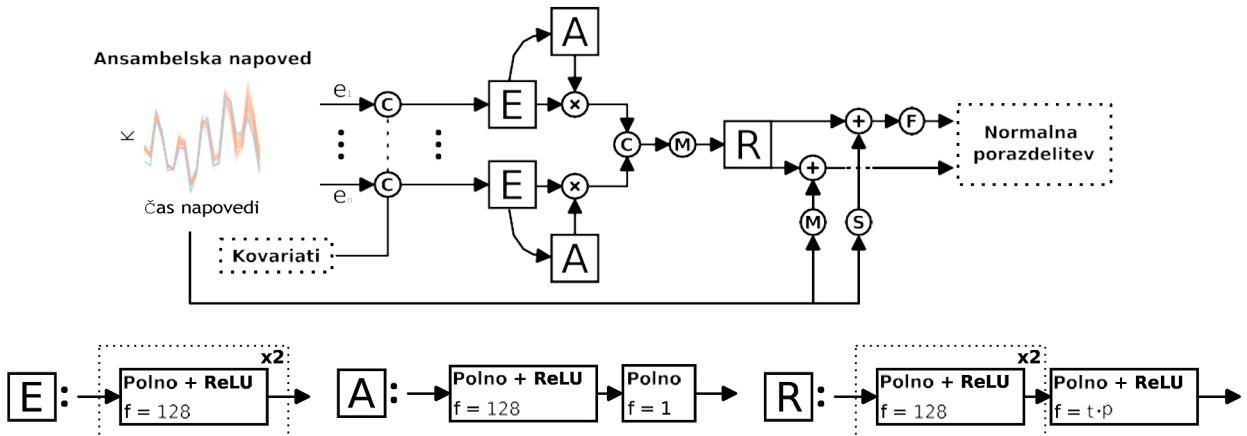
ANET1 je algoritem za poprocesiranje ansambelskih vremenskih napovedi, ki temelji na nevronskega mrežah. Za oceno parametrov normalne porazdelitve, s katero nato napove verjetnost vremenskih dogodkov, uporabi arhitekturo, ki je prikazana na sliki 1.

Arhitektura ANET1 je prilagojena obdelavi ansambelskih napovedi z različnimi števili članov ansambla. Število teh se lahko v praksi razlikuje v odvisnosti od NWP. ANET1 tako sprva posamezne napovedi v ansamblu transformira s skupno kodirano strukturo, ki je na sliki 1 označena s simbolom  $E$ . Pred tem vsaki ansambelski napovedi doda kovariate, ki opisujejo značilnosti posameznih lokacij, za katere napovedujemo vreme. Ti kovariati vključujejo podatke o nadmorski višini, lokaciji (geografsko dolžino in širino) in modelske napovedi ter rabo zemljišča, poleg tega pa še kodiranje dneva v letu, ko je bila napoved izdana. Kodirna struktura  $E$  posamezne napovedi iz ansambla ter njihove kovariate pretvoriti v visoko dimenzionalne vektorje. Te ANET1 uteži z dinamičnim blokom „pozornosti“ in nato povpreči v en sam vektor, ki predstavlja vremensko stanje ansambla. Naloga mehanizma pozornosti je ta, da dodatno poudari pomembnost bolj zanesljivih članov ansambla v specifičnih vremenskih situacijah.

Povprečni vektor na koncu transformiramo s pomočjo regresijskega bloka (označen z  $R$  na sliki 1), katerega izhod je korekcijski člen za ansambelsko povprečno napoved ter standardni odklon, za vsak posamezen čas napovedi. Z drugimi besedami: izhod nevronskega mrež ANET1 prišteje povprečni napovedi ter odklonu ansambla napovedi. Popravljeno povprečje in standardni odklon nato uporabimo kot parametra napovedne normalne porazdelitve, ki tvori končni izhod ANET1. ANET1 tako pretvoriti ansambelsko vremensko napoved v verjetnostno porazdelitev, ki bolje opisuje prihodnjo vremensko situacijo ter njeni negotovost.

### 2.2 Učni postopek

Za učenje ter evalvacijo ANET1 smo uporabili temperaturne napovedi za 229 lokacij v zahodni Evropi. Te so zbrane v podatkovni zbirke EUPP Bench [5]. EUPP Bench vsebuje dva podatkovna niza. Prvi po-



Slika 1: Oris arhitekture nevronske mreže ANET1. Simboli  $e_i$  označujejo posamezno napoved iz ansambla. Okrogli simboli C, M, S, F označujejo operacije konkatenacije, povprečenja, računanja standardnega odklona ter aktivacijsko funkcijo softplus. Kvadratni elementi E, A, R označujejo blok skupne kodirne strukture, blok dinamične pozornosti ter regresijski blok. S simbolom  $f$  je označeno število nevronov znotraj posamezne polno povezane plasti. Simbol  $t$  označuje število časov napovedi ter  $p$  število parametrov, potrebnih za opis napovedne porazdelitve (v primeru normalne porazdelitve sta to dva parametra: povprečje ter standardni odklon).

datkovni niz, označen z  $D_{11}$ , vsebuje 20-letne *pretekle vremenske napovedi* [5] za leti 2017, 2018. Za vsako izmed let je na voljo 209 časov zagona modela, kjer vsak zagon vsebuje 21 časov napovedi (termini vremenskih napovedi v prihodnosti glede na čas zagona modela). Ansambel za ta podatkovni niz vsebuje 11 članov. Niz  $D_{11}$  smo uporabili za učenje ANET1. Tekom učenja smo uporabili učno serijo velikosti 256 vzorcev.

Drugi podatkovni niz, označen kot  $D_{51}$ , vključuje *napovedi* za leti 2017, 2018, s 730 časi zagona modela in 21 časi napovedi. Ansambel za ta podatkovni niz šteje 51 članov.  $D_{51}$  smo uporabili za testiranje ANET1 modela po zaključenem učenju.

Uspešnost ANET1 tekom učenja smo ocenjevali s pomočjo validacijskega podatkovnega niza. Ta je vseboval 20 odstotkov naključno izbranih napovedi iz niza  $D_{11}$ . Napovedi so naključno izbrane iz vseh časovnih obdobji, ki jih obsegajo niz  $D_{11}$ . Različico ANET1, ki je tekom učenja dosegla najnižjo napako (negativni logaritem verjetnosti) na validacijskem nizu, smo uporabili v nadaljnji evalvaciji. Prav tako, če se napaka na validacijskem nizu tekom učenja ni izboljšala v 20 zaporednih epohah, smo učenje predčasno ustavili. Za minimizacijo napake smo uporabili postopek gradientnega spusta skupaj z optimizacijskim algoritmom Adam [15] v ogrodju PyTorch, s hitrostjo učenja  $10^{-3}$  in propadom uteži enakim  $10^{-9}$ . V primeru, da se napaka na validacijskem nizu ni izboljšala v 10 epohah, smo zmanjšali hitrosti učenja za faktor 0.9, da bi pospešili konvergenco.

### 3 REZULTATI

V tem poglavju bomo predstavili evalvacijo naše metode ANET1 in jo primerjali s pristopoma EMOS in DVQR na testnem nizu  $D_{51}$ . Uspešnost metod smo ocenjevali z uporabo zvezne rangirane verjetnostne spretnosti (CRPS) [8], kvantilno napako (QL) in kvantilno spretnostjo (QSS) [2], pristranskostjo in rang histogrami [13].

Metodi EMOS ter DVQR smo izbrali zato, ker sta bili, poleg ANET1, najboljši metodi poprocesiranja v pilotni študiji EUPPBenč podatkovne zbirke [5]. Poprocesirane napovedi obeh metod za niz  $D_{51}$  smo pridobili na [4].

#### 3.1 Umerjenost verjetnostnih napovedi

Rezultati CRPS in QL za vse tri metode so prikazani na sliki 2. Tu so vrednosti kriterijev povprečene čez celoten podatkovni niz in prikazane za posamezen čas napovedi. V prvi vrstici slike 2 lahko razberemo, da ANET1 v povprečju deluje bolje od preostalih dveh metod za večino časov napovedi. Napaki EMOS ter DVQR korelirata, z večjimi nihaji v dnevno nočnem ciklu (razviden iz skokov napake vsake 24 ur). Ravno te napake ANET1 odpravi, saj poprocesira napovedi za celoten čas napovedi naenkrat. Za odpravo napake ob določenem času izkoristi tudi informacije iz preostalih časov napovedi [19]. Za najpoznejše čase napovedi vse tri metode dosegajo podoben CRPS saj ne uspejo razbrati zadostnih informacij iz vhodne vremenske napovedi.

Do podobnega zaključka nas privede tudi QSS (desno v zgornji vrstici v sliki 2), kjer smo metodo DVQR uporabili kot referenčno. Vidimo lahko, da ANET1 prekaša preostali metodi v vseh kvantilih, le v najnižjih se približa metodi DVQR. Metoda EMOS, ki prav tako napovedi tvori s pomočjo normalne porazdelitve, deluje mnogo slabše od ANET1. Razlog za tem je, da EMOS parametre normalne porazdelitve izračuna kot linearno kombinacijo ansamblov vhodne napovedi. ANET1 pa te oceni s pomočjo nevronske mreže in je tako zmožen opisati mnogo bolj kompleksne relacije med kovariati ter opazovanji.

V spodnji vrstici slike 2 lahko vidimo histogram rangov posameznih metod. Prikazujejo stopnjo umerjenosti napovednih verjetnostnih porazdelitev. Bolj kot je histogram uniformen, bolj umerjena je načeloma napoved. Med metodama ANET1 ter EMOS lahko opazimo podobnost. Obe izkazujeta izstopajočo pristransko na intervalu med 20. ter 40. kvantilom. To je verjetno posledica uporabe normalne porazdelitve v obeh pristopih. DVQR močno zmanjša pristransko na intervalu med 20. in 40 kvantilom. Hkrati pa tvori preozko porazdelitev pri nižjih kvantilih ter preširoko na najvišjih, zaradi katere premajhen ali prevelik delež napovedi pade izven pričakovanega

obsega porazdelitve. Podoben vzorec je prisoten pri veliki večini metod [5]. Metodi DVQR ter ANET1 tako tvorita najbolj uniformne histograme, metoda EMOS pa najmanj, z bolj izrazitim pristranskom.

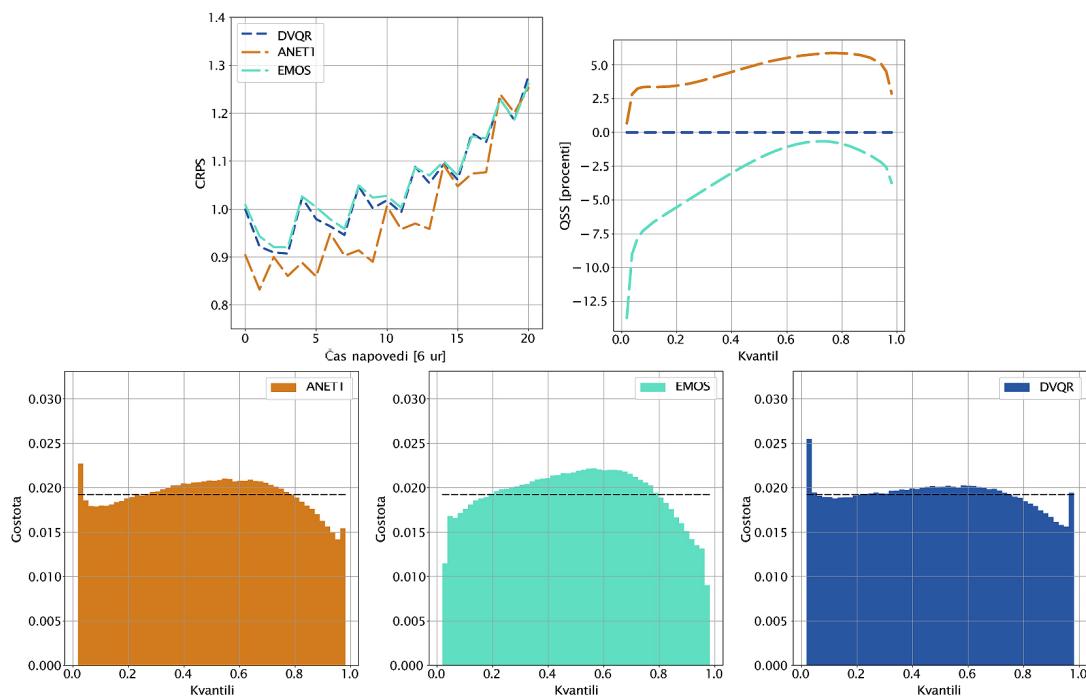
Povprečne vrednosti CRPS, QL ter pristransko vseh metod, čez celoten niz  $D_{51}$  so prikazane v tabeli 1. ANET1 je najboljša metoda tako v CRPS kot QL. Za metodo EMOS zaostaja samo v pristransko. ANET1 dosega 0.94 ter 0.92 krat manjši CRPS in QL kot EMOS, in 0.94 ter 0.95 krat manjši CRPS in QL kot DVQR.

Tabela 1: **Povprečni CRPS, pristransko ter QL za vse tri metode, čez celoten niz  $D_{51}$ . Manjša CRPS in QL prikazuje boljše delovanje, pristransko bliže nič je prav tako zaželeno.**

	<b>CRPS</b>	<b>Pristransko</b>	<b>QL</b>
EMOS	1.056	<b>0.074</b>	0.419
DVQR	1.047	0.096	0.408
ANET1	<b>0.988</b>	0.092	<b>0.386</b>

### 3.2 Napaka napovedi glede na posamezno lokacijo ter nadmorsko višino

Oglejmo si še primerjavo vseh treh metod glede na posamezne lokacije ter nadmorske višine lokacij. Na sliki 3 so prikazani QSS, agregirani glede na tri inter-



Slika 2: (Zgornja vrstica:) CRPS ter QSS izračunana za vse tri metode, za posamezen čas napovedi in posamezen kvantil. DVQR služi kot referenčna metoda za QSS. Positiven QSS nakazuje boljše delovanje kot referenca. (Spodnja vrstica:) Rang histogrami za vse tri metode, izračunani na 51 kvantilih. Uniformen histogram (črna črtka) zaznamuje optimalno verjetnostno napoved.

vale nadmorskih višin lokacij, ter CRPS za posamezne lokacije in vse nadmorske višine lokacij.

Opazimo lahko, da ANET1 deluje bolje od obeh preostalih metod glede na CRPS za lokacije na vseh intervalih nadmorskih višin. Le v lokacijah na nižjih nadmorskih višinah se CRPS ANET1 približa ostalima metodama.

Podoben zaključek lahko razberemo, če rangiramo metode glede na CRPS za posamezne lokacije (desna slika, zgornja vrstica 3). Opazimo lahko, da je ANET1 najboljša metoda na 151 lokacijah od 229. Največja razlika je ravno v visokogorju na jugu Nemčije ter v Švici, kjer v večini lokacij ANET1 deluje najbolje. Zaključimo lahko, da je ANET1 najboljša metoda za poprocesiranje napovedi v razgibanem terenu.

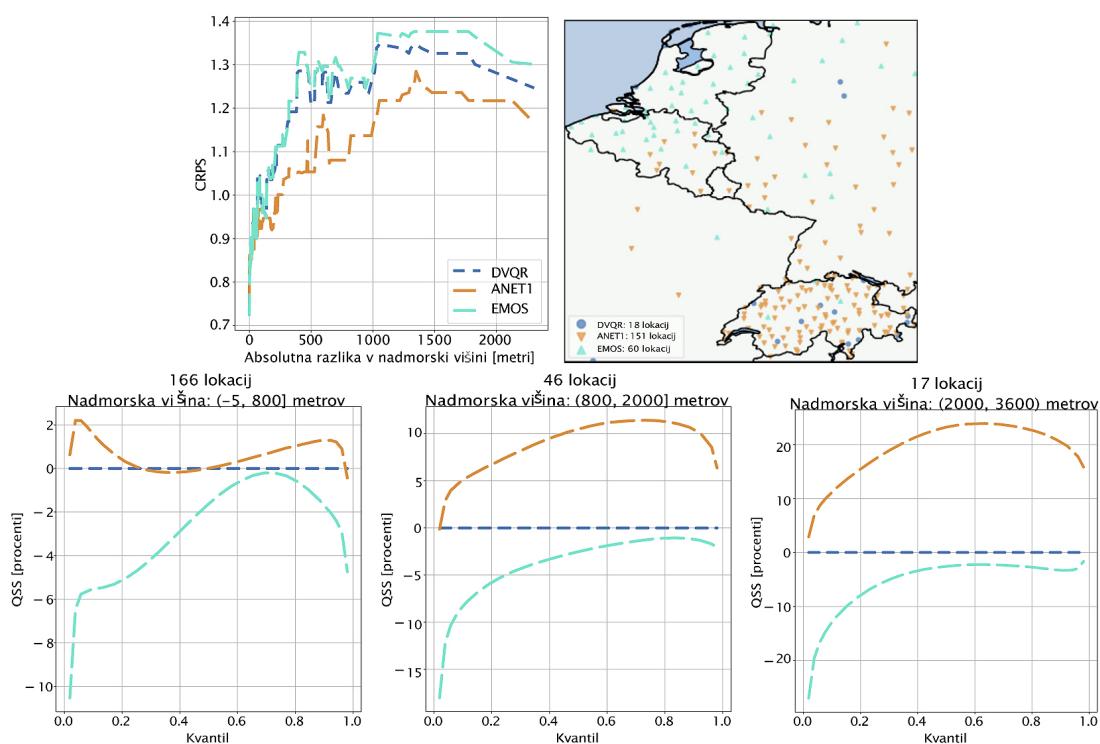
V priobalnih regijah Belgije in Nizozemske deluje bolje EMOS, ki je najboljša metoda v 60 lokacijah izmed 229. Vse metode so si blizu glede na CRPS ravno na območjih z nizko nadmorsko višino, saj je poprocesiranje temperature na teh lokacijah lažje kot v primeru bolj razgibanega terena. Ker je EMOS model ustvarjen za vsako lokacijo posebej se je ta lažje prilagodil enostavnejšim lokacijam. ANET1, ki poprocesira napovedi vseh lokacij hkrati, večji delež para-

metrov modela nameni kompleksnejšim vremenskim situacijam v goratem ter hribovitem svetu.

QSS (spodnja vrstica slike 3) nakazuje na podoben zaključek, saj je ANET1 boljši od preostalih dveh metod v vseh kvantilih. Edina izjema je QSS postaj z nižjimi nadmorskimi višinami, kjer se ANET1 približa DVQR metodi in na določeni podmnožici kvantilov deluje slabše kot DVQR. Z naraščanjem nadmorske višine se razlika med ANET1 in preostalima metodama povečuje, kar je skladno s prej opisanimi rezultati.

#### 4 SKLEP

V našem delu smo predstavili novo metodo ANET1 za verjetnostno poprocesiranje ansambelskih vremenskih napovedi. ANET1 temelji na nevronske mrežah, ki omogočajo opisovanje kompleksnih razmerji med vremenskimi napovedmi ter meritvami. Naš pristop se razlikuje od konvencionalnih po tem, da ANET1 tvori en sam model za vse napovedne lokacije in čase napovedi, saj mnogi konkurenčni pristopi tvorijo posamezne modele za specifične čase napovedi ter lokacije [5]. ANET1 verjetnostno napoved ustvari z uporabo predpostavke normalne porazdelitve.



Slika 3: (Zgornja vrstica:) CRPS vseh metod glede na nadmorsko višino lokacij ter rangiranje metod za posamezno lokacijo glede na CRPS.  
(Spodnja vrstica:) QSS vseh metod, agregiran na tri intervala nadmorske višine lokacij. DVQR služi kot referenčna metoda za QSS.  
Pozitiven QSS nakazuje boljše delovanje kot referenca.

ANET1 smo primerjali z dvema drugima najboljšima metodama, EMOS ter DVQR, na podatkovni množici EUPPbench [5]. ANET1 se je glede na več kriterijev izkazala kot najboljša metoda za poprocesiranje napovedi temperature za glavnino lokacij ter časov napovedi. ANET1 tako doseže 0.94 ter 0.92 krat manjši CRPS in QL kot EMOS in 0.94 ter 0.95 krat manjši CRPS in QL kot DVQR v povprečju čez celotno podatkovno zbirko.

Šibkost metode ANET1 je zaenkrat poprocesiranje napovedi v nižinskih lokacijah, kjer ga prehitita metoda EMOS glede na CRPS. Prav tako ANET1 zaostaja za metodo EMOS v pristranskosti napovedi.

Klub temu menimo, da ANET1 predstavlja pomemben napredok na področju poprocesiranja vremenskih napovedi. Z napovedovanjem za vse čase napovedi hkrati smo izrazito zmanjšali variabilnost napake v dnevno nočnem ciklu, kar ni uspelo nobeni drugi metodi [5]. Upamo, da bo pristop, ki smo ga razvili, koristil drugim raziskovalcem pri razvoju novih ter nadgradnjih obstoječih metod za tvorjenje bolj natančnih ter uporabnih vremenskih napovedi.

## ZAHVALA

Avtorji tega dela se zahvaljujemo konzorciju EUMETNET za zagotovitev potrebnih sredstev, ki so omogočila oblikovanje podatkovne zbirke EUPPbench, in našim sodelavcem, ki so s svojim predanim delom pripomogli k njegovi realizaciji. Prav tako se zahvaljujemo agenciji MétéoSuisse, l'Office fédéral de météorologie et de climatologie, za priskrbo postajskih meritev na območju Švice.

Poleg tega je bilo to delo podprtlo s sredstvi Agencije za raziskovalno dejavnost Republike Slovenije (ARRS) za raziskovalno jedro P2-0209 (Jana Faganeli Pucer).

## LITERATURA

- [1] Peter Bauer, Alan Thorpe, and Gilbert Brunet. The quiet revolution of numerical weather prediction. *Nature*, 525(7567):47–55, September 2015.
- [2] John Bjørnar Bremnes. Ensemble postprocessing using quantile function regression based on neural networks and Bernstein polynomials. *Monthly Weather Review*, 148(1):403–414, 2020. Publisher: American Meteorological Society.
- [3] William E Chapman, Luca Delle Monache, Stefano Alessandriani, Aneesh C Subramanian, F Martin Ralph, Shang-Ping Xie, Sebastian Lerch, and Negin Hayatbini. Probabilistic predictions from deterministic atmospheric river forecasts with deep learning. *Monthly Weather Review*, 150(1):215–234, 2022.
- [4] Jieyu Chen, Markus Dabernig, Jonathan Demaeeyer, Gavin Evans, Jana Faganeli Pucer, Ben Hooper, Nina Horat, David Jobst, Sebastian Lerch, Peter Mlakar, Annette Möller, Janko Merše, and Zied Ben Bouallègue. Esdd benchmark output data, April 2023.
- [5] J. Demaeeyer, J. Bhend, S. Lerch, C. Primo, B. Van Schaeybroeck, A. Atencia, Z. Ben Bouallègue, J. Chen, M. Dabernig, G. Evans, J. Faganeli Pucer, B. Hooper, N. Horat, D. Jobst, J. Merše, P. Mlakar, A. Möller, O. Mestre, M. Taillardat, and S. Vannitsem. The EUPP Benchpost processing benchmark dataset v1.0. *Earth System Science Data Discussions*, 2023:1–25, 2023.
- [6] Florian Dupuy, Olivier Mestre, Mathieu Serrurier, Valentin Kivachuk Burdá, Michaël Zamo, Naty Citlali Cabrera-Gutiérrez, Mohamed Chafik Bakkay, Jean-Christophe Jouhaud, Maud-Alix Mader, and Guillaume Oller. ARPEGE Cloud Cover Forecast Postprocessing with Convolutional Neural Network. *Weather and Forecasting*, 36(2):567 – 586, 2021. Place: Boston MA, USA Publisher: American Meteorological Society. ECMWF. <https://www.ecmwf.int/en/forecasts>, 2022.
- [7] Tilmann Gneiting, Fadoua Balabdaoui, and Adrian E. Raftery. Probabilistic forecasts, calibration and sharpness. *Journal of the Royal Statistical Society. Series B: Statistical Methodology*, 69(2), 2007.
- [8] Tilmann Gneiting, Sebastian Lerch, and Benedikt Schulz. Probabilistic solar forecasting: Benchmarks, post-processing, verification. *Solar Energy*, 252:72–80, 2023.
- [9] Tilmann Gneiting, Adrian E. Raftery, Anton H. Westveld, and Tom Goldman. Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation. *Monthly Weather Review*, 133(5), 2005.
- [10] Peter Grönquist, Chengyuan Yao, Tal Ben-Nun, Nikoli Dryden, Peter Dueben, Shigang Li, and Torsten Hoefer. Deep learning for post-processing ensemble weather forecasts. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194):20200092, February 2021. Publisher: Royal Society.
- [11] G.J. Hakim and J. Patoux. *Weather: A Concise Introduction*. Cambridge University Press, 2017.
- [12] Thomas M. Hamill. Interpretation of Rank Histograms for Verifying Ensemble Forecasts. *Monthly Weather Review*, 129(3):550 – 560, 2001. Place: Boston MA, USA Publisher: American Meteorological Society.
- [13] Timothy David Hewson and Fatima Maria Pillosu. A low-cost post-processing technique improves weather forecasts around the world. *Communications Earth & Environment*, 2(1):132, 2021. Publisher: Nature Publishing Group UK London.
- [14] Diederik P. Kingma and Jimmy Ba. Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*, 2017.
- [15] Charlie Kirkwood, Theo Economou, Henry Odber, and Nicolas Pugeault. A framework for probabilistic weather forecast post-processing across models and lead times using machine learning. *Philosophical Transactions of the Royal Society A*, 379(2194):20200099, 2021. Publisher: The Royal Society Publishing.
- [16] Sebastian Lerch and Kai L. Polsterer. Convolutional autoencoders for spatially-informed ensemble post-processing. *arXiv preprint arXiv:2204.05102*, 2022.
- [17] Amy McGovern, Kimberly L. Elmore, David John Gagne, Sue Ellen Haupt, Christopher D. Karstens, Ryan Lagerquist, Travis Smith, and John K. Williams. Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather. *Bulletin of the American Meteorological Society*, 98(10):2073 – 2090, 2017. Place: Boston MA, USA Publisher: American Meteorological Society.

- [19] Peter Mlakar, Janko Merše, and Jana Faganeli Pucer. Ensemble weather forecast post-processing with a flexible probabilistic neural network approach, 2023.
- [20] Annette Möller, Ludovica Spazzini, Daniel Kraus, Thomas Nagler, and Claudia Czado. Vine copula based post-processing of ensemble forecasts for temperature. *arXiv preprint arXiv:1811.02255*, 2018.
- [21] Kaleb Phipps, Sebastian Lerch, Maria Andersson, Ralf Mikut, Veit Hagenmeyer, and Nicole Ludwig. Evaluating ensemble post-processing for wind power forecasts. *Wind Energy*, 25(8):1379–1405, 2022. Publisher: Wiley Online Library.
- [22] Adrian E. Raftery, Tilmann Gneiting, Fadoua Balabdaoui, and Michael Polakowski. Using Bayesian model averaging to calibrate forecast ensembles. *Monthly Weather Review*, 133(5), 2005.
- [23] Stephan Rasp and Sebastian Lerch. Neural networks for postprocessing ensemble weather forecasts. *Monthly Weather Review*, 146(11):3885–3900, 2018. Publisher: American Meteorological Society.
- [24] Michael Scheuerer, Matthew B Switanek, Rochelle P Woronop, and Thomas M Hamill. Using artificial neural networks for generating probabilistic subseasonal precipitation forecasts over California. *Monthly Weather Review*, 148(8):3489–3506, 2020. Publisher: American Meteorological Society.
- [25] Benedikt Schulz, Mehrez El Ayari, Sebastian Lerch, and Sándor Baran. Post-processing numerical weather prediction ensembles for probabilistic solar irradiance forecasting. *Solar Energy*, 220:1016–1031, 2021.
- [26] Benedikt Schulz and Sebastian Lerch. Machine Learning Methods for Postprocessing Ensemble Forecasts of Wind Gusts: A Systematic Comparison. *Monthly Weather Review*, 150(1):235–257, January 2022. Place: Boston MA, USA Publisher: American Meteorological Society.
- [27] Bert Van Schaeybroeck and Stéphane Vannitsem. Ensemble post-processing using member-by-member approaches: theoretical aspects. *Quarterly Journal of the Royal Meteorological Society*, 141(688):807–818, 2015. Publisher: Wiley Online Library.
- [28] Stéphane Vannitsem, John Bjørnar Bremnes, Jonathan Demaeier, Gavin R. Evans, Jonathan Foweraker, Stephan Hemri, Sebastian Lerch, Nigel Roberts, Susanne Theis, Aitor Atencia, Zied Ben Bouallègue, Jonas Bhend, Markus Dabernig, Lesley de Cruz, Leila Hietala, Olivier Mestre, Lionel Moret, Iris Odak Plenković, Maurice Schmeits, Maxime Taillardat, Joris van den Bergh, Bert van Schaeybroeck, Kirien Whan, and Jussi Ylhäisi. Statistical postprocessing for weather forecasts review, challenges, and avenues in a big data world. *Bulletin of the American Meteorological Society*, 102(3), 2021.
- [29] Simon Veldkamp, Kirien Whan, Sjoerd Dirksen, and Maurice Schmeits. Statistical postprocessing of wind speed forecasts using convolutional neural networks. *Monthly Weather Review*, 149(4):1141–1152, 2021.

**Peter Mlakar** je doktorski študent na Univerzi v Ljubljani, Fakulteti za računalništvo in informatiko. Zaposlen je na Agenciji Republike Slovenije za okolje in se raziskovalno ukvarja z izboljšanjem vremenske napovedi s pomočjo strojnega učenja, s poudarkom na metodah globokega učenja.

**Janko Merše** je univerzitetni diplomirani fizik meteorološke smeri in na Agenciji Republike Slovenije za okolje vodi Oddelek za meteorološke, hidrološke in oceanografske izdelke.

**Jana Faganeli** Pucer je docentka na Fakulteti za računalništvo in informatiko. Njeno raziskovalno delo je osredotočeno na strojno učenje, predvsem na aplikacijo metod strojnega učenja v okoljskih znanostih. Več let sodeluje z Agencijo Republike Slovenije za okolje na področju kakovosti zraka.