

Več kot 30 let uporabe umetne inteligenčne na področju meteorologije v Sloveniji

Marija Zlata Božnar*, Primož Mlakar*, Boštjan Grašič*

Povzetek

V članku opisujemo več kot 30 let uporabe umetne inteligenčne na področju meteorologije v Sloveniji.

Ključne besede: umetne nevronske mreže, strojno učenje, umetna inteligenčna, meteorologija, razširjanje onesnaževanja ozračja

Key words: artificial neural networks, machine learning, artificial intelligence, meteorology, air pollution dispersion

Predgovor

10. januarja 2024 je ECMWF izdal sporočilo za javnost o uporabi in načrtih za uporabo strojnega učenja v procesu napovedovanja vremena: »Na zadnjih dveh zasedanjih Sveta ECMWF, junija in decembra 2023, so države članice ECMWF odobrile dve pomembni pobudi, namenjeni intenzivnejšemu razvoju, testiranju in izvajanju strojnega učenja v njihovih procesih za napovedovanje vremena.« (European Centre for Medium-Range Weather Forecasts, 2024)

Norveška in Švica sta prevzeli skupno enega od teh projektov in bosta usklajevali njegov razvoj: »Roar Skålin, generalni direktor Met Norway, in Christof Appenzeller, direktor MeteoSwiss, sta v skupni izjavi povedala: »Medtem ko se številne države članice ECMWF že ukvarjajo s strojnim učenjem v okviru svojih meteoroloških služb, je pomembno nadaljevati in krepiti skupni pristop. To bo ključnega pomena za vodilno vlogo Evrope na področju napovedovanja vremena. Strojno učenje ima velik potencial za izboljšanje napovedi in storitev ter nam bo omogočilo boljšo zaščito vseh državljanov pred posledicami nevarnih vremenskih pojavov. Iz nedavnih in zelo obetavnih rezultatov je jasno, da moramo v razvoj odločno vlagati.«« (prevod mag. Tanja Cegnar).

Uvod

Iz predgovora je razvidno, da so si orodja **strojnega učenja** iz podatkov kot ena od orodij **popularno poimenovanega področja umetne inteligenčne** končno zanesljivo utrla pot tudi na področje atmosferske znanosti.

V tem članku bomo kratko predstavili kako smo Slovenci orali ledino na tem področju in nadaljevali razvoj v zadnjih več kot 30 letih.

* MEIS storitve za okolje, d.o.o., Mali Vrh pri Šmarju 78, SI-1293 Šmarje-Sap, Slovenija

Orodja za strojno učenje, kratek vpogled v delovanje

O strojnem učenju govorimo takrat, ko iz množice podatkov o obravnavanem sistemu, naprimer iz meritev v atmosferi, s posebnimi orodji **izvlečemo informacijo, za katero morda še ne vemo vseh zakonitosti povezav med spremenljivkami v eksplisitni obliki**. Lahko pa so nam povezave poznane, a so tako kompleksne, da onemogočajo hitre izračune, v teh primerih pa metode strojnega učenja pomagajo izračune izdelati **mnogo hitreje**.

Eno od prvih orodij strojnega učenja so bile umetne nevronske mreže, naprimer **večnivojska perceptronska nevronska mreža VPNM**. Če je v njene nevrone vgrajena nelinearna prenosna funkcija, potem ima VPNM lastnost, da je univerzalni aproksimator. To pomeni, da z njo lahko poljubno dobro ponazorimo katerokoli nesingularno funkcijo. **V praksi to pomeni, da lahko z njo ponazorimo zapletene nelinearne odvisnosti** naprimer med spremenljivkami v ozračju, če le imamo na voljo dovolj pomerjenih primerov »parov« odvisne spremenljivke (ali večih spremenljivk), ki jo želimo ponazoriti, in neodvisnih spremenljivk, ki jo pogojujejo. Posamezne pomerjene primere imenujemo **vzorci** (ali tudi vektorji, patterns), odvisne in neodvisne spremenljivke pa imenujemo **značilke** (ali tudi regresorji, features). Nevron, ki je ključni element strukture nevronske mreže, pa je zgolj skupek enostavnih matematičnih operacij: z različnimi utežmi sešteje vrednosti s svojih vhodov in zatem vsoto podvrže prenosni funkciji. Izhod prenosne funkcije pa je izhod iz nevrona, ki se naprej povezuje na mrežo sestavljenou iz množice drugih nevronov. Od te konfiguracije je tudi nastalo poimenovanje umetne nevronske mreže, saj to posnema delovanje bioloških nevronske mrež. Mrežo konfiguriramo tako, da nevrone razporedimo v več slojev. Nevroni iz vsakega sloja so povezani z vsemi nevroni iz prejšnjega in iz naslednjega sloja. Možne pa so tudi druge kombinacije povezav, vključno s povratnimi zankami, kar pa niso več VPNM ampak druge vrste umetnih nevronske mrež.

Proces izdelave **modela na osnovi VPNM** poteka v več korakih. Najprej oblikujemo količino nevronov in število slojev kar z izkušnjami prilagodimo razsežnosti problema, količini značilk in količini vzorcev. Potem nadaljujemo oblikovanje modela tako, da množico poznanih vzorcev, ki so ponazorjeni s posamičnimi realizacijami značilk, razdelimo na **učno, optimizacijsko in testno množico**. V procesu učenja **parametre modela na osnovi VPNM** z ustreznim učnim algoritmom spremojemo tako, da se rezultati čim bolje prilagodijo učni množici. Hkrati pa testiramo vmesni izdelani model na optimizacijski množici. Končni model je tisti, ki najbolje ponazoriti optimizacijske vzorce. S tem zagotovimo, da ima nevronska mreža sposobnosti. To je pomembno zato, ker se ustrezno konfigurirana VPNM lahko popolnoma nauči učne vzorce, vendar takrat nima dobrih sposobnosti. Dejansko učinkovitost modela na osnovi VPNM pa potem pretestiramo na neodvisni testni množici, ki je nismo uporabili v procesu učenja.

Kohonenova nevronska mreža pa ima drugačne sposobnosti. V množici vzorcev zna poiskati skupine podobnih vzorcev na zelo učinkovit in pronicljiv način.

Razvoj je prinesel celo množico podobnih orodij, od številnih drugih vrst umetnih nevronske mrež do Gaussovih procesov (ki nimajo nobene zveze z Gaussovimi disperzijskimi modeli!), odločitvenih dreves (ti so primer »razložljive inteligence«) i.t.d..

Prva celovita metoda za uporabo umetne nevronske mreže za napovedovanje onesnaženja ozračja

Prvo celovito metodo v svetu za uporabo umetnih nevronske mreže za napovedovanje onesnaženja ozračja smo postavili že leta 1991 in jo objavili v letu 1993 (Božnar et al., 1993). Metodo smo razvili za kratkoročne napovedi zelo spremenljivih koncentracij žvepljivega dioksida SO₂ na postajah v okolici Termoelektrarne Šoštanj, ki je takrat delovala še brez mokre odzvepljevalne naprave in je bil zato SO₂ v ozračju zelo pomemben in dobro pomerjen problem.

Predstavitev, razvoj in nova področja, od modelov za točke do krajevno prenosljivih modelov

Metodo smo v naslednjih letih izpopolnili in predstavili na številnih konferencah in v člankih (Mlakar et al., 1994, Mlakar & Božnar, 1994, Božnar & Mlakar, 1995, Mlakar & Božnar, 1996, Mlakar, 1997, M. Božnar, 1997, Mlakar & Božnar, 1997, Božnar & Mlakar, 2002, Mlakar, 2004, Mlakar & Božnar, 2011).

Leta **2004** smo metodo s kolegi iz Sao Paula v Braziliji uspešno uporabili za točkovne napovedi **difuznega sončnega sevanja**, leta **2006** pa za korekcijo vpliva kupole na točkovne meritve dolgovalovnega sevanja s **pirgeometrom** (Soares et al., 2004, Oliveira et al., 2006, Mlakar et al., 2015; Mlakar, Božnar, Grašič, Oliveira, Soares, Gradišar, 2015).

Leta **2007** smo metodo razširili na uporabo še drugega orodja za strojno učenje, uporabili smo **Gaussove procese za točkovno napoved ozona** (Grašič et al., 2006). Razvoj na področju ozona smo nadaljevali v naslednjih letih (Kocijan et al., 2015, Petelin et al., 2015, Gradišar et al., 2016, Kocijan et al., 2016, Kocijan et al., 2018).

V letu 2008 smo orodja uporabili za pohitritve simulacij disperzije onesnaževal v ozračju z uporabo Lagrangevega modela delcev (Grašič, 2008).

V letu 2017 smo prešli iz napovedi za posamezne točke na napovedi, ki veljajo za različne kraje. Postavili smo **krajevno prenosljiv model za difuzno sončno sevanje** in **krajevno prenosljiv model za asimilacijo ozonskih meritev** za regionalni model maksimalnih koncentracij ozona (Božnar, Grašič, Mlakar, et al., 2017, Božnar, Grašič, Oliveira, et al., 2017).

Nadaljevali smo z modeli za izboljšanje točkovnih napovedi temperatur zraka, relativne vlage v zraku in vetra (Kocijan et al., 2019, Kocijan et al., 2020, Perne et al., 2021, Krivec et al., 2021).

Najnovejši nadomestni (»surogat«) modeli za ploskovne napovedi

V 2023 smo objavili razvoj dveh različnih nadomestnih (»surogat«) modelov, ki omogočajo hkratno ponazoritev širjenja onesnaženja ozračja za celotno obravnavano prizemno ploskev izbranega krajevnega področja. Modele smo izdelali za relativne koncentracije in za relativne doze (Perne et al., 2023, Kocijan et al., 2023, Hvala et al., 2023).

Kohonenova nevronska mreža za klasificiranje podatkov

S Kohonenovo nevronsko mrežo smo zelo uspešno klasificirali podatke o vetrovnem polju v okolici Šoštanja, ki je bilo predstavljeno s hkratnimi meritvami smeri in hitrosti veta na 10 m nad tlemi na številnih talnih merilnih postajah okoli Termoelektrarne Šoštanj (Mlakar, 2004).

Delo ostalih slovenskih skupin

Med prvimi so metodo poprijeli v 2004 Rahela in Jure Žabkar ter Danijel Čemas za napovedi ozona, tudi v sodelovanju z Vladušič Danielom, Šuc Dorianom in Bratko Ivanom (Fakulteta za matematiko in fiziko Univerze v Ljubljani, Agencija Republike Slovenije za okolje (ARSO) in Fakulteta za računalništvo in informatiko Univerze v Ljubljani) (Žabkar et al., 2004, Žabkar et al., 2006).

V zadnjem času je več zanimanja na katedri za Meteorologijo, pri Gregorju Skoku in sodelavcih ter študentih s Katedre za meteorologijo, Fakultete za matematiko in fiziko Univerze v Ljubljani (Skok et al., 2021). Predvidoma bo na tem srečanju predstavil magistrsko delo Uroš Perkan (Perkan, 2023).

Skupaj s sodelavci z ARSO, Petrom Mlakarjem in Jankom Meršetom pa se s tem področjem ukvarja tudi Jana Faganeli Pucer s Fakultete za računalništvo in informatiko Univerze v Ljubljani, predstavitev bo predvidoma tudi na tem srečanju (Mlakar et al., 2024, Faganeli Pucer et al., 2018, Mlakar et al., 2023, Demaeyer et al., 2023).

Če smo še koga izpustili, se opravičujemo.

Zaključek

Različne metode strojnega učenja se končno bolj množično uporabljajo na področju atmosferske znanosti.

Zahvala

Projekt (Modeliranje dinamike kratkoročne izpostavljenosti radiološkemu sevanju, L2-2615) je sofinancirala Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije iz državnega proračuna.

Literatura

- Božnar, M., Lesjak, M., & Mlakar, P. (1993). A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain. *Atmospheric Environment. Part B. Urban Atmosphere*, 27(2), 221–230. [https://doi.org/10.1016/0957-1272\(93\)90007-S](https://doi.org/10.1016/0957-1272(93)90007-S), (“Received 24 September 1991, Accepted 21 November 1992”)

- Božnar, M. Z., & Mlakar, P. (1995). Neural Networks - A New Mathematical Tool For Air Pollution Modelling. WIT Transactions on Ecology and the Environment. <https://doi.org/10.2495/AIR950301>
- Božnar, M. (1997). Pattern selection strategies for a neural network-based short term air pollution prediction model. Intelligent Information Systems, 1997. IIS '97. Proceedings, 340–344. <https://doi.org/10.1109/IIS.1997.645285>
- Božnar Marija Zlata, & Mlakar, P. (2002). Use of Neural Networks in the Field of Air Pollution Modelling. In G. Borrego Carlos and Schayes (Ed.), Air Pollution Modeling and Its Application XV (pp. 375–383). Springer US. https://doi.org/10.1007/0-306-47813-7_38
- Božnar, M. Z., Grašič, B., Mlakar, P., Gradišar, D., & Kocijan, J. (2017). Nonlinear data assimilation for the regional modeling of maximum ozone values. Environmental Science and Pollution Research, 24(31), 24666–24680. <https://doi.org/10.1007/s11356-017-0059-2>
- Božnar, M. Z., Grašič, B., Oliveira, A. P. de, Soares, J., & Mlakar, P. (2017). Spatially transferable regional model for half-hourly values of diffuse solar radiation for general sky conditions based on perceptron artificial neural networks. Renewable Energy, 103, 794–810. <https://doi.org/10.1016/j.renene.2016.11.013>
- Demaeyer, J., Bhend, J., Lerch, S., Primo, C., Van Schaeybroeck, B., Atencia, A., Ben Bouallègue, Z., Chen, J., Dabernig, M., Evans, G., Faganeli Pucer, J., Hooper, B., Horat, N., Jobst, D., Merše, J., Mlakar, P., Möller, A., Mestre, O., Taillardat, M., & Vannitsem, S. (2023). The EUPP Bench postprocessing benchmark dataset v1.0. Earth System Science Data, 15(6), 2635–2653. <https://doi.org/10.5194/essd-15-2635-2023>
- European Centre for Medium-Range Weather Forecasts. (2024). European met services pool resources to intensify use of AI in weather prediction. <https://www.ecmwf.int/en/about/media-centre/news/2024/european-met-services-pool-resources-intensify-use-ai-weather>, 10.01.2024
- Faganeli Pucer, J., Pirš, G., & Štrumbelj, E. (2018). A Bayesian approach to forecasting daily air-pollutant levels. Knowledge and Information Systems, 57(3), 635–654. <https://doi.org/10.1007/s10115-018-1177-y>
- Gradišar, D., Grašič, B., Božnar, M. Z., Mlakar, P., & Kocijan, J. (2016). Improving of local ozone forecasting by integrated models. Environmental Science and Pollution Research, 23(18), 18439–18450. <https://doi.org/10.1007/s11356-016-6989-2>
- Grašič, B., Mlakar, P., & Božnar, M. Z. (2006). Ozone prediction based on neural networks and Gaussian processes. Nuovo Cimento C Geophysics Space Physics C, 29, 651–661. <https://doi.org/10.1393/ncc/i2006-10011-5>
- Grašič, B. (2008). Improvement of the performance of an air-pollution dispersion model for use over complex terrain [Doctoral dissertation, University of Nova Gorica]. <http://www.ung.si/~library/doktorati/okolje/9Grasic.pdf>
- Hvala, N., Mlakar, P., Grašič, B., Božnar, M. Z., Perne, M., & Kocijan, J. (2023). Surrogate tree ensemble model representing 2D population doses over complex terrain in the event of a radiological release into the air. Progress in Nuclear Energy, 158, 104594. <https://doi.org/10.1016/j.pnucene.2023.104594>
- Kocijan, J., Hančič, M., Petelin, D., Božnar, M. Z., & Mlakar, P. (2015). Regressor selection for ozone prediction. Simulation Modelling Practice and Theory, 54, 101–115. <https://doi.org/10.1016/j.simpat.2015.03.004>
- Kocijan, J., Gradišar, D., Božnar, M. Z., Grašič, B., & Mlakar, P. (2016). On-line algorithm for ground-level ozone prediction with a mobile station. Atmospheric Environment, 131, 326–333. <https://doi.org/10.1016/j.atmosenv.2016.02.012>
- Kocijan, J., Gradišar, D., Stepančič, M., Božnar, M. Z., Grašič, B., & Mlakar, P. (2018). Selection of the data time interval for the prediction of maximum ozone concentrations. Stochastic Environmental Research and Risk Assessment, 32(6), 1759–1770. <https://doi.org/10.1007/s00477-017-1468-y>
- Kocijan, J., Perne, M., Mlakar, P., Grašič, B., & Božnar, M. Z. (2019). Hybrid model of the near-ground temperature profile. Stochastic Environmental Research and Risk Assessment, 33(11–12), 2019–2032. <https://doi.org/10.1007/s00477-019-01736-5>

- Kocijan, J., Perne, M., Grašič, B., Božnar, M. Z., & Mlakar, P. (2020). Sparse and hybrid modelling of relative humidity: the Krško basin case study. *CAAI Transactions on Intelligence Technology*, 5(1), 42–48. <https://doi.org/10.1049/trit.2019.0054>
- Kocijan, J., Hvala, N., Perne, M., Mlakar, P., Grašič, B., & Božnar, M. Z. (2023). Surrogate modelling for the forecast of Seveso-type atmospheric pollutant dispersion. *Stochastic Environmental Research and Risk Assessment*, 37(1), 275–290. <https://doi.org/10.1007/s00477-022-02288-x>
- Krivec, T., Kocijan, J., Perne, M., Grašič, B., Božnar, M. Z., & Mlakar, P. (2021). Data-driven method for the improving forecasts of local weather dynamics. *Engineering Applications of Artificial Intelligence*, 105, 104423. <https://doi.org/10.1016/j.engappai.2021.104423>
- Mlakar, P., Božnar, M., & Lesjak, M. (1994). Neural Networks Predict Pollution. In M. M. Gryning Sven-Erik and Millán (Ed.), *Air Pollution Modeling and Its Application X* (pp. 659–660). Springer US. https://doi.org/10.1007/978-1-4615-1817-4_93
- Mlakar, P., & Božnar, M. Z. (1994). Short-term Air Pollution Prediction On The Basis Of Artificial Neural Networks. *WIT Transactions on Ecology and the Environment*, 3, 4. <https://doi.org/10.2495/AIR940611>
- Mlakar, P. (1997). Determination of features for air pollution forecasting models. *Intelligent Information Systems, 1997. IIS '97. Proceedings*, 350–354. <https://doi.org/10.1109/IIS.1997.645291>
- Mlakar, P., & Božnar, M. Z. (1996). Analysis Of Winds And SO₂ Concentrations In Complex Terrain. *WIT Transactions on Ecology and the Environment*, 10, 10. <https://doi.org/10.2495/AIR960461>
- Mlakar, P., & Božnar, M. (1997). Perceptron neural network-based model predicts air pollution. In *Intelligent Information Systems, 1997. IIS '97. Proceedings* (pp. 345–349). <https://doi.org/10.1109/IIS.1997.645288>
- Mlakar, P. (2004). Analysis of ambient SO₂ concentrations and winds in the complex surroundings of a thermal power plant. *Nuovo Cimento- Societa Italiana Di Fisica Sezione C*, 6(6), 595–609. <https://doi.org/10.1393/ncc/i2004-10023-1>
- Mlakar, P., & Božnar, M. (2011). Artificial Neural Networks - a Useful Tool in Air Pollution and Meteorological Modelling. In *Advanced Air Pollution*. InTech. <https://doi.org/10.5772/20824>
- Mlakar, P., Božnar, M., Grašič, B., Oliveira, A. P. de, Soares, J. R., Gradišar, D., & Kocijan, J. (2015). Modeliranje difuznega sončnega obseva. *Raziskave s Področja Geodezije in Geofizike 2014 : Zbornik Del. 20. Srečanje Slovenskega Združenja Za Geodezijo in Geofiziko, Ljubljana, 29. Januar 2015. Ljubljana: Fakulteta Za Gradbeništvo in Geodezijo*, 45.
- Mlakar, P., Merše, J., & Faganelli Pucer, J. (2023). Ensemble weather forecast post-processing with a flexible probabilistic neural network approach. *ArXiv Preprint ArXiv:2303.17610*.
- Mlakar, P., Merše, J., & Faganelli Pucer, J. (2024). ANet: metoda za poprocesiranje vremenskih napovedi s pomočjo strojnega učenja. *Raziskave s Področja Geodezije in Geofizike 2023 : Zbornik Del. 29. Srečanje Slovenskega Združenja Za Geodezijo in Geofiziko, Ljubljana, 1. Februar 2024. Ljubljana: Fakulteta Za Gradbeništvo in Geodezijo*.
- Oliveira, A. P., Soares, J., Božnar, M. Z., Mlakar, P., & Escobedo, J. F. (2006). An Application of Neural Network Technique to Correct the Dome Temperature Effects on Pyrgeometer Measurements. *Journal of Atmospheric and Oceanic Technology*, 23(1), 80–89. <https://doi.org/10.1175/JTECH1829.1>
- Perkan, U. (2023). Napovedovanje vremena s konvolucijskimi nevronskimi mrežami [Magistrsko delo, Univerza v Ljubljani, FMF - Fakulteta za matematiko in fiziko]. <https://repozitorij.uni-lj.si/IzpisGradiva.php?id=150234>
- Perne, M., Božnar, M. Z., Grašič, B., Mlakar, P., & Kocijan, J. (2021). Improving wind vector predictions for modelling of atmospheric dispersion during Seveso-type accidents. *Atmospheric Pollution Research*, 12(2), 76–83. <https://doi.org/10.1016/j.apr.2020.10.010>
- Perne, M., Kocijan, J., Božnar, M. Z., Grašič, B., & Mlakar, P. (2023). Hybrid Forecasting of Wind for Air Pollution Dispersion over Complex Terrain. *Journal of Environmental Informatics*. <https://doi.org/10.3808/jei.202300489>
- Petelin, D., Mlakar, P., Božnar, M. Z., Grašič, B., & Kocijan, J. (2015). Ozone forecasting using an online updating Gaussian-process model. *International Journal of Environment and Pollution*, 57(3–4). <https://doi.org/10.1504/IJEP.2015.074494>

- Skok, G., Hoxha, D., & Zaplotnik, Ž. (2021). Forecasting the Daily Maximal and Minimal Temperatures from Radiosonde Measurements Using Neural Networks. *Applied Sciences*, 11(22), 10852. <https://doi.org/10.3390/app112210852>
- Soares, J., Oliveira, A. P., Božnar, M. Z., Mlakar, P., Escobedo, J. F., & Machado, A. J. (2004). Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. *Applied Energy*, 79(2), 201–214. <https://doi.org/10.1016/j.apenergy.2003.11.004>
- Žabkar, R., Žabkar, J., & Čemas, D. (2004). Ground-level Ozone Forecast Based On Machine Learning. *WIT Transactions on Ecology and the Environment*, 74, 8. <https://doi.org/10.2495/AIR040051>
- Žabkar, J., Žabkar, R., Vladušić, D., Čemas, D., Šuc, D., & Bratko, I. (2006). Prediction of ozone concentrations. *Ecological Modelling*, 191(1), 68–82. <https://doi.org/10.1016/j.ecolmodel.2005.08.013>