

Válasz Prof. Dr. Terdik György opponensi véleményére


Először is szeretném megköszönni, hogy Terdik György Professzor Úr elvállalta a dolgozatom véleményezését, azt tüzetesen végigolvasta és bőven a hivatalos határidő lejárta előtt elkészítette bírálatát. Nagyon nagy örömet okoz, hogy munkámat pozitívan értékelte és bírálatában javasolta a nyilvános vita kitűzését, valamint az MTA doktori cím odaítélését.

Az alábbiakban a Professzor Úr által feltett kérdésekre szeretnék válaszolni.

1. *Az előrejelzéshez fontos a tanuló adatok méretének kiválasztása: vannak-e a tapasztalati módszeren túlmenően például információs kritériumon alapuló módszerek is, illetve, hogyan látja a jelölt ezek alkalmazhatóságát?*

A valószínűségi előrejelzések illeszkedésének vizsgálatára egy standard mutató a Roulston and Smith (2002) által javasolt logaritmikus mutató (LogS; ignorance score), azaz az előrejelző sűrűségfüggvény negatív logaritmus a megfigyelés helyen (lásd az értekezés 12. oldala, (1.4.3) képlet). Ez egy szigorúan megfelelő illeszkedési mutató (strictly proper scoring rule; Gneiting and Raftery, 2007), aminek a várható értéke, amennyiben a megfigyelés eloszlása éppen az előrejelző eloszlás, ez utóbbi entrópiája. A LogS minimalizálása így az előrejelzésben rejlő bizonytalanságot minimalizálja, illetve azt az információmennyiséget, ami a tökéletes előrejelzés meghatározásához szükséges.

A valószínűségi modellezéshez használt tanulói időszak hossza kiválasztásának egyik általánosan elterjedt módja, különösen gördülő tanulóperiódus esetén, hogy egy rögzített validáló adathalmazon összehasonlítjuk a különböző hosszúságú tanulóperiódusokhoz tartozó modellek egy vagy több illeszkedési mutatóját és az ezeket optimalizáló hosszt választjuk. Az alábbi ábra ezt illusztrálja az értekezés 4. fejezetében a csapadékelőrejelzések kalibrálására bevezetett cenzorált eltolt gamma eloszláson alapuló ensemble model output statistics (EMOS) modell esetén.



A 4.3.2 fejezet esettanulmányában vizsgált University of Washington mesoscale ensemble esetén mind az átlagos CRPS, mind pedig a MAE 70 napnál veszi fel a globális minimumát. A 4.3.3. fejezetben szereplő ALADIN-HUNEPS ensemble előrejelzésekre a globális minimumhely egyértelműen 85 napnál van, azonban az 55 napnál megjelenő „könyök” után mindkét mutató értéke már csak keveset változik. Ez indokolta az értekezésben is használt 55 napos

tanulóperiódus hosszát. Amennyiben a CRPS vagy a MAE helyett a logaritmikus mutató átlagos értékét használjuk (lásd pl. Raftery *et al.*, 2005; Fig. 7g), ennek minimalizálása bizonyos értelemben az előrejelzések entrópiájának minimalizálását jelenti.

2. *A tanuló adatok meghatározásánál figyelembe veszi-e az esetleges szezonalitást? (Természetesen csak azoknál a komponenseknél, ahol ez egyáltalán lehetséges.)*

Az értekezésben vizsgált esettanulmányokban a modellezés minden esetben gördülő tanuló periódusokon alapul, ami nem veszi figyelembe a szezonalitást. Az értekezés benyújtása óta azonban születtek eredményeink a felhősödés ensemble előrejelzéseinek gépi tanulási technikákkal történő statisztikai utófeldolgozása terén (Baran *et al.*, 2021), ahol referenciamodellként a Hemri *et al.* (2016) által vizsgált többosztályos, illetve rendezett (ordered) logisztikus regresszió alapuló eljárásokat tekintettük, és a módszereinket (többretegű perceptron neurális hálók, véletlen erdők, gradient boosting machines) is az ott javasolt kétféle technikával tanítottuk. Az egyszerűbb (nem szezonális) esetben öt teljes év előrejelzéseivel és megfigyeléseivel tanítottuk be a következő naptári évre vonatkozó modelleket, majd a tanulóidőszak egy teljes évet csúszott előre. Szezonális tanítás esetén viszont külön kezeltük az északi féltekén nyári (április – szeptember) és téli (október – március) időszakokat, és az egyes időszakokra vonatkozó előrejelzéseket az előző 5 naptári év azonos időszakaira vonatkozó adatai segítségével kalibráltuk. Az egyes modellek előrejelző képességét a European Centre for Medium-Range Weather Forecasts (ECMWF) 2002. január 1 – 2014. március 20. időintervallumra vonatkozó globális (3300 meteorológiai állomás) felhősödés előrejelzésein hasonlítottuk össze. Az esettanulmány azt mutatta, hogy a szezonális becslés mindegyik vizsgált modell esetén jobban kalibrált előrejelzéseket eredményezett, mint a nem szezonális.


Egy másik lehetőség a megfigyelésekben rejlő szezonális figyelembevételére a szezonális ingadozás beépítése magába a paraméteres utófeldolgozó modellbe. Erre példa a Hemri *et al.* (2014) által a hőmérséklet előrejelzések utófeldolgozására javasolt normális eloszláson alapuló EMOS modell, ahol a várható érték tartalmaz egy szezonális komponenst, melynek paramétereit szintén a tanuló adatokból becslik. Ugyanezt a technikát követi Schultz *et al.* (2021) napsugárzás előrejelzések kalibrálására szolgáló cenzorált logisztikus eloszláson alapuló EMOS modellje.

Egy további módszer a hasonlóság alapú tanítás, amikor egy adott helyre és időpontra vonatkozó előrejelző eloszlás paramétereit olyan tanuló adatok segítségével becsüljük meg, amik valamilyen szempontból hasonlóan viselkednek, mint az éppen kalibrálandó megfigyelések. Ez a technika véleményem szerint alkalmas a szezonális kezelésére is. Az értekezés 2. fejezetében szereplő hidrológiai előrejelzések Bayes modell átlagolás (BMA) és EMOS modellekkel való kalibrálását az ott tárgyalt 100 napos gördülő tanuló periódus mellett elvégeztük a Hemri and Klein (2017) által javasolt három, analógiákon alapuló kiválasztási módszerrel kapott tanulóadatok segítségével is (Baran *et al.*, 2019). 50 órás előrejelzési horizontig ezen fejlettebb tanítási technikák mindegyike szignifikánsan jobban kalibrált BMA előrejelzéseket eredményezett, mint a gördülő tanuló periódus, valamint eltüntette a BMA és EMOS modellek előrejelző képessége közötti különbséget.

3. *Az eloszlás családok kiválasztásánál gondoltak-e ferde eloszlás családra, pl. ferde normális (skew-normal) eloszlásokra?*

Az értekezésben tárgyalt négy időjárási, illetve hidrológiai mennyiséggel kapcsolatban még nem merült fel. Azóta viszont foglalkoztunk a hőmérséklettől és a harmatponttól függő különféle hőindexek, nevezetesen a diszkomfort index (DI) és beltéri nedvesgömb-hőmérséklet (indoor wet-bulb globe temperature; WBGT_{id}) statisztikai utófeldolgozásával (Baran *et al.*, 2020). Ezekre a

mennyiségekre eddig nem létezett semmilyen közvetlen utófeldolgozó technika, így a paraméteres modell megalkotásához nekünk kellett keresni egy alkalmas előrejelző eloszlást. Amint azt az alábbi ábrán látható klimatológiai hisztogramok mutatják (Európa közepes szélességein fekvő 1459 meteorológiai állomásnak a 2017. május 1 - szeptember 30. időszakban 1200 UTC-kor mért 2m hőmérséklet és harmatpont megfigyeléseiből számolt DI és WBGTid értékek hisztogramjai), mindkét index egy jobbra ferdült eloszlással írható le. Itt jött elő lehetőségként a ferde normális, az osztott normális, valamint az általánosított extrémérték (GEV) eloszlással való modellezés. Az illeszkedésvizsgálat alapján a DI megfigyelésekre az *osztott normális – GEV – ferde normális*, míg a WBGTid megfigyelésekre a *ferde normális – GEV – osztott normális* rangsor alakult ki, ami alapján végül a GEV eloszlás mellett döntöttünk. Ez utóbbi mellett szólt az az érv is, hogy hőindexekkel kapcsolatos figyelmeztetések szempontjából fontos szélsőértékek modellezésére a GEV tűnt a legalkalmasabbnak. A GEV eloszláson alapuló EMOS modell az ECMWF ensemble előrejelzéseivel végzett tesztek során aztán jól vizsgázott, különösen a magas DI és WBGTid értékek esetén.



4. Milyen tér-idő modelleket lát a jelölt reálisnak a további kutatások témájaként?

Az elmúlt években számos többdimenziós módszert dolgoztak ki annak érdekében, hogy térben és/vagy időben konzisztens utófeldolgozott előrejelzéseket hozzanak létre, vagy modellezzék az egyes időjárási mennyiségek közötti összefüggéseket (lásd pl. Schefzik and Möller (2018) részletes összefoglalóját). Ezek alapvetően két csoportba oszthatóak. Az első megközelítés többdimenziós paraméteres előrejelző eloszlások illesztése, erre ad példát Berrocal *et al.* (2007) vagy Feldmann *et al.* (2015). Ez a technika azonban leginkább alacsony dimenzió esetén lehet hatékony, amit jól illusztrál az értekezés 5. fejezete.

A másik alapvető technika egy kétlépcsős eljárás. Itt az első lépésben minden egyes dimenzióra (hely, időpont, időjárási mennyiség) elvégzünk egy egydimenziós utófeldolgozást, majd az így kapott előrejelző eloszlásokból mintákat generálunk. Az egydimenziós utófeldolgozás során elveszett tér-, idő-, illetve változók közötti összefüggéseket ezek után úgy állítjuk helyre, hogy a generált mintákat átrendezzük valamilyen többdimenziós rangstruktúra-sablon alapján. Matematikailag ez egy paraméteres, vagy nemparaméteres kopula alkalmazásának felel meg. Az előbbire példa Möller *et al.* (2013) Gauss-kopula módszere, utóbbira pedig az ensemble copula coupling (Schefzik *et al.*, 2013), ahol a sablont a nyers előrejelzések rangstruktúrája adja.

Egy NKFIH-DFG nemzetközi pályázat keretében összeállt magyar-német kutatócsoport (Baran, S., Hemri, S., Groß, J., Lerch, S., Möller, A., Schefzik, R., Szokol, P.) első lépésként szimulációs vizsgálatok segítségével hasonlított össze a fent említett kétlépcsős technikákat (Lerch *et al.*, 2020), különféle időjárási mennyiségekre jellemző egydimenziós eloszlásokat használva. Ennek

közvetlen folytatása az a jelenleg folyó munka, amiben ugyanezen módszerek előrejelző képességét az ECMWF 2002. január 1 – 2014. március 20. időszakra vonatkozó globális hőmérséklet, szélsősebesség és 24h csapadékösszeg előrejelzésein hasonlítják össze.

Ugyanezen csapat másik két tervezett kutatási iránya Möller and Groß (2016) időbeli összefüggéseket modellező AR EMOS technikájának, valamint Möller *et al.* (2015) térbeli Markov EMOS módszerének kiterjesztése Gausstól eltérő eloszlással leírható időjárási mennyiségekre. Az ensemble előrejelzésekre illesztett EMOS előrejelző eloszlás paramétereit az előbbi módszer egy AR folyamattal, míg az utóbbi egy véletlen Markov mezővel modellezi.

Tisztelettel,



Dr. Baran Sándor
egyetemi docens

Debrecen, 2021. március 30.

Irodalom

- Baran, Á., Lerch, S., El Ayari, M. and Baran, S. (2021) Machine learning for total cloud cover prediction. *Neural. Comput. Appl.* **33**, 2605–2620.
- Baran, S., Baran, Á., Pappenberger, F. and Ben Bouallègue, Z. (2020) Statistical post-processing of heat index ensemble forecasts: is there a royal road? *Q. J. R. Meteorol. Soc.* **146**, 3416–3434.
- Baran, S., Hemri, S. and El Ayari, M. (2019) Statistical post-processing of water level forecasts using Bayesian model averaging with doubly-truncated normal components. *Water Resour. Res.* **55**, 3997–4013.
- Berrocal, V. J., Raftery, A. E. and Gneiting, T. (2007) Combining spatial statistical and ensemble information in probabilistic weather forecasts. *Mon. Weather Rev.* **135** 1386–1402.
- Feldmann, K., Scheuerer, M., and Thorarinsdottir, T. L. (2015) Spatial postprocessing of ensemble forecasts for temperature using nonhomogeneous Gaussian regression. *Mon. Weather Rev.* **143**, 955–971.
- Gneiting, T. and Raftery, A. E. (2007) Strictly proper scoring rules, prediction and estimation. *J. Amer. Statist. Assoc.* **102**, 359–378.
- Hemri, S., Haiden, T. and Pappenberger, F. (2016) Discrete postprocessing of total cloud cover ensemble forecasts. *Mon. Weather Rev.* **144**, 2565–2577.
- Hemri, S. and Klein, B. (2017) Analog based post-processing of navigation-related hydrological ensemble forecasts. *Water Resour. Res.* **53**, 9059–9077
- Hemri, S., Scheuerer, M., Pappenberger, F., Bogner, K. and Haiden, T. (2014) Trends in the predictive performance of raw ensemble weather forecasts. *Geophys. Res. Lett.* **41**, 9197–9205.
- Lerch, S., Baran, S., Möller, A., Groß, J., Schefzik, R., Hemri, S. and Graeter, M. (2020) Simulation-based comparison of multivariate ensemble post-processing methods. *Nonlinear Process. Geophys.* **27**, 349–371.

- Möller, A. and Groß, J. (2016) Probabilistic temperature forecasting based on an ensemble AR modification. *Q. J. R. Meteorol. Soc.* **142**, 1385–1394.
- Möller, A., Lenkoski, A. and Thorarinsdottir, T. L. (2013) Multivariate probabilistic forecasting using ensemble Bayesian model averaging and copulas. *Q. J. R. Meteorol. Soc.* **139**, 982–991.
- Möller, A., Thorarinsdottir, T. L., Lenkoski, A. and Gneiting, T. (2015) Spatially adaptive, Bayesian estimation for probabilistic temperature forecasts. arXiv:1507.05066.
- Raftery, A. E., Gneiting, T., Balabdaoui, F. and Polakowski, M. (2005) Using Bayesian model averaging to calibrate forecast ensembles. *Mon. Weather Rev.* **133**, 1155–1174.
- Roulston, M. S. and Smith, L. A. (2002) Evaluating probabilistic forecasts using information theory. *Mon. Weather Rev.* **130**, 1653–1660.
- Schefzik, R. and Möller, A. (2018) Chapter 4 – Ensemble postprocessing methods incorporating dependence structures. In Vannitsem, S., Wilks, D. S., Messner, J. W. (eds.), *Statistical Postprocessing of Ensemble Forecasts*, Elsevier pp. 91–125.
- Schefzik, R., Thorarinsdottir, T. L. and Gneiting, T. (2013) Uncertainty quantification in complex simulation models using ensemble copula coupling. *Statist. Sci.* **28**, 616–640.
- Schulz, B., El Ayari, M., Lerch, S. and Baran, S. (2021) Post-processing numerical weather prediction ensembles for probabilistic solar irradiance forecasting. *Sol. Energy* **220**, 1016–1031.