

## Válasz Prof. Dr. Bartholy Judit bírálói véleményére

Először is szeretném megköszönni, hogy Bartholy Judit Professzor Asszony elvállalta a dolgozatom bírálatát, azt tüzetesen végigolvasta és elkészítette részletes és inspiráló bírálatát. Nagyon nagy örömet okoz, hogy vezető meteorológiai szakemberként munkámat nemzetközi összehasonlításban is magas-szintűnek tartja és bírálatában javasolta a disszertáció vitára bocsátását.

Az alábbiakban a Professzor Asszony által feltett kérdésekre szeretnék válaszolni.

1. *A 2. fejezet 2.3-as pontjánál bemutatott esettanulmányban a Német Vízügyi Hatóság (Bundesanstalt für Gewässerkunde) által a Rajna Kaub gátjára készített 79 tagú ensemble előrejelzés segítségével megtörtént a csonkított normális BMA (Bayes modell átlagolás) tesztelése mindhárom paraméterbecslési eljárásra. Az esettanulmány eredménye szerint megállapítható, hogy a nyers ensemble előrejelzésekhez képest az utófeldolgozás minden esetben javít a valószínűségi előrejelzések kalibráltságán. Ha túllépünk ezen az eredményen, s általánosítani szeretnénk, ki-mondhatjuk, hogy például a Duna folyó bármelyik mérőpontjára készített ensemble előrejelzéseire is igaz ez az állítás? Vagy minden esetben újabb előzetes esettanulmányok elvégzésével az adott folyóra, mérőhelyre újból és újból ellenőrizni kell az állítás hitelességét?*

Mivel egzakt matematikai bizonyításról nincs tudomásom, felelőséggel nem tudnám kijelenteni, hogy pont ez a fajta utófeldolgozási technika, ugyanezekkel a becslési módszerekkel, ugyanilyen tanulóperiódussal minden esetben működőképes. Az eddig publikált hidrológiai esettanulmányok azonban azt mutatják, hogy a különféle BMA és ensemble model output statistics (EMOS) előrejelző eloszlások kalibráltsága, amennyiben elegendő tanulóadat áll rendelkezésre, legalább rövid távon (1–5 nap) felülmúlja a nyers ensemble előrejelzéseket.

- Hemri *et al.* (2013) a svájci Thur folyó vízhozam előrejelzéseit utófeldolgozták egy normális eloszláson alapuló BMA modellel, ami 120h előrejelzési horizontig jóval alacsonyabb CRPS értékeket eredményezett, mint a nyers ensemble.
- Hemri *et al.* (2014) a Rajna két mellékfolyója, a Wied és az Ahr vízhozamát modellezték alulról csonkított, illetve cenzorált normális előrejelző eloszlást használó EMOS modellel 1-114h előrejelzési horizontot vizsgálva. Az utófeldolgozás itt is jelentősen javított a nyers előrejelzések kalibráltságán.
- Hemri *et al.* (2015) már a Rajna három különböző szakaszának vízhozamát modellezték felülről csonkított normális EMOS modellel. Az utófeldolgozás a maximálisan vizsgált 120h előrejelzési időtávig jelentősen javította a valószínűségi előrejelzések kalibráltságát.
- A Baran *et al.* (2019a) előzményeül szolgáló Hemri and Klein (2017) cikkben a szerzők a Kaub mellett a Rajna másik két gátjának 1-120h időtávra vonatkozó vízállás ensemble előrejelzéseit is kalibrálják duplán csonkított normális eloszláson alapuló EMOS modellel. Analógiákon alapuló tanulóadat kiválasztással ez a nyers előrejelzéshez képest a CRPS legalább 15%-os javulását eredményezi.

Ezek alapján úgy vélem, hogy nagyjából 100 napos gördülő tanulóperiódust használva a 2.

fejezetben vizsgált duplán csonkított normális BMA és EMOS modellek bármelyike, adaptálva az ensemble tulajdonságaihoz (pl. felcserélhető csoportok száma), nagy eséllyel javítana a Duna bármelyik mérőpontjára készített legfeljebb 120h időtávú ensemble előrejelzések kalibráltságán.


2. *Tovább görgetve az előző kérdést: a 3., 4., 5. fejezetek esettanulmányainál is találunk következtetéseket, mennyire általános érvényűek ezek a megállapítások az ott elemzett paraméterekre, a szélre, a csapadékra, stb. más földrajzi térségekre?*

Az irodalomban fellelhető különböző időjárási változókra vonatkozó esettanulmányok azt mutatják, hogy a BMA és EMOS utófeldolgozó technikák földrajzi térségtől függetlenül javítanak a rövidtávú nyers előrejelzések kalibráltságán. Szélesebséggel, hőmérséklettel és csapadékkal nekem is több tapasztalatom van, mint vízügyi adatokkal, így saját példákat szeretnék bemutatni.

A disszertáció 3.2. fejezetében ismertetett csonkított normális (TN), log-normális (LN) és általánosított extrémérték (GEV) eloszláson alapuló EMOS modelleket, kiegészítve egy újonnan kifejlesztett csonkított GEV modellel (TGEV EMOS), a korábban vizsgált UWME, ALADIN-HUNEPS és Németországra vonatkozó ECMWF adatok mellett leteszteltük az ECMWF 2014. január 1 – 2018. június 25 időszakra vonatkozó 1-15 napos 10m magasságban mért napi maximum szélesebség előrejelzéseit. A esettanulmányhoz Európa és Ázsia 1059 SYNOP állomásának ensemble előrejelzéseit és megfigyeléseit használtuk. Az eredmények azt mutatják (Baran *et al*, 2021b), hogy 100 napos gördülő tanulóperiódust és lokális becslést használva mind a négy utófeldolgozó módszer mind a 15 előrejelzési horizontra jelentősen alacsonyabb átlagos CRPS értéket eredményez, mint a nyers ECMWF ensemble, és 9 napig a megfelelő klimatológiai előrejelzéseket is felülmúlják.

Egy, az Országos Meteorológiai Szolgálat (OMSZ) megbízásából végzett vizsgálatban a TN, LN és TGEV EMOS modelleket minden változtatás nélkül alkalmaztuk az AROME-EPS 2020. május 7. – 2021. március 28. időszak három szélfarmra kiadott 100m magasán mért szélesebség előrejelzéseinek kalibrálására. Negyedikként egy új módszert is teszteltünk (TN MLP), amikor a TN előrejelző eloszlás hely és skála paraméterét egy neurális háló segítségével becsüljük meg a nyers ensemble különböző funkcionáljait használva bemenő paraméterként (Baran and Baran, 2021). Az egyes modelleket a szélfarmok üzemeltetői által biztosított negyedórás időléptékű megfigyelésekkel validáltuk.

Az alábbi ábra az 51 napos gördülő tanuló periódussal tanított lokális EMOS modellek, és az AROME-EPS átlagos CRPS értékeit (a), valamint nyers előrejelzésre vonatkozó CRPSS mutatót (b) ábrázolja az előrejelzési horizont függvényében. Látható, hogy mindegyik utófeldolgozó technika átlagosan 10 % körüli mértékben csökkenti a CRPS értékét.



Hasonlóképpen, a Gneiting *et al.* (2005) által kifejlesztett és az UWME hőmérséklet előrejelzése-in tesztelt normális EMOS modellt később sikeresen alkalmaztuk az OMSZ ALADIN-HUNEPS magyarországi hőmérséklet előrejelzéseinek kalibrálására (Baran *et al.*, 2014), de 10 napos előre-jelzési horizontig jól működött az ECMWF Európa közepes szélességeire kiadott hőmérséklet és harmatpont predikciói esetén is (Baran *et al.*, 2020).

A fenti példák talán jól illusztrálják a disszertáció esettanulmányainál tett megállapításaim általánosságának mértékét.

3. A 6. fejezetben az eddig ismert lokális, illetve regionális paraméterbecslési technikák ötvöztetésével ún. szemi-lokális eljárást vezet be a jelölt. Itt a hasonló állomások kiválasztásához a  $k$ -közép clusterezési eljárást használja. A hasonló állomások clusterezéséhez milyen paraméterek felhasználásával végzi az osztályozást, s ehhez milyen metrikákat használ? Milyen előnyökkel kecsegtet ez a módszer a távolságalapú megközelítésekhez képest?

A disszertáció 6.2.2. fejezetében leírt távolságalapú szemi-lokális modellnél az egyes állomások klimatológiáján, illetve az ensemble előrejelzések hibáin alapuló távolságok alapján kiválasztott „hasonló” állomásokkal feldúsított tanuló adatok jóval hatékonyabb utófeldolgozást eredményeznek, mint a földrajzi távolság alapján legközelebbiekkal számoltak (6.1. táblázat). Az adatokon alapuló hasonlóság előnyeit próbálja szemléltetni a 6.2. ábra is, ahol látszik, hogy a tengerparti Ouessant városához a klimatológiát és az előrejelzési hibákat egyaránt figyelembe vevő 4. távolság alapján „legközelebbi” 100 állomás szinte mindegyike part menti, ahol hasonló jellegű lehet a széljárás, míg Bécs esetén ez a 100 állomás tipikusan a tengertől messze található. Ezek alapján gondoltuk úgy, hogy a klimatológiát és az előrejelzések hibáját a klaszterezésnél is felhasználjuk.

A legjobbnak bizonyult konfigurációban a validációs időszak egy adott napján az 1738 állomás mindegyikéhez egy 24 elemű leíró vektort rendeltünk és a  $k$ -közép klaszterezést ezek alapján a Hartigan-Wong algoritlussal végeztük. A tulajdonságvektorokat az alábbi három módon választottuk ki:

- 1. típusú leíró vektor: *Klimatológiai jellemzők.* Az  $i$ . állomás tulajdonságait leíró vektor a 80 napos tanuló időszak adott állomásra vonatkozó szélsőérték megfigyelései empirikus eloszlásfüggvényének 24 ekvidisztáns kvantiliséből áll.
- 2. típusú leíró vektor: *Az ensemble előrejelzések hibái.* Az  $i$ . állomás tulajdonságait leíró vektor a 80 napos tanuló időszak adott állomásra vonatkozó ensemble átlagainak hibáiból

számolt empirikus eloszlásfüggvény 24 ekvidisztáns kvantiliséből áll.

- *3. típusú leíró vektor: Az 1. és 2. típusú leírók kombinációja.* 12 koordináta a megfigyelésekből, 12 pedig az ensemble átlagok hibáiból számított empirikus eloszlásfüggvény ekvidisztáns kvantilise.

Ezek a leíró vektorok a gördülő tanulmányidőszak miatt napról-napra változnak, ami a klaszterek változását is indukálja. A disszertációban tárgyalt GLAMEPS EPS esetén a 3. típusú leíró vektor alapján számolt klaszterezés adta a legjobban kalibrált EMOS modelleket.

A klaszterezésen alapuló szemi-lokális paraméterbecslést azóta sikerrel alkalmaztuk Európa közepes szélességeire vonatkozó hőindex ensemble előrejelzések statisztikai utófeldolgozására (Baran *et al*, 2020). Ebben az esetben rövidtávú előrejelzésekre a lokális becslés, hosszabb távon viszont a szemi-lokális eredményez kalibráltabb előrejelző eloszlásokat, a használt klaszterek száma az előrejelzési horizont növekedésével egyre csökken, közelítve a teljes tartományon alapuló regionális becslést.

- 4. *Baran Sándor jelölt disszertációhoz benyújtott téziszfüzete rendhagyó jellegű, hiszen egyetlen tézist sem tartalmaz, sőt nincs olyan szakasz sem benne, mely összefoglalja a disszertáció új eredményeit. Ezért kérem, hogy ennek pótlását végezze el, s **foglalja össze** nagyon tömören, pontokba szedve, tézis jelleggel **disszertációjának fontosabb kutatási eredményeit**. Kérem külön emelje ki, hogy ezek közül **melyek tekinthetők önálló eredményeknek**.*

Először is szeretnék elnézést szeretnék kérni, hogy félreértelmeztem a téziszfüzet formáját. A III. osztály ügyrendét meghatározó kiadványban nem találtam erre vonatkozó szabályozást, a beadandó dokumentumoknál a „a doktori mű összefoglalóját (téziseit) tartalmazó füzet” meghatározás szerepel, amiből én sajnos csupán az összefoglalóra koncentráltam. A hiányosságot a Professor Asszony kérésének megfelelően alább pótolom.

- 1. **tezis** Kidolgoztunk egy a folyók vízállása ensemble előrejelzéseinek statisztikai kalibrálására szolgáló duplán csonkított normálisok keverékén alapuló BMA modellt, valamint egy numerikusan hatékony algoritmust a modell paramétereinek becslésére. Az esettanulmányunk eredménye alapján a BMA utófeldolgozás jelentősen javít az előrejelzések kalibráltságán.

A tézis a disszertáció 2. fejezetének eredményein alapul és önálló eredménynek tekinthető.  
*Kapcsolódó publikáció:* Baran *et al.* (2019a).

- 2. **tezis** Az 1. tézisben említett általános csonkított normális BMA modell előzménye volt egy korábban kifejlesztett, nullában alulról csonkított BMA módszer, amit szélsőérték ensemble előrejelzések utófeldolgozására alkalmaztunk. Az esettanulmányok alapján a modell előrejelző képessége felülmúlja mind a nyers előrejelzéseket, mind pedig a már ismert gamma eloszláson alapuló BMA modellt.

A tézis a disszertáció 3.1.2 és 3.3.2. fejezeteinek eredményein alapul és önálló eredménynek tekinthető.

*Kapcsolódó publikáció:* Baran (2014).

- 3. **tezis** Kidolgoztunk egy log-normális eloszláson alapuló EMOS modellt, valamint egy előrejelző eloszlásként csonkított normális és log-normális eloszlások keverékét használó utófeldolgozó módszert. Az esettanulmányok alapján mindkét modell jelentősen javít a nyers előrejelzések kalibráltságán, a legjobb eredményeket a keverék modell biztosítja.

A tézis a disszertáció 3.2.2, 3.2.5 és 3.3.3. fejezeteinek eredményein alapul és önálló eredménynek tekinthető.

*Kapcsolódó publikációk:* Baran and Lerch (2015, 2016).

4. **tézis** Kifejlesztettünk egy csapadék ensemble előrejelzések utófeldolgozására alkalmas cenzorált eltolt gamma eloszláson alapuló EMOS modellt. Az esettanulmányok eredményei alapján az új modell szignifikánsan javít a nyers előrejelzések kalibráltságán és felülmúlja a referenciaként tekintett cenzorált általánosított extrémérték EMOS, valamint a diszkrét-folytonos gamma BMA modelleket.

A tézis a disszertáció 4. fejezetének eredményein alapul és önálló eredménynek tekinthető.

*Kapcsolódó publikáció:* Baran and Nemoda (2016).

5. **tézis** Kétdimenziós BMA és EMOS modellt alkottunk a szélsősebesség és hőmérséklet ensemble előrejelzések együttes utófeldolgozására, kidolgoztuk az EM algoritmusnak az BMA modell paramétereire becslésre szolgáló változatát. Az esettanulmányok alapján mindkét utófeldolgozás jelentősen javít a nyers ensemble előrejelzések kalibráltságán és hasonló eredményeket ad, mint a kétlépcsős Gauss kopula eljárás. A két új eljárás közül az EMOS mellett szól annak jóval kisebb számítási igénye.

A tézis a disszertáció 5. fejezetének eredményein alapul és önálló eredménynek tekinthető.

*Kapcsolódó publikációk:* Baran and Möller (2015, 2017).

6. **tézis** Távolság- és klaszteralapú szemi-lokális eljárásokat dolgoztunk ki az utófeldolgozó modellek paraméterbecsléséhez szükséges tanulmányok kiválasztására. Az esettanulmány alapján, amennyiben a vizsgált időintervallum csak rövid tanulóperiódust enged meg, mindkét szemi-lokális eljárás hatékonyabb modelleket eredményez, mint az általában legjobban működő lokális becslés.

A tézis a disszertáció 6. fejezetének eredményein alapul, a klaszterezésen alapuló eljárás a jelölt önálló eredményének tekinthető, míg a távolságalapú a társszerzőjének az érdeme.

*Kapcsolódó publikáció:* Lerch and Baran (2017).

5. *Kérem, fejtse ki bővebben, hogy mely eredmények, s hogyan alkalmazhatóak az **operatív időjárás előrejelzési gyakorlatban**. Melyek azok, amelyek már alkalmazásra kerültek, mely szolgálatok, mely felhasználók által?*

A disszertációban bemutatott egydimenziós utófeldolgozó eljárások egyikénél sem látom akadályát az operatív alkalmazásnak, a modellező algoritmusok futási ideje, különösen az alacsony számításiigényű EMOS eljárásoknál, elhanyagolható. „Éles” használat esetén valószínűleg az implementáción kell finomítani, különös tekintettel a kivételkezelésre.

Ismereteink szerint a disszertációban bemutatottakhoz hasonló paraméteres utófeldolgozó modellt (kétdimenziós EMOS, lásd Schuhen *et al.*, 2012) operatíván egyedül a Német Meteorológiai Szolgálat (DWD; Deutscher Wetterdienst) alkalmaz a Frankfurti Nemzetközi Repülőtérre kiadott szél-vektor előrejelzések kalibrálására.

Jelenleg az OMSZ megbízásából dolgozunk egy olyan projekten, melynek célja megújuló energiatermeléshez kapcsolódó időjárási mennyiségek statisztikai utófeldolgozása. Ennek keretében a szélerőművek működéséhez szükséges 100 m magasságban mért szélsősebesség, valamint a fotovoltaikus energiatermelésben elengedhetetlen globálsugárzás ensemble előrejelzések különféle

kalibrálási módjait teszteljük. Az előrejelzéseket az OMSZ AROME-EPS rendszere, míg a megfigyeléseket az OMSZ mérőhálózata, valamint a vizsgálatba bevont szél-, illetve napfarmok üzemeltetői szolgáltatják. A 2021. decemberében záruló projekt végső célja a kiválasztott módszerek operatív implementációja.

**6. Lát-e lehetőséget a kutatások folytatására? Ha igen, mik lennének a fontosabb célkitűzések? Milyen modellek, milyen paraméterek, milyen módszertan alkalmazásával folytatható?**

Természetesen látunk, hiszem már a disszertáció benyújtása óta eltelt közel két év alatt is számos eredményünk született a témában és 6 folyóiratcikkünk meg is jelent.

Foglalkoztunk felhősödés ensemble előrejelzések statisztikai utófeldolgozásával, aminek különlegességét a megfigyelések diszkrét volta jelenti. Az utófeldolgozás így visszavezethető egy osztályozási problémára, amelynek megoldására különböző gépi tanuláson alapuló technikákat javasoltunk (Baran *et al.*, 2021a).

2019. őszén három hónapig dolgoztam Readingben, ahol az ECMWF kutatóival közösen kifejlesztettünk egy a hőindex ensemble előrejelzések kalibrálására szolgáló általánosított extrémérték (GEV) eloszláson alapuló EMOS modellt (Baran *et al.*, 2020). Emellett azt is vizsgáltuk, mi a hatékonyabb: maguknak a hőindexeknek az utófeldolgozása, vagy az előállításukhoz szükséges hőmérséklet és harmatpont együttes kalibrálása.

Kidolgoztuk a szélsőbesség ensemble előrejelzések kalibrálására szolgáló GEV EMOS modell csonkított változatát, ami kiküszöböli a GEV eloszlás azon problémáját, hogy pozitív valószínűséggel tud negatív szélsőbességeket is előrejelezni (Baran *et al.*, 2021b).

Részben az előző pontban említett OMSZ projekthez kapcsolódva kifejlesztettünk egy nullában alulról cenzorált logisztikus (CL0) eloszláson alapuló EMOS modellt a napsugárzás előrejelzések kalibrálására, amit sikeresen teszteltünk az OMSZ AROME-EPS globálsugárzás, valamint a DWD ICON EPS közvetlen és szórt napsugárzás előrejelzésein (Schultz *et al.*, 2021). Az új modell előnye az eddig ismert utófeldolgozó eljárásokkal szemben, hogy egyben kezeli a nappali és éjszakai időszakot. Ennek kapcsán szeretnék kidolgozni egy CL0 eloszlások keverékét használó BMA modellt is.

Ugyancsak az OMSZ projekt kapcsán dolgoztuk ki a 2. pontban említett TN MLP utófeldolgozó eljárást, ahol a TN előrejelző eloszlás hely és skála paraméterét egy neurális háló segítségével becsüljük meg a nyers ensemble különböző funkcionáljait használva bemenő paraméterként (Baran and Baran, 2021). A módszer előnye az EMOS modellekkel szemben, hogy egyben tudja kezelni a különböző előrejelzési horizontokat. Ennek folytatásaként egy hasonló módszerrel próbálkozunk a globálsugárzás előrejelzések kalibrálásánál is.

Egy NKFIH-DFG nemzetközi pályázat keretében összeállt magyar-német kutatócsoporttal (Baran, S., Hemri, S., Groß, J., Lerch, S., Möller, A., Schefzik, R., Szokol, P.) szimulációs vizsgálatok segítségével összevetettük a különféle kétlépcsős többdimenziós utófeldolgozó technikák hatékonyságát (Lerch *et al.*, 2020). 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, szélsőbesség és 24h csapadékösszeg előrejelzésein hasonlítjuk 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.

Korábban foglalkoztunk az ECMWF duális-felbontású hőmérséklet ensemble előrejelzéseinek statisztikai utófeldolgozásával (Baran *et al.*, 2019b), mely kutatások szorosan kapcsolódnak az ECMWF 2025-ig szóló stratégiai terveihez, amiben szerepel az operatív előrejelző rendszer rácsfelbontásának 18 km-ről 5 km-re való finomítása. Jelenleg ehhez kapcsolódóan vizsgáljuk a duális felbontású csapadékösszeg előrejelzések paraméteres utófeldolgozását, kiegészítve ezzel Gascón *et al.* (2019) nemparaméteres eredményeit.

A readingi kutatókkal eddig végzett közös munkám elismeréseként a 2021–2023 időszakra elnyertem az ECMWF Ösztöndíját<sup>1</sup>, ami jelentősen bővíti a közös kutatási projektjeink palettáját. A tervek között szerepel például többdimenziós utófeldolgozó módszerek és verifikációs mutatók kidolgozása (partner: Zied Ben Bouallègue), a duális felbontás további vizsgálata (partner: Martin Leutbecher), a reforecast előnyeinek vizsgálata az utófeldolgozás szemponjából (partner: Florian Pappenberger), vagy az energiatermelésben használt változók kalibrálása (partner: Thomas Haiden).

Tisztelettel,



Dr. Baran Sándor  
egyetemi docens

Debrecen, 2021. május 28.

## Irodalom

- Baran, Á., Lerch, S., El Ayari, M. and Baran, S. (2021a) Machine learning for total cloud cover prediction. *Neural. Comput. Appl.* **33**, 2605–2620.
- Baran, S. (2014) Probabilistic wind speed forecasting using Bayesian model averaging with truncated normal components. *Comput. Stat. Data. Anal.* **75**, 227–238.
- Baran, S. and Baran, Á. (2021) Calibration of wind speed ensemble forecasts for power generation. *arXiv:2104.14910*. Elérhető: <https://arxiv.org/abs/2104.14910>.
- 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. (2019a) Statistical post-processing of water level forecasts using Bayesian model averaging with doubly-truncated normal components. *Water Resour. Res.* **55**, 3997–4013.
- Baran, S., Horányi, A. and Nemoda, D. (2014) Comparison of the BMA and EMOS statistical methods in calibrating temperature and wind speed forecast ensembles. *Időjárás* **118**, 217–241.
- Baran, S. and Lerch, S. (2015) Log-normal distribution based EMOS models for probabilistic wind speed forecasting. *Q. J. R. Meteorol. Soc.* **141**, 2289–2299.

---

<sup>1</sup>[www.ecmwf.int/en/about/media-centre/news/2020/ecmwf-appoints-seven-new-fellows-scientific-collaboration](http://www.ecmwf.int/en/about/media-centre/news/2020/ecmwf-appoints-seven-new-fellows-scientific-collaboration)



- Baran, S. and Lerch, S. (2016) Mixture EMOS model for calibrating ensemble forecasts of wind speed. *Environmetrics* **27**, 116–130.
- Baran, S., Leutbecher, M., Szabó, M. and Ben Bouallègue, Z. (2019b) Statistical post-processing of dual-resolution ensemble forecasts. *Q. J. R. Meteorol. Soc.* **145**, 1705–1720.
- Baran, S. and Möller, A. (2015) Joint probabilistic forecasting of wind speed and temperature using Bayesian model averaging. *Environmetrics* **26**, 120–132.
- Baran, S. and Möller, A. (2017) Bivariate ensemble model output statistics approach for joint forecasting of wind speed and temperature. *Meteorol. Atmos. Phys.* **129**, 99–112.
- Baran, S. and Nemoda, D. (2016) Censored and shifted gamma distribution based EMOS model for probabilistic quantitative precipitation forecasting. *Environmetrics* **27**, 280–292.
- Baran, S., Szokol, P. and Szabó, M. (2021b) Truncated generalized extreme value distribution based EMOS model for calibration of wind speed ensemble forecasts. *Environmetrics*, doi:10.1002/env.2678.
- Gascón, E., Lavers, D., Hamill, T. M., Richardson, D. S., Ben Bouallègue, Z., Leutbecher, M., Pappenberger, F., Statistical post-processing of dual-resolution ensemble precipitation forecasts across Europe. *Q. J. R. Meteorol. Soc.* **145** (2019), 3218–3235.
- Gneiting, T., Raftery, A. E., Westveld, A. H. and Goldman, T. (2005) Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation. *Mon. Weather Rev.* **133**, 1098–1118.
- Hemri, S., Fundel, F. and Zappa, M. (2013) Simultaneous calibration of ensemble river flow predictions over an entire range of lead times. *Water Resour. Res.* **49**, 6744–6755.
- Hemri, S., Lisniak, D. and Klein, B. (2014) Ermittlung probabilistischer Abflussvorhersagen unter Berücksichtigung zensierter Daten. *HyWa* **58**, 84–94.
- Hemri, S., Lisniak, D. and Klein, B. (2015) Multivariate postprocessing techniques for probabilistic hydrological forecasting. *Water Resour. Res.* **51**, 7436–7451.
- Hemri, S. and Klein, B. (2017) Analog based post-processing of navigation-related hydrological ensemble forecasts. *Water Resour. Res.* **53**, 9059–9077.
- Lerch, S. and Baran, S. (2017) Similarity-based semi-local estimation of EMOS models. *J. R. Stat. Soc. Ser. C Appl. Statist.* **66**, 29–51.
- 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., Thorarinsdottir, T. L., Lenkoski, A. and Gneiting, T. (2015) Spatially adaptive, Bayesian estimation for probabilistic temperature forecasts. arXiv:1507.05066.
- Schuhen, N., Thorarinsdottir, T. L. and Gneiting, T. (2012) Ensemble model output statistics for wind vectors. *Mon. Weather Rev.* **140**, 3204–3219.
- 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.