

Doktori (PhD) értekezés tézisei

Valószínűségi időjárás modellek és alkalmazásaik magyarországi adatokra

NEMODA DÓRA RENÁTA

TÉMAVEZETŐ: DR. BARAN SÁNDOR



Debreceni Egyetem
Természettudományi Doktori Tanács
Matematika- és Számítástudományok Doktori Iskola
Debrecen, 2017

1. Bevezetés

Az időjárás előrejelzés célja az, hogy egy megbízható előrejelzést adjunk az atmoszféra jövőbeli állapotáról, tényleges megfigyelések, korábbi előrejelzések, illetve az atmoszféra dinamikáját leíró matematikai modellek segítségével. Ezek a modellek olyan nemlineáris parciális differenciálegyenletekből állnak, melyeknek csak numerikus megoldása van. A numerikus időjárás-előrejelzés (NWP) problémája az, hogy a megoldás erősen függ a modell kezdeti érték paramétereitől.

Az előrejelzések bizonytalanságának csökkentése érdekében fejlesztették ki az ensemble (együttes) előrejelzési technikát (Leith, 1974). Ezeket úgy készítik, hogy a kezdeti érték feltételeket vagy a modell paramétereit kismértékben megváltoztatják (perturbálják), és mindegyik változattal készítenek egy előrejelzést. Ezen ensemble-együttes átlagát vagy mediánját felhasználva kapnak pontbecsléseket, melyekkel már nagymértékben sikerül csökkenteni az NWP modellek előrejelzési hibáit. Napjainkban minden fontosabb meteorológiai szolgálat üzemeltet valamilyen ensemble előrejelző rendszert (Ensemble prediction system; EPS). Az esetek többségben az ensemble előrejelzéseknek kicsi a szóródásuk, valamint a belőlük származó előrejelzések nem kalibráltak. Az ensemble előrejelzések pontosságát különböző utófeldolgozó módszerekkel sikerült javítani.

A disszertációm témája különböző valószínűségi időjárás modellek bemutatása, illetve azok alkalmazása magyarországi adatokra. A dolgozat három részből tevődik össze. Manapság a Bayesian model averaging (BMA; Raftery *et al.*, 2005) és az Ensemble model output statistics (EMOS; Gneiting *et al.*, 2005) a két legszéleskörűben alkalmazott statisztikai utófeldolgozó módszer (Gneiting, 2014), melyeket az 1.1. alfejezetben mutatok be.

2. Ensemble előrejelző rendszerek

Manapság számos statisztikai utófeldolgozó módszer közül választhatunk, melyekkel javíthatunk az ensemble előrejelzések pontosságán (Gneiting, 2014; Williams *et al.*, 2014). Ezek közül a két legnépszerűbbet, a Bayesian Model Averaging (BMA; Raftery *et al.*, 2005) illetve az Ensemble Model Output Statistics (EMOS) módszereket mutatom be. Ezeket az utófeldolgozó módszereket az időjárási változók széles skáláján lehet sikeresen alkalmazni.

A modellek paramétereit tanulóadatok segítségével becsüljük meg, melyek valamely megelőző időszak előrejelzéseit és tényleges megfigyeléseit tartalmazzák. A tanuló adatsor így dinamikusan változik, melynek választása szempontjából lokális és globális módszereket különböztetünk meg. Vizsgálataink során a globális módszert alkalmaztuk, ekkor minden paraméterbecsléshez minden adatot felhasználunk, az egyes állomások azonos paraméterhalmazon osztoznak.

Legyen y egy tetszőleges időjárási mennyiség, valamint legyen $f_1, \dots, f_K$ a hozzá tartozó ensemble előrejelzés egy adott helyre és időre vonatkozóan. Az y sűrűségfüggvényét jelölje $g_k(y|f_k)$, feltéve, hogy a tanuló időszakban a legjobb előrejelzést

f_k adta. A BMA előrejelző eloszlás (Raftery *et al.*, 2005) az egyes ensemble tagokhoz tartozó feltételes sűrűségfüggvények egy súlyozott átlagaként áll elő, azaz

$$p(y|f_1, \dots, f_K) = \sum_{k=1}^K \omega_k g_k(y|f_k), \quad (2.1)$$

ahol ω_k annak a posteori valószínűsége, hogy a tanuló időszakban f_k volt a legjobb előrejelzés. Az ω_k súlyok valószínűségi eloszlást alkotnak, azaz egyrészt nemnegatívak, másrészt $\sum_{k=1}^K \omega_k = 1$.

Az eddig bemutatott módszer akkor alkalmazható, amikor az ensemble előrejelzések egymástól egyértelműen megkülönböztethetőek, azaz mindegyik tag azonosítható és visszakövethető, ilyen például a 8 tagú University of Washington mesoscale ensemble. Manapság a legtöbb NWP modell olyan állományt generál, amely statisztikailag megkülönböztethetetlen ensemble tagokból álló csoportokat tartalmaz, ez a kezdeti érték feltételek véletlen perturbációja miatt jön létre. Ilyen a 11 tagú ALADIN-HUNEPS ensemble, amit az OMSZ állít elő.

Az egymástól nem megkülönböztethető ensemble előrejelzéseket felcserélhetőnek tekintjük. Ha az M darab ensemble tagot K darab felcserélhető tagokból álló csoportba osztjuk, jelölje $f_{k,\ell}$ a k -adik csoport ℓ -edik tagját. A BMA előrejelző eloszlás felcserélhető csoportokat tartalmazó ensemble esetén

$$p(y|f_{k,\ell}, k = 1, \dots, K, \ell = 1, \dots, M_k) = \sum_{k=1}^K \sum_{\ell=1}^{M_k} \omega_k g_k(y|f_{k,\ell}), \quad (2.2)$$

ahol az egy csoportba tartozó ensemble tagok ugyanolyan súlyt és paramétereket kapnak.

A különböző időjárási mennyiségek esetén különböző eloszlásokat használnak. Hőmérséklet és tengerszint feletti nyomás előrejelzése esetén Raftery *et al.* (2005) normális eloszlást alkalmazott, a szélsébség nemnegativitása és ferdesége miatt Slougher *et al.* (2010) gamma eloszlást használt, majd Baran (2014) nullában csonkított normális eloszlást alkalmazva javított ez előrejelzések pontosságán. Szélirány előrejelzésére Bao *et al.* (2010) Von Mises eloszláson, szélvektor esetén pedig Slougher *et al.* (2013) kétváltozós normális eloszláson alapuló BMA modellt dolgozott ki. Végezetül csapadékmennyiség előrejelzés esetén Slougher *et al.* (2007) egy diszkrét-folytonos gamma eloszlást alkalmazott.

Az Ensemble Model Output Statistics (EMOS) (nem-homogén regressziós) módszer egyetlen paraméteres eloszlást állít elő, ahol a paraméterek az ensemble előrejelzésektől függenek. Az EMOS előrejelző eloszlás általános alakja

$$y|f_1, \dots, f_K \sim g(y|f_1, \dots, f_K),$$

ahol y egy tetszőleges időjárási mennyiség, $f_1, \dots, f_K$ pedig a hozzá tartozó megkülönböztethető ensemble előrejelzés egy adott helyre és időre vonatkozóan.

Gneiting *et al.* (2005) hőmérséklet és nyomás előrejelzéshez az alábbi regressziót használta

$$y = a_0 + a_1 f_1 + \dots + a_K f_K + \varepsilon, \quad \text{és} \quad \varepsilon \sim \mathcal{N}(0, b_0 + b_1 S^2),$$

ahol $a_0, \dots, a_K \in \mathbb{R}$ és $b_0, b_1 \in \mathbb{R}^+$ a becsülendő paraméterek, S az ensemble szórása,

$$S^2 = \frac{1}{K-1} \sum_{k=1}^K (f_k - \bar{f})^2,$$

valamin $\bar{f}$ az ensemble átlaga, azaz

$$\bar{f} = \frac{1}{K} \sum_{k=1}^K f_k.$$

A normális EMOS előrejelző modell

$$y|f_1, \dots, f_K \sim \mathcal{N}(\mu, \sigma^2), \quad (2.3)$$

melynek $\mu = a_0 + a_1 f_1 + \dots + a_K f_K$ várható értéke az ensemble előrejelzések, míg a $\sigma^2 = b_0 + b_1 S^2$ szórásnégyzete az ensemble szórásnégyzetének affin függvényeként áll elő.

Felcserélhető ensemble tagok esetén az M darab ensemble tagot osszuk K darab csoportba, és $f_{k,\ell}$ jelölje a k -adik csoport ℓ -edik tagját. Az EMOS előrejelző eloszlás

$$\mathcal{N}\left(a_0 + a_1 \sum_{\ell_1=1}^{M_1} f_{1,\ell_1} + \dots + a_K \sum_{\ell_K=1}^{M_K} f_{K,\ell_K}, b_0 + b_1 S^2\right), \quad (2.4)$$

ahol az egy csoportba tartozó ensemble tagok ugyanolyan várható érték paramétert kapnak.

A modellben fellépő $a_0, \dots, a_K$ várható érték és b_0, b_1 szórás paraméterek becslését a tanuló periódus alapján végezzük el, egy megfelelő illeszkedési mutató optimalizálásával. Gneiting *et al.* (2005) a continuous ranked probability score (CRPS) minimalizálását javasolja.

Különböző időjárási mennyiségek esetén eltérő eloszlású EMOS modelleket alkalmazunk. A BMA módszerhez hasonlóan Gneiting *et al.* (2005) hőmérséklet és tengerszint feletti nyomás előrejelzésre normális eloszlást választott. A szélsőbesség nemnegativitása és ferdesége miatt Thorarinsdottir and Gneiting (2010) csenkített normális eloszlást alkalmazott, majd Lerch and Thorarinsdottir (2013) általánosított extrémérték eloszlást (GEV) használt, végül Baran and Lerch (2015, 2016) log-normális eloszlással és eloszlások keverékével javított az előrejelzések pontosságán. Csapadékmennyiség előrejelzése esetén Scheuerer (2014) nullában balról cenzorált általánosított extrémérték (GEV) modellt alkalmazott, majd Scheuerer and Hamill (2015) cenzorált, eltolt gamma eloszláson alapuló többlépcsős modellt fejlesztett ki.

Az ensemble előrejelzések BMA illetve EMOS módszerrel való statisztikai utófeldolgozására az R program `ensembleBMA` illetve `ensembleMOS` programcsomagját használtuk (Fraley *et al.*, 2009, 2011). Ezek a programcsomagok részben tartalmazzák a szükséges eloszlásokat, a többi esetben a témavezetőm által írt saját kódokat használtunk. A modellező eljárás tudja kezelni a felcserélhető és nem felcserélhető ensemble előrejelzések esetét is, továbbá hiányzó előrejelzéseket is figyelembe tud venni. Tartalmazza továbbá az illeszkedésvizsgálathoz szükséges legfontosabb mutatókat, valamint a kapott eredményeket grafikai úton is megjeleníti.

A valószínűségi előrejelzés célja az, hogy maximalizáljuk az előrejelző eloszlás pontosságát, azaz az általunk meghatározott modell minél jobban illeszkedjen a tényleges megfigyelésekre. Egy megfelelő illeszkedési mutató alkalmazásával a valószínűségi előrejelzéshez és a hozzá tartozó tényleges megfigyeléshez egy numerikus értéket tudunk rendelni, így az illeszkedés mértékét számszerűsíteni tudjuk.

A továbbiakban jelölje $x_{s,t}$ az s helyre és t időre vonatkozó tényleges megfigyelést, $p_{s,t}$ illetve $P_{s,t}$ az s helyre és t időre vonatkozó előrejelzés becsült sűrűség- és eloszlásfüggvényét, $\hat{x}_{s,t}$ pedig legyen az előrejelző sűrűségfüggvény, vagy az ensemble alapján számított pontbecslés (medián vagy átlag). Jelölje továbbá n a mintaelemszámot, azaz az összes $s \in \mathcal{S}$ helyhez és $t \in \mathcal{T}$ időponthoz tartozó esetek számát.

Pontelőrejelzések illeszkedésének vizsgálatára a leggyakoribb mutatók az *átlagos abszolút eltérés* (mean absolute error, MAE)

$$\text{MAE} = \frac{1}{n} \sum_{s,t} |x_{s,t} - \hat{x}_{s,t}|,$$

és az *átlagos négyzetes eltérések négyzetgyöke* (root mean square error, RMSE), azaz

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{s,t} (x_{s,t} - \hat{x}_{s,t})^2}.$$

Mindkét mutató negatív irányultságú, vagyis a kisebb értékek jelentik a jobb illeszkedést. MAE esetén az optimális pontelőrejelzés a medián, míg RMSE esetén az átlag (Gneiting, 2011).

Eloszlások illeszkedésének vizsgálatára az egyik legnépszerűbb mutató a *continuous ranked probability score* (CRPS; Gneiting and Raftery, 2007), mely egy F eloszlásfüggvény és x érték esetén

$$\text{crps}(F, x) = \int_{-\infty}^{\infty} (F(y) - \mathbb{I}_{y \geq x})^2 dy = \mathbb{E}|X - x| - \frac{1}{2} \mathbb{E}|X - X'|, \quad (2.5)$$

ahol X és X' független, F eloszlású, véges várható értékű valószínűségi változók. A nyers ensemble esetén az előrejelző eloszlást az empirikus eloszlásfüggvény helyettesíti.

Az átlagos CRPS mutató az összes helyre és időre vonatkozó előrejelző eloszlás és a hozzájuk tartozó tényleges megfigyelések crps értékeinek az átlaga, azaz

$$\text{CRPS} = \frac{1}{n} \sum_{s,t} \text{crps}(P_{s,t}, x_{s,t}). \quad (2.6)$$

A CRPS mutató szintén negatív irányultságú, a különböző eloszlások esetén pedig zárt alakok adhatók meg a $\text{crps}(F, x)$ kiszámítására.

Eloszlások illeszkedésének vizsgálatára a széleskörűen alkalmazott *probability integral transform* (PIT; Raftery *et al.*, 2005) hisztogramot használjuk. A PIT értéket általában az előrejelző eloszlásfüggvényt a tényleges megfigyelés helyén kiértékelve kapjuk, melyeket hisztogrammal ábrázolunk. Minél közelebb van ez a hisztogram az egyenleteshez, annál pontosabb az előrejelző eloszlás. Csapadék előrejelzéskor a nulla csapadék esetén a PIT érték a $[0, p_0]$ intervallumon egyenletes eloszlásból vett érték, ahol p_0 a nulla csapadék előrejelzés valószínűsége (Sloughter *et al.*, 2007).

A nyers ensemble előrejelzések illeszkedésének vizsgálatára a *verification rank hisztogramot* alkalmazzuk, mely a tényleges megfigyelés és az ensemble előrejelzések egymáshoz viszonyított elhelyezkedését illusztrálja. A hisztogramot úgy kapjuk, hogy minden egyes helyre és időre kiszámítjuk a tényleges megfigyelés rangját, azaz az ensemble tagokkal közösen alkotott rangsorban elfoglalt helyét, majd a kapott rangokat hisztogramon ábrázoljuk. Csapadék esetében a hisztogram készítése úgy módosul, hogy nulla csapadék esetén egyenletesen választunk a $\{1, 2, \dots, k + 1\}$ halmazból, ahol k a nulla csapadékot előrejelző ensemble előrejelzések száma.

Mindezekon túl az előrejelző eloszlások kalibráltságát és élességét az $(1 - \alpha)100\%$ -os ($\alpha \in (0, 1)$) előrejelző intervallumok *lefedettségével* és *átlagos szélességével* tudjuk vizsgálni. A lefedettség az alsó és a felső $\alpha/2$ -kvantilis közé esés aránya, α választása pedig a nyers ensemble nominális lefedettségével van összhangban (UWME: $\alpha = 0.222$, ALADIN-HUNEPS: $\alpha = 0.1667$). Egy kalibrált előrejelző eloszlás esetében ez az arány közel $(1 - \alpha)100\%$. A legjobb előrejelző eloszlást ezek után úgy kapjuk meg, hogy a kalibrált előrejelző eloszlások közül kiválasztjuk azt, amelyik a legszűkebb előrejelző intervallumot szolgáltatja.

Ensemble előrejelzések előállítására az Országos Meteorológiai Szolgálat az ALADIN-HUNEPS rendszert használja, mely a Météo France globális ARPEGE alapú PEARP rendszerének egy dinamikus leskálázása (Horányi *et al.*, 2006). Az Európa kontinentális részét lefedő ALADIN modellt egy 8 km-es horizontális rácsfelbontással futtatják. A rendszer egy 11 tagú ensemble előrejelzést állít elő, melyek közül 10 perturbált kezdeti értékekkel van generálva, a tizenegyedik a kontroll tag, melyet perturbálatlan kezdeti értékekkel készítenek (Horányi *et al.*, 2011).

A hőmérséklet és szélesebbesség adatállomány 10 magyarországi nagyváros 2 méter magasságban mért hőmérséklet (Kelvin), valamint 10 méter magasságban mért szélesebbesség (m/s) előrejelzéseit, és a hozzájuk tartozó tényleges megfigyeléseket tartalmazza. Az előrejelzési időszak 42 órás, ami azt jelenti, hogy a modellt 18 UTC időpontban inicializálják (nyári időszámítás szerint ez este 8 óra, különben 7 óra), és két nap múlva délre kapnak előrejelzést. A munkánk folyamán egy éves adatsorral (2012. április 1. és 2013. március 31.) dolgoztunk. Ez az adatbázis majdnem teljes volt, csak 6 napról hiányoztak előrejelzések, ezeket a napokat kihagytuk a

feldolgozásból.

A nyers hőmérséklet és szélsőbesség ensemble verification rank hisztogramját megvizsgálva azt láttuk, hogy mindkét hisztogram erősen U alakú, az esetek többségében az ensemble előrejelzések alul- vagy felülbecsülik a tényleges megfigyelést. Az ensemble tagok által lefedett tartomány hőmérséklet esetén 60.61%-ban, szélsőbesség esetén 68.52%-ban tartalmazza a tényleges megfigyelést. Az elvárt (nominális) érték mindkét esetben 10/12, vagyis 83.33% lenne. Ezek alapján azt mondhatjuk, hogy az ensemble szórása mindkét esetben kicsi, így a belőlük számolt előrejelzések nem lesznek kalibráltak, utófeldolgozás szükséges.

A csapadék adatállomány ugyancsak 10 magyarországi nagyváros 24 órás csapadékösszeg 42 órás ensemble előrejelzéseit tartalmazza (a modellt szintén 18 UTC időpontban inicializálják), valamint a hozzájuk tartozó tényleges megfigyeléseket a 2010. október 1-e és 2011. március 25-e közötti időszakban. Az adatbázis szinte teljes, hiszen csupán két nap esetén hiányzott 3-3 ensemble előrejelzés, ezeket a feldolgozás folyamán elhagytuk.

A nyers ALADIN-HUNEPS csapadék ensemble verification rank hisztogramja alapján az ALADIN-HUNEPS ensemble lefedettsége 84.20%, mely már nagyon közel van a nominális 83.33% értékhez, így ez a hisztogram egy jó kalibrációt mutat.

A nyolc tagú University of Washington mesoscale ensemble (UWME) Észak-Amerika északnyugati csendes-óceáni partvidékét fedi le 12 km-es horizontális rácsfelbontással. Az ensemble tagokat az ötödik generációs PSU-NCAR MM5 (Grell *et al.*, 1995) mesoscale modell különböző futtatásaiból készítik, különböző időjárási központok kezdeti és határ feltételeit felhasználva. A csapadék adatállományt a 152 állomáson mért 48 órás előrejelzések és a hozzájuk tartozó tényleges megfigyelések alkotják. A modellt 0 UTC időpontban inicializálják (ez nyári időszámítás szerint délután 5 órának felel meg, különben délután 4 óra), az előrejelzéseket a 2008-as évre vizsgáltuk, de a paraméterek becsléséhez az előző év utolsó három hónapját is hozzávettük. A hiányzó adatokat tartalmazó sorok elhagyása után 2008-ra 83 állomás 20522 előrejelzése maradt meg.

A nyers UWME csapadék ensemble verification rank hisztogramját megvizsgálva azt kaptuk, hogy ez a hisztogram erősen ferde, a legtöbb esetben az ensemble előrejelzések túlbecsülik a tényleges megfigyelést. A validáló megfigyelés mindössze az esetek 67.82%-ban esik az ensemble tagok által lefedett tartományba, míg az elvárt, azaz az ensemble nominális lefedettsége 7/9 vagyis 77.78% lenne. Így a UWME csapadék ensemble előrejelzés nem kalibrált, statisztikai utófeldolgozást igényel.

3. ALADIN-HUNEPS ensemble előrejelzések statisztikai utófeldolgozása

Az ALADIN-HUNEPS hőmérséklet és szélsőbesség adataira különböző modelleket alkalmaztunk, majd meghatároztuk az adatokra legjobban illeszkedőt. Mindkét

esetben BMA és EMOS módszereket hasonlítottuk össze. Hőmérséklet esetén normális BMA és normális EMOS modellt használtunk, szélsőbesség esetén gamma BMA, csonkított normális BMA és csonkított normális EMOS modellt illesztettünk.

Az ALADIN-HUNEPS hőmérséklet és szélsőbesség előrejelzései esetén az ensemble tagok két különböző csoportosítását alkalmaztuk. Az ensemble generálási módjából természetesen adódó kétcsoportos modellben a 11 előrejelzést két csoportba osztottuk ($K = 2$), az egyik csoportba az f_c kontroll tag ($M_1 = 1$), míg a másik csoportba a 10 felcserélhető $f_{p,1}, \dots, f_{p,10}$ ensemble tag került ($M_2 = 10$). Az ensemble tagok részletes vizsgálata adta a háromcsoportos modell ötletét, ekkor az ensemble tagokat három csoportba osztottuk ($K = 3$). Az első csoportba az f_c kontroll tag ($M_1 = 1$), a másodikba a $f_{p,2}, f_{p,4}, f_{p,6}, f_{p,8}, f_{p,10}$ páros sorszámú ensemble tagok ($M_2 = 5$), míg a harmadikba a $f_{p,1}, f_{p,3}, f_{p,5}, f_{p,7}, f_{p,9}$ páratlan sorszámú ensemble tagok kerülnek ($M_3 = 5$).

Hőmérséklet esetén az adatainkra a Raftery *et al.* (2005) által javasolt normális BMA módszert alkalmaztuk. A (2.2) modell speciális alakja a kétcsoportos esetben

$$p(y|f_c, f_{p,1}, \dots, f_{p,10}; b_{0,c}, b_{0,p}, b_{1,c}, b_{1,p}, \sigma) = \omega g_c(y|f_c, b_{0,c}, b_{1,c}, \sigma) + \frac{1-\omega}{10} \sum_{\ell=1}^{10} g_p(y|f_{p,\ell}, b_{0,p}, b_{1,p}, \sigma), \quad (3.1)$$

ahol $\omega \in [0, 1]$ és $g(y|f, b_0, b_1, \sigma)$ normális eloszlás sűrűségfüggvénye $b_0 + b_1 f$ várható értékkel és σ^2 szórásnégyzettel (Baran *et al.*, 2014a). Ekkor a két csoportnak különbözőek a várható érték paraméterei ($b_{0,c}, b_{1,c}$ és $b_{0,p}, b_{1,p}$), viszont a szórási paraméterei (σ) megegyeznek.

Ez a lineáris modell, amikor a várható érték paraméter az ensemble előrejelzések affin függvényeként áll elő. Speciális esetként megvizsgáltuk az additív korrekciós modellt, amikor $b_{1,c} = b_{1,p} = 1$, és a korrekció nélküli esetet, amikor $b_{1,c} = b_{1,p} = 1$ és $b_{0,c} = b_{0,p} = 0$.

A háromcsoportos esetben az (2.2) modell speciális alakja

$$p(y|f_c, f_{p,1}, \dots, f_{p,10}; b_{0,c}, b_{0,o}, b_{0,e}, b_{1,c}, b_{1,o}, b_{1,e}, \sigma) = \omega_c g_c(y|f_c, b_{0,c}, b_{1,c}, \sigma) + \omega_o \sum_{j=1}^5 g_o(y|f_{p,2j-1}, b_{0,o}, b_{1,o}, \sigma) + \omega_e \sum_{j=1}^5 g_e(y|f_{p,2j}, b_{0,e}, b_{1,e}, \sigma), \quad (3.2)$$

ahol $\omega_c, \omega_o, \omega_e \in [0, 1]$, $\omega_c + 5\omega_o + 5\omega_e = 1$, és a g a fentiekhez hasonlóan definiált normális eloszlású sűrűségfüggvény. Hasonlóan a kétcsoportos esethez itt is megvizsgáltuk a speciális eseteket, azaz az additív korrekciós modellt, amikor $b_{1,c} = b_{1,o} = b_{1,e} = 1$, és korrekció nélküli modellt, amikor $b_{1,c} = b_{1,o} = b_{1,e} = 1$ és $b_{0,c} = b_{0,o} = b_{0,e} = 0$.

Az EMOS előrejelző eloszlás egyetlen parametrikus sűrűségfüggvényt állít elő, ahol a paraméterek az ensemble előrejelzések függvényeiként állnak elő. Hasonlóan

a BMA módszerhez, hőmérséklet esetén normális eloszlást használunk. Az (2.4) EMOS előrejelző eloszlás speciális alakja a kétcsoportos esetben

$$\mathcal{N}(a_0 + a_1 f_c + a_2 \sum_{i=1}^{10} f_{p,i}, b_0 + b_1 S^2), \quad (3.3)$$

a háromcsoportos esetben pedig

$$\mathcal{N}(a_0 + a_1 f_c + a_2 \sum_{i=1}^5 f_{p,2i-1} + a_3 \sum_{i=1}^5 f_{p,2i}, b_0 + b_1 S^2), \quad (3.4)$$

ahol S^2 jelöli az ensemble szórásnégyzetét.

Szélesség modellezésére egy nemnegatív, balra ferdült eloszlásra van szükség, ezért gamma eloszlású BMA módszert alkalmaztunk adatainkra. A (3.1) kétcsoportos és a (3.2) háromcsoportos BMA modell szélesség esetén úgy módosul, hogy a $g(y|f, b_0, b_1 c_0, c_1)$ gamma eloszlás sűrűségfüggvénye, $b_0 + b_1 f$ várható érték és $c_0 + c_1 f$ szórási paraméterrel (Baran *et al.*, 2013). A várható érték és a szórási paraméterek is az ensemble előrejelzések affin függvényeiként állnak elő. Az egyes csoportoknak különbözőek a várható érték paraméterei, viszont a szórási paraméterei minden esetben megegyeznek.

Gamma eloszlás mellett nullában alulról csonkított normális eloszlást is alkalmazunk. Ekkor a (3.1) kétcsoportos és a (3.2) háromcsoportos modellben a $g(y|f, b_0, b_1, \sigma)$ csonkított normális eloszlás sűrűségfüggvénye $b_0 + b_1 f$ hely és σ^2 skála paraméterrel. Ekkor a csoportoknak különbözőek a hely paraméterei, viszont a skála paraméterei megegyeznek.

Az EMOS módszer esetén nullában alulról csonkított normális eloszlást alkalmazunk. Az (3.3) kétcsoportos és a (3.4) háromcsoportos EMOS előrejelző eloszlásban a normális eloszlást csonkított normális eloszlással helyettesítjük.

A továbbiakban a 11 tagú ALADIN-HUNEPS hőmérséklet és szélesség ensemble előrejelzésekre alkalmazott BMA és EMOS modellekkel kapott eredményeimet összegzem. A disszertációban részletesen indoklom a tanuló periódus hosszának választását, illetve az illeszkedésvizsgálat konkrét eredményei is fel vannak tüntetve.

Hőmérséklet ensemble esetén normális BMA (lineáris, additív és korrekció nélküli esetben) és normális EMOS módszert alkalmaztunk két- illetve háromcsoportos esetben. A 35 napos tanuló periódust használva ensemble előrejelzések, tényleges megfigyelések és előrejelző sűrűségfüggvények 2012. május 7. és 2013. március 31. között állnak rendelkezésünkre.

A probability integral transform (PIT) hisztogramok jól mutatják a nyers ensemble előrejelzések statisztikai utófeldolgozásának hasznosságát. Ezeket a nyers hőmérséklet ensemble verification rank hisztogramjával összehasonlítva azt mondhatjuk, hogy a statisztikai utófeldolgozás minden módszer esetében javított az előrejelzések pontosságán. Megfigyelhető továbbá az is, hogy a háromcsoportos modell jobb mint a kétcsoportos. A különböző utófeldolgozó módszereket összehasonlítva egyrészt megfigyelhető, hogy az EMOS adja a legkisebb CRPS, MAE és

RMSE értékeket, a legélesebb előrejelző intervallumokat, mind a két- mind pedig a háromcsoportos esetben, viszont a lefedettsége jóval az elvárt 83.33% alatt van. Ugyanakkor a lineáris BMA módszer CRPS, MAE és RMSE értékei csak kicsit rosszabbak ettől, és ez a módszer adja a legjobb lefedettséget. A PIT hisztogramok eredményeit is figyelembe véve megállapítható, hogy a négy módszer közül a normális BMA módszer lineáris korrekcióval adja a legjobb illeszkedést.

A 11 tagú ALADIN-HUNPES szélsőbesség ensemble esetén 43 napos tanuló periódussal gamma BMA, csonkított normális BMA és csonkított normális EMOS módszert alkalmaztunk, két- illetve háromcsoportos esetben. Így ensemble előrejelzések, tényleges megfigyelések és előrejelző sűrűségfüggvények 2012. május 15. és 2013. március 31. között állnak rendelkezésünkre.

A BMA módszerek esetén a háromcsoportos modell jobb, mint a kétcsoportos, míg az EMOS módszernél ez pont fordítva van. Mind a két- mind a háromcsoportos esetben a legkisebb CRPS értékeket a csonkított normális BMA módszer adja, míg az EMOS szolgáltatja a legszűkebb előrejelző intervallumokat és a legjobb lefedettséget. A pontbecsléseket tekintve a csonkított normális BMA és EMOS előrejelző sűrűségfüggvényekkel kapott MAE és RMSE értékek kisebbek mint, a nyers mintából számoltak. A gamma BMA módszer rosszabbnak bizonyult, hiszen itt az illeszkedési mutató értékei növekedtek. Összegzésképp elmondható, hogy a gamma BMA módszer felülmúlja a másik két módszert a PIT értékek esetében, viszont ez a módszer adja a legnagyobb CRPS értékeket, és a pontbecslések értékei is nagyon gyengék. Az EMOS és a csonkított normális BMA módszer MAE és RMSE értékei egymáshoz eléggé hasonlóak és jóval kisebbek, mint a nyers mintából számolt megfelelő értékek. Az utóbbi két módszer közül a csonkított normális BMA adja a legkisebb CRPS értékeket, míg az EMOS adja a legélesebb előrejelző intervallumokat, valamint a PIT hisztogramja is jobb, így azt mondhatjuk, hogy a nyers szélsőbesség ensemble előrejelzések esetén ennek a módszernek van a legjobb előrejelző képessége.

4. Csapadék előrejelzések statisztikai utófeldolgozása

A csapadékmennyiség statisztikai utófeldolgozása jóval nehezebb, mint bármely más időjárási mennyiségé, több okból kifolyólag. Először is a diszkrét-folytonos természete megnehezíti, hogy találjunk egy megfelelő parametrizált modellt. Figyelembe kell venni, hogy a nulla csapadéknak lehet pozitív valószínűsége, illetve pozitív mennyiségű csapadékot folytonos eloszlással kell modellezni. Másrészről, az előrejelzési bizonytalanság a várható csapadékmennyiség terjedelmének függvényében nő.

Egy olyan nemnegatív eloszlásra van szükségünk, mely pozitív valószínűséget enged a nulla csapadéknak. Egy nullában balról cenzorált folytonos eloszlást fogunk használni, melynek az is az előnye, hogy a nulla csapadék valószínűsége az eredeti eloszlásfüggvényből direkt módon számolható, így együtt kezelhetőek a nulla és a

pozitív csapadékmennyiségű esetek is.

Scheuerer (2014) EMOS modellje egy cenzorált, általánosított extrém érték modellt használ fel, melynek paramétere biztosítja a pozitív ferdeséget és a véges várható értéket. Ezzel szemben az általunk készített EMOS módszer (Baran and Nemoda, 2016) egy cenzorált, eltolt gamma eloszláson alapszik, mely Scheuerer and Hamill (2015) összetett modelljének egy egyszerűsített továbbfejlesztése.

Tekintsünk a $\Gamma(k, \theta)$ k -adrendű θ paraméterű gamma eloszlást, amelynek sűrűségfüggvénye

$$g_{k,\theta}(y) := \begin{cases} \frac{x^{k-1}e^{-y/\theta}}{\theta^k \Gamma(k)}, & y > 0, \\ 0, & \text{különben,} \end{cases} \quad (4.1)$$

ahol $\Gamma(k)$ jelöli a gamma függvény k -beli értékét. A gamma eloszlást parametrizálhatjuk a $\mu > 0$ várható értékével és $\sigma > 0$ szórásával az alábbi kifejezéseket felhasználva

$$k = \mu^2/\sigma^2 \quad \text{és} \quad \theta = \sigma^2/\mu. \quad (4.2)$$

Legyen $\delta > 0$ és jelölje $\Gamma^0(k, \theta, \delta)$ az eltolt, nullában balról cenzorált (CSG) k -adrendű θ skála- δ eltolásparaméterű gamma eloszlást, melynek eloszlásfüggvénye az alábbi szerint definiálható

$$G_{k,\theta,\delta}^0(y) := \begin{cases} G_{k,\theta}(y + \delta), & y \geq 0, \\ 0, & \text{különben,} \end{cases} \quad (4.3)$$

ahol $G_{k,\theta}$ a $\Gamma(k, \theta)$ eloszlás eloszlásfüggvénye. Ez az eloszlás az origóhoz a $G_{k,\theta}(\delta)$ súlyt rendeli, általánosított sűrűségfüggvénye pedig

$$g_{k,\theta,\delta}^0(y) := \mathbb{I}_{y=0}G_{k,\theta}(\delta) + \mathbb{I}_{y>0}(1 - G_{k,\theta}(\delta))g_{k,\theta}(y + \delta).$$

Rövid számolással kapjuk a $\Gamma_{k,\theta,\delta}^0$ eloszlás κ várható értékét

$$\kappa = \theta k(1 - G_{k,\theta}(\delta))(1 - G_{k+1,\theta}(\delta) - \delta(1 - G_{k,\theta}(\delta)))^2, \quad (4.4)$$

továbbá a (4.3) eloszlás q_p ($0 < p < 1$) p -kvantilise egyenlő 0, ha $p \geq G_{k,\theta}(\delta)$, egyébként pedig a $G_{k,\theta}(q_p + \delta) = p$ egyenlet megoldása.

A fent bevezetett CSG modellben az $f_1, f_2, \dots, f_K$ megkülönböztethető ensemble tagok (például UWME) az alapul szolgáló gamma eloszláshoz a

$$\mu = a_0 + a_1 f_1 + \dots + a_K f_K \quad \text{és} \quad \sigma^2 = b_0 + b_1 \bar{f}, \quad (4.5)$$

összefüggéssel kapcsolódnak, ahol $\bar{f}$ jelöli az ensemble átlagát. Felcserélhető ensemble esetén (például ALADIN-HUNEPS) a (4.5) modell megfelelő alakja

$$\mu = a_0 + a_1 \sum_{\ell_1=1}^{M_1} f_{1,\ell_1} + \dots + a_K \sum_{\ell_K=1}^{M_K} f_{K,\ell_K} \quad \text{és} \quad \sigma^2 = b_0 + b_1 \bar{f}. \quad (4.6)$$

Megjegyezzük, hogy általában az EMOS modellek esetén a várható érték (hely) paraméter az egyes ensemble előrejelzések affin függvényeként áll elő (Thorarinsdottir and Gneiting, 2010; Scheuerer, 2014; Baran and Lerch, 2015), a szórás paraméter pedig az ensemble különféle jellemzőitől függhet. Esetünkben a variancia az ensemble átlagának affin függvénye, melyhez hasonló esetet Sloughter *et al.* (2007) gamma BMA modellje használ. Így a modellben az előrejelzésekben felmerülő bizonytalanság az ensemble átlaggal arányosan nő.

Követve Gneiting and Raftery (2005) valamint Scheuerer (2014) ötletét a (4.5) és (4.6) modell $a_0, a_1, \dots, a_K \geq 0$ várható érték paramétereit és $b_1, b_1 \geq 0$ szórás paramétereit CRPS minimalizációs módszerrel becsültük meg.

A cenzorált, eltolt gamma EMOS modellt az UWME és az ALADIN-HUNEPS csapadék ensemble előrejelzéseken teszteltünk, és az eredményeket összehasonlítottuk Scheuerer (2014) általánosított extrémérték EMOS modelljével (GEV EMOS) és Sloughter *et al.* (2007) gamma BMA modelljével, valamint a nyers ensemble illeszkedési mutatóival. Scheuerer (2014) javaslatait figyelembe véve, a GEV EMOS modell adott napra vonatkozó paraméterbecslésekor a BFGS optimalizációs algoritmusnál kezdeti értéknek az előző napra vonatkozó becslést használtuk fel. Így a módszer előrejelző képessége valamelyest növekedett, viszont a mi adatainkra a CSG EMOS modellben a rögzített kezdeti érték feltételek szolgáltatottak jobb előrejelzéseket.

Az UWME adatállományt különböző kezdeti és peremfeltételekkel generálják, így ezek az ensemble tagok egymástól egyértelműen megkülönböztethetőek. Ezek alapján a CSG EMOS modellben szereplő gamma eloszlás várható értéke és szórása (4.5) képlet alapján függ az ensemble tagoktól, ahol $K = 8$. Nyilvánvalóan a GEV EMOS és a gamma BMA modellek (lásd Scheuerer (2014) és Sloughter *et al.* (2007)) esetében szintén a nem-felcserélhető ensemble tagok esetét tekintettük.

A tanuló periódust 20, 25, $\dots$, 100 napnak tekintve, a CSG EMOS és a gamma BMA modellek CRPS és MAE értékeinek részletes vizsgálatakor azt tapasztaltuk, hogy mindkét mutató globális minimuma 70 napnál van. A részletes eredményeket a dolgozatom tartalmazza. Így a 2008-as évre vonatkozó UWME előrejelzések utófeldolgozása során 70 napos tanuló periódust választottunk.

A nyers ensemble előrejelzések verification rank hisztogramja, valamint a CSG EMOS, GEV EMOS és gamma BMA modellek PIT hisztogramjai szintén egyértelműen mutatják a statisztikai utófeldolgozás előnyét. Az illeszkedési mutatók eredményeit vizsgálva egyértelműen megfigyelhető a statisztikai utófeldolgozás előnye. A különböző utófeldolgozó modellek CRPS és MAE értékei egyrészt jelentősen csökkentek a nyers ensemble ugyanezen mutatóihoz képest, másrészt nagymértékű fejlődést értünk el a lefedettség tekintetében is. A két EMOS modell CRPS és MAE értékei között nincs nagy különbség, viszont egyértelműen jobb előrejelzéseket adnak, mint a gamma BMA módszer. A CSG EMOS modell szolgáltatja a szűkebb előrejelző intervallumot és majdnem tökéletes lefedettséget biztosít, míg a másik két módszer esetén kapott hasonló intervallumok még a nyers mintához tartozótól is szélesebbek.

Így azt a következtetést lehet levonni, hogy az UWME adatállomány esetén mindkét EMOS modell jobb előrejelzést szolgáltat, mint a nyers ensemble vagy a gamma BMA modell, és az általunk készített CSG EMOS modell előrejelző képessége van olyan jó, mint a GEV EMOS modellé.

A 11 tagú ALADIN-HUNEPS csapadék ensemble egy kontroll és 10 felcserélhető tagból áll, így az ensemble tagok egy természetes csoportosítását alkalmaztuk, azaz az első csoportba a kontroll tag, míg a másodikba a 10 felcserélhető ensemble tag került. Így módon a (4.6) CSG EMOS modellben $K = 2$, $M_1 = 1$ és $M_2 = 10$, és ezt a csoportosítást alkalmaztuk a GEV EMOS és a gamma BMA modellnél is.

Az ALADIN-HUNEPS csapadék ensemble esetén 55 napos tanuló periódust használtunk, melynek részletes indoklása megtalálható dolgozatomban. Ez alapján ensemble előrejelzések és tényleges megfigyelések 119 napra (2010 november 27. és 2011 március 25. között) érhetők el.

A nyers ensemble verification rank hisztogramja és az utófeldolgozott előrejelzések PIT hisztogramjai jól illusztrálják az utófeldolgozás pozitív hatását, a gamma BMA modell viszont púpos alakú lett, amely túlzott szórást jelez. A két EMOS módszert tekintve hasonló eredményeket kaptunk, mint az UWME esetén. Az illeszkedési mutatók értékeit vizsgálva a CSG és GEV EMOS módszerek MAE értékei között nincs szignifikáns különbség, viszont a CSG EMOS adja a legkisebb CRPS értékeket és a legélesebb 83.33%-os előrejelző intervallumokat. Emellett mindkét EMOS módszer felülmúlja mind a nyers ensemble, mind pedig a gamma BMA módszerrel kapott előrejelzéseket, annak ellenére, hogy a nyers ensemble előrejelzések sokkal pontosabbak, mint a BMA módszerrel kapott előrejelzések.

Összefoglalásként azt mondhatjuk, hogy az ALADIN-HUNEPS csapadék előrejelzései esetén az általunk kifejlesztett új CSG EMOS modellnek (Baran and Nemoda, 2016) van a legjobb előrejelző képessége.

PhD Thesis

Probabilistic models for weather forecasting and their application on Hungarian data

DÓRA RENÁTA NEMODA

SUPERVISOR: DR. SÁNDOR BARAN



University of Debrecen
Doctoral School of Mathematical and
Computational Sciences

Debrecen, 2017

1. Introduction

The aim of weather forecasting is to give a reliable prediction of the future state of the atmosphere on the basis of present observations, prior forecasts and mathematical models describing the dynamics of the atmosphere. These models consists of sets of nonlinear partial differential equations which can only be solved numerically. The problem with these numerical weather prediction models (NWP) is that the solutions highly depend on the initial conditions.

Ensemble prediction systems (EPSs) were developped in order to represent the uncertainty of forecasts based on observational data and numerical weather prediction models. One can run these models with different initial conditions or change model physics and produce an ensemble of forecasts with each version (Leith, 1974). The ensemble mean or median on average gives better forecasts of a meteorological quantity than a forecast of a NWP model. Recently all major weather prediction centres have their own operational ensemble prediction systems. However it is often the case that the ensemble is under-dispersive and in this way, uncalibrated, so that calibration is needed to account for this deficiency. By statistical post-processing of the raw ensemble one can correct the possible bias and underdispersion of the original forecasts.

This dissertation describes different calibration method and their applications to Hungarian data sets. It consists of three chapters, where the first gives an overview of the existing methods and the datasets used for model verification. In Chapter 1. the Bayesian Model Averaging (BMA; Raftery *et al.*, 2005) and the Ensemble model output statistics (EMOS; Gneiting *et al.*, 2005) methods are introduced, which are probably the most popular approaches in statistical calibration of ensemble forecasts (Gneiting, 2014).

2. Ensemble prediction systems

From the various modern post-processing techniques (Gneiting, 2014; Williams *et al.*, 2014), probably the most widely used methods are the Bayesian model averaging (BMA; Raftery *et al.*, 2005) and the ensemble model output statistics (EMOS), which provide estimates of the density of the predictable weather quantity.

In both post-processing techniques, the unknown parameters are estimated using forecasts and validating observations from a rolling training period. Further, we consider regional (or global) EMOS approach, which is based on ensemble forecasts and validating observations from all available stations during the rolling training period and consequently results in a single universal set of parameters across the entire ensemble domain.

Let y be a future weather quantity of interest, and $f_1, \dots, f_K$ be the ensemble forecast for y . Denote by $g_k(y|f_k)$ the conditional PDF of y corresponding to the k th ensemble member f_k . The BMA method generates calibrated and sharp predictive probability density functions, which are weighted averages of individual PDFs

corresponding to the ensemble members. In this way the general BMA predictive PDF is defined as

$$p(y|f_1, \dots, f_K) = \sum_{k=1}^K \omega_k g_k(y|f_k), \quad (2.1)$$

where ω_k is the posterior probability, that f_k gives the best forecast in the training period. The weights ω_k form a probability distribution, so they are nonnegative and $\sum_{k=1}^K \omega_k = 1$.

The method described so far, is for a situation where ensemble members came from clearly distinguishable sources, that is each ensemble member can be identified and tracked down, this is the case for the 8-member University of Washington mesoscale ensemble. Currently most of the EPSs produce ensembles containing groups of statistically indistinguishable members which are obtained with the help of random perturbations of the initial conditions, e.g., the 11-member ALADIN-HUNEPS system of the Hungarian Meteorological Service (HMS).

These ensemble members should be treated as exchangeable. Suppose we have M ensemble members divided into K exchangeable groups, and we denote by $f_{k,\ell}$ the ℓ th member of the k th group. In the case of groups of exchangeable ensemble members the BMA predictive PDF is

$$p(y|f_{k,\ell}, k = 1, \dots, K, \ell = 1, \dots, M_k) = \sum_{k=1}^K \sum_{\ell=1}^{M_k} \omega_k g_k(y|f_{k,\ell}), \quad (2.2)$$

where the ensemble members within a given group get the same weight and parameter value.

Different weather quantities require different predictive distributions. To model temperature or sea level pressure a normal mixture seems to be appropriate (Raftery *et al.*, 2005), wind speed requires nonnegative and skewed component PDFs such as gamma (Sloughter *et al.*, 2010) or truncated normal (Baran, 2014) distributions, whereas for surface wind direction, a von Mises distribution (Bao *et al.*, 2010) is suggested. Finally, for modelling precipitation Sloughter *et al.* (2007) propose a discrete-continuous gamma distribution.

In contrast with the BMA method, the EMOS predictive PDF is a single parametric density where the parameters are functions of the ensemble members. The general EMOS predictive PDF is

$$y|f_1, \dots, f_K \sim g(y|f_1, \dots, f_K),$$

where y a future weather quantity, and $f_1, \dots, f_K$ the ensemble forecast for a given day and location.

Particularly, in the case of temperature and pressure Gneiting *et al.* (2005) use the regression

$$y = a_0 + a_1 f_1 + \dots + a_K f_K + \varepsilon, \quad \text{and} \quad \varepsilon \sim \mathcal{N}(0, b_0 + b_1 S^2),$$

where the parameters to be estimated are $a_0, \dots, a_K \in \mathbb{R}$ and $b_0, b_1 \in \mathbb{R}^+$, and S^2 denotes the ensemble variance

$$S^2 = \frac{1}{K-1} \sum_{k=1}^K (f_k - \bar{f})^2,$$

and $\bar{f}$ is the ensemble mean

$$\bar{f} = \frac{1}{K} \sum_{k=1}^K f_k.$$

The normal EMOS predictive PDF is

$$y|f_1, \dots, f_K \sim \mathcal{N}(\mu, \sigma^2), \quad (2.3)$$

with mean parameter $\mu = a_0 + a_1 f_1 + \dots + a_K f_K$ and variance $\sigma^2 = b_0 + b_1 S^2$.

Similar to the BMA approach, in case of exchangeable members, the ensemble members within a given group get the same location parameters. In this way the EMOS predictive PDF is

$$\mathcal{N}\left(a_0 + a_1 \sum_{\ell_1=1}^{M_1} f_{1,\ell_1} + \dots + a_K \sum_{\ell_K=1}^{M_K} f_{K,\ell_K}, b_0 + b_1 S^2\right), \quad (2.4)$$

where the ensemble members within a given group get the same mean parameters.

The mean parameters $a_0, \dots, a_K$ and variance parameters b_0, b_1 can be estimated from the training data by minimizing an appropriate verification score. Gneiting *et al.* (2005) suggests the minimization of the continuous ranked probability score (CRPS).

Similar to the BMA approach, different weather quantities require different predictive distributions. Again, for temperature and sea level pressure, the EMOS predictive PDF is normal (Gneiting *et al.*, 2005), whereas for wind speed, truncated normal (Thorarinsdottir and Gneiting, 2010), generalized extreme value (GEV, Lerch and Thorarinsdottir (2013)), and log-normal (Baran and Lerch, 2015, 2016) distributions are suggested. For modelling precipitation, Scheuerer (2014) suggests an EMOS model based on a censored GEV distribution. Finally, Scheuerer and Hamill (2015) propose a complex three-step model based on censored and shifted gamma (CSG) distribution.

For statistical post-processing of ensemble forecasts using BMA and EMOS we made use of the `ensembleBMA` and `ensembleMOS` packages of R (Fraley *et al.*, 2009, 2011). These packages contains some of the required predictive models, in other cases we used the corresponding codes written by my supervisor. The modelling routines can handle both exchangeable and non-exchangeable ensemble members and can

also treat missing values. The most important scoring rules are also implemented and the visualization of the results is also solved.

The main aim of probabilistic forecasting is to access the maximal sharpness of the predictive distribution subject to calibration. In order to check the overall performance of the calibrated forecasts based on probability distribution functions, we introduce various kind of scoring rules.

Denote by $x_{s,t}$ the validating observation for location s and time t , denote by $p_{s,t}$ and $P_{s,t}$ the predictive PDF and CDF for location s and time t , respectively, denote further by $\hat{x}_{s,t}$ the point forecast based on $P_{s,t}$ or on the ensemble (mean or median). Let n be the total number of different locations $s \in \mathcal{S}$ and dates $t \in \mathcal{T}$, where forecasts are available.

Thus to check the performance of probabilistic forecasts and the corresponding point forecasts, as a reference we use the ensemble mean and the ensemble median. We compare the mean absolute error (MAE)

$$\text{MAE} = \frac{1}{n} \sum_{s,t} |x_{s,t} - \hat{x}_{s,t}|,$$

and the root mean square error (RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{s,t} (x_{s,t} - \hat{x}_{s,t})^2}$$

of these point forecasts. We remark that both scores are negatively oriented, i.e. the smaller the better. For MAE the optional point forecast is the median, and for RMSE is the mean (Gneiting, 2011).

The continuous ranked probability score (CRPS) is the most popular scoring rule for evaluating density forecasts (Gneiting and Raftery, 2007). Given a CDF F and a real number x , the CRPS is defined as

$$\text{crps}(F, x) = \int_{-\infty}^{\infty} (F(y) - \mathbb{I}_{y \geq x})^2 dy = \mathbb{E}|X - x| - \frac{1}{2} \mathbb{E}|X - X'|, \quad (2.5)$$

where X and X' are independent random variables with CDF F and finite first moment. For the raw ensemble the empirical CDF of the ensemble replaces the predictive CDF.

The mean CRPS of a probabilistic forecast is the average of the CRPS values of the predictive CDFs and corresponding validating observations taken over all locations and time points considered:

$$\text{CRPS} = \frac{1}{n} \sum_{s,t} \text{crps}(P_{s,t}, x_{s,t}). \quad (2.6)$$

The CRPS is a proper scoring rule which is also negatively oriented. For different distributions, the CRPS can be expressed in closed forms.

To acquire the first insight about the calibration of EMOS and BMA post-processed forecasts, we consider *probability integral transform* (PIT) histograms (Raftery *et al.*, 2005). Generally, the PIT is the value of the predictive CDF evaluated at the verifying observation. Obviously, the closer the histogram to the uniform, the better the calibration. For precipitation, in case of zero observed precipitation, a random value is chosen uniformly from $[0, p_0]$, where p_0 is the probability of no precipitation (Sloughter *et al.*, 2007).

To illustrate the goodness of fit of the raw ensemble we use the *verification rank histogram*, that is, the histogram of ranks of validating observations with respect to the corresponding ensemble forecasts computed for all forecast cases. For precipitation, in case of zero precipitation, a random value is chosen uniformly from the set $\{1, 2, \dots, k + 1\}$, where k is the number of zero ensemble member forecasts.

Further, one can investigate calibration and sharpness of a predictive distribution with the help of the *coverage* and *average width* of the $(1 - \alpha)100\%$, $\alpha \in (0, 1)$ central prediction interval. By coverage, we mean the proportion of validating observations located between the lower and upper $\alpha/2$ quantiles of the predictive CDF, and level α should be chosen to match the nominal coverage of the raw ensemble (UWME: $\alpha = 0.222$, ALADIN-HUNEPS: $\alpha = 0.1667$). As the coverage of a calibrated predictive distribution should be around $(1 - \alpha)100\%$, the suggested choices of α allow direct comparisons with the raw ensembles, whereas the average width of the central prediction interval assesses the sharpness of the forecast.

The ALADIN-HUNEPS system of the HMS covers a large part of continental Europe with a horizontal resolution of 8 km, and it is obtained with dynamical downscaling (by the ALADIN limited area model) of the global ARPEGE based PEARP system of Météo France (Horányi *et al.*, 2006). The ensemble consists of 11-members, 10 initialized from perturbed initial conditions and one control member from the unperturbed analysis, implying that the ensemble contains groups of exchangeable forecasts.

The database contains 11-member ensembles of 42-hour forecasts for 2-meter temperature (given in K) and 10-meter wind speed (given in m/s) for 10 major cities in Hungary produced by the ALADIN-HUNEPS system of the HMS, together with the corresponding validating observations for the one-year period between April 1, 2012 and March 31, 2013. The forecasts are initialized at 18 UTC (i.e., 8 PM local time when DST operates and 7 PM otherwise). The data set is fairly complete, since there are only six days when no forecasts are available. These dates were excluded from the analysis.

Examining the verification rank histograms of temperature and wind speed ensemble, we saw, that both histograms are far from the desired uniform distribution, as in many cases the ensemble members either underestimate or overestimate the validating observations. The ensemble ranges contain the observed temperature and wind speed only in 60.61% and 68.52% of the cases, respectively (while their nominal values equal 10/12, i.e., 83.33%). Hence, both ensembles are under-dispersive and, in this way, they are uncalibrated. This supports the need of statistical post-processing

in order to improve the forecasted probability density functions.

The precipitation database at hand contains ensembles of 42-h forecasts for 24-h precipitation accumulation for 10 major cities in Hungary together with the corresponding validating observations for the period between 1 October 2010 and 25 March 2011. The data set is fairly complete because there are only two dates when three ensemble members are missing for all sites. These dates are excluded from the analysis.

The coverage of the raw precipitation ensemble is 84.20%, which is close to the nominal value 83.33%, so this histogram shows an improvement in calibration.

The 8-member University of Washington mesoscale ensemble (UWME) covers the Pacific Northwest region of North America and operates on a 12-km grid. The ensemble members are obtained from different runs of the fifth generation PSU-NCAR MM5 mesoscale model (Grell *et al.*, 1995) with initial and boundary conditions from various weather centers. We consider 48-h forecasts and corresponding validating observations of 24-h precipitation accumulation for 152 stations. The forecasts are initialized at 0 UTC (5 PM local time when daylight saving time (DST) is in use and 4 PM otherwise), and we investigate data for calendar year 2008 with additional forecasts and observations from the last 3 months of 2007 used for parameter estimation. After removing days and locations with missing data, 83 stations remain resulting in 20 522 forecast cases for 2008.

Examining the verification rank histogram of the raw precipitation ensemble, it can be seen, that this histogram is far from the desired uniform distribution, as in many cases, the ensemble members overestimate the validating observation. The ensemble range contains the observed precipitation accumulation in 67.82% of the cases, whereas the nominal coverage of the ensemble equals 7/9, that is, 77.78%. Hence, the UWME is uncalibrated and would require statistical post-processing to yield an improved forecast PDF.

3. Statistical post-processing of the ALADIN-HUNEPS ensemble

We applied different statistical post-processing methods on the temperature and wind speed ensemble forecasts of the ALADIN-HUNEPS system. In both cases we compared the BMA and EMOS methods. For temperature we used normal BMA and normal EMOS models, whereas in case of wind speed gamma BMA, truncated normal BMA and truncated normal EMOS models are applied.

For both data sets we consider two different groupings of the ensemble members. In the first case we applied a natural grouping of the ensemble members, and we split the 11 member ensemble into two different groups ($K = 2$), one contains the control member denoted by f_c ($M_1 = 1$), while in the other are 10 exchangeable ensemble members denoted by $f_{p,1}, \dots, f_{p,10}$ ($M_2 = 10$).

Further investigation of the ensemble members show that the behaviour of en-

semble member groups $\{f_{p,1}, f_{p,3}, f_{p,5}, f_{p,7}, f_{p,9}\}$ and $\{f_{p,2}, f_{p,4}, f_{p,6}, f_{p,8}, f_{p,10}\}$ significantly differ from each other. Therefore, in this way one can also consider a model with three exchangeable groups ($K = 3$): the control ($M_1 = 1$), odd numbered exchangeable members ($M_2 = 5$) and even numbered exchangeable members ($M_3 = 5$).

For modeling temperature Raftery *et al.* (2005) use normal component PDFs, and (2.2) takes the form

$$p(y|f_c, f_{p,1}, \dots, f_{p,10}; b_{0,c}, b_{0,p}, b_{1,c}, b_{1,p}, \sigma) = \omega g_c(y|f_c, b_{0,c}, b_{1,c}, \sigma) + \frac{1-\omega}{10} \sum_{\ell=1}^{10} g_p(y|f_{p,\ell}, b_{0,p}, b_{1,p}, \sigma), \quad (3.1)$$

where $\omega \in [0, 1]$, and $g(y|f, b_0, b_1, \sigma)$ is a normal PDF with mean $b_0 + b_1 f$ and variance σ^2 (Baran *et al.*, 2014a). In this way the two groups have different mean parameters ($b_{0,c}, b_{1,c}$ and $b_{0,p}, b_{1,p}$) and a common standard deviation parameter (σ).

This is the linear bias correction model, when the mean parameter is affine function of the ensemble. We also investigate two special cases, when in model (3.1) only additive bias correction is present, that is $b_{1,c} = b_{1,p} = 1$, and when bias correction is not applied at all, i.e., $b_{1,c} = b_{1,p} = 1$ and $b_{0,c} = b_{0,p} = 0$.

In the case of the three exchangeable groups the special form of model (2.2) is

$$p(y|f_c, f_{p,1}, \dots, f_{p,10}; b_{0,c}, b_{0,o}, b_{0,e}, b_{1,c}, b_{1,o}, b_{1,e}, \sigma) = \omega_c g_c(y|f_c, b_{0,c}, b_{1,c}, \sigma) + \omega_o \sum_{j=1}^5 g_o(y|f_{p,2j-1}, b_{0,o}, b_{1,o}, \sigma) + \omega_e \sum_{j=1}^5 g_e(y|f_{p,2j}, b_{0,e}, b_{1,e}, \sigma), \quad (3.2)$$

where for weights $\omega_c, \omega_o, \omega_e \in [0, 1]$ we have $\omega_c + 5\omega_o + 5\omega_e = 1$, while the definition of the PDF g remains the same. Similar to the two group case we also investigate the two special cases, with additive bias correction ($b_{1,c} = b_{1,o} = b_{1,e} = 1$), and without bias correction at all ($b_{1,c} = b_{1,o} = b_{1,e} = 1$ and $b_{0,c} = b_{0,o} = b_{0,e} = 0$).

The EMOS predictive PDF is a single parametric density where the parameters are functions of the ensemble members. Similar to the BMA approach, for modeling temperature normal distribution seems to be a reasonable choice. Special form of the EMOS predictive distribution given by (2.4), in the two group case is

$$\mathcal{N}(a_0 + a_1 f_c + a_2 \sum_{i=1}^{10} f_{p,i}, b_0 + b_1 S^2), \quad (3.3)$$

whereas in the three group case is

$$\mathcal{N}(a_0 + a_1 f_c + a_2 \sum_{i=1}^5 f_{p,2i-1} + a_3 \sum_{i=1}^5 f_{p,2i}, b_0 + b_1 S^2), \quad (3.4)$$

where S^2 denotes the ensemble variance.

Since wind speed can take only non-negative values, for modeling this weather quantity a skewed distribution is required, so we applied gamma BMA model on our dataset. In case of wind speed in the two and three group BMA model given by (3.1) and (3.1), resp., $g(y|f, b_0, b_1 c_0, c_1)$ denotes the PDF of gamma distribution with mean $b_0 + b_1 f$ and standard deviation $c_0 + c_1 f$ (Baran *et al.*, 2013). Both the mean parameters and the standard deviation parameters are affine functions of the ensemble members. Different groups have different mean parameters, but they have a common standard deviation parameter.

As an alternative to the gamma BMA approach, we applied a mixture of truncated normal distributions with a cutoff at zero. In this case in the two- and three-group model defined by (3.1) and (3.1), $g(y|f, b_0, b_1, \sigma)$ is a truncated normal PDF with location parameter $b_0 + b_1 f$ and scale parameter σ^2 . Here the different groups have different location parameters, but their scale parameters are the same.

To take into account the non-negativity of the predictable quantity, in the EMOS model for wind speed, the normal predictive distribution of (3.1) and (3.2) is replaced by a truncated normal distribution with cut-off at zero.

In what follows the summary of the results of BMA and EMOS post-processing of the 11-member ALADIN-HUNEPS ensemble of temperature and wind speed is given, the details together with the method of choosing the training period lengths, can be found in Chapter 2 of my dissertation.

For modelling temperature we applied a normal BMA (linear, additive and no bias correction) and normal EMOS method in the two- and three-group situation. We use a training period of 33 calendar days, in this way ensemble members, validating observations and predictive distributions are available for the period 07.05.2012–31.03.2013.

The probability integral transform (PIT) histograms clearly shows the advantage of the statistical post-processing of the raw ensemble. To compare with the verification rank histogram of the raw temperature ensemble, we can say, that the statistical post-processing significantly improves the statistical calibration of the forecasts. Furthermore the three group model is better than the two group model. Comparing the different post-processing methods, one should remark, that EMOS model provides lower CRPS, MAE, and RMSE values and, moreover, the lower coverage combined with sharper central prediction interval in case of two- and three-group models, but the coverage for the EMOS model is always below the nominal value 83.33%. At the same time the CRPS, MAE and RMSE values of the normal BMA method with linear bias correction are slightly worse, but this method gives the best coverage. According to the PIT histograms, from the applied methods the normal BMA model with linear bias correction gives the best fit.

For modelling wind speed we applied gamma BMA, truncated normal BMA and truncated normal EMOS method to the 11-member ALADIN-HUNEPS wind speed ensemble, with two different grouping. We use a training period of 43 calendar days, in this way ensemble members, validating observations and predictive distributions

are available for the period 15.05.2012–31.03.2013.

In case of BMA the three group model outperforms the two group one, while for EMOS the situation is the reverse. Both for the two- and the three-group cases the smallest CRPS values belong to the truncated normal BMA model, while EMOS post-processing produces the sharpest central prediction intervals and the best approximation of the nominal coverage. Regarding the point forecasts calculated from the truncated normal BMA and EMOS predictive PDFs, generally, they produce smaller MAE and RMSE values than those of the raw ensemble. However, there is an exception for the gamma BMA model, since these scores are higher indicating degradations. To summarize, gamma BMA model outperforms the other two methods in terms of fit of PIT values, but it has the highest CRPS and very poor verification scores for the point forecasts. MAE and RMSE values corresponding to EMOS and truncated normal BMA are lower than those of the raw ensemble and rather similar to each other. From these two methods, truncated normal BMA produces much lower CRPS, while EMOS post-processing results in sharper central prediction intervals, better coverage, and better fit of PIT values to the uniform distribution, so we conclude that the overall performance of this method is the best for the calibration of the wind speed raw ensemble forecasts.

4. Statistical post-processing of precipitation ensemble forecasts

The statistical calibration of ensemble forecasts of precipitation is far more difficult than the post-processing of the above mentioned weather quantities. First of all, precipitation has a discrete-continuous nature with a positive probability of being zero, moreover larger expected precipitation amount results in larger forecast uncertainty.

One should think only of nonnegative predictive distributions assigning positive mass to the event of zero precipitation. Mixing a point mass at zero and a separate non-negative distribution does the job, but left censoring of an appropriate continuous distribution at zero can also be a reasonable choice. The advantage of the latter approach is that the probability of zero precipitation can directly be derived from the corresponding original (uncensored) CDF, so the cases of zero and positive precipitation can be treated together.

The EMOS model of Scheuerer (2014) utilizes a censored GEV distribution with shape parameter ensuring a positive skew and finite mean, whereas our EMOS approach (Baran and Nemoda, 2016) is based on a CSG distribution appearing in the more complex model of Scheuerer and Hamill (2015).

Consider a gamma distribution $\Gamma(k, \theta)$ with shape $k > 0$ and scale $\theta > 0$ having PDF

$$g_{k,\theta}(y) := \begin{cases} \frac{x^{k-1}e^{-y/\theta}}{\theta^k \Gamma(k)}, & y > 0, \\ 0, & \text{otherwise,} \end{cases}$$

where $\Gamma(k)$ denotes value of the gamma function at k . A gamma distribution can also be parametrized by its mean $\mu > 0$ and standard deviation $\sigma > 0$ using expressions

$$k = \mu^2/\sigma^2 \quad \text{and} \quad \theta = \sigma^2/\mu.$$

Now, let $\delta > 0$ and denote by $G_{k,\theta}$ the CDF of the $\Gamma(k, \theta)$ distribution. Then the shifted gamma distribution left censored at zero (CSG) $G_{k,\theta,\delta}^0$ with shape k , scale θ and shift δ can be defined with CDF

$$G_{k,\theta,\delta}^0(y) := \begin{cases} G_{k,\theta}(y + \delta), & y \geq 0, \\ 0, & \text{otherwise.} \end{cases} \quad (4.1)$$

This distribution assigns mass $G_{k,\theta}(\delta)$ to the origin and has generalized PDF

$$g_{k,\theta,\delta}^0(y) := \mathbb{I}_{y=0}G_{k,\theta}(\delta) + \mathbb{I}_{y>0}(1 - G_{k,\theta}(\delta))g_{k,\theta}(y + \delta),$$

where $\mathbb{I}_A$ denotes the indicator function of the set A . Short calculation shows that the mean κ of $G_{k,\theta,\delta}^0$ equals

$$\kappa = \theta k(1 - G_{k,\theta}(\delta))(1 - G_{k+1,\theta}(\delta) - \delta(1 - G_{k,\theta}(\delta))^2),$$

whereas the p -quantile q_p ($0 < p < 1$) of (4.1) equals 0 if $p \leq G_{k,\theta}(\delta)$, and the solution of $G_{k,\theta}(q_p + \delta) = p$, otherwise.

In the proposed CSG EMOS model the distinguishable ensemble members (e.g. UWME) are linked to the mean μ and variance σ^2 of the underlying gamma distribution via equations

$$\mu = a_0 + a_1 f_1 + \dots + a_K f_K \quad \text{and} \quad \sigma^2 = b_0 + b_1 \bar{f}, \quad (4.2)$$

where $\bar{f}$ denotes the ensemble mean. In the case of exchangeable ensemble members (e.g. ALADIN-HUNEPS) the above model has the form

$$\mu = a_0 + a_1 \sum_{\ell_1=1}^{M_1} f_{1,\ell_1} + \dots + a_K \sum_{\ell_K=1}^{M_K} f_{K,\ell_K} \quad \text{and} \quad \sigma^2 = b_0 + b_1 \bar{f}. \quad (4.3)$$

Note, that the expression of the mean (or location) as an affine function of the ensemble is general in EMOS post-processing (e.g., Thorarinsdottir and Gneiting (2010); Scheuerer (2014); Baran and Lerch (2015)), whereas the dependence of the variance parameter on the ensemble mean is similar to the expression of the variance in the gamma BMA model of Sloughter *et al.* (2007), and it is in line with the relation of forecast uncertainty to the expected precipitation amount.

Following the ideas of Gneiting and Raftery (2005) and Scheuerer (2014), the parameters of models (4.2) (and (4.3) as well) are estimated by minimizing the mean CRPS of predictive distributions and validating observations corresponding to forecast cases of the training period.

We tested the censored, shifted gamma EMOS model on ensemble forecasts of precipitation accumulation of the ALADIN-HUNEPS ensemble and UWME, then we compared the results with the generalized extreme value EMOS model of Scheuerer (2014) and the gamma BMA model of Sloughter *et al.* (2007), and the verification scores of the raw ensemble. We remark that according to the suggestions of Scheuerer (2014) for estimating the parameters of the GEV EMOS model for a given day, the estimates for the preceding day serve as initial conditions for the box constrained BFGS optimization algorithm. Compared with the case of fixed initial conditions, this approach results in a slight increase of the forecast skills of the GEV EMOS model, whereas for the CSG EMOS method, at least in our case studies, fixed initial conditions are preferred.

The 8-members of the UWME are generated using initial and boundary conditions from different sources, implying that the ensemble members are clearly distinguishable. Hence, the mean and the variance of the underlying gamma distribution of the CSG EMOS model are linked to the ensemble members according to (4.2) with $K = 8$. Obviously, the reference GEV EMOS and gamma BMA models (see Scheuerer (2014) and Sloughter *et al.* (2007)) are also formulated under the assumption of non-exchangeable ensemble members.

A detailed study of CRPS and MAE values of the CSG EMOS and gamma BMA models corresponding to training period lengths of 20, 25, $\dots$, 100 days indicates that both scores have global minima at 70 days. Hence, in our analysis, we calibrate the UWME forecasts for calendar year 2008 using this training period length.

The verification rank histogram of the raw ensemble and the PIT histograms of the CSG EMOS, GEV EMOS, and gamma BMA models clearly illustrate the advantage of statistical post-processing. By examining the results of the verification scores, one can clearly observe the obvious advantage of post-processing with respect to the raw ensemble, which is quantified in the significant decrease of CRPS and MAE values and in a substantial improvement in coverage. Further, the CSG EMOS model results in the lowest CRPS value, whereas in terms of MAE there is no difference between the two EMOS methods, which significantly outperform the gamma BMA approach both in calibration of probabilistic and accuracy of point forecasts. The CSG EMOS model results in the sharpest central prediction interval combined with a rather fair coverage, whereas the central prediction intervals corresponding to the other two calibration methods are slightly wider than that of the raw ensemble.

Hence, one can conclude, that in case of the UWME, the EMOS approaches outperform both the raw ensemble and the gamma BMA model, and the proposed CSG EMOS model slightly outperforms the GEV EMOS method.

The way the ALADIN-HUNEPS ensemble is generated induces a natural grou-

ping of the ensemble members. The first group contains the control, whereas the second group consists of the 10 exchangeable ensemble members. This splitting results in the GEV EMOS model (4.3) with $K = 2$, $M_1 = 1$ and $M_2 = 10$; and the same grouping is considered for the benchmarking GEV EMOS and gamma BMA models.

For calibrating the ALADIN-HUNEPS ensemble, a training period of length 55 days is used. This means that ensemble members, validating observations, and predictive PDFs are available for the period from 27 November 2010 to 25 March 2011 having 119 calendar days. Compared with the verification rank histogram of the raw ensemble, the PIT histograms of the post-processed forecasts show a substantial improvement in calibration, whereas the histogram of the gamma BMA model is hump shaped indicating some overdispersion. In the case of the two EMOS methods we get similar behavior as in the case of the UWME. There is no significant difference between the MAE values of the CSG and GEV EMOS methods, and the former results in the lowest CRPS and the sharpest 83.33% central prediction interval. Further, the EMOS models significantly outperform both the raw ensemble and the gamma BMA approach, despite that the raw ensemble is rather well calibrated and has far better predictive skill than the BMA calibrated forecast.

Taking into account both the uniformity of the PIT values and the verification scores, it can be said that the proposed CSG EMOS model (Baran and Nemoda, 2016) has the best overall performance in calibration of the raw ALADIN-HUNEPS ensemble forecasts of precipitation accumulation.

Irodalomjegyzék/References

- Bao, L., Gneiting, T., Raftery, A. E., Grimit, E. P. and Guttorp, P. (2010) Bias correction and Bayesian model averaging for ensemble forecasts of surface wind direction. *Mon. Wea. Rev.* **138**, 1811–1821.
- Baran, S., Horányi, A. and Nemoda, D. (2013) Statistical post-processing of probabilistic wind speed forecasting in Hungary. *Meteor. Z.* **22**, 273–282.
- Baran, S. (2014) Probabilistic wind speed forecasting using Bayesian model averaging with truncated normal components. *Comput. Stat. Data. Anal.* **75**, 227–238.
- Baran, S., Horányi, A. and Nemoda, D. (2014) Probabilistic temperature forecasting with statistical calibration in Hungary. *Meteor. Atmos. Phys.* **124**, 129–142.
- 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. and Lerch, S. (2015) Log-normal distribution based EMOS models for probabilistic wind speed forecasting. *Q. J. R. Meteorol. Soc.* **141**, 2289–2299.
- Baran, S. and Lerch, S. (2016) Mixture EMOS model for calibrating ensemble forecasts of wind speed. *Environmetrics* **27**, 116–130.
- Fraley, C., Raftery, A. E., Gneiting, T. and Slughter, J. M. (2009) EnsembleBMA: An R package for probabilistic forecasting using ensembles and Bayesian model averaging. *Technical Report* 516R, Department of Statistics, University of Washington.
- Fraley, C., Raftery, A. E., Gneiting, T., Slughter, J. M. and Berrocal, V. J. (2011) Probabilistic weather forecasting in R. *The R Journal* **3**, 55–63.
- Gneiting, T. and Raftery, A. E. (2005) Weather forecasting with ensemble methods. *Science* **310**, 248–249.
- 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. Wea. Rev.* **133**, 1098–1118.
- Gneiting, T. and Raftery, A. E. (2007) Strictly proper scoring rules, prediction and estimation. *J. Amer. Statist. Assoc.* **102**, 359–378.

- Gneiting, T. (2011) Making and evaluating point forecasts. *J. Amer. Statist. Assoc.* **106**, 746–762.
- Gneiting, T. (2011) Calibration of medium-range weather forecasts. ECMWF Technical Memorandum No. 719. Elérhető: <http://www.ecmwf.int/sites/default/files/elibrary/2014/9607-calibration-medium-range-weather-forecasts.pdf> [Letöltve: 2016.09.17.]
- Grell, G. A., Dudhia, J. and Stauffer, D. R. (1995) A description of the fifth-generation Penn state/NCAR mesoscale model (MM5). *Technical Note NCAR/TN 398+STR*. National Center for Atmospheric Research, Boulder. Elérhető: <http://nldr.library.ucar.edu/repository/assets/technotes/TECH-NOTE-000-000-000-214.pdf> [Letöltve: 2016.09.17.]
- Horányi, A, Kertész, S., Kullmann, L. and Radnóti, G. (2006) The AR-PEGE/ALADIN mesoscale numerical modeling system and its application at the Hungarian Meteorological Service. *Időjárás* **110**, 203–227.
- Horányi, A., Mile, M. and Szűcs, M. (2011) Latest developments around the ALADIN operational short-range ensemble prediction system in Hungary. *Tellus A* **63**, 642–651.
- Leith, C. E. (1974) Theoretical skill of Monte-Carlo forecasts. *Mon. Wea. Rev.* **102**, 409–418.
- Lerch, S. and Thorarinsdottir, T. L. (2013) Comparison of non-homogeneous regression models for probabilistic wind speed forecasting. *Tellus A* **65**, 21206.
- Lorenz, E. N. (1963) Deterministic nonperiodic flow. *J. Atmos. Sci.* **20**, 130–141.
- Raftery, A. E., Gneiting, T., Balabdaoui, F. and Polakowski, M. (2005) Using Bayesian model averaging to calibrate forecast ensembles. *Mon. Wea. Rev.* **133**, 1155–1174.
- Scheuerer, M. (2014) Probabilistic quantitative precipitation forecasting using ensemble model output statistics. *Q. J. R. Meteorol. Soc.* **149**, 1086–1096.
- Scheuerer, M. and Hamill, T. M. (2015) Statistical Post-Processing of Ensemble Precipitation Forecasts by Fitting Censored, Shifted Gamma Distribution *Mon. Wea. Rev.* **143**, 4578–4596.
- Sloughter, J. M., Gneiting, T. and Raftery, A. E. (2007) Probabilistic quantitative precipitation forecasting using Bayesian model averaging. *Mon. Wea. Rev.* **135**, 3209–3220.

Sloughter, J. M., Gneiting, T. and Raftery, A. E. (2010) Probabilistic wind speed forecasting using ensembles and Bayesian model averaging. *J. Amer. Stat. Assoc.* **105**, 25–35.

Sloughter, J. M., Gneiting, T. and Raftery, A. E. (2013) Probabilistic wind vector forecasting using ensembles and Bayesian model averaging. *Mon. Wea. Rev.* **141**, 2107–2119.

Thorarinsdottir, T. L. and Gneiting, T. (2010) Probabilistic forecasts of wind speed: ensemble model output statistics by using heteroscedastic censored regression. *J. Roy. Statist. Soc. Ser. A* **173**, 371–388.

Williams, R. M., Ferro, C. A. T. and Kwasniok, F. (2014) A comparison of ensemble post-processing methods for extreme events. *Q. J. R. Meteorolog. Soc.* **140**, 1112–1120.

A szerző publikációi/Publications

Referált folyóiratban megjelent cikkeim:

1. Baran, S., Horányi, A., **Nemoda, D.**, Statistical post-processing of probabilistic wind speed forecasting in Hungary. *Meteorol. Z.* **22** (2013), no. 3, 273–282.
(Impakt faktor: 1.160, Atmospheric Science: Q2, Független idézők száma: 7)
2. Baran, S., Horányi, A., **Nemoda, D.**, Probabilistic temperature forecasting with statistical calibration in Hungary. *Meteorol. Atmos. Phys.* **124** (2014), no. 3-4, 129–142.
(Impakt faktor: 1.049, Atmospheric Science: Q3, Független idézők száma: 1)
3. Baran, S., Horányi, A., **Nemoda, D.**, Comparison of the BMA and EMOS statistical methods in calibrating temperature and wind speed forecast ensembles. *Időjárás* **118** (2014), no. 3, 217–241.
(Impakt faktor: 0.500, Atmospheric Science: Q3, Független idézők száma: 2)
4. Baran, S., **Nemoda, D.**, Censored and shifted gamma distribution based EMOS model for probabilistic quantitative precipitation forecasting. *Environmetrics* **27** (2016), no. 5, 280–292.
(Impakt faktor: 1.160, Statistics and Probability: Q2, Független idézők száma: 1)

A szerző konferencia-előadásai/List of conference talks

1. *Probabilistic wind speed prediction in Hungary*, 17th Young Statisticians Meeting, Piran, Szlovénia, 2012. október 12-14.
2. *Valószínűségi szélsőbesség előrejelzés*, XXXI. Országos Tudományos Diákköri Konferencia, Budapest, Magyarország, 2013. március 25-27.
3. *Probabilistic temperature forecasting with statistical calibration in Hungary*, The 9th International Conference on Applied Informatics, Eger, Magyarország, 2014. január 29. - február 1.
4. *Comparison of BMA and EMOS statistical calibration methods for temperature and wind speed ensemble weather prediction*, 11th German Probability and Statistics Days, Ulm, Németország, 2014. március 4-7.
5. *Probabilistic temperature forecasting in Hungary*, Summer school on Weather Extremes, Annweiler, Németország, 2014. június 10-13. (poszter)
6. *Censored and shifted gamma distribution based EMOS model for probabilistic quantitative precipitation forecasting*, 12th German Probability and Statistics Days, Bochum, Németország, 2016. március 1-4.



Nyilvántartási szám: DEENK/39/2017.PL
Tárgy: PhD Publikációs Lista

Jelölt: Nemoda Dóra

Neptun kód: C29GI9

Doktori Iskola: Matematika- és Számítástudományok Doktori Iskola

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű tudományos közlemények hazai folyóiratban (1)

1. Baran, S., Horányi, A., **Nemoda, D.**: Comparison of the BMA and EMOS statistical methods in calibrating temperature and wind speed forecast ensembles.
Időjárás. 118 (3), 217-241, 2014. ISSN: 0324-6329.
IF: 0.5

Idegen nyelvű tudományos közlemények külföldi folyóiratban (3)

2. Baran, S., **Nemoda, D.**: Censored and shifted gamma distribution based EMOS model for probabilistic quantitative precipitation forecasting.
Environmetrics. 27 (5), 280-292, 2016. ISSN: 1180-4009.
DOI: <http://dx.doi.org/10.1002/env.2391>
IF: 1.16 (2015)
3. Baran, S., Horányi, A., **Nemoda, D.**: Probabilistic temperature forecasting with statistical calibration in Hungary.
Meteorol. Atmos. Phys. 124 (3-4), 129-142, 2014. ISSN: 0177-7971.
DOI: <http://dx.doi.org/10.1007/s00703-014-0314-8>
IF: 1.049





4. Baran, S., Horányi, A., **Nemoda, D.**: Statistical post-processing of probabilistic wind speed forecasting in Hungary.
Meteorol. Z. 22 (3), 273-282, 2013. ISSN: 0941-2948.
DOI: <http://dx.doi.org/10.1127/0941-2948/2013/0428>
IF: 1.16

A közlő folyóiratok összesített impakt faktora: 3,869

A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre): 3,869

A DEENK a Jelölt által az iDEa Tudóstérbe feltöltött adatok bibliográfiai és tudománymetria ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2017.03.02.





Registry number: DEENK/39/2017.PL
Subject: PhD Publikációs Lista

Candidate: Dóra Nemoda

Neptun ID: C29GI9

Doctoral School: Doctoral School of Mathematical and Computational Sciences

MTMT ID: 10039092

List of publications related to the dissertation

Foreign language scientific articles in Hungarian journals (1)

1. Baran, S., Horányi, A., **Nemoda, D.**: Comparison of the BMA and EMOS statistical methods in calibrating temperature and wind speed forecast ensembles.
Idojaras. 118 (3), 217-241, 2014. ISSN: 0324-6329.
IF: 0.5

Foreign language scientific articles in international journals (3)

2. Baran, S., **Nemoda, D.**: Censored and shifted gamma distribution based EMOS model for probabilistic quantitative precipitation forecasting.
Environmetrics. 27 (5), 280-292, 2016. ISSN: 1180-4009.
DOI: <http://dx.doi.org/10.1002/env.2391>
IF: 1.16 (2015)
3. Baran, S., Horányi, A., **Nemoda, D.**: Probabilistic temperature forecasting with statistical calibration in Hungary.
Meteorol. Atmos. Phys. 124 (3-4), 129-142, 2014. ISSN: 0177-7971.
DOI: <http://dx.doi.org/10.1007/s00703-014-0314-8>
IF: 1.049





4. Baran, S., Horányi, A., **Nemoda, D.**: Statistical post-processing of probabilistic wind speed forecasting in Hungary.
Meteorol. Z. 22 (3), 273-282, 2013. ISSN: 0941-2948.
DOI: <http://dx.doi.org/10.1127/0941-2948/2013/0428>
IF: 1.16

Total IF of journals (all publications): 3,869

Total IF of journals (publications related to the dissertation): 3,869

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on the basis of Web of Science, Scopus and Journal Citation Report (Impact Factor) databases.

02 March, 2017

