

Katedra Vodního Hospodářství a Environmentálního Modelování
Fakulta Životního Prostředí
Česká Zemědělská Univerzita v Praze

DISERTAČNÍ PRÁCE

Verifikace ensemblové předpovědi srážek
pro hydrologické modelování



Fakulta životního
prostředí

2021

Vedoucí práce: prof. Ing.
Martin Hanel, Ph.D.

Ing. Martin Vokoun

Studijní obor: Environmentální
modelování, prezenční forma

Bibliografické údaje

Autor: Ing. Martin Vokoun
Název práce: Verifikace ensemblové předpovědi srážek pro hydrologické modelování
Typ práce: disertační práce
Pracoviště: Katedra Vodního Hospodářství a Environmentálního Modelování, Fakulta Životního Prostředí, Česká a Zemědělská Univerzita v Praze
Rok obhajoby: 2021
Studijní obor: Environmentální modelování, prezenční forma
Vedoucí práce: prof. Ing. Martin Hanel, Ph.D.
Počet stran: 142
Přílohy: Odborný článek
Jazyk práce: český

Bibliographic info

Author: Ing. Martin Vokoun
Title: Verification of ensemble precipitation forecast for hydrological modelling
Thesis type: bachelor thesis
Department: Department of Water Resources and Environmental Modeling, Faculty of Life Sciences, Czech University of Life Sciences Prague
Year of defense: 2021
Study field: Environmental modeling, full-time form
Supervisor: prof. Ing. Martin Hanel, Ph.D.
Page count: 142
Supplements: Research paper
Thesis language: Czech

Abstrakt

Vydávání povodňových výstrah a hydrologické modelování obecně, se neobejde bez kvalitní předpovědi srážek. Tato práce má dva hlavní cíle, které se zaměřují právě na zvýšení přesnosti hydrologických předpovědí. Prvním cílem je porovnat úspěšnost předpovědí deterministického modelu ALADIN-CZ (Aire Limitée, Adaptation Dynamique, Développement International–Czech Republic) a ensemblového modelu ALADIN-LAEF (Limited Area Ensemble Forecasting), který v současnosti není shledán jako přínosný pro hydrologickou předpověď a není operativně využíván. Srážková data byla pro účel verifikace upravena do podoby, v jaké vstupují do hydrologického modelu. Pro hodnocení byly vybrány významné srážkové události z letních částí roku v letech 2011-2015. Výsledky ukazují, že ensemblový model ALADIN-LAEF je stejně a v určitých případech i více úspěšný, než ALADIN-CZ. Druhým cílem bylo nalezení postprocesingové metody nebo jejich kombinaci, která by pomohla nakalibrovat ensemblové predikce a vedla k přesnějším předpovědím srážek a také přímo průtoků. Testovány byly metody tvorby multimodelu, kalibrace pomocí metody BMA (Bayesian Model Averaging) a využití neuronových sítí. Výsledky prokázaly, že aplikace těchto metod generuje předpovědi o úspěšnosti srovnatelné s regionálním modelem o vysokém rozlišení ALADIN-CZ. Nejpřesnějších předpovědí dosáhla vytvořená kombinace modelu ALADIN-CZ v kombinaci s kvantilovou předpovědí vypočtenou z metodou BMA z modelů ALADIN-LAEF a COSMO-LEPS. Tato kombinace byla úspěšná i v případě testování neuronové sítě pro přímý výpočet průtoků na základě predikce srážek.

Klíčová slova: *hydrologické modelování, předpověď srážek, verifikace, kalibrace, postprocesing*

Abstract

Precipitation forecasting has great significance for hydrological modelling, particularly for issuing flood alerts. The objective of this work is to assess the high-resolution deterministic model ALADIN-CZ (Aire Limitée, Adaptation Dynamique, Development International–Czech Republic) and the ensemble model

ALADIN-LAEF (Limited Area Ensemble Forecasting). Verified precipitation data were modified to the form in which they enter the hydrological model used for flood forecasting in the Czech Republic. Unlike ALADIN-CZ, ALADIN-LAEF is currently not considered to be of any value for hydrological predictions in the Czech Republic. In the present paper, we assess the added value of the ensemble model. The most significant rainfall events from the summer seasons during 2011–2015 were selected for the purpose of this study. The results show that ALADIN-LAEF does not have a lower success rate than ALADIN-CZ in predicting significant rainfall events. In fact, for the most verification scores and metrics, ALADIN-LAEF was assessed as more skilful. Second aim was finding of postprocessing method, leading to the more accurate precipitation forecast and also directly compute the river discharges. The second aim of this work was to find a postprocessing method or combination of postprocessing methods that would help calibrate ensemble predictions and lead to more accurate predictions of precipitations and river discharges. Methods of multimodel creation, calibration method using the BMA (Bayesian Model Averaging) and the use of neural networks were tested. The results shows, that the application of used methods generates predictions of success comparable to the regional model of high resolution ALADIN-CZ. The most accurate predictions were achieved by the created combination of the ALADIN-CZ model in combination with the quantile prediction calculated by the BMA method from the ALADIN-LAEF and COSMO-LEPS models. This combination was also successful in the case of testing a neural network for direct discharge calculation based on precipitation prediction.

Keywords: *hydrological modelling, precipitation forecast, verification, calibration, postprocessing*

Tímto bych chtěl poděkovat mému vedoucímu prof. Ing. Martinu Hanelovi, Ph.D. za rady, pomoc a vstřícný přístup při řešení práce a v průběhu celého doktorského studia. Dále pak panu Mgr. Tomáši Vlasákovi, PhD. za konzultace a odborné rady ohledně hydrologického modelování. Děkuji Ústavu fyziky atmosféry AV ČR v.v.i., zejména RNDr. Petru Zacharovovi PhD., a Českému hydrometeorologickému ústavu za poskytnutí dat. V neposlední řadě také Fakultě životního prostředí, která podpořila tuto práci interními granty č. 20164225 a 20154234.

Prohlašuji, že jsem celou práci včetně příloh vypracoval samostatně a za použití pouze zdrojů citovaných v textu práce a uvedených v seznamu literatury.

podpis autora

Obsah

I	Úvod do problematiky využití předpovědi srážek v hydrologickém modelování	20
1	Tvorba krátkodobé hydrologické předpovědi	20
1.1	Vstupní data	20
1.1.1	Hydrologická data	20
1.1.2	Meteorologická data	21
1.1.3	Fyzickogeografická data	22
1.2	Kalibrace modelů	22
1.3	Nejistoty v hydrologickém modelování	23
1.3.1	Nejistoty předpovědi a měření srážek	23
1.4	Hydrologické předpovědi v ČHMÚ	25
1.4.1	Manuální hydrometrické předpovědi	25
1.4.2	Zpracování modelové deterministické předpovědi	26
2	Tvorba krátkodobé numerické předpovědi počasí	29
2.1	Princip numerické předpovědi počasí	29
2.1.1	Ensemblová předpověď	33
2.2	ALADIN-LACE a ALADIN-CZ	33
2.3	ALADIN-LAEF	34
2.3.1	Perturbace a počáteční podmínky modelu ALADIN-LAEF	35
2.3.2	Blending metoda	36
2.3.3	ALADIN Breeding	38
II	Porovnání předpovědi srážek pro hydrologické modelování modelu ALADIN-CZ a ALADIN-LAEF	40
3	Obecné principy verifikace numerické předpovědi	40
3.1	Data pro verifikaci	40
3.1.1	Kvalita dat a předpovědi	41
3.1.2	Kvalita vs. hodnota předpovědi	42
3.1.3	Prostorové předpovědi	42
3.2	Verifikace ensemblové předpovědi	43
3.2.1	Souhrnné statistiky pro ensemblovou předpověď	43
3.3	Verifikace deterministické předpovědi	45

4	Verifikace modelu ALADIN-CZ a ALADIN-LAEF	49
4.1	Data a oblast zájmu	49
4.1.1	Předpovědi srážek	50
4.1.2	Měřené srážky	50
4.1.3	Zájmová oblast	51
4.1.4	Synoptické povětrnostní situace	51
4.1.5	Definice srážkových událostí	51
4.2	Metodika verifikace	52
5	Výsledky verifikace	56
5.1	Kontinuální veličiny	56
5.2	Binární události	57
5.3	Rank histogram	60
5.4	Hydrologické oblasti	61
5.5	Povětrnostní situace	62
5.6	Povodňová událost 3. června 2013	63
5.7	Souhrn II. části práce	65

III Kalibrace a postprocessing ensemblové předpovědi srážek pro hydrologické modelování **67**

6	Využití metod kalibrace a postprocesingu v předpovědi srážek	67
6.1	Bayesian Model Averaging (BMA)	68
6.2	Multimodel	69
6.3	Neuronové sítě	69
7	Kalibrace a postprocessing předpovědi srážek	71
7.1	Data a oblast zájmu	71
7.1.1	Předpovědi srážek	71
7.1.2	Měřené srážky	72
7.1.3	Zájmová oblast	72
7.1.4	Porovnání modelu ALADIN-LAEF a COSMO-LEPS	74
7.2	Výpočet kvantilové předpovědi srážek využitím BMA metody	79
7.3	Kalibrace předpovědi srážek využitím neuronové sítě	80
7.4	Přímý výpočet průtoků využitím neuronové sítě	81
7.5	Vybrané kombinace a varianty postprocesovaných předpovědí srážek	82

8	Výsledný dopad kalibrace a postprocesingu na přesnost srážkových předpovědí	84
8.1	Verifikace postprocesovaných předpovědí srážek a modelu ALADIN-CZ	84
8.2	Verifikace na příkladu vybraných událostí	90
9	Využití neuronových sítí k výpočtu hydrologických předpovědí	97
9.1	Verifikace průtoků vypočtených neuronovou sítí na základě postprocesingu předpovědi srážek	98
9.2	Verifikace průtoků vypočtených neuronovou sítí pro vybrané události	100
9.3	Souhrn III. části práce	105
IV	Diskuze a souhrn výsledků	107
10	Diskuze	107
11	Závěr	115
11.1	Verifikace	115
11.2	Kalibrace	116
11.3	Shrnutí výsledků	118
	Literatura	119
A	Typizace povětrnostních situací	127
B	Odborný článek	128

Seznam obrázků

1	Nepředvídatelná událost v povodí z kategorie operativních nejistot [12]	24
2	Mapa hydrologických profilů hlásné a předpovědní sítě ČHMÚ, čtverečkem jsou označeny profily, pro které je počítána modelová hydrologická předpověď, tmavě modrou a černou barvou jsou zvýrazněny profily, pro které je počítána i manuální hydrologická předpověď [23]	25
3	Hydrologická předpověď v grafické podobě pro profil Ústí nad Labem ze dne 3. 6. 2013 [26]	27
4	Princip schematizace povodí v modelu HYDROG-S [24]	28
5	Schéma hydrologické předpovědi pomocí předpovědních systémů AQUALOG a HYDROG-S [24]	29
6	Richardsonův horizontální gridový systém [29]	30
7	Vliv vlnové délky na přesnost reprezentace meteorologických prvků [29]	31
8	Schématické zobrazení rovnice (2)	32
9	Rozdíl v reprezentaci výsledků spektrálního modelu (vlevo) a gridového modelu (vpravo)	32
10	Přehled Evropské Sítě Koordinace Krátkodobé Numerické Předpovědi Počasí [35]	34
11	Přehled multi-fyzikálního schématu modelu ALADIN-LAEF [9]	35
12	Oblast pokrytá modelem ALADIN-LAEF a topografie modelu. Červeně vyznačená vnitřní oblast je verifikační oblast ALADIN-LAEF, která pokrývá Střední Evropu s rozlišením 0.15 x 0.15 stupně [9]	36
13	Schématické zobrazení spektrálních zón při blendingu [38]	37
14	Schematický popis spektrálního blendingu [10]	38
15	Schematické zobrazení konfigurace ALADIN-LAEF, popis procesu breedingu a blendingu. Platné pro předpověď z 12:00UTC [9]	39
16	: Příklad Rank histogramu předpovědi srážek na 30-36hodin modelem ALADIN/LAEF v roce 2010. Na levé straně před kalibrací se znaky nedostatečného rozptylu a napravo po kalibraci [8]	44
17	Zájmová oblast rozdělená do 37 hydrologických oblastí. Oblasti označené malým písmenem jsou pokryty modelem AquaLOG, oblasti s velkým písmenem modelem Hydrog.	49
18	Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro ME (a), MAE (b), RMSE (c) a COR (d) jako funkce horizontu předpovědi. Šedé linie reprezentují 16 členů ensmbly.	57

19	Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro ME (a), MAE (b), RMSE (c) a COR (d) jako funkce horizontu předpovědi. Šedé linie reprezentují 16 členů ensamble.	58
20	Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro POD (a), TS (b), FAR (c) a BS (d) jako funkce prahových hodnot. Šedé linie reprezentují 16 členů ensamble. V případě BS je soubor 16 předpovědí prezentován šedou čarou.	59
21	Skill skóre ensamble za využití referenční předpovědi v podobě modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená). RPSS (a) a BSS (b) ukazují pozitivní úspěšnost ensamble s rostoucím horizontem předpovědi. . . .	60
22	Rank histogram pro ensablou předpověď (ALADIN-LAEF). Dekompozice jednotlivých košů vychází z 6 h úhrnů <1 mm (černé slupce), <2.5 mm, <5 mm, <10 mm a >10 mm (bílé slupce).	61
23	Hodnocení přesnosti předpovědi v jednotlivých oblastech v závislosti na výšce srážkového úhrnu. Oblasti jsou hodnoceny od 1 do 5, kde 1 znamená nejvyšší úspěšnost (světle červená) a 5 znamená nejnižší úspěšnost (tmavě červená). Výsledky jsou prezentovány pro model ALADIN a MEAN. Poslední řádek představuje průměr výsledků všech srážkových prahů.	62
24	Boxploty pro RMSE (a), MAE (b), COR (c), POD (d), TS (e) a BS (f) v závislosti na typu povětrnostní situace. Výsledky pro ALADIN jsou vyznačeny fialovými boxy, pro MEAN červenými boxy.	63
25	Srovnání modelu ALADIN-CZ (fialová), MEAN (červená), MEDIAN (modrá), CF (zelená) a měřených hodnot OBS (oranžová). Šedé linie představují jednotlivé členy ensamble. Linie pro měřené průtoky jsou rozšířeny do doby kulminace. (a) oblast "k", (b) Lásenice, (c) oblast "i", (d) Pilař.	64
26	Příklad BMA prediktivní distribuce složené z diskrétní komponenty pro nulové srážky a gamma rozdělením pro nenulové hodnoty srážek [76]	69
27	Architektura neuronové sítě se dvěma skrytými vrstvami. V této práci představují vstupní vrstvu hodnoty srážek předpovídané jednotlivými členy ensamble, multimodelu nebo kvantilová předpověď.	70
28	Integrační doména modelu (šedá plocha) COSMO-LEPS a klastrovací oblast (černá linie). Černé body představují SYNOP stanice určené k verifikaci modelu [11].	72

29	Povodí vybraná pro kalibraci ensemblové předpovědi srážek. 1060: profil Lenora - Teplá Vltava, 1125: profil Ličov - Černá, 1530: Varvažov - Skalice	74
30	Porovnání ensemblových modelů ALADIN-LAEF (zelená barva) a COSMO-LEPS (oranžová barva) v rámci jednotlivých skóre (RMSE - Root Mean Square Error A, Mean Error B a Mean Absolute Error D) v závislosti na čase. Boxplot RMSE (C) popisuje úspěšnost v jednotlivých povodích 1060, 1125 a 1530.	76
31	Porovnání ensemblových modelů ALADIN-LAEF (zelená barva) a COSMO-LEPS (oranžová barva) ve formě binární předpovědi v rámci jednotlivých skóre v závislosti na čase. A-Bias, B-Probability Of Detection, C-Brier Score, D-Ranked Probability Score)	78
32	Společný rank histogram pro ALADIN-LAEF a COSMO-LEPS.	79
33	Ukázka BMA prediktivní distribuce pro srážky v termínu 2017103000 pro povodí 1060. Silná černá křivka je BMA funkce hustoty pravděpodobnosti(PDF), zatímco barevné křivky představují vážené funkce hustoty pravděpodobnosti jednotlivých členů. Tenká vertikální linie je medián BMA PDF, přerušované vertikální linie vymezují 10. a 90. percentil. Oranžová vertikální linie je měřená hodnota. Vertikální silná křivka v bodě 0 znázorňuje pravděpodobnost nulových srážek (42%).	80
34	Graf zobrazuje hodnoty jednotlivých skóre RMSE, MAE a ME pro kombinace modelů ACZ (ALADIN-CZ), AL (ALADIN-LAEF), CL (COSMO-LEPS) a QF (kvantilovou předpověď). Skóre jsou počítány na vzorku dat za účelem výběru kombinací modelů.	83
35	Grafické znázornění výsledků verifikace kontinuálních veličin. Graf A zobrazuje výsledky RMSE pro jednotlivé kombinace modelů v jednotlivých povodích. Graf B, C a D zobrazuje skóre RMSE, MAE a ME v závislosti na horizontu předpovědi. . .	86
36	Grafické znázornění výsledků verifikace binárních veličin v závislosti na horizontu předpovědi. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.	88
37	Grafy výsledků verifikace binárních veličin v závislosti na rostoucím srážkovém prahu. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.	89
38	Sumarizace srážek pro vybrané události 27.5.2014, 22.10.2014 a 19.5.2015 pro povodí 1060, 1125 a 1530. Tmavě žlutou barvou jsou znázorněny měřené srážky.	91

39	Grafické znázornění výsledků verifikace kontinuálních veličin vybraných srážkových událostí. Graf A zobrazuje výsledky RMSE pro jednotlivé kombinace modelů v jednotlivých povodích. Graf B, C a D zobrazuje skóre RMSE, MAE a ME v závislosti na horizontu předpovědi.	92
40	Grafické znázornění výsledků verifikace binárních veličin vybraných srážkových událostí v závislosti na horizontu předpovědi. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.	93
41	Grafy výsledků verifikace binárních veličin v závislosti na rostoucím srážkovém prahu. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.	95
42	Modelová předpověď průtoku při srážkové události 27.5.2014. Průtoky byly spočteny na základě 4 variant postprocesovaných predikcí srážek. Světle zelená linie Q_m představuje předpověď ČHMÚ a žlutá linie měřený průtok Q	96
43	Porovnání úspěšnosti výpočtů neuronové sítě trénovaných na vstupech bez informace o aktuálním průtoku (modré linie) a s informací o aktuálním průtoku (zelené a červené linie)(+ Q) .	98
44	Grafické znázornění výsledků verifikace průtoků vypočtených neuronovou sítí. Sloupcové grafy A a B zobrazují výsledky RMSE a NSE pro jednotlivé kombinace modelů v v každém povodí zvlášť. Grafy C až F zobrazují skóre RMSE, MAE, ME a NSE v závislosti na horizontu předpovědi.	99
45	Přehled průtoků v m^3/s pro vybrané srážkové události z kapitoly č. 8. (19.5.2015, 22.10.2014 a 27.5.2014) pro profily 1060 - Lenora, 1125 - Ličov a 1530 - Varvažov. Červenou barvou jsou prezentovány měřené průtoky - Q , modrou barvou průtoky modelované Českým hydrometeorologickým ústavem - Q_m .	101
46	Přehled sum objemu průtoku v m^3 pro vybrané srážkové události z kapitoly č. 8. Červenou barvou jsou prezentovány měřené průtoky - Q , modrou barvou průtoky modelované Českým hydrometeorologickým ústavem - Q_m	102
47	Grafické znázornění výsledků verifikace průtoků vybraných událostí vypočtených neuronovou sítí. Sloupcové grafy A a B zobrazují výsledky RMSE a NSE pro jednotlivé kombinace modelů v v každém povodí zvlášť. Grafy C až F zobrazují skóre RMSE, MAE, ME a NSE v závislosti na horizontu předpovědi.	104
48	Suma srážek predikovaných modelem ACZ a suma měřených srážek pro jednotlivé horizonty předpovědi modelu ACZ. Použit byl celý datový soubor z let 2012-2018.	108

49	Srovnání sum srážek modelu ACZ a měřených srážek z horizontu předpovědi 36 h. Sumy jsou rozděleny do jednotlivých let.	109
50	Hydrologické předpovědi pro vybraná povodí obsahující vliv falešných alarmů modelu ACZ uvedených v tabulce č.8. Zdroj [92]	110
51	Hodnocení předpovědí průtoků. Výsledky RMSE a NSE pro jednotlivé události.	112
52	Srovnání průtoků modelovaných hydrologickým modelem na základě postprocesovaných srážek - NS-srážky a průtoků přímo vypočtených neuronovou sítí NS-průtok. Pro srovnání byly vybrány modely ACZ+QF, ACZ+AL+CL+QF+Q, předpověď ČHMÚ Q _m a měřený průtok Q.	114

Seznam tabulek

1	Kontingenční tabulka pro binární deterministické předpovědi	45
2	Porovnání verifikačních skóre modelů ALADIN a MEAN pro všechna data dohromady bez vlivu závislosti na časovém horizontu předpovědi a mezní hranice srážkového úhrnu. Tučně vyznačené hodnoty indikují lepší výsledek.	55
3	Hydrologické charakteristiky pro regiony "k" a "i" během povodňové události 3.6. 2013	64
4	Tabulkový přehled výsledků verifikace. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.	90
5	Tabulkový přehled výsledků verifikace vybraných událostí. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.	95
6	Tabulkový přehled výsledků verifikace vypočtených průtoků. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý sestavený model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.	100
7	Tabulkový přehled výsledků verifikace vypočtených průtoků pro vybrané události. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý sestavený model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.	105
8	Ukázka výrazných kladných odchylek v předpovědi modelu ACZ na +36 h.	109

Úvod

Hydrologickému modelování v České republice je věnována větší pozornost od ničivých povodní v letech 1997 a 2002, kdy byla postupně zavedena operativní hydrologická předpověď. V hydroprognóze se využívají stále častěji soubory (ensembly) numerické předpovědi počasí, které poskytují varianty průběhu počasí vypočítané na základě různých počátečních podmínek a různých parametrů předpovědního modelu. Výsledkem jsou informace o trendu vývoje, rozptylu predikovaných veličin a pravděpodobnosti výskytu daného jevu. Na základě ensemblových předpovědí meteorologických prvků lze sestavit na stejném principu (různé srážkové vstupní informace) ensemblovou hydrologickou předpověď [1].

I přes stále se zdokonalující metody hydrologických předpovědí se nelze vyhnout nepřesnostem způsobeným kvantitativní předpovědí srážek. Právě možnost určení míry nejistoty předpovědi je jedním z důvodů rostoucí popularity ensemblové předpovědi [2]. Jak také zmiňují Cloke a Pappenberger [3] nebo Alfieri et al. [4], ensemblová předpověď je přínosný nástroj při rozhodování v hydrologické prognóze, zejména při vydávání výstrah před povodněmi. Zvyšující se oblíbenost vede ke vzniku a vývoji několika mezinárodních projektů [5, 6]. Na druhou stranu, díky výraznější jednoduchosti prezentace, je deterministická předpověď stále vhodnější způsob prezentace pro širokou veřejnost [7].

V současnosti má ČHMÚ k dispozici ensemblovou předpověď srážek v horizontu +72h, která je počítána pro 17 členů ensmbly (1 hlavní běh a 16 perturbovaných předpovědí) modelem ALADIN-LAEF (Aire Limitée Adaptation Dynamique Développement InterNational – Limited Area Ensemble Forecasting; [8]). Tyto předpovědi jsou založeny na downscalingu prognóz globálního ensmbly modelu ECMWF-EPS (European Centre for Medium-range Weather Forecasts - Ensemble Prediction Systems; [9]). Jednotlivé počáteční perturbace jsou generovány pomocí breeding-blendingových metod pro atmosférická pole a metodou záměny počátečních povrchových polí modelu ECMWF-EPS za počáteční analýzy globálního modelu ARPEGE (Action de Recherche Petite Echelle Grande Echelle; [10]). Predikce odtoku jsou počítány modely AquaLOG (povodí Labe) a Hydrog (povodí Moravy a Odry) celkem pro 111 říčních profilů. Od roku 2011 je testován systém ESP (Ensemble Streamflow Prediction), jehož produktem je ensemblová předpověď průtoků vycházející z predikce srážek modelu ALADIN-LAEF. Avšak jeho praktické uplatnění a veřejná prezentace je z důvodu neuspokojivých výsledků omezena.

Prvotní verifikace hydrologických předpovědí vytvořených na základě ensemblové předpovědi srážek modelem ALADIN-LAEF přinesla neuspokojivé výsledky a žádný významný přínos pro hydroprognózu [8]. Z tohoto důvodu

byla ensemblová předpověď zařazena jako produkt druhé kategorie. V praxi to znamená, že dokud není významný srážkový úhrn predikován deterministickým modelem ALADIN-CZ, povodňová výstraha není vydána, ani pokud členy ensemblu ALADIN-LAEF významné srážky predikují. Úkolem této práce není vzájemné srovnání těchto dvou typů předpovědí, ale spíše posoudit výhody modelu ALADIN-LAEF a jeho užitečnost pro hydrologickou prognózu během významných srážko-odtokových událostí. Srážková data nejsou verifikována v originálním rastrovém formátu, ale jsou agregována do hydrologických oblastí nepravidelného tvaru. Stejný postup je aplikovaný v praxi během pre-processingu dat pro hydrologický model. Tato prostorová úprava má prokázaný pozitivní vliv na úspěšnost hydrologického modelu [8]. Důležitou součástí ensemblové predikce je kalibrace a statistický postprocessing, který z modelu primárně odstraňuje systematické chyby. Klasickému přístupu kalibrace, ale také novému přístupu s využitím neuronových sítí, za účelem získání co nejpřesnější informace o predikovaných srážkách pro hydrologický model a zároveň také přímo samotných předpovědí průtoků, se věnuje třetí část této práce. Zde došlo k následnému rozšíření datového souboru o model COSMO-LEPS (Consortium for Small-scale MOdeling - Limited-area Ensemble Prediction Sytem) [11], který rozšířil možnosti návrhu efektivního postupu postprocessingu.

Cíle práce

Předmětem řešení práce je verifikace ensemblové předpovědi srážek modelu ALADIN-LAEF pro oblast České republiky. Tato forma předpovědi je k dispozici v Českém hydrometeorologickém ústavu pro možné využití v hydrologickém modelování. Tento typ předpovědi může sloužit jako nová vstupní data do hydrologických modelů AquaLOG a HYDROG. Cílem je určení míry závislosti a její proměnlivosti pro případy jednotlivých členů ensamble a za účelem využití v hydroprognóze v závislosti na výsledcích verifikace.

Dalším cílem práce je návrh efektivního postupu postprocesingu souboru předpovědí ALADIN-LAEF spolu s modelem ALADIN-CZ. Datový soubor bude pro tyto potřeby rozšířen o model COSMO-LEPS. Testovány budou postupy tvorby multimodelů a jejich kalibrace pomocí vhodných statistických metod. V neposlední řadě bude ověřen možný přínos využití neuronových sítí v podobě kalibračního nástroje aplikovaného na předpověď srážek pro hydrologické modelování a pro přímý výpočet průtoků. Úspěšnost výsledných postprocesovaných předpovědí bude ověřena porovnáním s modelem ALADIN-CZ a měřeními srážkami a průtoky ve vybraných povodích.

Část I

Úvod do problematiky využití předpovědi srážek v hydrologickém modelování

1 Tvorba krátkodobé hydrologické předpovědi

1.1 Vstupní data

Vstupní data jsou pro simulaci hydrologického modelu klíčovou součástí, ovlivňující ve velké míře výsledky. Daňhelka [12] rozděluje vstupní data do tří skupin: hydrologická, meteorologická a fyzicko-geografická.

1.1.1 Hydrologická data

Z hydrologických měření je pro simulaci odtoku nejvýznamnější měření aktuálního průtoku v korytě. Důležité je, aby naměřená data byla co nejrychleji a v dostatečném časovém kroku k dispozici pro výpočet. To zaručí pouze automatické měření, jaké je například prováděno ve vodoměrných profilech ČHMÚ, kde je ve většině případů pomocí limnigrafu sledována aktuální výška hladiny a průtok je odvozen z měrné křivky [13]. Data jsou automaticky odesílána v časovém intervalu 1 hodiny, v případě povodňové situace se interval zkracuje na 10 minut. V případě extrémních průtoků se může stát, že měrná křivka nepostihuje výšku hladiny v dostatečném rozsahu. V tomto případě se používá buď metoda prosté extrapolace měrné křivky, kterou lze upřesnit hydrotechnickými výpočty nebo přímou metodou měření, například použitím technologie ADCP (Acoustic Doppler Current Profiler). Reprezentativnost a účelnost naměřených dat také závisí na vhodně zvoleném místě měření. Ve větším měřítku je cílem rozmístit stanice tak, aby v závislosti na morfologii říční sítě rozdělovaly povodí na homogenní dílčí povodí a mezipovodí. Vlastní lokace stanice je upřednostňována v rovných úsecích toků s hloubkou a charakterem proudění vhodným pro měření nízkých i povodňových průtoků. Vliv na umístění mají také přítoky a stavby působící jako překážky pro proudění vody (mosty, jezy; [12]).

Mezi nepostradatelná hydrologická vstupní data patří také data o nádržích. Ty zahrnují údaje o manipulaci na vodních dílech, dělení odtoku na odtokových objektech (spodní výpusti, přepady, turbíny elektrárny) a objemové křivky nádrže, které slouží k odhadu budoucího vývoje odtoku z nádrže, respektive potenciálního množství zadržené vody. Objem zadržené vody

nezávisí čistě jen na objemu nádrže, ale i na manipulačním řádu, který je stanovený zvláště pro každou nádrž. Ten však nemusí být za každé situace dodržen a v určitých případech může manipulaci na nádrži ovlivnit subjektivní rozhodnutí dispečerů. Tento fakt vnáší do výpočtu předpokládaného odtoku nejistotu, s níž je třeba v hydrologických modelech pro povodí s nádržemi počítat [12, 14].

1.1.2 Meteorologická data

Mezi nejdůležitější vstupní data patří srážky, které právě ve většině případů bývají hlavní příčinou povodní. Schopnost předpovídat srážky numerickými modely je stále i v dnešní době zatížena určitou chybou, která roste v případě konvektivních srážek s lokálně vysokými úhrny. Předpověď velikosti úhrnu srážek, neboli QPF (Quantitative Precipitation Forecast), je tedy spojena se značnou vstupní nejistotou, která může zásadně ovlivnit úspěšnost modelové simulace. Celková nejistota předpovědi se skládá z nejistoty (1) velikosti úhrnu srážek, (2) časového rozložení srážek v intervalu předpovědi a (3) prostorového rozložení srážek na ploše povodí [15]. Jedním z řešení jak zvýšit míru přesnosti QPF je například statistický postprocessing, který spočívá v aplikaci statistických metod na výstupy numerického předpovědního modelu (NWP – Numerical Weather Predictions models). Zejména se využívá porovnání časové řady modelového výstupu a skutečných měření, ze kterých se odvozují statistické parametry [16].

Stejně jako předpověď srážek je důležitý i odhad skutečných úhrnů. Jelikož srážkoměrné stanice podávají pouze bodové hodnoty, je nezbytné pomocí interpolace a extrapolace (případně využití radarových dat) vytvořit odhad srážek pro celou plochu povodí. Radarová data obstarávají v ČR dva dopplerovské radary Vaisala WRM-200, které měří v C-pásmu v intervalu 5 minut na 12 elevačních úhlech [17, 18]. Pro odhad se používají data odrazivosti z výšky 2000 m n. m., a to především v případě konvektivních srážek, jejichž prostorové rozložení je velice variabilní a je obtížné určit jejich rozložení v prostoru pouze z pozemních dat [19]. Plošnou distribuci srážek lze odvodit z dat srážkoměrů celou řadou metod, od výpočtu prostého průměru, až k metodám zohledňujícím nadmořskou výšku, expozici svahů či například převládající směry větrů. Mezi pokročilejší metody se řadí například metoda izohyet (konstrukce spojnic bodů se stejným srážkovým úhrnem), metoda vážené inverzní vzdálenosti IDW – Inverse Distance Weighted (hodnota odhadu je ovlivněna vzdáleností od srážkoměrné stanice) nebo krigging (převod bodových hodnot do gridové sítě metodou založenou na popisu prostorové závislosti variogramem). Více o metodách plošné distribuce srážek uvádí např. Hrádek a Kuřík ([13]) nebo Daňhelka ([12]).

K dalším nepostradatelným meteorologickým vstupním datům patří evapotranspirace, která se projevuje při simulaci odtoku zejména na snižování

základního odtoku. Z tohoto důvodu má vyšší význam pro kontinuální modely. Jako zanedbatelný vliv lze evapotranspiraci považovat v případě epizodních modelů řešících odtoky intenzivních srážek. Pro potřeby modelů je používána potenciální evapotranspirace (PET), která ve zjednodušené formě udává míru evapotranspirace za předpokladu dostatečného množství vody pro výpar a transpiraci rostlin [12]. Výpočet PET vychází jednak z meteorologických činitelů (teplota vzduchu, vlhkost vzduchu, proudění vzduchu, sluneční radiace atd.), charakteristik půdy a pokryvu půdy [13].

Sněhová pokrývka je dalším meteorologickým prvkem, avšak odtok vody neovlivňuje celoročně, nýbrž pouze v zimním a jarním období. Více než výška sněhu je důležitější informace o jeho vodní hodnotě, respektive jak velké množství vody je ve sněhové pokrývce zadrženo. Opět je poměrně problematické určit co nejpřesněji skutečné zásoby vody ve sněhu, vzhledem k jeho vysoké prostorové variabilitě a to zejména v horských oblastech. Stejně tak je obtížné určit rychlost tání, která se značně liší například od lesních a polních ploch nebo stinných a slunných svahů [12, 14]. Samotnému odtoku vody při tání sněhu předchází tzv. fáze zrání sněhu, kdy se teplota sněhové pokrývky blíží k 0° a vzduchové póry se začínají plnit vodou. Fáze odtoku nastává ve chvíli, kdy voda v pórech překoná kapilární síly a začíná odtékat z porézního prostředí sněhové pokrývky pryč. Odhad odtoku je prováděn například empirickou metodou den stupeň (Day Degree Method), v závislosti na teplotě vzduchu, hustotě sněhu a koeficientu tání [14].

1.1.3 Fyzickogeografická data

Tento typ dat je využíván především ve spojení hydrologického modelu s GIS. V základě se jedná o mapové podklady nesoucí informace o fyzikálních a geografických podmínkách majících vliv na odtok srážek z povodí. V posledních letech je GIS využíván stále více a ve vývoji dochází při integraci s modely ke snižování nejistot. Výhodou jsou vlastní hydrologické funkce (např. ArcHydro nástavba pro ArcGIS software), které usnadňují práci s digitálním modelem terénu (odtokové linie, rozvodnice atd.; [20]). Z ostatních prostorových dat jsou používány například vrstvy objektů a překážek proudění, vegetační pokryv a využití území (vliv na odtok a evapotranspiraci; [12, 13]).

1.2 Kalibrace modelů

Kalibrace je proces iterační obměny hodnot parametrů a testování shody měřených dat se simulovanými (například srovnání hydrogramů). Cílem je nalézt nejvhodnější sadu parametrů, odvozených na základě kalibračních dat, která poskytuje nejlepší shodu simulace s pozorováním. Úspěšnost kalibrace je ovlivněna kvalitou a množstvím dat a správnou parametrizací povodí. Dle

způsobu provedení lze použít kalibraci automatickou a manuální. Automatická kalibrace hledá maximum objektivního hodnotícího kritéria pomocí optimalizačních procedur. Manuální kalibrace je prováděna manuální změnou parametrů na základě vlastních zkušeností hydrologa a může být preferována v případě nedostatečného množství kalibračních dat. V případě událostních modelů a kalibraci vrcholů odtokových vln je potřeba zaměřit se na rychlé složky odtoku. U bilančních modelů je důležitější nastavení parametrů pro základní odtok, evapotranspiraci apod. Obě metody je možné samozřejmě kombinovat vzhledem ke konkrétním vlastnostem modelu a účelem kalibrace [8, 12, 14].

1.3 Nejistoty v hydrologickém modelování

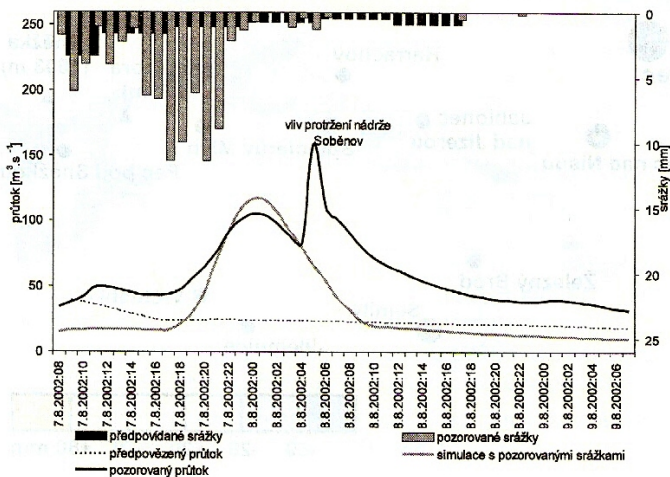
Největší nejistoty do hydrologické předpovědi vnáší právě předpověď srážek, která zahrnuje nejistotu v predikovaném množství a časoprostorovém rozložení srážek. S rostoucím rozlišením předpovědních modelů roste význam nejistoty, a to zejména v případě lokálního výskytu konvektivních srážek s velice vysokou časovou a prostorovou variabilitou. Zejména v případě předpovědi výskytu extrémního jevu, je třeba před vydáním varování posoudit míru nejistoty. V úvahu připadá například pravidelná verifikace predikovaných a měřených dat nebo využití ensemblové předpovědi [21].

Obecně lze nejistoty deterministických hydrologických, ale také meteorologických modelů, klasifikovat do 4 skupin [15].

- (i) **Nejistota modelu:** nepřesnosti v koncipování reálného systému pomocí modelových rovnic
- (ii) **Vstupní nejistoty:** nepřesnosti vstupních dat, předpovědi srážek apod
- (iii) **Parametrické nejistoty:** nepřesné posouzení parametrů modelu
- (iv) **Přírodní a operativní nejistoty:** nepředvídané přírodní příčiny, poruchy systémových komponentů (obr. č. 1), chybějící data apod.

1.3.1 Nejistoty předpovědi a měření srážek

Tato práce se nejvíce dotýká právě předpovědi srážek (QPF), která tvoří hlavní část ze všech vstupních nejistot. V případě lokalizace predikovaných srážek roste nejistota v hydrologickém modelu v závislosti na velikosti povodí. Platí, že čím je povodí menší, tím je větší riziko, že srážky spadnou do jiného povodí, než uvádí předpověď. Problematické je také určení míry vlivu orografie. Vzhledem k tomu, že jeden gridový bod má přiřazenou jednu průměrnou nadmořskou výšku, tak v případě ostrých vrcholů, úzkých údolí



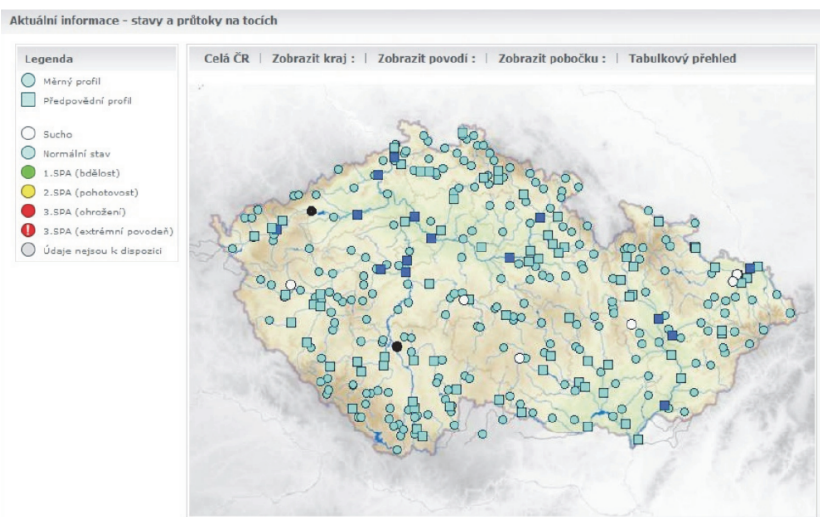
Obrázek 1: Nepředvídatelná událost v povodí z kategorie operativních nejistot [12]

apod., dochází k vyhlazení rozdílů a celkovému zploštění reliéfu. Tento problém se u nás citelně projevuje například v pohoří Krkonoš. Obdobně může být také opomíjen zvýšený úhrn srážek na návětrných svazích [12, 13].

Stejně jako předpověď srážek, je pro hydrologickou simulaci důležité i aktuální měření z pozemních srážkoměrů. To je realizováno v síti pozemních automatických srážkoměrů, ze kterých jsou data automaticky posílána ke zpracování. V tomto ohledu vzniká nejistota v plošném odhadu srážek, jelikož měřicí síť srážkoměrů je nedostatečně hustá, zejména v případě lokálních konvektivních srážek. Naměřená data je třeba interpolovat a extrapolovat a kombinovat s radarovým měřením (viz kap. č. 3). Další nejistoty vznikají při samotném měření vlastnostmi srážkoměrů, kde dochází v naprosté většině k různě velkému podhodnocení oproti skutečnému úhrnu. To je způsobeno například větrem, kdy turbulence okolo srážkoměru směřuje kapky mimo měřicí zařízení. Naopak měření intenzivního deště je zkresleno krátkými intervaly mezi překlápěním člunku, kdy je voda rozstříkována mimo zachytnou plochu a na obě poloviny člunku, takže na překlopení je potřeba více než 0,1 mm srážek. Problémy při měření přináší také zimní období, kdy může dojít k namrznutí vody na člunku nebo k vyššímu výparu za stěn srážkoměru, způsobené nadměrným výhřevem [12, 22].

1.4 Hydrologické předpovědi v ČHMÚ

V České republice začal výraznější rozvoj hydrologické předpovědi po roce 1997, kdy byla Morava postižena katastrofální povodní. Hydrologické předpovědní modely byly nasazeny do zkušebního provozu v roce 2001 a operativně využívány jsou od roku 2002. Předpovědi pro jednotlivé profily (obr. č. 2) jsou denně počítány na hydrologických pracovištích, které dané profily spravují. Jedná se o Centrální předpovědní pracoviště (CPP) ČHMÚ v Praze Komořanech a Regionální předpovědní pracoviště (RPP) šesti poboček ČHMÚ v Plzni, Českých Budějovicích, Ústí nad Labem, Hradci Králové, Ostravě a Brně. Počítány jsou jak hydrologické, tak v některých případech také manuální hydrologické předpovědi. Za normální odtokové situace jsou hydrologické předpovědi vydávány jedenkrát denně, a to 18 manuálních předpovědí a 116 modelových předpovědí na 48 hodin dopředu [23].



Obrázek 2: Mapa hydrologických profilů hlásné a předpovědní sítě ČHMÚ, čtverečkem jsou označeny profily, pro které je počítána modelová hydrologická předpověď, tmavě modrou a černou barvou jsou zvýrazněny profily, pro které je počítána i manuální hydrologická předpověď [23]

1.4.1 Manuální hydrometrické předpovědi

Aplikace manuální hydrologické předpovědi je limitována délkou koryta a tedy i velikostí povodí. Tuto metodu lze uplatnit pouze na větších nebo středních tocích s větší délkou koryta. V porovnání s kontinuální modelovou

předpovědi se liší svojí diskrétností, kdy výsledkem předpovědi je hodnota vodního stavu v konkrétním termínu. Nelze tedy vyčíst jedinečný průběh vodního stavu či průtoku. K základním metodám manuální předpovědi patří *Metoda tendencí* a *Metoda odpovídajících si průtoků* [23, 24].


Metoda tendencí popisuje pomocí extrapolace změn vodního stavu budoucí vývoj na určitou dobu dopředu. Uplatnění má na tocích se s ustálenou tendencí klesání nebo stoupání. Na tocích, kde jedna z těchto tendencí netrvá alespoň 5 dní, nelze vytvořit předpověď na více jak jeden den dopředu.

Metoda odpovídajících průtoků předpovídá průtok pro určitou stanicí na základě měření průtoku na stanici umístěné výše na toku. Je třeba určit postupovou dobu průtoků, což je doba, za kterou se dostane voda z horního profilu k profilu, kde určujeme předpověď. Je třeba brát v úvahu příbytek vody v úseku mezi profily z tzv. bočního přítoku. Tato voda je zdrojem z přítoků, výronu podpovrchových vod a povrchového odtoku.

1.4.2 Zpracování modelové deterministické předpovědi


V České republice jsou pro hydrologickou předpověď používány dva předpovědní systémy. Pro celé povodí Labe je používán předpovědní systém AQUA-LOG a pro povodí Odry a Moravy předpovědní systém HYDROG-S. V obou případech je souborem matematických rovnic zjednodušeně popsán odtok vody z povodí v závislosti na procesech infiltrace, proudění podzemní vody, tání sněhu apod. ČHMÚ vydává alespoň jednou denně modelovou předpověď pro 88 vybraných vodoměrných profilů [24].

V první fázi tvorby předpovědi je provedeno v interní databázi předpovědního systému zpracování vstupních dat, která jsou získávána z různých zdrojů z operativní datové základny ČHMÚ. AQUA-LOG disponuje interní databází AquaBase a HYDROG-S databázovou aplikací SOMDATA. V této fázi probíhá kontrola dat, jejich editace. Možný je i manuální zásah hydrologa v případě opravy či doplnění chybějících dat (například z důvodu poruchy měřících přístrojů nebo ovlivnění průtoku změnou průtočnosti koryta). Do předpovědi vstupuje mnoho nejistot, které ji mohou negativně ovlivnit. Může se jednat o nejistoty ve výpočtu způsobené deterministickým zjednodušením celého procesu odtoku nebo již zmíněné chyby měření. Největší nejistotu však do celého výpočtu vnáší předpověď srážek meteorologického modelu (ALADIN-CZ). Hodnoty predikované meteorologickými modely je třeba kontrolovat a případně před vstupem do modelu provést editaci na základě vlastních zkušeností meteorologa nebo porovnání s jinými modely. Do výpočtu může zasáhnout hydrolog-prognostik a upravit nastavení modelu, tak aby se výsledky blížily realitě. Upravit lze výsledný hydrogram nebo parametry a počáteční podmínky (nasycenost půdy, množství sněhu). Na konci procesu tvorby předpovědi jsou výstupy ve vhodné formě (textová, grafická; obr. č. 3) distribuovány uživatelům [25].



Obrázek 3: Hydrologická předpověď v grafické podobě pro profil Ústí nad Labem ze dne 3. 6. 2013 [26]

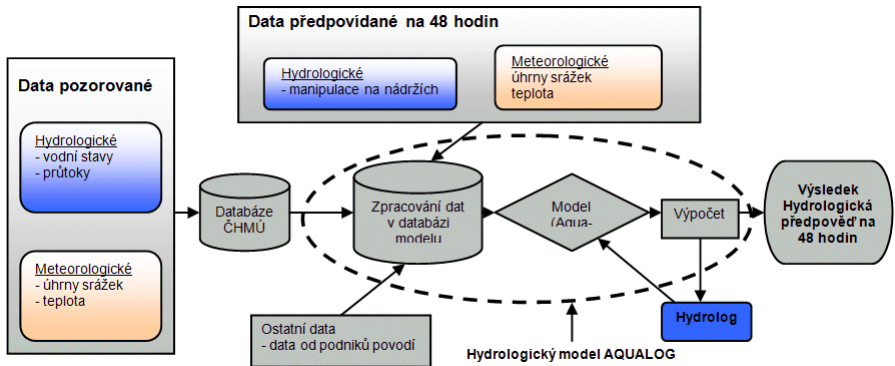
- (i) **Předpovědní systém HYDROG-S:** schematizace povodí je v tomto srážko-odtokovém semidistribuovaném modelu popsána prostřednictvím grafů tzv. zavěšených ploch, hran a vrcholů (obr. č. 4). Hrany grafu představují koryta toku, zatímco vrcholy reprezentují uzly říční sítě a plochy odpovídají jednotlivým dílčím povodím. Jednotlivá povodí mají přiřazeny vlastní parametry (sklon, drsnost povrchu, délku povrchového odtoku atd.), které jsou konstantní v celé ploše dílčího povodí. Plošný odtok je pomocí jednotkového hydrogramu transformován do koryta toku. Numericky je odtok řešen kinematickou vlnovou aproximací Saint-Venantových rovnic pro neustálené proudění a základní odtok je řešen koncepčním regresním modelem, za předpokladu, že v povodí je pouze jedna podzemní nádrž [12]).
- (ii) **Předpovědní systém AQUALOG:** zpracování vstupních dat z různých zdrojů probíhá ve speciální databázi AquaBase, napojené na operativní datovou základnu ČHMÚ ((obr. č. 5). AquaBase připravuje vstupní datový soubor pro chod modelu a zároveň umožňuje jeho kontrolu a editaci. AQUALOG se skládá z následujících dílčích modulů,



Obrázek 4: Princip schematizace povodí v modelu HYDROG-S [24]

určených pro simulaci jednotlivých hydrologických procesů v povodí [24]:

- (a) **SNOW17** - Model sněhu
- (b) **SAC-SMA** - Srážkoodtokový model
- (c) **MAN** – Model nádrží
- (d) **TDR, M-C (Muskingum-Cunge), FLDAW** – Modely pohybu vody korytem toku
- (e) **RSNELEV** - Procedura určující skupenství srážek
- (f) **UIH** – Procedura jednotkového hydrogramu (spojeno se SAC-SMA)



Obrázek 5: Schéma hydrologické předpovědi pomocí předpovědních systémů AQUALOG a HYDROG-S [24]

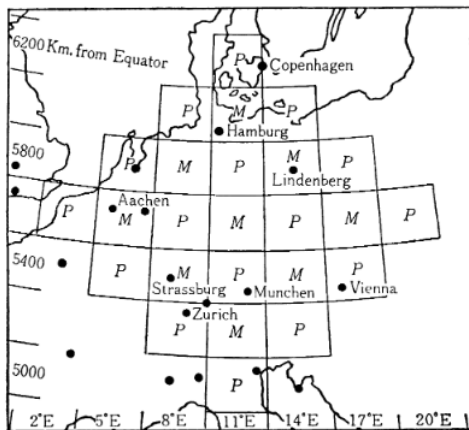
2 Tvorba krátkodobé numerické předpovědi počasí

2.1 Princip numerické předpovědi počasí

Jak uvádí Meteorologický slovník [27], numerická předpověď je předpověď polí meteorologických prvků, která je výsledkem časové integrace prognostických rovnic některého fyzikálního modelu atmosféry, prováděné na počítačích metodami numerické matematiky. Cílem je, v co nejkratším čase zpracovat data pozemního měření a na jejich základě provést počítačovou simulaci budoucího vývoje stavu atmosféry. V současné meteorologii má numerická předpověď nenahraditelný význam a neustále probíhá její zdokonalování pomocí parametrizace dějů subsynoptického měřítko a zpřesňování časového i prostorového rozlišení modelu a zdokonalování metod numerické integrace. Samotný numerický model se skládá ze soustav fyzikálních rovnic, popisujících fyzikální zákony vývoje atmosféry. Měřená (vstupní) data jsou před výpočtem upravena tzv. numerickou analýzou a asimilací dat. I přesto, že model zjednodušuje procesy probíhající v atmosféře a řadu méně důležitých dat vypouští, k výpočtům je třeba používat velice výkonné počítače (tzv. superpočítače), schopné provádět velké množství výpočtů nad velkým objemem dat. V ČHMÚ přispěl k rozvoji numerické předpovědi model ALADIN, který se v ČR používá od 90. let 20. stol. [28].

V historii nastartoval výraznější rozvoj numerické předpovědi Lewis F. Richardson v roce 1922, kdy navrhl předpovídat změnu atmosférické cirkulace numerickou integrací řídicích rovnic pro atmosférickou cirkulaci. Příkladem

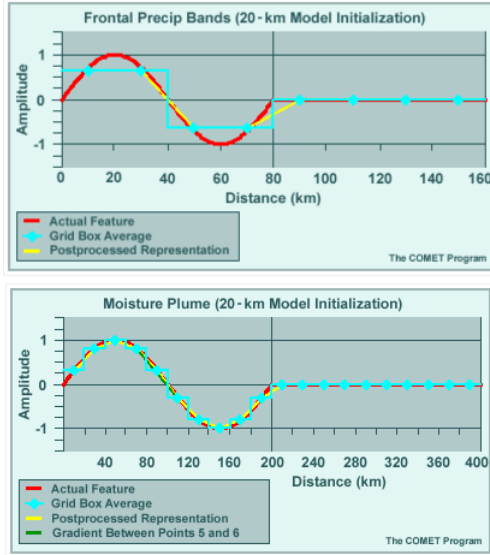
jsou Navier-Stokesovi rovnice, rovnice continuity a první zákon termodynamiky. Stejně tak Richardson zavedl horizontální gridový systém, kde každý bod z pravidelné bodové sítě reprezentuje průměrnou hodnotu příslušného grid boxu (viz obr. č. 6). Avšak v té době nedostatečná znalost počátečních podmínek a hydrodynamických charakteristik atmosférické cirkulace způsobovala extrémní obtížnost provedení správné časové integrace [29].



Obrázek 6: Richardsonův horizontální gridový systém [29]

V současnosti se k předpovědi počasí využívají dva různé druhy numerických modelů. Spektrální model založený na kombinaci spektrálních metod a metod konečných diferencí a gridový model. Spektrální modely pracují na základě souvislých vlnových funkcí v definovaném horizontálním rozlišení. Horizontální rozlišení je určeno vlnovou délkou označující celkový počet vln. Spektrální modely reprezentují přesnější výsledky při co nejvyšším počtu vln, menší vlny však obsahují detailnější informace (viz obr. č. 7). Horizontální pole jsou popsána pomocí konečné řady vln o různé vlnové délce (na rozdíl od gridového modelu, kde k popisu dochází pouze v uzlových bodech). Oproti gridovému modelu má spektrální metoda mnoho výhod. Jednou z nich je možnost analyticky přesného výpočtu horizontálních derivací, které redukuje chybu numerického schématu [28]. Také náročnost výpočtu je v případě spektrálního modelu nižší, přičemž v každém časovém kroku je prováděna jedna přímá a jedna zpětná transformace předpovědních polí pomocí algoritmu Fourierovy transformace. Za nevýhody lze považovat schopnost poskytovat dobré výsledky pouze v nižším rozlišení, se zvyšujícím se rozlišením roste náročnost výpočtu rychleji než u gridového modelu. Při rozlišení 250 vln zabere transformace do spektrálního prostoru a zpět celou polovinu času výpočtu. Spektrální metoda je tedy přesná a efektivní do určitého rozlišení [30]. Dalším

negativem je nevhodnost modelu v případech limitovaných (regionálních) domén [31], kdy nejsou pole v žádném směru periodická, na rozdíl od globálních modelů. V modelu ALADIN je periodicitu ošetřena rozšířením polí do tzv. rozšiřujících zón. Vzhledem k periodičnosti polí pouze v zonálním směru, je v meridionálním směru použita Legenderoва transformace [28].



Obrázek 7: Vliv vlnové délky na přesnost reprezentace meteorologických prvků [29]


Gridové modely mohou na rozdíl od spektrálního modelu přiřadit data do jakéhokoliv rozlišení, to však může být příčinou vnesení počátečních chyb. Jelikož zde popisujeme predikovanou veličinu pouze hodnotami v uzlových bodech (obr. č. 9), prostorové derivace jsou aproximovány pomocí rozdílů v sousedních bodech a předpověď je provedena v postupných časových krocích Δt [28]. Touto tzv. metodou konečných diferencí je aproximována advekční rovnice (1):

$$q_{x,y}^{t+\Delta t} = q_{x,y}^t - \bar{u} \frac{\Delta t}{2\Delta x} (q_{x+1,y}^t - q_{x-1,y}^t) \quad (1)$$

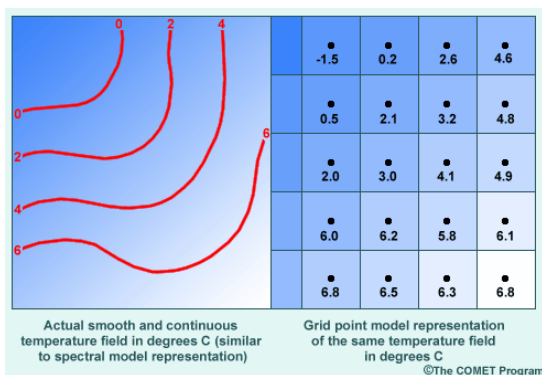
kde q je kontinuální skalární proměnná (např. teplota), u je konstanta, t je čas, x a y jsou vzdálenosti. Rovnici (1) lze schematicky vyjádřit následujícím

způsobem (2):

$$q_x^{forecast} = q_x^{now} - \bar{u} \frac{\Delta t}{2\Delta x} (q_{east} - q_{west})^{now} \quad (2)$$



Obrázek 8: Schématické zobrazení rovnice (2)



Obrázek 9: Rozdíl v reprezentaci výsledků spektrálního modelu (vlevo) a gridového modelu (vpravo)

Kvalita předpovědi postupem doby neustále roste díky zvyšování rozlišení modelů, zvyšování množství vstupních dat a zlepšování matematického popisu fyzikálních dějů. Kvantitativní předpověď srážek (předpověď srážkového úhrnu pro určité místo) vychází z integrace modelu numerické předpovědi počasí s velkou rozlišovací schopností a uplatněním na omezeném území. Tyto typy modelů využívají prognostické výstupy hrubšího modelu integrovaného

na větší oblasti a nazývají se LAM (Limited Area Model). Za účelem objevení slabín numerického modelu a zlepšení výsledků, je v praxi aplikována řada verifikačních metod. V případě hodnocení nejistoty kvantitativní předpovědi srážek je v poslední době stále více využívána skupinová neboli ensemblová předpověď. Jde o provedení výpočtů předpovědi s odlišnými vstupními podmínkami a daty [32].

2.1.1 Ensemblová předpověď

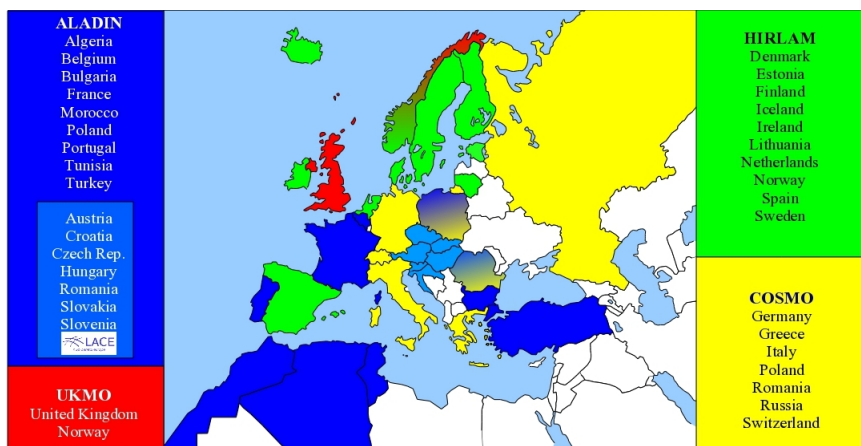
Numerická předpověď se vzhledem k náročnosti popisu přírodních jevů potýká s množstvím nejistot. I pouhá drobná chyba v počátečních podmínkách může v průběhu předpovědi vzrůst ve významnou nepřesnost. Navíc samotný popis fyzikálních jevů v atmosféře numerickými algoritmy obsahuje značné množství nejistot. Chyby jsou do výpočtů vnášeny zaokrouhlováním hodnot a také problematickým popisem lokálních jevů (např. konvekce) při příliš velkém rozlišení modelu. Během posledních let se stala ensemblová předpověď nástrojem pro popis přirozeně se vyskytujících nejistot v procesu predikce. Primárním cílem ensemblové předpovědi je kvantitativní predikce míry pravděpodobnosti určitého stavu atmosféry v budoucím čase. Odhad míry pravděpodobnosti budoucího vývoje může být pro mnoho uživatelů užitečnější a poskytnout více informací než pouze jedna předpověď, ačkoliv bude vycházet z nejlepšího dostupného odhadu počátečního stavu [33].

Existují dva hlavní způsoby tvorby ensemblové předpovědi počasí využívané ve světových meteorologických centrech. První z nich je metoda počátečních perturbací. Zde dochází k asimilaci počátečních nejistot (měření vstupních dat a analýza dat) použitím malých a náhodných počátečních perturbací. Druhý způsob generování ensemblové předpovědi je založen na využití rozdílných numerických modelů (spektrálních a gridových) a různých fyzikálních balíků. Např. v Canadian Meteorological Centre (CMC) je k výpočtu využíváno 8 různých fyzikálních balíků pro dva různé modely. Výsledkem je soubor 16 různých běhů (předpovědí; [34]).

2.2 ALADIN-LACE a ALADIN-CZ

Model ALADIN (Air Limitée, Adaptation Dynamique, Development International) byl vyvinut mezinárodním týmem vedeným Météo-France. Jedná se o prostorově omezený hydrostatický model zaměřený na krátkodobou předpověď (+72h) atmosférických procesů v mezo-gama měřítku. Horizontální rozlišení dosahuje v současnosti až 1 km, ale pro operativní synoptickou předpověď se prozatím využívá 2 km rozlišení. Řada nejen evropských zemí využívá regionální verzi modelu ALADIN (obr. č.10), s upravenými parametry pro místní podmínky. Česká verze nese název ALADIN-CZ a je částí projektu RC LACE (Regional Cooperation for Limited Area modeling in Central Europe), kam

patří sedm sousedících států. V rámci RC LACE je výzkum a vývoj modelu koordinován společně, na rozdíl od samotného provozu, který je zajišťován každým státem samostatně [35].



Obrázek 10: Přehled Evropské Síť Koordinace Krátkodobé Numerické Předpovědi Počasí [35]

Výpočet modelu ALADIN probíhá na principu zpřesnění předpovědi globálního modelu ARPEGE v cílové oblasti (ČR). Výpočet globálního modelu ARPEGE probíhá v Météo-France (Toulouse). Odtud jsou data pro oblast modelu ALADIN-CZ přenesena do ČHMÚ. Následně probíhá interpolace polí z rozlišení ARPEGE na vyšší rozlišení modelu ALADIN a příprava dat metodou blendingu digitálním filtrem (viz dále). V průběhu vlastní předpovědi modelu ALADIN na +72h jsou průběžně zapisovány výsledky v hodinovém kroku. V posledním kroku jsou výsledky zpracovány do podoby map, datových souborů apod [35].

2.3 ALADIN-LAEF

V posledních letech roste význam Limited Area Model Ensemble Prediction System (LAMEPS), jakožto vědeckého nástroje pro zlepšení krátkodobé předpovědi počasí, zejména díky identifikaci zdrojů modelových chyb a rozvoji metod pro jejich redukci. V rámci spolupráce s ALADIN/LACE byl vyvinut a v roce 2007 uveden do zkušebního provozu The Central European Limited Area Ensemble Forecasting systém ALADIN-LAEF. Podstatou výpočtu je dynamický downscaling ensamble European Centre for Medium-Range Weather Forecasts, Ensemble Prediction System ECMWF EPS. Perturbace počátečních podmínek jsou počítány blendingovými a breedingovými metodami za

použití multi-fyzikálního schématu (obr. č. 11; [9, 36]). Multi-fyzikální schéma implementuje mnohonásobné fyzikální kombinace za účelem reprezentování nejistot modelu a vede k významnému zlepšení kontroly nad předpovědním ensemblem založeným na downscalingu globálního ensmbly se stejnými fyzikálními parametry pro každý člen souboru [37].

mem #	configuration	Cloud-physics	deep convection	radiation	turbulent transport	shallow convection	mixing length & entrainment rate
M 1	ALADIN-25	Kessler	BGMC	RG	Louis81	JFG03	Setting_0
M 2	ALADIN-25	Kessler	BGCP	RG	Louis81	JFG03	Setting_1
M 3	HARMONIE	Sunquist	STRACO	Savijarvi90	CBR+S90	JFG03	---
M 4	ALARO+3MT	Alaro	3MT	JFG05	JFG06	JFG03	---
M 5	ALADIN-32	Lopez	BGMC	ECMWF	Louis81	KFB	Setting_0
M 6	ALADIN-32	Lopez	BGCP	ECMWF	Louis81	KFB	Setting_1
M 7	ALARO	Alaro	BG_MCON	JFG05	JFG06	JFG03	---
M 8	ALARO	Alaro	BG_MCON	JFG05	JFG06	JFG03	---
M 9	ALADIN-32	Lopez	BG_MCON	ECMWF	CBR+B81	KFB	Setting_0
M 10	ALADIN-32	Lopez	BG_CAPE	ECMWF	CBR+B81	KFB	Setting_1
M 11	ALADIN-32	Lopez	BG_MCON	ECMWF	CBR+S90	KFB	Setting_0
M 12	ALADIN-32	Lopez	BG_CAPE	ECMWF	CBR+S90	KFB	Setting_1
M 13	ALADIN-32	Lopez	BG_MCON	ECMWF	CBR+S90	JFG03	Setting_0
M 14	ALADIN-32	Lopez	BG_CAPE	ECMWF	CBR+S90	JFG03	Setting_1
M 15	ALARO+3MT	Alaro+XR	3MT	JFG05	JFG06	JFG03	---
M 16	ALARO+3MT	Alaro+XR1	3MT	JFG05	JFG06	JFG03	---
M 0	ALARO	Alaro	BG_MCON	JFG05	JFG06	JFG03	---
M 99	ALADIN-32	Lopez	BG_MCON	ECMWF	Louis81	KFB	Setting_0

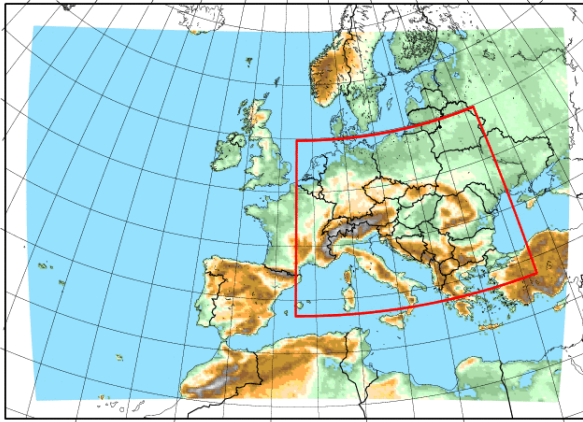
Obrázek 11: Přehled multi-fyzikálního schématu modelu ALADIN-LAEF [9]

Integrační oblast ALADIN-LAEF pokrývá celou Evropu a poměrně rozsáhlou část Atlantiku, jak je vidět na obr. č. 12. Důvodem je, že právě nad Atlantikem vzniká velká část povětrnostních systémů, majících vliv na budoucí průběh počasí v Evropě. ALADIN-LAEF je počítán dvakrát denně (00UTC a 12UTC) s horizontálním rozlišením 11 km a vertikálním 37 hladin. LAEF je tvořen 18 členy souboru, kde prvních 16 perturbovaných souborů poskytuje ECMWF EPS. Zbýlé 2 členy využívají Lateral Boundary Conditions (LBC) z ECMWF EPS a deterministickou předpověď ECMWF [9, 10, 36].

2.3.1 Perturbace a počáteční podmínky modelu ALADIN-LAEF

Techniky ensembleové předpovědi jsou aplikovány ve většině NWP center jako dynamický způsob vyhodnocení nejistoty předpovědi. Optimální nastavení EPS závisí především na kvantifikaci nejistot vzniklých v důsledku chyb v počátečních podmínkách (dále jen IC - initial condition), formulaci modelu a fyzikálních parametrech. V případě generování počátečních podmínek pro perturbace jsou brány v úvahu tři klíčové požadavky. Jednak by vygenerované počáteční podmínky měly mít vliv na vznik odchylek předpovědi již od počátečního času. To znamená zacílení na kvantifikaci nejistot již v průběhu analýzy výchozího stavu. Druhým požadavkem je, že původní LAM (Limited

ALADIN-LAEF Domain & Topography




Obrázek 12: Oblast pokrytá modelem ALADIN-LAEF a topografie modelu. Červeně vyznačená vnitřní oblast je verifikační oblast ALADIN-LAEF, která pokrývá Střední Evropu s rozlišením 0.15×0.15 stupně [9]

Area Model) IC perturbace by měly být konzistentní s počátečními LBC (Lateral Boundary Conditions) perturbacemi. Jinak řečeno, generační metoda LAM IC vygeneruje počáteční hraniční hodnoty, které by měly být určitým způsobem konzistentní s hraničními hodnotami EPS. To zejména v případě řešení perturbačních hraničních podmínek při párování LAMEPS s řídicím globálním EPS. Třetí požadavek klade důraz na shodnost mezi prostorovým měřítkem IC perturbací a měřítkem variability regionálního modelu [9].

2.3.2 Blending metoda

Obecně je blending metoda popisována jako kombinace velkoměřítkových prvků analyzovaných globálním modelem a středněměřítkových prvků předpovědi modelu s vysokým rozlišením. Předpokládá se, že tyto prvky středního měřítka získané krátkodobou předpovědí modelu s vysokým rozlišením jsou blíže realitě díky lepší rovnováze s vlivem orografie. V analýzách globálního modelu je tato krátkovlnná část spektra výsledkem čisté interpolace. Spektrální rozsahy jsou schematicky znázorněny v obr. č. 13 „Long waves“ reprezentují velkoměřítkovou část spektra získanou globálním modelem, „Short waves“ reprezentují malá měřítka pro lepší zachycení modelem s vysokým rozlišením. V přechodové zóně („transition zone“) musí být provedeno zkom-

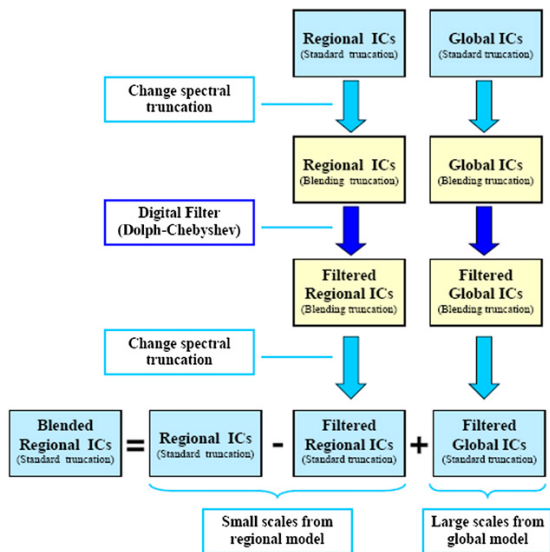
binování (blending) obou spekter [38].



Obrázek 13: Schématické zobrazení spektrálních zón při blendingu [38]

Blending metoda je doporučeným způsobem pro generování IC perturbací v regionálních ensemblových předpovědních systémech (EPS). Blending kombinuje IC perturbací ve velkém měřítku z globálních EPS s IC perturbací v malém měřítku z regionálních EPS použitím digitálního filtru a techniky spektrálních analýz. IC perturbací generovaných blending metodou mohou v rámci analýzy vhodně reprezentovat jak velkoměřítkové, tak maloměřítkové nejistoty a navíc jsou konzistentní s LBC perturbací poskytovaných globálním EPS. Blending metoda je implementována v regionálním ensemblovém systému ALADIN-LAEF, kterému jsou k dispozici velkoměřítkové perturbace z ECMWF-EPS a maloměřítkové perturbace jsou generovány breeding metodou v ALADIN-LAEF. Procedura blendingu je schematicky popsána na obr. č. 14 a skládá se z několika po sobě jdoucích kroků: i) interpolace počátečních podmínek modelových polí globálního ensmbly na spektrální rozlišení regionálního ensmbly; ii) mapování polí ze spektrálního rozlišení regionálního ensmbly na nižší spektrální rozlišení, tzv. „blending truncation“ (neboli proces aplikace blendingu na gridové pole regionálního ensmbly v plném rozlišení, avšak s nižším spektrálním rozlišením, které reprezentuje měřítko určené IC perturbací globálního modelu), které je předdefinováno blendingovým poměrem; iii) použití digitálního filtru na oboje perturbované počáteční podmínky globálního a regionálního ensmbly na původní rastr regionálního modelu v „blending truncation“ procesu; iv) opětovné mapování polí z „blending truncation“ do původního spektrálního rozlišení regionálního ensmbly po digitálním filtrování; v) výpočet rozdílu mezi těmito filtrovanými poli, který představuje velkoměřítkový přírůstek. Tento přírůstek obsahuje téměř čistou nízkofrekvenční perturbační informaci a je následně přidán k původnímu vysokofrekvenčnímu signálu perturbovaných počátečních podmínek re-

gionálního ensamble s vysokým rozlišením. Spojení (blending) obou spekter je vytvořeno ve spektrální zóně, která je implicitně definována pomocí techniky inicializace inkrementálního digitálního filtru. Podrobný matematicky vyjádřený popis blendingu lze nalézt v [38] a [10].



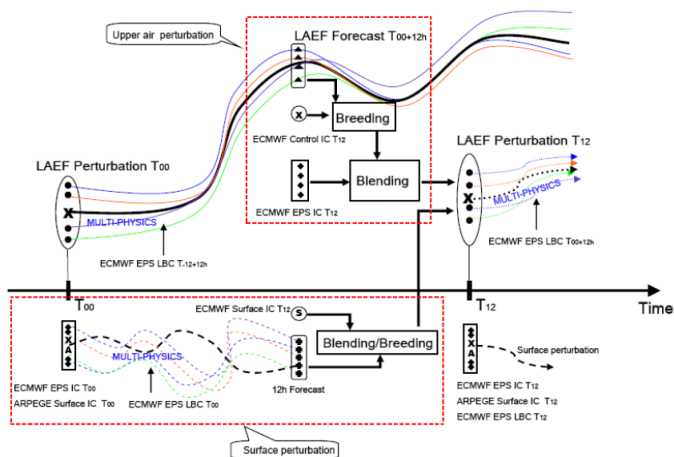
Obrázek 14: Schematický popis spektrálního blendingu [10]

2.3.3 ALADIN Breeding

Breeding rostoucích vektorů je navržen za účelem simulace způsobu směřování a breedingu („pěstování“) rostoucích chyb v cyklu konvenčních analýz prostřednictvím postupného využití krátkodobých předpovědí. Takto ošetřené vektory by měly poskytovat kvalitní odhad možnosti růstu chyby v analýze [39]. Nastavení procesu breedingu obsahuje následující kroky: i) přidání náhodné perturbace do kontrolní analýzy pro úplně první soubor (tento úkon může být proveden pouze jedenkrát); ii) integrace modelu s kontrolní analýzou a perturbovanými IC; iii) sestavení rozdílů mezi dvěma předpověďmi v daném časovém intervalu (12h); iv) zmenšení rozlišení rozdílů předpovědi v amplitudě na rozlišení perturbace; v) přidání nebo odečtení rozdílů ve změněném měřítku do nové kontrolní analýzy. Perturbované IC jsou generovány v sadách kladných a záporných dvojic okolo kontrolní analýzy. Kroky ii) až v) jsou následně opakovány a perturbace jsou tvořeny podél trajektorie předpovědi (obr. č. 15). Při breedingu v modelu ALADIN jsou komponenty větru,

teploty, vlhkosti a tlaku vzduchu na povrchu země perturbovány v každé výškové hladině a v každém gridovém bodu [9, 10].

Schematic of ALADIN-LAEF configuration



Obrázek 15: Schematické zobrazení konfigurace ALADIN-LAEF, popis procesu breedingu a blendingu. Platné pro předpověď z 12:00UTC [9]

Část II

Porovnání předpovědi srážek pro hydrologické modelování modelu ALADIN-CZ a ALADIN-LAEF

3 Obecné principy verifikace numerické předpovědi

Verifikace numerické předpovědi slouží k získávání zpětné vazby na výsledky předpovědi počasí a vyhodnocení úspěšnosti. Výsledky verifikace mohou být použity pro hodnocení a posouzení přesnosti předpovědi nebo porovnání kvality modelů. Tímto způsobem lze také identifikovat nedostatky modelu za účelem jejich nápravy, případně usměrnění budoucího vývoje. Na druhou stranu je možné určit výhody a silné stránky modelu, tzn. například situace, ve kterých je předpověď velice přesná [40].

3.1 Data pro verifikaci

Pro vyhodnocení úspěšnosti modelu je třeba mít k porovnání předpovídaná a pozorovaná (naměřená) data. Druhy předpovědi schematicky rozdělujeme například Stephenson [40], který je dělí na deterministické (nepravděpodobnostní) a pravděpodobnostní. Deterministické předpovědi předpovídají pouze jednu hodnotu prediktandu, zatímco pravděpodobnostní předpovědi předpovídají pravděpodobnost výskytu všech možných hodnot prediktandů. Obě tyto kategorie jsou dále děleny do pěti kategorií podle typu prediktandu na **binární, kategorické, celočíselné, reálné a komplexní**. Příkladem nejjednodušší formy předpovědi (binární 0-1) může být předpověď výskytu tornáda, kdy v deterministické předpovědi (DBF- Deterministic Binary Forecast) dostáváme tyto hodnoty: 0 - žádné tornádo, 1 - tornádo. Jinak tomu je v případě pravděpodobnostní předpovědi (PBF – Probabilistic Binary Forecast), kde je určena hodnota hranice pravděpodobnosti výskytu daného jevu (tornáda), např. pravděpodobnost výskytu tornáda $P=0,3$. V případě kategorie komplexních prediktandů lze uvést deterministickou předpověď (DCF – Deterministic Complex Forecast) prostorového rozložení srážek, vyjádřenou v konkrétních hodnotách a pravděpodobnostní předpověď (PCF – Probabilistic Complex Forecast), kde je vyjádřena pravděpodobnost výskytu srážek ve

vymezeném prostoru [40].

Dalším příkladem typologie numerických předpovědí srážek je rozdělení dle CAWCR (The Centre for Australian Weather and Climate Research), kde řadí druhy předpovědí do třech kategorií v závislosti na jejich způsobu získávání, časoprostorové charakteristice a specifičnosti předpovědi (v závorkách jsou příklady z dané kategorie; [41]):

(i) **Druh předpovědi**

- 1) Deterministická (kvantitativní předpověď srážek)
- 2) Pravděpodobnostní (pravděpodobnost srážek)
- 3) Kvalitativní (5denní výhled)

(ii) **Časoprostorová doména**

- 1) Časové řady (denní srážkové úhrny)
- 2) Prostorové rozložení (mapa srážek)
- 3) Časoprostorové rozložení (mapa měsíčních úhrnů)

(iii) **Specifičnost předpovědi**

- 1) Dichotomická (ano/ne) (výskyt deště)
- 2) Multikategorická (teplotní podmínky studené, normální, teplé)
- 3) Kontinuální (maximální teplota)
- 4) Objektově nebo událostně orientované (pohyb a intenzita tropické cyklony)

3.1.1 Kvalita dat a předpovědi

Výsledky verifikace a jejich hodnota se odvíjí od kvality dat. Základem je mít dostatečné množství dat k postihnutí co nejvíce možných variant situací, které chceme verifikovat. Problémem mohou být například chybějící data. Mezera v měřených řadách může nastat například technickým problémem při měření. V případě měření srážek může dojít v zimním období k zamrznutí srážkoměru či při silném větru k výraznému zkreslení naměřených hodnot [12]. Jindy může být kvalita dat ovlivněna během procedury jejich vyhodnocování. Takovéto riziko zkreslení skutečných hodnot nalezneme například u plošného odhadu srážek, kdy výsledná data dostaneme procesem interpolace a extrapolace pozemního bodového měření a výstupů z meteorologického radaru. Výsledky verifikace mohou ovlivnit změny týkající se měřících prvků. Odlišné hodnoty může zapříčinit výměna měřidla (srážkoměr, teplotní čidlo) nebo i nepatrná změna jeho polohy. Tyto a podobné vlivy ve výsledku mohou znatelně ovlivnit kvalitu verifikace [40].

3.1.2 Kvalita vs. hodnota předpovědi

Primárním smyslem verifikace je ověření kvality předpovědi porovnáním předpovídáných a měřených dat. Čím je vyšší shoda, tím je vyšší i kvalita předpovědi. Avšak může existovat druh předpovědi, jehož kvalita může být nižší, ale naopak s vysokou hodnotou. Především se jedná o typ předpovědi, kde velkou roli hraje úsudek meteorologa na základě vlastních zkušeností. Mezi takovéto předpovědi lze zařadit předpověď lokálních bouřek. S nejvyšší pravděpodobností bude vždy kvalita těchto předpovědí nízká, protože model jen velmi zřídka správně předpoví polohu výskytu lokálních srážek. Na druhou stranu pro meteorologa má tato předpověď vysokou hodnotu, jelikož může určit oblast, kde je nejvyšší pravděpodobnost výskytu vysokých úhrnů a případně vydat i varování před nebezpečnými jevy. To znamená, že kvalita předpovědi závisí na porovnání s měřenými hodnotami a hodnota předpovědi popisuje přidané ekonomické a jiné výhody realizované na základě této predikce [42]. Příkladem kvalitní předpovědi je předpověď jasné oblohy v letním suchém období. Zde lze dosáhnout absolutní shody a tím i maximální kvality. Pokud chceme do výsledků verifikace zavést větší váhu hodnoty předpovědi, není vhodné používat kvadratická bodovací pravidla (např. RMSE), které kladou důraz na chybné předpovědi. Jako vhodnější se v této situaci nabízí pozitivně orientované skóre (např. „hit rate“; [41]).

3.1.3 Prostorové předpovědi

Předpověď může být bodová, to znamená, že predikce byla vypočtena několikrát pro jediný parametr (srážky, teploty apod.) v jednom prostorovém bodě a je pouze funkcí času. Kdežto prostorová předpověď počítá stejný parametr nad vymezeným prostorem. Prediktandy mohou být spojité nebo diskrétní veličiny a předpověď může být vyjádřena deterministicky nebo formou pravděpodobnosti. Problém verifikace předpovědi v prostorových polích vzniká srovnáváním dat v pravidelné mřížce s měřenými daty v nepravidelně vzdálených místech. NWP modely procházejí cyklem asimilace (modifikace výsledků modelu za účelem dosažení konzistence s měřenými daty), analýzy a postprocessingu dat, které zajistí, že verifikační pole je k dispozici na stejném gridovém poli, se stejným časovým a prostorovým rozlišením jako pole předpovědi. Speciální pozornost je třeba věnovat srážkovým datům, pro která je nutné provádět analýzu a asimilaci dat odděleně. Důvodem je, že zejména v oblastech s významnou topografií a variabilním rozmístěním měřicích stanic se velice komplikuje analýza srážkových dat [42].

3.2 Verifikace ensemblové předpovědi

Verifikaci ensemblové předpovědi je možné obvykle provádět porovnáním předpovědi ve formě gridového výstupu s analýzami ve stejném formátu nebo porovnáním interpolovaného modelového výstupu s hodnotami měřenými v určitých bodech. V případě disertační práce je pro verifikaci aplikována první varianta, která je modifikována agregací do výsledných bodových hodnot. Tzv. „chyba předpovědi“ je stanovena prostým rozdílem predikovaných a měřených hodnot meteorologických prvků. Ensemblové verifikační metody mají dva hlavní cíle. Prvním z nich je verifikace charakteristik rozdělení předpovídané veličiny v ensamble (souhrnné statistiky) a verifikace rozdělení pravděpodobnosti v ensemblové předpovědi. Hodnotit lze také výkonost jednotlivých členů ensamble vzhledem k měřeným datům pomocí základních verifikačních metod (korelace, root mean square error atp.). U verifikace ensemblové předpovědi srážek je zapotřebí vybírat takové metody hodnocení, které kladou důraz na důležité prvky předpovědi, tedy časovou a prostorovou variabilitu srážek [43, 44].

3.2.1 Souhrnné statistiky pro ensemblovou předpověď

Většina verifikačních nástrojů určených pro ensemblovou předpověď se zaměřuje na statistickou úspěšnost předpovědi. Ve výsledku může být více podrobně odhalena například příčina nekonzistentnosti chování ensamble. Tyto informace jsou důležité pro parametrizaci předpovědního modelu [40]. Souhrnné statistiky lze rozdělit do dvou skupin na základě výsledné interpretace ensemblové předpovědi. Ta může být v podobě souboru jednotlivých deterministických předpovědí prezentujících diskrétní prvky z pravděpodobnostního rozdělení. Druhou variantou je samotná pravděpodobnostní předpověď odvozená ze členů ensamble [42].


Rozptyl a střední chyba ensamble

Obecně platí, že střední předpověď ensamble získaná průměrem všech členů souboru, vykazuje menší chybu, než předpověď sestávající z jednoho členu [45]. Z tohoto hlediska se nabízí využití průměru ensamble jako nejlepšího dostupného odhadu budoucího stavu atmosféry. Výsledný průměr ensamble nedosahuje vždy stejné úspěšnosti. Ta se odvíjí od velikosti rozptylu ensamble. V praxi to znamená, že čím je vyšší rozptyl, tím větší je střední chyba ensamble. Tento vztah mezi rozptylem a přesností průměru ensamble potvrzují pozitivní výsledky lineární korelace těchto dvou veličin [46, 47].

Rank histogram (Talangrand diagram)

Rank histogramy (také zvané jako Talangrand diagramy) jsou nástroje určené pro hodnocení ensemblové předpovědi. Jsou užitečné zejména pro hodnocení nejistoty odhadu a určení chyb v průměru a rozptylu ensemblu. Pro vygenerování rank histogramu se nejprve stanoví počet třídních intervalů, který je o 1 vyšší, než počet členů ensemblu n . Poté jsou hodnoty předpovědi jednotlivých členů ensemblu seřazeny od nejnižší po nejvyšší, čímž vytvoří $n+1$ intervalů zahrnujících dva otevřené intervaly na krajích. Bod četnosti do jednoho z $n+1$ třídních intervalů je vždy přidělen tomu intervalu, do kterého se zařadí hodnota pozorovaná. Následuje opakované dotazování na pořadí správné předpovědi vzhledem k aktuální distribuci roztržděných ensemblových předpovědí. Reprezentativních výsledků lze dosáhnout mnohačetným opakováním určení pořadí a akumulací případů lišících se v prostoru a čase [40, 48].

Spolehlivá a statisticky konzistentní ensemblová předpověď se vyznačuje plochým rank histogramem, který naznačuje rovnoměrné rozdělení pravděpodobnosti mezi jednotlivými členy ensemblu. Z toho vyplývá, že rozptyl ensemblu vhodně postihuje nejistoty předpovědi. Asymetrické rozložení naopak obvykle značí nerovnoměrnost, popř. trend v průměru ensemblové předpovědi. Histogram ve tvaru písmene „U“ nebo převráceného písmene „U“ může být důsledkem podhodnocení nebo nadhodnocení rozptylu ensemblu [48]. To nastává například v případě, kdy rozptyl nezahrnuje měřené hodnoty, které se řadí mimo vymezené extrémy ensemblu, jak je vidět na obr. č. 16 [8].



Obrázek 16: : Příklad Rank histogramu předpovědi srážek na 30-36hodin modelem ALADIN/LAEF v roce 2010. Na levé straně před kalibrací se znaky nedostatečného rozptylu a napravo po kalibraci [8]

3.3 Verifikace deterministické předpovědi

Na ensemblovou předpověď lze nahlížet jako na soubor deterministických předpovědí, kde je možné hodnotit samostatně jednotlivé členy. Do podoby deterministické předpovědi lze také převést celý soubor například výpočtem průměru nebo mediánu. V těchto případech se nabízí aplikace verifikačních skóre právě pro deterministické předpovědi [42]. Předmětem verifikace bývají často tzv. binární, neboli dichotomní události, u který se posuzuje zda pozorovaný jev (déšť, mlha, povodeň apod.) nastal (yes) či nenastal (no). Kromě výskytu samotného jevu lze binárně posoudit také předpověď intenzity jevu stanovením hranice (thresholdu), která byla nebo nebyla překročena. Při hodnocení se poté používá kontingenční tabulka (tab. č.1), obsahující četnosti jednotlivých možných vztahů mezi předpovědí a měřením. Pro účely disertační práce byly využity zejména následující charakteristiky.

Event forecasted	Event observed		
	Yes	No	Total
Yes	a (Hits)	b (False alarms)	a + b
No	c (Misses)	d (Correct rejection)	c + d
Total	a + c	b + d	a + b + c + d = n

Tabulka 1: Kontingenční tabulka pro binární deterministické předpovědi

Root Mean Squared Error (RMSE)

RMSE vyhodnocuje průměrnou kvadratickou chybovou odchylku kontinuálních veličin o celkovém počtu N . Výsledná hodnota nabývá stejných jednotek jako předpověď (F), respektive měřená data (O). Výsledky jsou negativně orientovány v rozsahu 0 až $+\infty$ [40, 49]

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2} \quad (3)$$

Korelační koeficient (r)

Korelační koeficient hodnotí lineární závislost mezi kontinuálními hodnotami předpovědí (F) a pozorováními (O). Korelace má rozsah od -1 do 1, přičemž nejlepší skóre je 1 [50].

$$r = \frac{\sum_{i=1}^N (F_i - \bar{O}) (O_i - \bar{O})}{\sqrt{\sum_{i=1}^N (F_i - \bar{O})^2} - \sqrt{\sum_{i=1}^N (O_i - \bar{O})^2}} \quad (4)$$

Frequency Bias Score (B)

Frequency Bias Score je počítáno jako poměr počtu předpovědí výskytu dané veličiny a počtu skutečných výskytů. Skóre nabývá hodnot od 0 do ∞ , kde nejlepším výsledkem je hodnota 1 (nulový bias). Skóre nižší než 1 znamená podhodnocování předpovědí, naopak skóre vyšší než 1 nadhodnocování předpovědí [40]. Následující rovnice vycházejí z kontingenční tabulky, kde proměnné a - c znamenají: a =hits (úspěšná předpověď), b =false alarms (předpovídaný jev nenastal), c =misses (jev nebyl předpovídan a nastal).

$$B = \frac{a + b}{a + c} \quad (5)$$

Equitable Threat Score (ETS)

ETS se zaměřuje na správně predikované předpovědi (a). Ve výpočtu je navíc počítáno s hodnotou a_r , prezentující referenční předpověď. Tou nejčastěji bývá klimatický průměr vztažený k posuzované lokalitě [40]. Výsledné ETS může být poněkud zkreslené vzhledem k faktu, že hodnotí pouze vybrané srážkové události. Naopak pro potřeby verifikace v této práci a vzhledem k metodice výběru dat, se jeví jako užitečné. Nejlepší výsledky ETS se dosahují hodnoty 1 [42].

$$ETS = \frac{a - a_r}{a - a_r + b + c} \quad (6)$$

Probability of detection (POD)

Hodnotu podílu pozorovaných *Yes* událostí, které byly správně předpovězeny, dostaneme výpočtem POD skóre, které je také známo pod názvem Hit rate (H). Skóre se soustředí na pozorované výskyty jevu, naopak úplně pomíjí falešné alarmy. Ideální skóre je 1.

$$POD = \frac{a}{a + c} \quad (7)$$

Probability of false detection (POFD)

POFD, jinak také známé jako False alarm rate (F), je opačnou charakteristikou k POD. Výsledkem je posouzení do jaké míry model chybně detekuje predikovaný jev, který ve skutečnosti nenastal. Ideální skóre je 0.

$$POFD = \frac{b}{b + d} \quad (8)$$

Mean error (ME)

ME posuzuje střední chybu předpovědi kontinuálních veličin. Jedná se o jednoduchou metriku, která může způsobit kompenzaci kladných a záporných odchylek a tím považovat nepřesnou předpověď za kvalitní. Nejlepší skóre je 0.

$$ME = \frac{1}{N} \sum_{i=1}^N (F_i - O_i) \quad (9)$$

Mean absolute error (MAE)

MAE je počítáno jako průměr absolutních odchylek měření od předpovědi. Na rozdíl od MAE nedochází ke kompenzaci chyb. Nelze však indikovat, zda má předpověď tendenci nadhodnocovat nebo podhodnocovat. Nejlepší skóre je 0.

$$MAE = \frac{1}{N} \sum_{i=1}^N |F_i - O_i| \quad (10)$$

Nash Sutcliffe coeficient (NSE)

NSE skóre je používáno zejména k posouzení úspěšnosti hydrologických modelů. Výpočet sestává z předpovědi průtoků F_t , měřeným průtokem O_t a průměrným průtokem \bar{O} . Ideální skóre je 1. Výsledná hodnota 0 znamená úspěšnost hodnot předpovědi srovnatelnou s průměrem měřených hodnot. V případě výsledné hodnoty menší než 0 je prediktor úspěšnější než předpověď [51].

$$NSE = 1 - \frac{\sum_{t=1}^T (F_t - O_t)^2}{\sum_{t=1}^T (O_t - \bar{O})^2} \quad (11)$$

Threat score (TS)

TS skóre popisuje do jaké míry korespondují "yes"predikce s "yes"pozorováními. Narůstající počet misses (b) a false alarms(c) snižuje hodnotu skóre, které je v ideálním případě 1.

$$TS = \frac{a}{a + b + c} \quad (12)$$

False alarm ratio (FAR)

FAR vyjadřuje, jaký podíl predikovaných "yes"událostí ve skutečnosti nenastal. Skóre ignoruje misses (c) a je ovlivněno zejména předpověďmi kategorie

false alarms (c). Nejlepší skóre je 0.

$$FAR = \frac{b}{a + b} \quad (13)$$

Brier Score (BS)

Princip výpočtu BS je podobný metrice RMSE, která hodnotí chybovost kontinuálních veličin, zatímco BS pozuje chybovost u diskretních předpovědí, resp. pravděpodobnosti výskytu daného jevu. Výsledkem je tedy velikost chyby pravděpodobnostní předpovědi v rozsahu 0-1, kde ideální skóre je 0.

$$BS = \frac{1}{N} \sum_{i=1}^N (p_i - o_i)^2 \quad (14)$$

Brier Skill Score (BSS)

BSS posuzuje přínos pravděpodobnostní předpovědi oproti referenční předpovědi, za kterou bývají nejčastěji zvolené klimatologické (průměrné) hodnoty pro posuzovaný termín. Mezní hodnotou BSS je 0. Výsledné skóre v rozmezí hodnot 0 až 1 indikuje přínos pravděpodobnostní předpovědi oproti klimatologickým hodnotám. Skóre menší než 0 naopak znamená menší úspěšnost předpovědi oproti klimatologickým hodnotám. Místo klimatologických dat lze použít ke srovnání libovolnou deterministickou předpověď.

$$BSS = 1 - \frac{BS}{BS_{ref}} \quad (15)$$

Ranked probability skill score (RPSS)

Stejně jako BSS, také RPSS porovnává přínos pravděpodobnostní předpovědi oproti klimatologickým hodnotám nebo jiné referenční předpovědi. K výpočtu využívá Ranked probability score (RPS), které narozdíl od BS hodnotí multi-kategorické předpovědi. Tzn., že není stanoven jediný threshold, ale minimálně tři kategorie, do kterých může předpověď spadnout. Pozitivní přínos předpovědi opět indikuje skóre v rozmezí 0 až 1. Vyšší úspěšnost referenční předpovědi je v případě hodnot menších než 0.

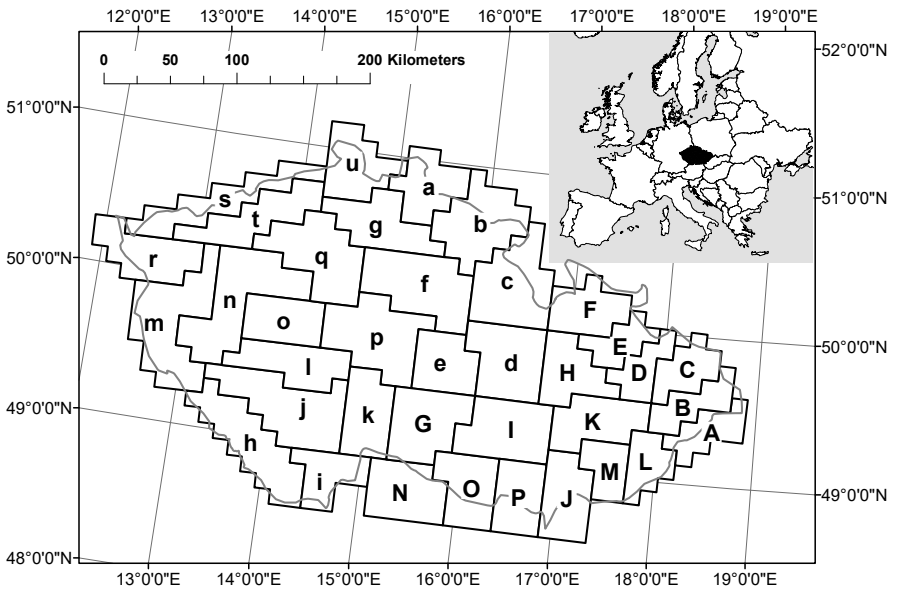
$$RPS = \frac{1}{N-1} \sum_{n=1}^N \left(\sum_{k=1}^n p_k - \sum_{k=1}^n o_k \right)^2 \quad (16)$$

$$RPSS = 1 - \frac{RPS}{RPS_{ref}} \quad (17)$$

4 Verifikace modelu ALADIN-CZ a ALADIN-LAEF

4.1 Data a oblast zájmu

Srážkové události způsobující významnou odtokovou odezvu v povodí se v podmínkách České republiky vyskytují především v průběhu teplé letní části roku. Z tohoto důvodu tato práce posuzuje srážkové události v období duben - říjen. Data pro verifikaci pokrývají roky 2011 - 2015. Práce se zaměřuje na vybraná povodí České republiky, která je pro potřeby hydrologického modelování rozdělena do 37 oblastí, pro které jsou predikovány srážkové úhrny agregovány.



Obrázek 17: Zájmová oblast rozdělená do 37 hydrologických oblastí. Oblasti označené malým písmenem jsou pokryty modelem AquaLOG, oblasti s velkým písmenem modelem Hydrog.

4.1.1 Předpovědi srážek

V práci jsou využity dva odlišné zdroje předpovědi srážek. Prvním je deterministický ALADIN-CZ provozovaný ČHMÚ a druhým je ensemble ALADIN-LAEF, který provozuje European Centre for Medium-Range Weather Forecast (ECMWF) využívající konfiguraci modelu ALADIN-AUSTRIA. Všechny modely jsou vyvíjeny v rámci projektu mezinárodní spolupráce Limited Area modelling Central Europe (LACE) [10].

ALADIN-CZ je hydrostatický spektrální regionální model s vysokým rozlišením. Produktem je předpověď srážek v 6 h intervalu v horizontu 72h, která je počítána 4krát denně v termínech 00UTC, 06UTC, 12UTC a 18UTC. Horizontální rozlišení modelu je 4,7 Km a vertikálně je model rozčleněn do 87 vrstev. Pro účel práce byly použity srážkové simulace z termínů 00UTC a 12UTC, které slouží pro hydrologické předpovědi.

ALADIN-LAEF je regionální ensemblevý předpovědní systém poskytující variantní predikce s počátečními podmínkami, které jsou generovány, jak popisuje Wang et al. [9, 10], pomocí breeding-blending metody. Tato metoda kombinuje ECMWF-EPS velkoměřítkové perturbace a maloměřítkové perturbace modelu ALADIN-LAEF z předchozí běhu pomocí digitálního filtrování. Součástí jsou také analýzy a multifyziky modelu ARPEGE (Action de Recherche Petite Echelle Grande Echelle) [36]. ALADIN/LAEF je tvořen 17 členy, které sestávají z 16 perturbací a kontrolního běhu. Horizontální rozlišení v současnosti dosahuje 11 km a vertikálně je model rozčleněn do 60 vrstev. Výstupy předpovědi jsou dostupné dvakrát denně v 00UTC a 12UTC s horizontem předpovědi 72 h. Vzhledem k potřebě pro hydrologické modelování byl horizont verifikovaných predikcí zkrácen na 54 h. Z rozsahu dat modelu ALADIN-LAEF pokrývajících celou Evropu a část Atlantiku [52], byla využita oblast omezena na hydrologické zóny ČR.

4.1.2 Měřené srážky

Pro potřeby verifikace byly použity 1 h zpřesněné radarové odhady sumy srážek, které jsou výsledkem kombinace radarových měření a hodnot ze srážkoměrných stanic [53]. Česká radarová síť (CZRAD) je provozována Českým hydrometeorologickým ústavem a skládá se ze dvou radarů pracujících v pásmu C a pokrývajících celou plochu ČR . [17]. Síť srážkoměrných stanic (databáze CLIDATA) se stále rozrůstá a v současnosti zahrnuje přibližně 500 srážkoměřů [54]. Hustota této sítě nezaručuje přesné plošné odhady srážek během konvektivních událostí a poskytuje pouze částečný náhled na prostorovou variabilitu srážek. Z tohoto důvodu slouží pozemní měření ke kalibraci radarových snímků a za pomoci radarových měření je odhadnuta prostorová variabilita procesu [14]. Kombinování radarových odhadů a srážkoměrných měření je v ČHMÚ prováděno užitím regresního krigingu [54, 55]. Tato data

jsou mimo jiné použita na několika povodích jako alternativní srážkový vstup pro hydrologické modely. V porovnání s interpolovanými daty ze srážkoměrů samotných vyplývá, že na základě modelovaných průtoků vykazují nejlepší plošný odhad srážek [56]. K dispozici byly 1 h plošné sumy srážek, které byly agregovány do 6 h kroku shodně s předpovědními modely.

4.1.3 Zájmová oblast

Zájmová oblast sestává z 37 hydrologických oblastí. Hranice těchto oblastí byly navrženy ČHMÚ a jsou rutinně používány v operativní hydrologii. Vnější hranice území přibližně koresponduje s vnější hranicí povodí České republiky. Tvar jednotlivých území částečně respektuje hranice subpovodí a zároveň orografii terénu. Tyto oblasti jsou rozděleny do dvou skupin. První skupina je pokryta hydrologickým modelem AquaLog a v obrázku 17 označena malými tiskacími písmeny. Druhá skupina je pokryta modelem HYDROG a je označena velkými tiskacími písmeny [8]. Rozloha jednotlivých oblastí se pohybuje od 1338.6 km² (oblast “M”) do 4041.3 km² (region “m”), zatímco průměrná rozloha oblastí je 2503.8 km². Srážková data vstupující do hydrologického modelu jsou v rámci každé oblasti agregovány, tzn. že každá oblast má pro každý časový krok přiřazenou pouze jedinou vstupní hodnotu srážkového úhrnu.

4.1.4 Synoptické povětrnostní situace

Pro oblast České republiky je od roku 1946 veden kalendář typizace povětrnostních situací (TPS). Tato data jsou volně dostupná na webových stránkách ČHMÚ. Ze seznamu 25 povětrnostních situací [57], je každý den vybrána jedna situace popisující momentální situaci nad územím české republiky s ohledem na stav nad celou Evropou a částí Atlantiku. V práci byla provedena verifikace prediktability srážek v závislosti na typu povětrnostní situace. Pro tyto potřeby bylo vybráno 6 nejčastěji se vyskytujících TPS v posuzovaném období, které byly příčinou srážko-odtokových událostí. Celkový počet událostí, při kterých se v letech 2011-2015 (duben-říjen) vyskytly srážko-odtokové události, je 19. Vybraných 6 typů zahrnuje: **B**-brázda nízkého tlaku nad střední Evropou, **Bp**-brázda postupující přes střední Evropu, **C**-cyklóna nad střední Evropou, **Ec**-východní cyklonální situace, **NEc**-severovýchodní cyklonální situace, **SWc2**-jihozápadní cyklonální situace 2. Podrobný popis jednotlivých situací je uveden v příloze.

4.1.5 Definice srážkových událostí

Předmětem práce je posouzení úspěšnosti predikce srážek modelů ALADIN-CZ a ALADIN-LAEF během událostí, které způsobují významnou srážko-odtokovou odezvu. Výběr událostí byl proveden aplikováním definice USLE

stejným způsobem, jak jej prakticky prezentují ve svých pracích Hanel a Máca [58] a Svoboda et al. [59]. Tato metodika definuje událost na základě parametrů, kde je podmínkou celkový úhrn vyšší než 12.7 mm nebo dosažené maximální intenzity deště větší než 6.35 mm/15min, separace od jiné události bezdeštným úsekem trvajícím alespoň 6 h. Překročení těchto mezí potenciálně vede k půdní erozi a povrchovému odtoku [60].

Takto definované události pro každou hydrologickou oblast zvlášť, měly následující charakteristiky. Celkový počet událostí v jednotlivých regionech je 824. Nejvyšší počet událostí (35) byl pozorován v oblasti "h", zatímco nejmenší počet událostí (14) v oblasti "r". Průměrná doba trvání jedné události je 28.5 h. Nejvyšší dosažený srážkový úhrn se vyskytl v oblasti "a" dne 22. 7. 2011, kde dosáhl hodnoty 145.3 mm a doba trvání této události byla 72 h. Událost nastala během povětrnostní situace typu "C". Nejnižší úhrn v rámci vybraných událostí má hodnotu 15 mm, přičemž průměrná hodnota je 26 mm. Nejdéle trvající událost se vyskytla v oblasti "C" během povětrnostní situace "Bp" a trvala 96 h od 13. 7. do 17. 7. 2011. Nejvýznamnější povodňová odezva během posuzovaného období byla pozorována 3. ž. 2013 a postihla celé povodí Vltavy a oblasti v severní části Čech. Průtoky během kulminace dosahovaly hodnot 100-letých povodní. Pro účel verifikace byly hodnoceny všechny 54 h predikce srážek překrývající časový rozsah stanovených srážko-ových epizod.

4.2 Metodika verifikace

Vzhledem k zaměření této práce na srážková data pro hydrologické modelování v ČHMÚ s jejich primárním zaměřením na deterministickou předpověď, bylo nezbytné verifikovat ensemblová data vyjádřená formou jak deterministické, tak i pravděpodobnostní předpovědi. Modely ALADIN-CZ a ALADIN-LAEF byly tedy hodnoceny verifikačními metodami pro kontinuální proměnné a stejně tak pro binární (dichotomní) události. V rámci verifikace ensemblu, všech 16+1 členů bylo hodnoceno individuálně. Stejně tak byl hodnocen i průměr (značen jako MEAN) a medián ensemblu (označen jako MEDIAN). MEAN i MEDIAN jsou vypočítány ze souboru 16 členů. Ze souboru je separovaný 17. člen, tzv. kontrolní předpověď (označena jako CF), která nemá pozměněné počáteční podmínky. Perturbace jsou centrovány právě od této kontrolní analýzy, čímž vznikají pozitivní a negativní perturbace od této předpovědi [36, 61]. Z tohoto důvodu by měli být výsledky CF podobné vypočteným výsledkům průměru ensemblu MEAN. Pokud je porovnávána deterministická a pravděpodobnostní předpověď, je nezbytné převést pravděpodobnostní předpověď na deterministickou nebo deterministickou předpověď na pravděpodobnostní pomocí binárních hodnot [62]. Vzhledem k záměru práce jsou ALADIN-CZ a MEAN dvě nejčastěji hodnocené varianty deterministických předpovědí.

V práci byly použity verifikační metody doporučené v publikacích od Jolliffe a Stephenson [42], WMO [50] a Wilks [63]. Míra shody mezi predikcemi a pozorováními ve formě kontinuálních veličin byla posouzena výpočtem chybových metrik mean error (ME), mean absolute error (MAE) a root mean squared error (RMSE). Závislost mezi měřeními a pozorovanými hodnotami byla hodnocena Pearsonovým korelačním koeficientem (COR). Pro aplikaci postupu pro binární události, kontinuální veličiny byly transformovány na binární určení pravděpodobnosti deterministické předpovědi hodnotou 1, pokud predikovaná událost měla nastat, v jiném případě hodnotou 0 [2]. Verifikace binárních událostí poskytuje velký rozsah binárních skóre vycházejících z kontingenční tabulky sumarizující četnosti "yes"(1) a "no"(0) předpovědí a měření, kde srážkové úhrny rovné nebo větší než definovaná mezní hodnota jsou označeny jako "yes" a nižší úhrny jako "no". Kontingenční tabulka nabízí 4 možné párovací kombinace (hits, misses, false alarms a correct rejections) počtu celkových četností "yes"/"no" predikcí a pozorování (tab. č.1) [50, 63]. Jelikož byly hodnoceny pouze vybrané srážkové události, byly upřednostněny ty skóre, které nejsou zaměřené na četnost "correct rejections".

Binární skóre byly počítány pro stejné události, jako v případě kontinuálních hodnot. Vypočteny byly následující binární verifikační skóre: frequency bias (B); threat score (TS); probability of detection (POFD), také známé jako false alarm rate; proportion correct (PC); Heidke skill score (HSS); odds ratio (OR); odds ratio skill score (ORSS); Pierce skill score (PSS); Brier score (BS); a ranked probability score (RPS). Poslední dvě zmíněné jsou aplikovatelné také pro posouzení pravděpodobnostní předpovědi [50, 62]. V tabulce č.2 jsou popsány možné rozsahy hodnot jednotlivých skóre, hodnoty indikující nejlepší možný výsledek a také obecné výsledky srovnání modelu ALADIN (ALADIN-CZ) a MEAN (průměr ALADIN-LAEF).

Na rozdíl od deterministických předpovědí binárních událostí a kontinuálních hodnot, pravděpodobnostní předpověď je vyjádřena jako pravděpodobnost výskytu určitého jevu s hodnotami v rozmezí 0 až 1. Vypočteny byly běžné statistiky hodnotící schopnosti ensemblu, tj. Brier skill score (BSS) a Ranked probability skill score (RPSS) [64]. Tyto skóre posuzují schopnosti ensemblu oproti referenční předpovědi, která je obvykle odvozena z klimatologických dat. Jinou možností je využití jako referenční předpovědi deterministickou předpověď. Vzhledem k cílům této práce byla porovnána pravděpodobnostní předpověď ensemblu ALADIN-LAEF s deterministickými referenčními předpověďmi ALADIN-CZ, MEAN, MEDIAN a CF. Ještě jiný pohled na hodnocení ensemblové předpovědi nabízí rank histogram, neboli tzv. Talagrand diagram. Tato grafická metoda testuje spolehlivost ensemblu metodou výběru n -tého intervalu mezi hodnotami členů ensemblu, kam spadá měřená hodnota. Ensemblu jsou vždy seřazeny od nejnižší hodnoty po nejvyšší, tím jsou vytvořeny intervaly pro rankování. Tento postup se opakuje

pro každou předpověď. [48, 64]. V závislosti na tvaru histogramu lze odvodit informace o rozptylu ensamble a jeho biasu. Nejlepších výsledků je dosaženo v případě plochého histogramu, resp. uniformní distribuce n -tých intervalů. Nedostatek variability (nízký rozptyl hodnot) způsobuje tvar histogramu do písmene "U". Kopulovitý tvar znamená naopak příliš velký rozptyl predikovaných hodnot. Asymetrické rozložení histogramu je výsledkem předpovědi zatížené kladným či záporným biasem. [63, 65].

SCORE	ALADIN	MEAN	RANGE	PERFECT SCORE
Correlation (COR)	0.0396	0.0774	[-1,1]	1
Root Mean Squared Error (RMSE)	7.3250	6.6944	[0, +∞]	0
Mean Absolute Error (MAE)	5.0287	4.5540	[0, +∞]	0
Bias (BIAS)	0.7611	0.7011	[0, +∞]	1
Brier Score (BS)	0.3878	0.3630	[0,1]	0
Ranked Probability Score (RPS)	0.2440	0.2439	[0,1]	0
Equitable Threat Score (ETS)	0.1354	0.1614	[-1/3,1]	1
Threat Score (TS)	0.3915	0.3997	[0,1]	1
Probability Of Detection (POD)	0.4955	0.4858	[0,1]	1
False Alarm Ratio (FAR)	0.3489	0.3071	[0,1]	0
Probability Of False Detection (POFD)	0.2579	0.2091	[0,1]	0
Proportion Correct (PC)	0.6206	0.6406	[0,1]	1
Heidke skill score (HSS)	0.2385	0.2779	[-1,1]	1
Odds ratio (OR)	2.8266	3.5734	[0, +∞]	+∞
Odds ratio skill score (ORSS)	0.4773	0.5627	[-1,1]	1
Pierce Skill Score (PSS)	0.2376	0.2767	[-1,1]	1

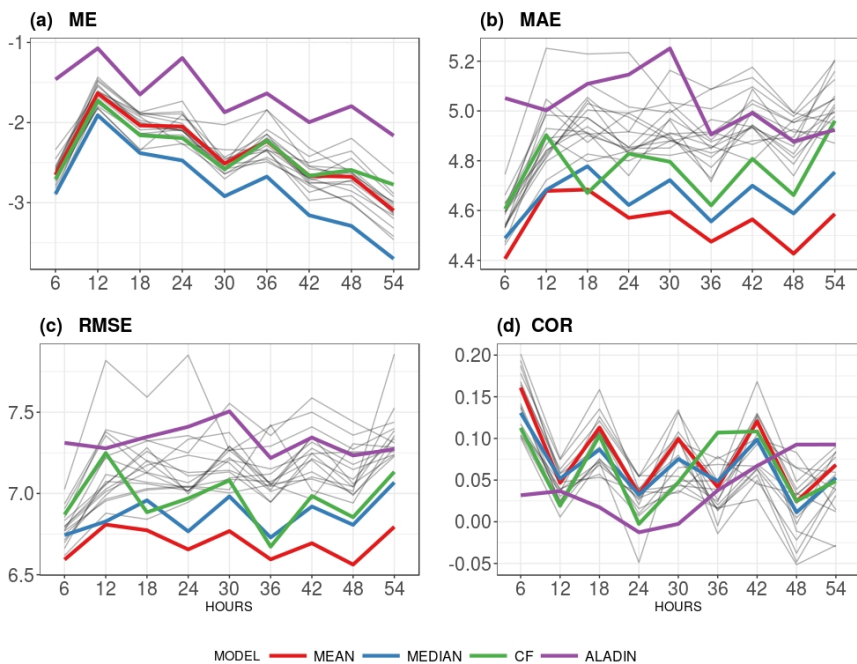
Tabulka 2: Porovnání verifikačních skóre modelů ALADIN a MEAN pro všechna data dohromady bez vlivu závislosti na časovém horizontu předpovědi a mezní hranice srážkového úhrnu. Tučně vyznačené hodnoty indikují lepší výsledek.

5 Výsledky verifikace

Všechny předpovědi byly verifikovány z hlediska závislosti na časovém horizontu předpovědi a na prahových hodnotách srážek. Srážkové prahy byly stanoveny, s ohledem na 6h akumulace, na 1, 2.5, 5 a 10 mm. Výpočty charakteristik byly vztaženy k jednotlivým hydrologickým oblastem a pro přehlednost byly také zprůměrovány do hodnot reprezentujících všechny oblasti. Odlišný přístup hodnocení byl proveden při hodnocení přesnosti předpovědí během povětrnostních typů, které se nejčastěji vyskytly během srážkových událostí. 6h sumy srážek byly verifikovány pro všech 16938 dvojic "předpověď - měření". V následujících grafech je ALADIN-CZ uváděn jako ALADIN, průměr ensamble ALADIN-LAEF jako MEAN, median ensamble ALADIN-LAEF jako MEDIAN a kontrolní předpověď modelu ALADIN-LAEF jako CF.

5.1 Kontinuální veličiny

Tato kapitola porovnává závislost přesnosti předpovědí na časovém horizontu předpovědi (v 6 h časovém kroku). Obr. č. 18 popisuje chybové metriky (ME, MAE a RMSE) a korelaci (COR). Vyjma ME, přesnost předpovědí neklesá s rostoucí dobou, na kterou je předpověď počítána. ALADIN dosahuje nejlepších výsledků pouze v případě ME. Jeho kladné a záporné odchylky se zde kompenzují, na rozdíl od MAE, kde jsou chyby načítány v absolutní hodnotě. ME indikuje pro všechny modely negativní bias, tedy podhodnocení množství srážek. Z ensamble ALADIN-LAEF nejlepších výsledků dosahuje MEAN a nejhorsích MEDIAN a CF.

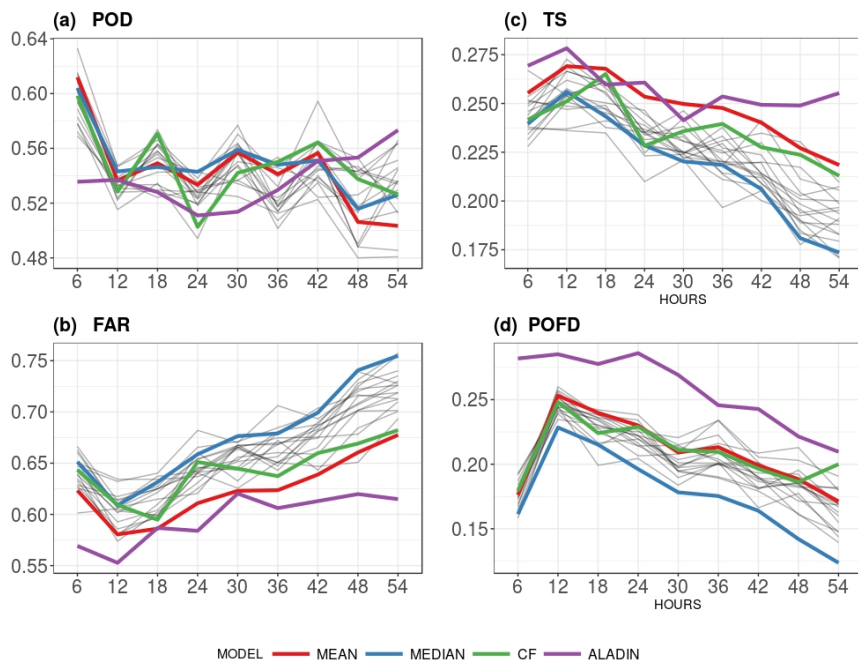


Obrázek 18: Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro ME (a), MAE (b), RMSE (c) a COR (d) jako funkce horizontu předpovědi. Šedé linie reprezentují 16 členů ensmbly.

5.2 Binární události

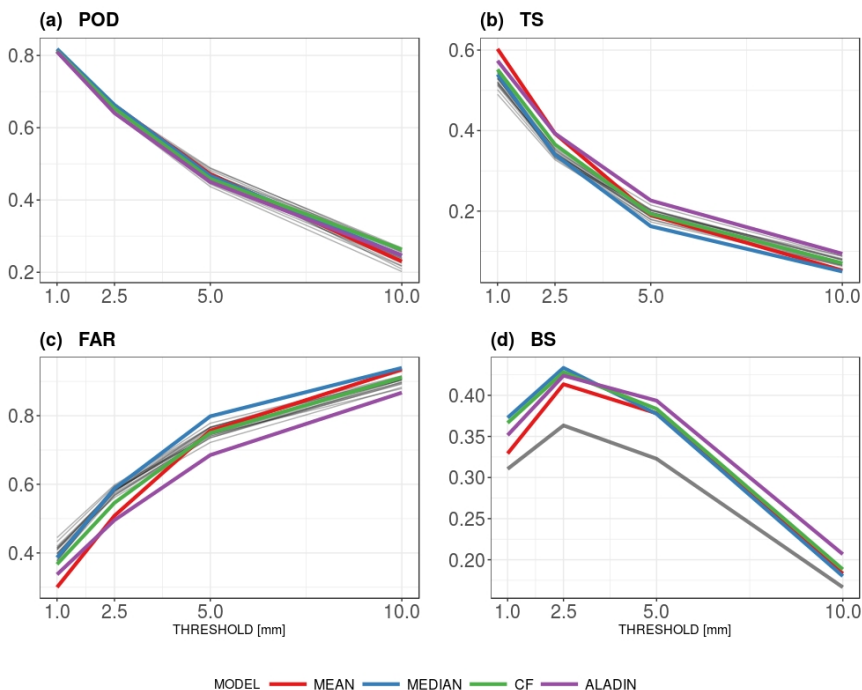
Jak je možné vidět v obr. č. 19, metody hodnocení binárních událostí poskytují méně zřejmé rozdíly mezi modely, v porovnání s metodami pro kontinuální veličiny. POD je podíl četnosti výskytů, které byly správně predikovány [62] a nejlepší skóre je 1. Obr. č. 19 ukazuje vyšší úspěšnost modelu MEAN v kratším horizontu předpovědi. Významnější pokles nastává v čase 48 h, od kdy naopak úspěšnost modelu ALADIN výrazněji roste. TS se také zaměřuje na správně predikované události, to je reflektováno stejným nárůstem rozdílu v úspěšnosti mezi modelem MEAN a ALADIN od 48 h. Odlišný přístup hodnocení poskytuje FAR a POFD, které kladou důraz na falešné alarmy a nejlepší skóre představuje v obou případech hodnota 0. FAR hodnotí model ALADIN nejlépe ve všech časových krocích. Na druhou stranu POFD hodnotí model ALADIN významně hůře, MEAN se pohybuje okolo průměrných hodnot a pouze v tomto případě nejlepších výsledků dosahuje MEDIAN. Důvod

těchto rozdílných výsledků je ten, že výpočet FAR zohledňuje přesné předpovědi "hits", zatímco POFD je podmíněno správným odmítnutím "correct rejections".



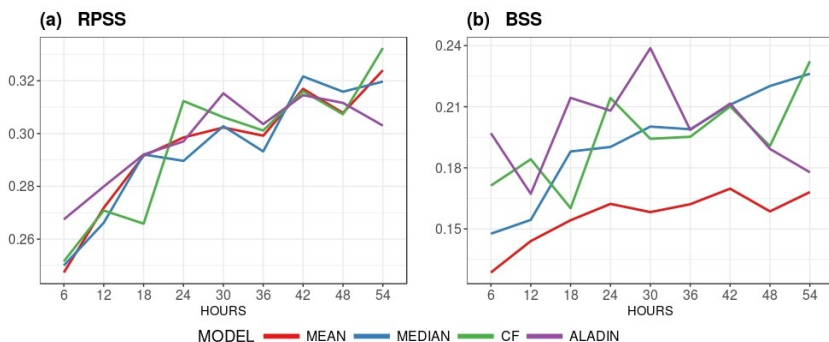
Obrázek 19: Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro ME (a), MAE (b), RMSE (c) a COR (d) jako funkce horizontu předpovědi. Šedé linie reprezentují 16 členů ensmbly.

Obr. č. 20 popisuje závislost přesnosti předpovědí na stanovených prahových hodnotách srážek pro skóre POD, TS, FAR a BS. Touto metodou nebyly zjištěny žádné významnější rozdíly v přesnosti předpovědí mezi jednotlivými modely. Vyjma BS, všechna skóre mají klesající trend úspěšnosti s rostoucí srážkovým prahem. Navíc BS není počítáno pouze na základě binárních hodnot. Ensemblová předpověď všech 16 členů je vyjádřena jako pravděpodobnostní, tedy jedinou hodnotou pravděpodobnosti v rozmezí 0-1, zatímco pozorování nabývají binárních hodnot 0 nebo 1 [64]. Z tohoto důvodu je v grafu BS soubor předpovědí prezentován pouze jednou šedou čarou.



Obrázek 20: Srovnání modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zelená) pro POD (a), TS (b), FAR (c) a BS (d) jako funkce prahových hodnot. Šedé linie reprezentují 16 členů ensamble. V případě BS je soubor 16 předpovědí prezentován šedou čarou.


Obr. č. 21 porovnává schopnosti ("skill") ensamble oproti referenční předpovědi (v tomto případě jsou jako referenční předpovědi aplikovány modely ALADIN, MEAN, MEDIAN a CF). V případě RPSS i BSS je nejlepší skóre 1 a 0 indikuje žádný přínos oproti referenční předpovědi. Tím pádem čím vyšší skóre, tím méně úspěšná je referenční předpověď, resp. deterministický model v porovnání s pravděpodobnostní ensamblovou předpovědí. Ve výsledcích se hodnota RPSS zvyšuje s rostoucím horizontem předpovědi bez výrazných rozdílů mezi referenčními predikcemi. Z výsledků BSS je zřejmé, že MEAN dosahuje nejlepších výsledků mezi referenčními predikcemi, avšak stále nedosahuje schopností ensamblové předpovědi. Nejvyššího skill skóre dosahuje ensabl na 30 h v porovnání s modelem ALADIN.



Obrázek 21: Skill skóre ensmbly za využití referenční předpovědi v podobě modelu ALADIN (fialová), MEAN (červená), MEDIAN (modrá) a CF (zeleň). RPSS (a) a BSS (b) ukazují pozitivní úspěšnost ensmbly s rostoucím horizontem předpovědi.

5.3 Rank histogram

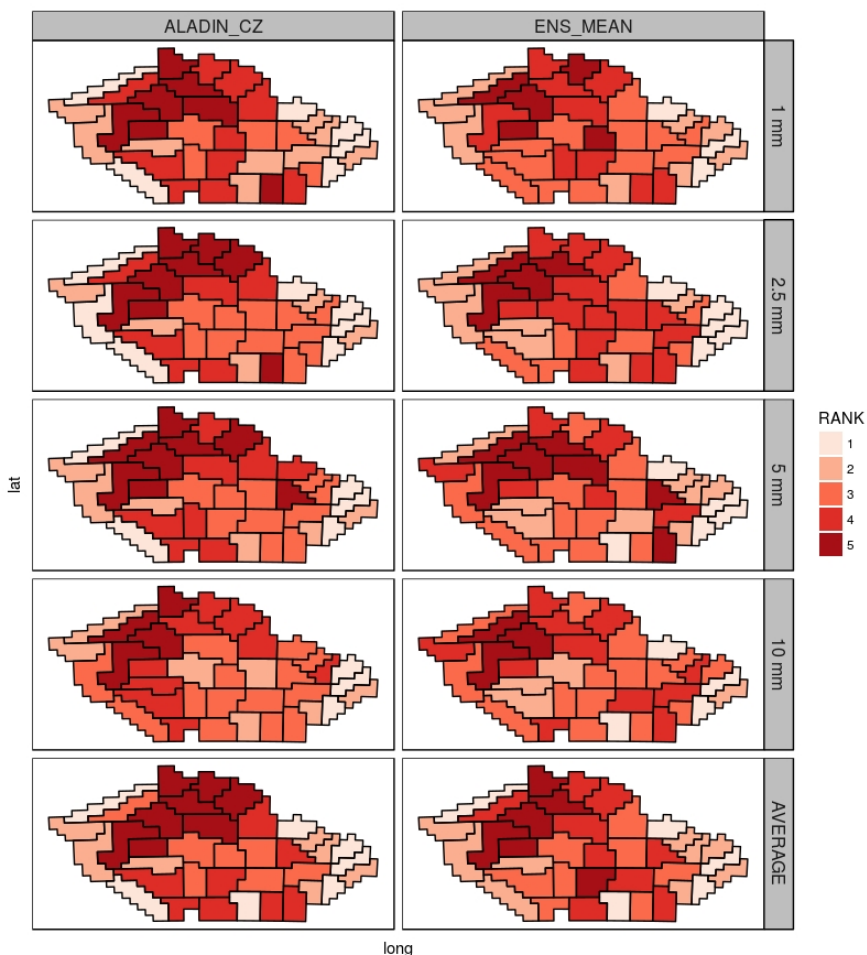
Rank histogram představuje verifikační metodu poskytující informace a charakteristiky rozptylu ensmbly. Tuto metodu nelze aplikovat na deterministické předpovědi. Z tohoto důvodu je posouzena pouze předpověď modelu ALADIN-LAEF. Za účelem získání rozptylových charakteristik pro různé srážkové úhrny, byly srážky rozděleny do tříd s množstvím srážek menším než 1, 2,5, 5, 10 a větší než 10 mm za časový úsek 6 h. obr. č. 22 prezentuje výsledný histogram ve tvaru "U", který je charakteristický pro ensmbly s nedostatečným rozptylem. Navíc díky dekompozici je čitelné nadhodnocování nízkých úhrnů a podhodnocování vyšších úhrnů.



Obrázek 22: Rank histogram pro ensemblvou předpověď (ALADIN-LAEF). Dekompozice jednotlivých košů vychází z 6 h úhrnů <1 mm (černé sloupce), <2.5 mm, <5 mm, <10 mm a >10 mm (bílé sloupce).

5.4 Hydrologické oblasti

Hodnocení předpovědi bylo provedeno také z pohledu jednotlivých hydrologických oblastí. Výsledná úspěšnost předpovědi v jednotlivých regionech byla stanovena kombinací výsledků pěti verifikačních metod (COR, MAE, RMSE, TS a POD). Na základě výsledných skóre byly regiony seřazeny a obodovány od nejlepšího po region s nejméně přesnou předpovědí. Každý region měl přiřazeno 5 pořadí, které byly sečteny. Následně byly regiony rozděleny do pěti skupin (pod hodnotami 1-5), kde 1 znamená nejlepší výsledky a 5 nejhorší výsledky. V obr. č. 23 jsou zobrazeny výsledky pro model ALADIN a MEAN v závislosti na srážkových prazích 1, 2.5, 5, 10 mm. V posledním řádku je uveden průměr těchto čtyř hodnot. Z výsledků je patrné, že zejména na severozápadě území se vyskytují problematické regiony, kde úspěšnost předpovědi je v porovnání se zbytkem území nižší. Hraniční a horské oblasti dosahují překvapivě ve většině případů lepších výsledků, zejména v západní a východní části republiky.

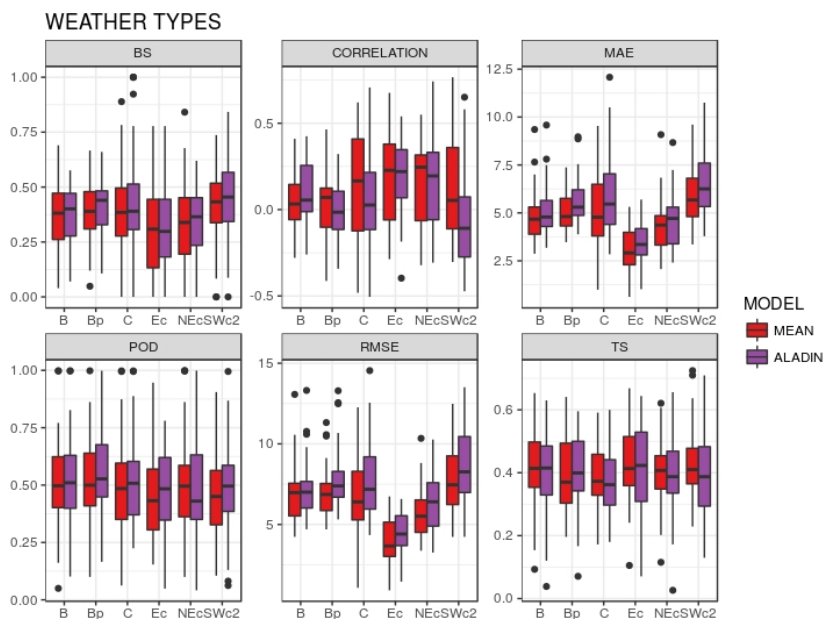


Obrázek 23: Hodnocení přesnosti předpovědi v jednotlivých oblastech v závislosti na výšce srážkového úhrnu. Oblasti jsou hodnoceny od 1 do 5, kde 1 znamená nejvyšší úspěšnost (světle červená) a 5 znamená nejnižší úspěšnost (tmavě červená). Výsledky jsou prezentovány pro model ALADIN a MEAN. Poslední řádek představuje průměr výsledků všech srážkových prahů.

5.5 Povětrnostní situace

Předpovědi modelu ALADIN a MEAN během pěti nejčastěji se vyskytujících povětrnostních typů byly verifikovány pomocí COR, MAE, RMSE, POD, TS

a BS. Jak je patrné z obr. č. 24, predikce srážek během povětrnostní situace Ec dosáhly nejvyšší míry přesnosti. Naopak, během situace Swc2 je předpověď nejméně přesná. Rodily mezi medelem ALADIN a MEAN potvrzují výsledky prezentované v obr. č. 18 a obr. č. 19

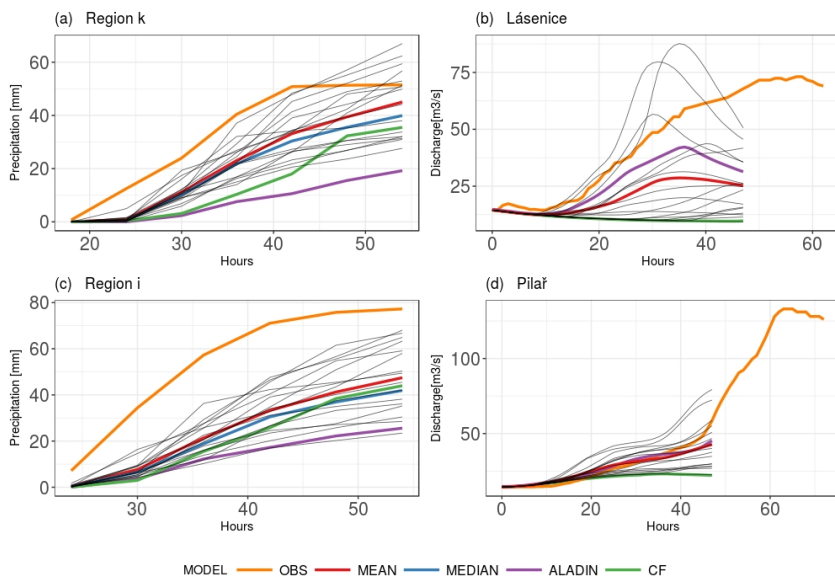


Obrázek 24: Boxploty pro RMSE (a), MAE (b), COR (c), POD (d), TS (e) a BS (f) v závislosti na typu povětrnostní situace. Výsledky pro ALADIN jsou vyznačeny fialovými boxy, pro MEAN červenými boxy.

5.6 Povodňová událost 3. června 2013

Koncem května 2013 byla oblast České republiky zasažena několika vlnami silného deště, který zapříčinil vysoké nasycení půdy. Nejvýraznější epizoda však nastala 1. června. Důvodem byla brázda nízkého tlaku vzduchu postupující z východu z východu přes území České republiky (typ povětrnostní situace "C") [26]. Oblast tlakové výše v nad severní Evropou a hřeben vysokého tlaku vzduchu nad západní Evropou bránil brázdě nízkého tlaku postupovat dále k západu. Výsledkem byl retrográdní postup zvlněných frontálních systémů přes střední Evropu a celkové úhrny v některých oblastech přesahovaly 100 mm za den [66]. Na obr. č. 25 (a) a (c) je zobrazena měřená (OBS) a predikovaná agregace srážek od termínu 1. června 00 UTC v oblastech "k" a

"i". Obě tyto oblasti jsou lokalizovány v jihovýchodní části jižních Čech. Tyto regiony byly vybrány z důvodu dostupnosti dat ensemblových hydrologických předpovědí a jelikož se nacházely v hlavním srážkovém pásu. Na obr. č. 25 (b) a (d) jsou zobrazeny měřené průtoky (OBS) a hydrologické předpovědi ze stejného data jako předpověď srážek. Průtoky jsou odvozeny na základě predikce srážek modelů ALADIN-LAEF a ALADIN-CZ pro měrné profily Pilař a Lásenice. Profil Pilař je se nachází na řece Lužnici v hydrologické oblasti "i"s plochou povodí 935.23 km². Profil Lásenice leží na řece Nežárka v hydrologické oblasti "k"s plochou povodí 684.66 km². Podrobnější charakteristiky naleznete v tab. č. 3.



Obrázek 25: Srovnání modelu ALADIN-CZ (fialová), MEAN (červená), MEDIAN (modrá), CF (zelená) a měřených hodnot OBS (oranžová). Šedé linie představují jednotlivé členy ensemblu. Linie pro měřené průtoky jsou rozšířeny do doby kulminace. (a) oblast "k", (b) Lásenice, (c) oblast "i", (d) Pilař.

Region	Měřené srážky (mm)	ALADIN-CZ (mm)	ALADIN-LAEF MEAN (mm)	ALADIN-LAEF maximum (mm)	Profil	Rozloha povodí (km ²)	Maximální průtok (m ³ /s)
k	51.5	19.2	45.0	62.4	Lásenice / Nežárka	684.7	73.1
i	77.3	25.6	47.4	66.7	Pilař / Lužnice	935.2	133.0

Tabulka 3: Hydrologické charakteristiky pro regiony "k" a "i" během povodňové události 3.6. 2013

Odhady celkových úhrnů srážek byly podhodnoceny v obou regionech, což se projevilo na predikci průtoků. V případě regionů "i" a "k", stejně jako v jiných regionech, začalo pršet dříve, než bylo očekáváno. Přesto modely dokázaly úspěšně odhadnout nástup povodňové vlny. Postupem času se podhodnocení srážek projevilo a predikované průtoky začaly být nižší než měřené hodnoty. Modely produkovaly větší nepřesnosti v profilu Lásenice, kde kulminačního průtoku bylo dosaženo, v porovnání s předpovědí, dříve. Ačkoliv průměr ensamble MEAN byl méně přesný, než deterministická předpověď ALADIN, rozptyl ensamble zahrnoval naměřené hodnoty. Tato extrémní srážko-odtoková událost koresponduje s výsledky verifikace v této práci, kde využití průměru ensamble předpovědi účelně doplňuje současnou deterministickou předpověď. Případová studie poukazuje na vhodnost aplikace ensamblevé předpovědi v operativní hydrologii za účelem přesnějšího popisu nejistot v hydrologických předpovědích.

5.7 Souhrn II. části práce

V této kapitole byly verifikovány a porovnány dva odlišné přístupy k predikci srážek pro hydrologické modelování. Prvním z nich jsou předpovědi regionálního deterministického modelu ALADIN-CZ. Výstupy tohoto modelu jsou operativně využívány pro hydrologickou předpověď v ČHMÚ. Druhým předmětem verifikace byla ensamblevá předpověď ALADIN-LAEF. Data z toho modelu byla po prvotních verifikacích před lety shledána jako nepřímá pro hydrologickou předpověď. Cílem kapitoly bylo zhodnotit přínos využití predikcí srážek modelu ALADIN-LAEF, zejména v případech významných srážkových událostí.

Při hodnocení modelů bylo aplikováno celé spektrum verifikačních metod. K porovnání s deterministické předpovědi ALADIN-CZ (ALADIN) s ensamblevou předpovědí ALADIN-LAEF, sestávající ze 16 členů, byl nejčastěji použit průměr ensamble MEAN. Dle výsledků ME oba modely tíhnou k podhodnocování množství srážek. V případě ensamblevé předpovědi, rank histogram ukazuje rostoucí podhodnocení s rostoucím srážkovým úhrnem. Nicméně je potřeba poznamenat, že verifikované události byly definovány na základě měřených dat, nikoliv modelových výstupů. ME je také jediné skóre, které jednoznačně vyhodnocuje předpověď modelu ALADIN jako nejlepší. Důvodem je s nejvyšší pravděpodobností kompenzace kladných a záporných odchylek, jelikož odlišných výsledků je dosaženo použitím tohoto kritéria v absolutní hodnotě (MAE). MAE, RMSE a COR hodnotí MEAN jako jakožto nejúspěšnější předpověď. Verifikační skóre pro binární a diskrétní hodnoty poskytuje méně jednoznačné výsledky. Dle FAR je MEAN méně přesný ve srovnání s modelem ALADIN. To znamená, že ALADIN se více vyhýbá falešným alarmům. Na druhou stranu MEAN dosahuje lepšího skóre pro POFD, což indikuje horší úspěšnost modelu ALADIN v případě "correct rejections".

POD a TS neindikují významný rozdíl mezi modely ALADIN a MEAN. Za zmínku stojí, že predikce modelu ALADIN se zlepšují ke konci předpovědního období. Obecně je předpokládáno, že vzhledem k vyššímu rozlišení deterministického modelu budou jeho výsledky přesnější zejména v predikcích na nejbližší hodiny. Agregace dat do hydrologických oblastí má zřejmě za následek potlačení této výhody a ALADIN-CZ není úspěšnější ani v tomto období.

Kromě deterministických verifikačních metod byly aplikovány také metody hodnocení pravděpodobnostních předpovědí, konkrétně RPSS a BSS. Obr. č. 21 ukazuje pozitivní schopnosti (skill) ensemblové předpovědi vzhledem k modelům ALADIN, MEAN, MEDIAN a CF, které byly použity jako referenční předpovědi. Tyto verifikační postupy umožňují mimo jiné porovnání samotných referenčních předpovědí. Zejména z výsledků BSS je patrné, že úspěšnost modelu MEAN je vyšší oproti modelu ALADIN. Respektive ensemblová předpověď má nižší pozitivní skill skóre vzhledem k modelu MEAN, než k modelu ALADIN.

Posouzen byl také vliv povětrnostních situací na přesnost předpovědí. Rozdíl mezi modelem ALADIN a MEAN zde nebyl tolik výrazný. Zřetelnější rozdíly jsou patrné mezi samotnými povětrnostními situacemi, zejména v případě RMSE. Nejnižší úspěšnosti dosahují předpovědi v průběhu povětrnostního typu SWc2, pro který jsou charakteristické rychlé přechody front z Atlantiku.

Hodnocena byla také úspěšnost předpovědi modelu ALADIN a MEAN v jednotlivých hydrologických oblastech pomocí 5 verifikačních metrik. Oblasti s nejhorsími výsledky byly stejné pro oba modely. To samé platí pro oblasti, kde přesnost predikcí byla nejvyšší. Bohužel nejhůře hodnocené oblasti jsou právě ty, které byly v posledních 60 letech nejčastěji zasaženy povodněmi. Nicméně tyto výsledky korespondují s výsledky hodnocení povětrnostních situací. Předpovědi během povětrnostní situace Ec a NEc dosahují nejvyšší úspěšnosti. Tyto situace přináší ve většině případů významné srážky do východní části České republiky, kde je úspěšnost předpovědí, ve srovnání se zbytkem republiky, přesnější. Naopak nejhůře hodnocená situace C přináší nejvýznamnější srážky do oblasti mezi jihozápadní a severní část republiky, kde jsou oblasti s nejnižší úspěšností.

Z výše uvedených výsledků je patrné, že ALADIN-LAEF je kvalitativně přinejmenším vhodný doplňkový zdroj dat pro tvorbu hydrologické předpovědi a měl by být považován za relevantní zdroj informací. Obecně jsou ensemblové systémy využívány ke stanovení míry nejistoty předpovědi. V tomto případě lze doporučit průměr ensemblu jako deterministickou předpověď společně se současnou předpovědí modelu ALADIN-CZ.

Část III

Kalibrace a postprocessing ensemblové předpovědi srážek pro hydrologické modelování

III. část práce má za cíl provést statistický postprocessing předpovědi srážek za účelem zpřesnění hydrologických předpovědí. Následující kapitoly popisují aplikaci doposud netestované kombinace odlišných postprocessingových metod, které sami o sobě mají prokázaný přínos v praxi ensemblové predikce srážek. Zvolena byla kombinace metody multimodelu, kvantilové předpovědi a neuronových sítí.

6 Využití metod kalibrace a postprocesingu v předpovědi srážek

Numerické modely představují robustní soubor výpočtů zatížených různými nejistotami a chybami. Ty se v modelu vyskytují od fyzikální aproximace reálných dějů přes chybně měřená vstupní data až po procedury asimilace dat a stanovení počátečních podmínek. Následný výpočet modelu se snaží zjednodušeně metodou konečných prvků popsat reálné děje v atmosféře, tedy v chaotickém systému [67]. I sebemenší odchylka na počátku výpočtu se promítá dále a v rámci atmosferických procesů se zvětšuje, což je typické chování pro chaotický systém [68]. Při takto složitých výpočetních procesech vznikají systematické chyby a tam, kde končí schopnost maximální přesnosti a spolehlivosti samotného ensemblu, přichází na řadu kalibrační a postprocessingové techniky [67].


Ve II. části práce byl podroben všestrannému hodnocení ensemblový model ALADIN-LAEF a zároveň byl porovnán s deterministickým regionálním modelem ALADIN-CZ. Posuzována byla data v podobě předpovědi srážek, které byly upraveny do podoby, v jaké vstupují do hydrologických modelů. Kalibrace nepostprocesovaného ensemblového modelu (tzv. raw modelu) je nutné před jeho aplikací provést z toho důvodu, že do modelu vstupuje řada nejistot v podobě chyb pozorovaných veličin, nejistoty samotného modelu a jeho aproximace a v neposlední řadě při asimilaci dat [67]. Ke zmírnění dopadu těchto nejistot pravděpodobnostní předpovědi a odstranění systematických chyb slouží právě kalibrace, mezi jejíž nejběžnější metody patří například řada regresních metod: NGR - Nonhomogeneous Gaussian Regression, logistická regrese, BMA - Bayesian Model Averaging a jiné, které popisují na-

příklad Hamill [69], Hamill [70], Wilks [71], Johnson [72] a Buizza [67]. Buizza také ve své práci porovnává jednotlivé metody a posuzuje jejich vhodnost použití. Na základě tohoto srovnání bylo rozhodnuto o aplikaci metody BMA, a to v podobě výpočtu kvantilové předpovědi touto metodou.

6.1 Bayesian Model Averaging (BMA)

Ensemblové předpovědi nám poskytují informaci o pravděpodobnosti výskytu predikovaného jevu na základě hustoty rozdělení pravděpodobnosti (PDF - Probability Density Function). Nižší rozptyl ensemblu znamená menší nejistotu v předpovědi a větší rozptyl naopak vyšší nejistotu (verifikaci rozptylu ensemblu pomocí Rank histogramu se podrobně věnuje kapitola 3.2.1). Žádoucí je však především to, aby skutečný stav predikované veličiny se nenacházel mimo rozptyl ensemblové předpovědi. Stejně tak naopak, rozptyl ensemblu by neměl být příliš velký. Ačkoliv skutečný stav bude uvnitř rozptylu, hodnota předpovědi bude nízká. Pokud nepřesnosti hustoty rozdělení pravděpodobnosti jsou systematické a mají konzistentní charakter, mohou být korigovány pomocí tzv. metod MOS - Model Output Statistics [63]. Podstatou těchto metod je, že shromažďují informace o chybách předpovědi na trénovacím datasetu a poté jsou schopny chybu v předpovědi odhalit a korigovat. Nejběžněji používanou metodou je v tomto ohledu BMA - Bayesian Model Averaging, kterou uvedl v roce 2005 Raftery [73]. BMA metoda je využita pro potřeby kalibrace v této práci. Principem BMA je vygenerování celkové hustoty rozdělení pravděpodobnosti předpovědi na základě váženého průměru jednotlivých hustot rozdělení pravděpodobnosti předpovědi každého modelu, resp. členu ensemblu. Váhy reprezentují přesnost nebo lépe řečeno pravděpodobnost, že konkrétní model produkuje správnou předpověď [74, 75]. BMA je doporučováno zejména pro kalibraci multimodelových ensemblů, kde každý soubor předpovědí byl integrován aplikací různých dynamických modelů s různými chybovými charakteristikami. Co se týká pravděpodobnostního rozdělení, pro případ srážek je počítáno s gamma rozdělením (obr. č. 26), na rozdíl například od teplot, kde je počítáno s normálním rozdělením. Stavba BMA prediktivní distribuce může být obecně vyjádřena rovnicí (18), kde w_k představuje nezápornou váhu spojenou se složkou hustoty pravděpodobnosti $f_k(y_t)$, vztahující se ke k-tému členu ensemblu.

$$f_{BMA}(y_t) = \sum_{k=1}^m w_k f_k(y_t) \quad (18)$$



Obrázek 26: Příklad BMA prediktivní distribuce složené z diskrétní komponenty pro nulové srážky a gamma rozdělením pro nenulové hodnoty srážek [76]


6.2 Multimodel

Jedním ze způsobů, jak z předpovědi ensamble odstranit systematické chyby (bias) nebo vylepšit popis nejistoty predikované veličiny, je sestavení tzv. multimodelu [63]. Nejjednodušší metodou je sdružení všech členů ensamble z alespoň dvou různých modelů [77, 78]. Přínosem multimodelu jsou zejména odlišné počáteční podmínky výpočtů a různé fyzikální přístupy [79]. Například García Moya [80] ve své studii poukazuje na přínos multimodelu oproti samotnému modelu AEMET-SREPS (Agencia Estatal de Meteorología - Short-Range Ensemble Prediction System), který využívá ECMWF analýzy pro své výpočty a je pro něj charakteristický nedostatečný rozptyl. V případě předpovědi srážek to znamená jejich podhodnocování. Stejně tak ALADIN-LAEF využívá analýzy ECMWF a jak ukázala verifikace ve druhé části této práce, resp. navazující článek [81], model také podhodnocuje srážky a jeho rozptyl je nedostatečný. Za účelem zpřesnění předpovědi srážek pro hydrologické modelování je v kapitole č. 7 testována varianta multimodelu ALADIN-LAEF a COSMO-LEPS.

6.3 Neuronové sítě

Postprocessing ensamblevé předpovědi je běžně vykonáván pomocí distribučních regresních modelů (BMA, MOS atd). Nabízí se ale flexibilní alternativa použitím neuronových sítí (ANN – Artificial Neural Network), které mo-

hou popisovat nelineární vztahy mezi libovolnými prediktory a prediktanty, které se učí automaticky z poskytnutých dat a nevyžadují předem specifikované (lineární) funkce [82]. Neuronové sítě jsou tedy metodou vedoucí k úspěšnému řešení lineární i nelineární problematiky a správnému přidělení váhy jednotlivých predikcí [83]. Nejvíce rozšířeny jsou vícevrstvé perceptrony, které jsou charakterizovány dopřednou architekturou skládající se ze vstupní vrstvy, jedné nebo více skrytých vrstev a jedné výstupní vrstvy [84]. Uzly v každé vrstvě jsou propojeny s uzly v nejbližší následující vrstvě acyklickými vazbami. V praxi je dostačující aplikace jedné až dvou skrytých vrstev. Optimálního stanovení vah je dosaženo opakovaným procesem trénování (učení) neuronových sítí. V této fázi se model neuronových sítí postupně učí z úspěšných vstupních vzorků a cílových hodnot a tímto jsou modifikovány přidělené váhy [85]. Pro hodnocení úspěšnosti je zvolena chybová funkce, v našem případě LMS (Least Mean Squares). Učení spočívá v hledání takových řešení, resp. vstupních vzorků, které vedou k nejnižším chybovým hodnotám [86]. V této práci je metoda neuronových sítí aplikována jak na nekalibrovaný ensembleový model, tak i na již kalibrovanou - kvantilovou předpověď metodou BMA. Toto spojení dvou kalibračních metod (regresní a nelineární) může být úspěšné, jak popisuje Rasp [82] ve své nedávné studii.



Obrázek 27: Architektura neuronové sítě se dvěma skrytými vrstvami. V této práci představují vstupní vrstvy hodnoty srážek předpovídané jednotlivými členy ensemble, multimodelu nebo kvantilová předpověď.

7 Kalibrace a postprocesing předpovědi srážek


7.1 Data a oblast zájmu

Ve III. části této práce jsou za účelem kalibrace vybrána a použita data v poněkud odlišné struktuře. Zatímco ve druhé části byly pro potřeby verifikace z dat vyselektovány srážkové události a srážky byly agregovány do 37 hydrologických oblastí, nyní ve třetí části došlo k následujícím změnám. Z dat již nejsou vybrány pouze srážkové události, ale pro potřebu kalibrace jsou použita všechna data v měsících duben-říjen pro roky 2012 - 2018. Důvodem je vhodnost širšího data-setu pro kalibrační metody. Rovněž již data nejsou agregována do 37 hydrologických oblastí. Namísto toho byla agregace provedena přímo pro jednotlivá povodí, což odpovídá novým metodám hydrologické předpovědi počítané v ČHMÚ. Pro samotnou kalibraci byla vybrána tři povodí v Jihočeském kraji. Další změnou je rozšíření data-setu o ensemblový model COSMO-LEPS (Consortium for Small-scale MOdeling - Limited-area Ensemble Prediction Sytem)[11]. Data byla opět upravena v 6 h kroku pro horizont předpovědi 54 h. Výsledkem prostorové agregace je vždy jedna hodnota srážky pro celé povodí.

7.1.1 Předpovědi srážek

Za účelem dosažení co nejlepší předpovědi srážek pro hydrologické modelování byly kombinovány celkem tři numerické modely. Deterministický model ALADIN-CZ a ensemblový model ALADIN-LAEF, kde oba tyto modely jsou podrobně popsány v kapitole 4.1.1. Modely svojí předpovědí pokrývají období duben - květen v letech 2012-2018. Srážkové simulace modelu ALADIN-CZ byly vybrány z termínů 00UTC a 12UTC, aby se překrývaly s běhy ensemblových modelů. Data-set byl navíc rozšířen o ensemblový model COSMO-LEPS.

COSMO-LEPS je nehydrostatický regionální ensemblový předpovědní systém, který vznikl v roce 2002 jako produkt dynamického downscalingu ensemblového integrovaného předpovědního systému ECMWF a byl prvním středně měřítkovým ensemblem s každodenním výpočtem v Evropě. Postupem času se model, stejně jako LAEF, vyvíjí a mění se jeho charakteristiky. Počet členů ensemblu vzrostl v roce 2016 na 20, přesto v práci je z důvodu konzistence počítáno se 16 členy pro celé sledované období. Horizontální rozlišení je od roku 2009 7 km² a vertikálně je model členěn do 40 vrstev. Horizont předpovědi je od roku 2005 132 hodin a doména modelu pokrývá velkou část Evropy (viz. obr.č.29 [11]). Model COSMO-LEPS není v současnosti nikterak využíván v operativní hydrologické předpovědi.



Obrázek 28: Integrační doména modelu (šedá plocha) COSMO-LEPS a klastrovací oblast (černá linie). Černé body představují SYNOP stanice určené k verifikaci modelu [11].

Na počátku výpočtů jsou shlukovou analýzou (Cluster Analysis and Representative Member Selection) vybrány predikce z tzv. super ensamble ECMWF, který je tvořen 153 členy s horizontálním rozlišením 80 km [87]. Podrobněji techniku shlukování ensamble popisuje Wilks [63]. Shlukovou analýzou je vybráno 20 členů na základě kterých jsou počítány COSMO-LEPS běhy. Zde jsou ještě před finálním výpočtem pertubovány fyziky modelu, respektive nastavení odchylek parametrů výchozích hodnot.

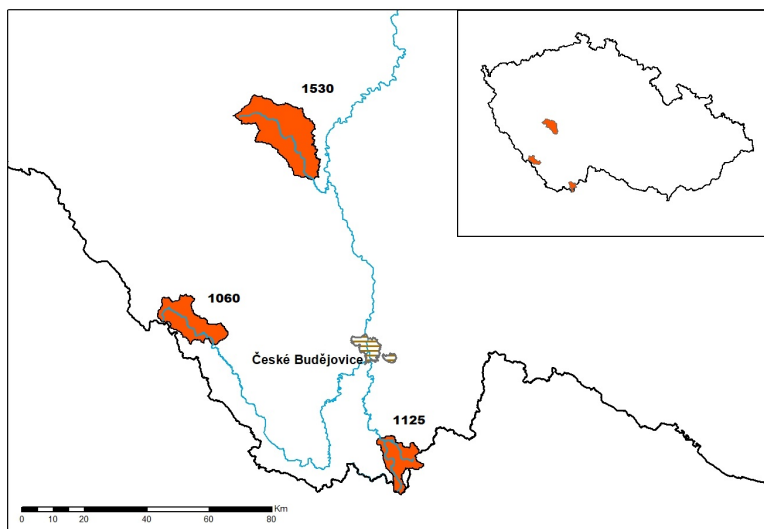
7.1.2 Měřené srážky

Pro účely kalibrace a verifikace byla použita data měřených srážek v podobě produktu MERGE2. Hodinové sumy srážek byly opět agregovány do 6 h kroku v souladu s predikčními modely. Informace k měřeným srážkám jsou popsány v kapitole 4.1.2.

7.1.3 Zájmová oblast

Vzhledem k nové metodologii výpočtu hydrologických modelů nejsou data ve třetí části práce agregována do 37 hydrologických oblastí, nýbrž přímo do

oblastí skutečných povodí. Povodí mají menší velikost, než původní hydrologické oblasti a jejich uzávěrovým profilem je vždy měrný profil, pro který je počítána hydrologická předpověď. Datové podklady byly získány pro 8 povodí v Jihočeském kraji, kde z důvodu náročnosti výpočtů došlo ke zúžení počtu na finální tři povodí, pro které byly zpracovány všechny metody kalibrace. Tato povodí jsou označena dle uzávěrového/měrného profilu jako 1060 - Lenora, 1125 - Ličov a 1530 Varvažov. Povodí 1060 pokrývá velkou část povodí Teplé Vltavy na Šumavě. Profil 1060 v Lenoře se nachází ve výšce 761.2 m n.m. Plocha povodí je 176.9 km² a průměrný průtok činí 3,11 m³s⁻¹. Jedná se o horské povodí s relativně pozvolným sklonem. Profil 1125 v Ličově se nachází ve výšce 585.2 m n.m. na toku řeky Černá. Plocha povodí je v tomto případě 126,45 km², tedy nejmenší z posuzovaných povodí. Průměrný průtok je 1,56 m³s⁻¹. Povodí se nachází převážně ve středních polohách a má opačnou orientaci oproti povodí 1060. Třetí povodí 1530 pokrývá téměř celé jižně orientované povodí řeky Skalice. Měrný profil 1530 ve Varvažově leží ve výšce 380 m n.m. Severní okraj povodí zasahuje do pohoří Brd, jinak se jedná o povodí nížinného charakteru s pozvolným sklonem. Plocha povodí 367,9 km² je největší z těchto tří povodí, přičemž průměrný průtok dosahuje pouze hodnoty 1,5 m³s⁻¹. Vybraná povodí tak reprezentují rozdílné nadmořské výšky a zároveň se liší i v dalších parametrech, jako například v rozloze, sklonu, expozici aj. Pro kalibraci může být výzva umístění povodí 1060 a 1125 v hraniční oblasti, kde je nižší spolehlivost jak měřených, tak předpovídaných dat.



Obrázek 29: Povodí vybraná pro kalibraci ensemblové předpovědi srážek. 1060: profil Lenora - Teplá Vltava, 1125: profil Ličov - Černá, 1530: Varvažov - Skalice

7.1.4 Porovnání modelu ALADIN-LAEF a COSMO-LEPS

V části II. této práce byla provedena podrobná verifikace modelů ALADIN-CZ a ALADIN-LAEF a porovnání jejich vzájemného vztahu. Vzhledem k využití modelu COSMO-LEPS pro tvorbu multimodelu a kalibraci předpovědi srážek je nezbytné provést jeho verifikaci a porovnání vzájemných charakteristik obou ensemblových modelů před provedením samotné kalibrace, abychom byli schopni po kalibraci správně interpretovat výsledky. Verifikace těchto dvou modelů byla provedena na data-setu připraveném pro kalibraci. Tzn. srážková měřená data a předpovědi agregované do oblastí vybraných povodí v 6 h kroku pro horizont předpovědi 54 h. Hranice akumulace srážek pro binární metody byly opět stanoveny na 1, 2.5, 5 a 10 mm. V tomto případě byl k dispozici obsáhlejší datový soubor skládající se z 17 běhů modelu ALADIN-LAEF a 16 běhů COSMO-LEPS. Po spárování predikcí s měřenými srážkami vzniklo téměř 7.5 milionu dvojic. Výsledky verifikace těchto dvou modelů jsou prezentovány jako průměrné skóre jednotlivých členů ensemblu. Tzn., že verifikační skóre bylo vypočteno pro každý člen a poté zprůměrováno do jedné hodnoty za celý soubor předpovědí. Výjimkou jsou skóre BS a RPS, kde již do výpočtu vstupují data z celého ensemblu a výsledkem je jedna hodnota. Podrobný popis verifikačních metod je popsán ve II. části práce a

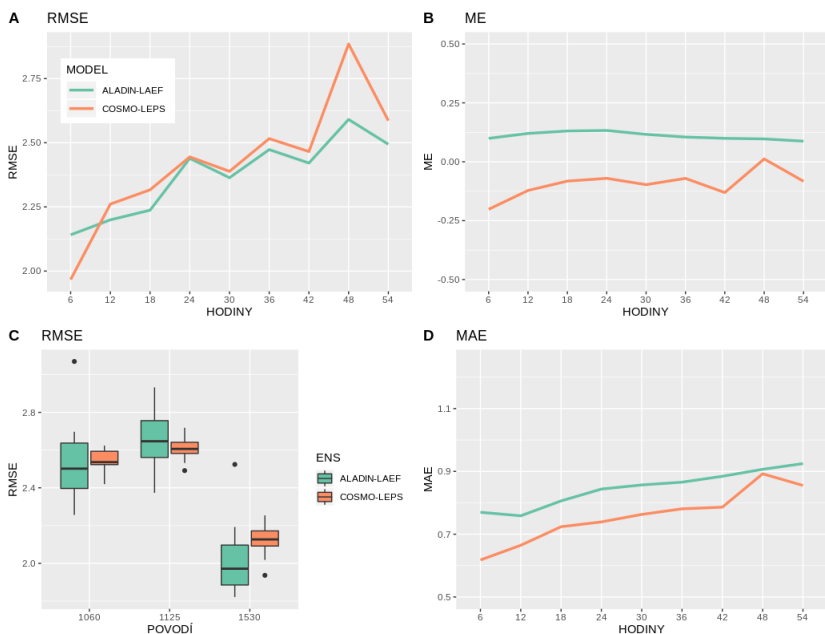
tato kapitola se věnuje pouze výslednému srovnání ensemblových modelů.

Skóre pro kontinuální hodnoty

Metriky RMSE, ME a MAE jsou založeny na podobném přístupu, kdy jsou přímo hodnocena residua v rozdílu predikovaných a měřených hodnot. RMSE díky druhé mocnině dává důraz na residua vyšších hodnot. Z grafu v obr. č.30-A je patrný velmi malý rozdíl mezi ensembly ALADIN-LAEF a COSMO-LEPS. V obou případech dochází k větším nepřesnostem s rostoucí dobou předpovědi. O něco vyšší chybovost vykazuje COSMO-LEPS model na horizontu předpovědi 48 h. Naproti tomu ALADIN-LAEF potvrzuje výsledky ze druhé kapitoly této práce a prezentuje se horšími predikcemi v nejbližším horizontu 6 h a nejlepšími predikcemi na 12 h. Výsledky RMSE pro jednotlivá povodí na obr. č.30-C odhalují například evidentně nižší rozptyl chybovosti modelu COSMO-LEPS, nikoliv však vyšší přesnost. Z výsledků je také zřejmý vliv polohy povodí na přesnost předpovědi. Povodí která se nacházejí přímo u hranic (1060, 1125) mají vyšší chybovost, než povodí 1530, které leží ve vnitrozemí. Důvodů horších výsledků může být několik. Jednak na straně předpovědi, kde zejména v létě jsou tato povodí vystavena vyšší četnosti lokálních konvektivních srážek, které mají velmi vysokou prostorovou variabilitu. Důvodem však může být i nepřesnost měřených srážek, resp. produktu Merge2. A to opět z důvodu vysoké prostorové variability, kdy srážky nemusí být plošně správně změřeny sítí srážkoměrných stanic nebo naopak nepřesným odvozením srážek z radarových odrazů. V horských oblastech a ve větších vzdálenostech od radaru dochází ke stínění radarových odrazů.

Dalším srovnáním dat v podobě kontinuálních veličin je střední chyba (Mean Error-ME) a střední absolutní chyba (Mean Absolute Error-MAE). Na první pohled velmi podobné přístupy hodnocení poskytují zásadně odlišné pohledy na chování modelů. Hraniční hodnotou pro ME je hodnota nula, pokud je skóre vyšší, model častěji nadhodnocuje, pokud je skóre nižší, model častěji podhodnocuje. Pokud je hodnota velmi blízko nule, neznamená to, že model předpovídá přesně. Může se jednat o rovnoměrné rozložení nepřesností směrem k nadhodnocování i podhodnocování a chyby modelu tak mohou být skryty. V tomto případě lze z výsledků vyčíst, že model ALADIN-LAEF odhaduje srážek nadhodnocuje. Ze zkušeností se jedná zejména o bezsrážková období, kdy část běhů stále predikuje určité množství srážek. Naopak při významných srážkových událostech dochází často k podhodnocení úhrnů, jak je pospáno ve II. části této práce. Naopak COSMO-LEPS vykazuje mírné podhodnocování srážek. V závislosti na horizontu předpovědi nedochází u obou modelů k výraznému zhoršení, dokonce naopak, modely se lehce přibližují k nulové hodnotě. Skóre MAE (stejně jako RMSE) neposkytuje informaci o případném systematickém nadhodnocování či podhodnocování předpovědí, ale díky absolutní hodnotě, na rozdíl od ME, chyby neprůměruje. Výsledky

MAE (obr.č.30-D) již prokazují rostoucí tendenci chybovosti v závislosti na čase. Průběh mají oba modely velmi podobný, přičemž model COSMO-LEPS se prezentuje obecně nižší chybovostí. Z těchto výsledků vychází otázka, z jakého důvodu jsou skóre modelu COSMO-LEPS mírně horší než skóre modelu ALADIN-LAEF pro RMSE a naopak lepšího skóre dosahují u MAE? Jelikož RMSE umocňuje residua na druhou, příkládá vyšší váhu vyšším residuům. Lze tedy vyvodit, že model COSMO-LEPS trpí vyšší nejistotou v predikci vyšších úhrnů v porovnání s ALADINEM-LAEF, ale naopak v predikci nižších úhrnů predikuje lépe, viz. MAE.

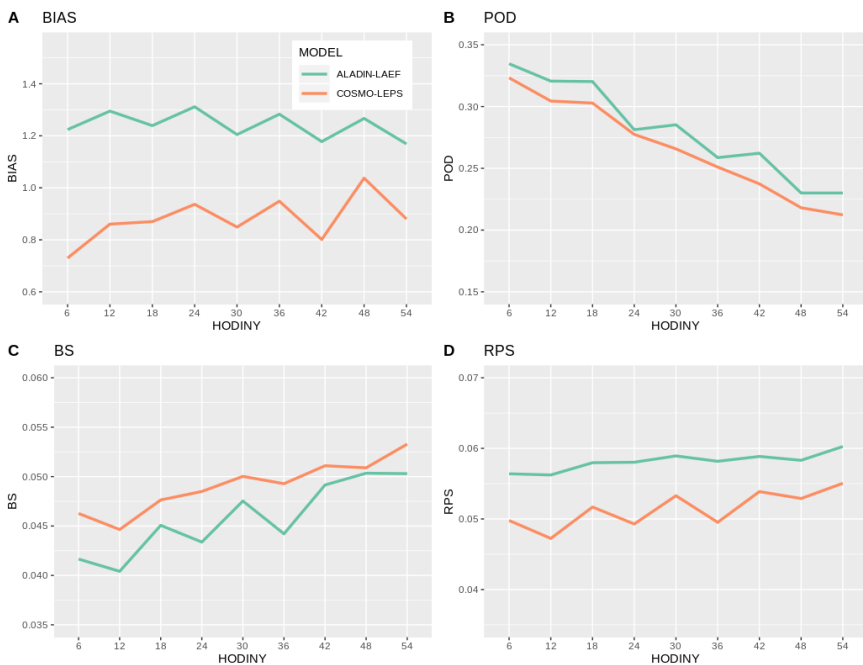


Obrázek 30: Porovnání ensemblových modelů ALADIN-LAEF (zelená barva) a COSMO-LEPS (oranžová barva) v rámci jednotlivých skóre (RMSE - Root Mean Square Error A, Mean Error B a Mean Absolute Error D) v závislosti na čase. Boxplot RMSE (C) popisuje úspěšnost v jednotlivých povodích 1060, 1125 a 1530.

Skóre pro binární hodnoty

Pro hodnocení binárních veličin byly stanoveny srážkové prahy na 1, 2.5, 5 a 10 mm. Pokud daný práh měl být dle předpovědi překročen, předpověď dostala přiřazenou hodnotu 1. Pokud k překročení dojít nemělo, dostala hodnotu 0. Stejným způsobem byly ohodnoceny i měřené srážky. Do výsledného

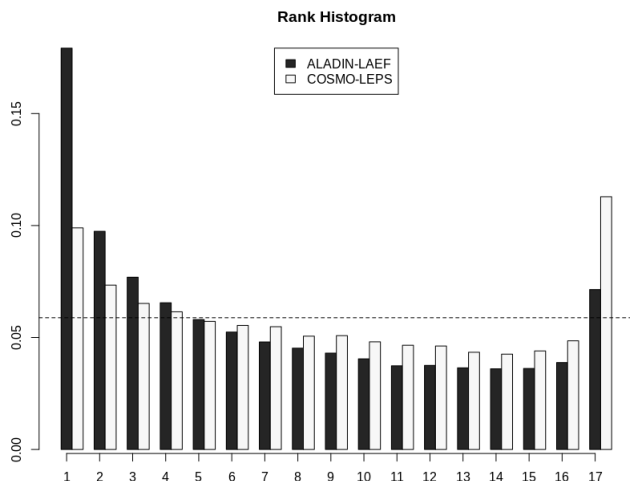
hodnocení vstupovaly hodnoty pro všechny prahy, které tedy nebyly hodnoceny samostatně. Prvním binárním kritériem je Bias, nebo také Frequency Bias Score (obr.č.31-A), který je poměrem počtu predikovaných výskytů překročení stanoveného srážkového prahu a počtu měřených výskytů. Ideální skóre je tedy 1, méně než jedna znamená podhodnocování modelu a více než jedna nadhodnocování modelu. V tomto případě výsledky navazují na skóre ME. Model ALADIN-LAEF nadhodnocuje své predikce, přičemž od druhé poloviny časového horizontu se míra nadhodnocování snižuje. Naopak model COSMO-LEPS se jeví jako podhodnocující, avšak odchylka od neutrální hodnoty 1 je nižší, než v případě ALADIN-LAEF. Skóre Probability of detection - POD (obr.č.31-B) posuzuje schopnost modelu správně detekovat události, resp. množství srážek. V tomto ohledu je nepatrně úspěšnější model ALADIN-LAEF. U obou modelů klesá schopnost detekce s rostoucím horizontem předpovědi stejným tempem. Brier score - BS je metrika velmi podobná RMSE, modifikována pro binární data. Výsledek popisuje velikost chyby pravděpodobnostní předpovědi v rozmezí 0-1, ideální skóre je 0. V našem případě má k nule o něco blíže model ALADIN-LAEF, i když rozdíl je velmi malý. Chybovost opět mírně roste s rostoucím časovým horizontem. Poslední variantou posouzení úspěšnosti kategorické předpovědi je Ranked probability score - RPS (obr. č. 31-D), kde ideální skóre je 0. V tomto ohledu je nepatrně úspěšnější model COSMO-LEPS. Změna úspěšnosti předpovědi v závislosti na horizontu předpovědi je pro tento případ neznatelná.



Obrázek 31: Porovnání ensemblových modelů ALADIN-LAEF (zelená barva) a COSMO-LEPS (oranžová barva) ve formě binární předpovědi v rámci jednotlivých skóre v závislosti na čase. A-Bias, B-Probability Of Detection, C-Brier Score, D-Ranked Probability Score)

Rank histogram

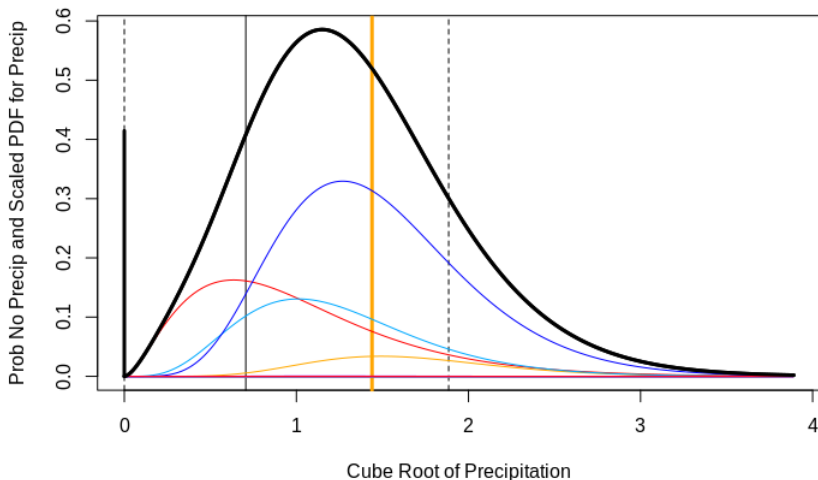
Rank histogram poskytuje informaci o rozptylu ensemblové předpovědi. Na obr. č. 32 jsou černou barvou zobrazeny hodnoty pro model ALADIN-LAEF a bílou barvou pro model COSMO-LEPS. Diagram ve tvaru písmene "U" značí nedostatečný rozptyl. Rozdíl mezi modely je zřejmý zejména na krajních hodnotách, kdy měřené hodnoty jsou často nižší, než je rozptyl modelu ALADIN-LAEF a naopak vyšší než je rozptyl modelu COSMO-LEPS.



Obrázek 32: Společný rank histogram pro ALADIN-LAEF a COSMO-LEPS.

7.2 Výpočet kvantilové předpovědi srážek využitím BMA metody

Postprocessing ensemblové předpovědi byl proveden, stejně jako ostatní výpočty, v R programu, a to pomocí balíku `ensembleBMA()`. Tento R balík pro pravděpodobnostní předpovědi používá BMA ensemblový postprocessing. Parametry modelu mohou být odhadovány jak pro veličiny s normálním rozdělením (teplota, tlak), tak pro veličiny s gamma rozdělením, které má své těžištěm u hodnoty 0 (srážky). Také nabízí možnost výpočtu předpovědi, která byla využita v podobě kvantilové predikce [73, 88]. V prvním kroku je nutné vytvořit datový objekt predikcí a měřených hodnot v odpovídajícím formátu pomocí funkce `ensembleData()`. Nastavuje se zde časový krok, počáteční čas, časový úsek a jiné. V této modifikované struktuře vstupují data do funkce `ensembleBMA()`, kde dochází k nařizování BMA modelu. Zde je důležité zvolit správný typ modelu, pro náš případ `model="gamma0"`. Funkce poté vytváří model a BMA prediktivní rozdělení pro každý termín. Ukázka pro jeden termín je zobrazena na obr. č.33 [89]. V posledním kroku je generována kvantilová předpověď pomocí funkce `quantileForecast()`, do kterého vstupuje nařizovaný model, datový objekt vytvořený funkcí `ensembleData()` a vektor požadovaných kvantilů (v našem případě 0.1, 0.3, 0.5, 0.7 a 0.9). Funkce vrací vektor předpovědí odpovídajících zadaným kvantilům.



Obrázek 33: Ukázka BMA prediktivní distribuce pro srážky v termínu 2017103000 pro povodí 1060. Silná černá křivka je BMA funkce hustoty pravděpodobnosti(PDF), zatímco barevné křivky představují vážené funkce hustoty pravděpodobnosti jednotlivých členů. Tenká vertikální linie je medián BMA PDF, přerušované vertikální linie vymezují 10. a 90. percentil. Oranžová vertikální linie je měřená hodnota. Vertikální silná křivka v bodě 0 znázorňuje pravděpodobnost nulových srážek (42%).

7.3 Kalibrace předpovědi srážek využitím neuronové sítě

Pro kalibraci modelu pomocí neuronových sítí byl použit R balík AMORE. Zvolen byl přístup, kde jako vstup je poskytnut soubor předpovědí, ze kterého má být vyvozen jeden výstup - měřená srážka. Balík využívá metodu TAO-robustního algoritmu neuronové sítě k vytváření dopředných umělých neuronových sítí [90]. Do výpočtu vstupuje opět data-set ensemblových predikcí a měřených dat. Nejprve je potřeba nastavit základní parametry a strukturu pro tvorbu neuronové sítě. Příkazem `newff()` se zadává numerický vektor obsahující počty neuronů v každé vrstvě. První - vstupní vrstva obsahuje stejný počet neuronů, jaký je počet členů předpovědního modelu. Následují skryté vrstvy. Pro všechny výpočty byly určeny dvě skryté vrstvy, počet neuronů se liší na základě počtu neuronů vstupní vrstvy. Tyto počty byly stanoveny na základě testování na vzorku dat a vybrána byla nejúspěšnější kombinace (vztaženo k hodnotícímu skóre v rámci této funkce). Posledním číslem vektoru

je počet výstupních neuronů, v našem případě číslo 1. Dále je nutné nastavit kritérium, podle kterého neuronová síť hodnotí, jak moc se blíží predikce měřeným hodnotám. Nejlepší učící efektivitu vykazovalo kritérium LMS - Least Mean Squares. Po nastavení zbývajících parametrů (aktivační funkce, míra učení a další) je vytvořen objekt neuronové sítě, který je společně s data-setem hlavním vstupem do následující funkce `train()`. Tato funkce spouští výpočet, neboli učení neuronové sítě a po dokončení výpočtu vrací dva prvky. Prvním je natrénovaný objekt neuronové sítě s váhami a biasem zpřesněným adaptivní zpětnou propagací s metodou hybnosti. Druhým je matice s chybami obdrženými během trénování [91]. V posledním kroku je provedena simulace srážek funkcí `sim.MLPnet()`. Do funkce vstupuje natrénovaná neuronová síť a data-set ensemblových predikcí. Ensemblové predikce zastávají funkci prediktorů, ze kterých je na základě natrénované neuronové sítě simulován jeden prediktant - tzn., že ve výsledku dostaneme deterministickou předpověď srážek. Jako trénovací set byla vybrána data z let 2012, 2013, 2017 a 2018. Ostatní data byla použita jako validační set.

7.4 Přímý výpočet průtoků využitím neuronové sítě

Učení neuronové sítě (NS) probíhá na základě poskytnutí vzorových dat, kde NS hledá nejpřesnější vztah mezi vstupem (v našem případě předpověď srážek) a výstupem (měřené srážky). Trénovacímu algoritmu nezáleží na tom, zda hledá vztah mezi předpovědí srážek a měřenými srážkami nebo nějakou úplně jinou veličinou. Proto v rámci práce byl mimo jiné aplikován výpočet neuronové sítě na vztah predikce srážek - predikce průtoků. Vstupní vrstva je tedy opět stejná jako v kapitole 7.3, ale výstupní vrstvu měřených srážek nahrazují měřené průtoky příslušící uzávěrovému profilu vybraných povodí. V tomto případě je však nutné podchytit dobu zpoždění odezvy toku na spadlé srážky. Nelze použít stejný časový vztah, jako u předpovědi srážek na určitý čas a jejich měření v tu samou dobu. Neuronová síť páruje vstupní data vždy ve stejném čase, proto bylo potřeba posunout hodnoty průtoků Q v čase t na čas $t - t_i$, kde t_i představuje časový interval mezi spadnutím srážky do povodí a a způsobenou odezvou na toku v uzávěrovém profilu. Zde vyvstaly dvě překážky. První byla limitace předpovědi srážek na 6 h akumulace a ve stejném kroku byly přiřazeny i hodnoty průtoků. Další problém je rozdílná doba odezvy na jednotlivých povodích. Vzhledem k těmto okolnostem se jako nejefektivnější ukázalo posunutí hodnot průtoků o jeden časový interval, tedy o 6 h zpět. Pro trénování neuronové sítě byly tedy vstupem predikce srážek a měřené průtoky posunuté o jeden časový interval t_i zpět. Další postup byl stejný jako v kapitole 7.3 a výstupem simulace byly průtoky odhadnuté neuronovou sítí na základě predikcí srážek.

7.5 Vybrané kombinace a varianty postprocesovaných předpovědí srážek

Předpoklad při tvorbě kombinací modelů byl takový, že rozšířením o každou další postprocesingovou metodu dojde ke zlepšení výsledků. K závěrečnému hodnocení bylo vybráno několik variant předpovědí srážek, u kterých byla hodnocena úspěšnost předpovědi srážek, v některých případech i průtoků. V operativní hydrologii je v ČHMÚ používán deterministický model ALADIN-CZ a částečně model ALADIN-LAEF. Tyto dva modely byly základním pilířem pro všechny postprocesingové metody. Postup postprocesingu byl takový, že byly vybrány 4 charakteristicky odlišné kombinace předpovědí a modelů predikujících srážkové úhrny. Jednalo se o kombinace deterministické předpovědi modelu ALADIN-CZ, ensamble ALADIN-LAEF, ensamble COSMO-LAEF a BMA kvantilové předpovědi vypočtené z multimodelu sestaveného z modelů ALADIN-CZ, ALADIN-LAEF a COSMO-LEPS. Tyto 4 varianty byly poté vstupem do neuronové sítě a na základě přiřazeného výstupu (měřené srážky nebo měřené průtoky) byly neuronovou sítí počítány postprocesované deterministické varianty předpovědi srážek nebo přímo průtoků. Vybrány byly následující kombinace (v závorkách jsou uvedeny zkratky, které jsou pro přehlednost používány v dalších kapitolách):

- **ALADIN-CZ (ACZ) + ALADIN-LAEF (AL) ⇒ 18 členů**

Kombinace těchto dvou modelů je používána v rámci hydroprognózy ČHMÚ

- **ALADIN-CZ (ACZ) + Kvantilová předpověď (QF) ⇒ 6 členů**

Druhá kombinace využívá deterministického modelu ACZ a pomocí BMA metody přiřazuje k souboru kvantilové předpovědi (QF) vytvořenou z multimodelu pro kvantily 0.1, 0.3, 0.5, 0.7 a 0.9.


- **ALADIN-CZ (ACZ) + ALADIN-LAEF (AL) + COSMO-LEPS (CL) ⇒ 34 členů**

- **ALADIN-CZ (ACZ) + ALADIN-LAEF (AL) + COSMO-LEPS (CL) + Kvantilová předpověď (QF) ⇒ 39 členů**

Výběru těchto kombinací předcházelo testování různých variant, u kterých byl předpokládán pozitivní dopad a přínos pro hydrologické modelování a i samotnou přesnost srážek. Testována byla například časová alokace predikcí, kdy byl vytvořen nový model posunutím předpovědi o jeden časový krok (6h) dopředu a další model s posunutím o jeden krok zpět. Snaha bylo postihnout nejistoty zejména v případě lokálních konvektivních jevů, kde jejich doba výskytu může být variabilní i přes úspěšnou lokaci modelu. Zlepšení výsledků bylo do jisté míry zaznamenáno, nebylo však takové jako u vybraných

variant. Na obr. č. 34 je ukázka testování, které probíhalo pomocí jednoduchých chybovým metrik RMSE, MAE a ME, na datech pro finální kalibraci neuronovou sítí. Toto testování pro výběr vhodných kombinací probíhalo na vzorku dat s horizontem předpovědi 6 h a povodí č. 1060. První sloupce reprezentují deterministický ALADIN-CZ bez jakékoliv kalibrace. Další sloupce reprezentují chybovost deterministické předpovědi vypočtené neuronovou sítí pro výše zmíněné kombinace modelů.

V případě testování variant pro přímý výpočet průtoků neuronovou sítí byly do vstupní vrstvy přidány k předpovědím i aktuální průtoky, což se pro správný výpočet predikovaného průtoku ukázalo jako stěžejní. Pro srovnání byly výpočty provedeny i pro soubory vstupních dat bez informace o aktuálním průtoku. Následující kapitoly popisují výsledky a hodnocení výpočtů předpovědi srážek a předpovědi průtoků.



Obrázek 34: Graf zobrazuje hodnoty jednotlivých skóre RMSE, MAE a ME pro kombinace modelů ACZ (ALADIN-CZ), AL (ALADIN-LAEF), CL (COSMO-LEPS) a QF (kvantilovou předpověď). Skóre jsou počítány na vzorku dat za účelem výběru kombinací modelů.

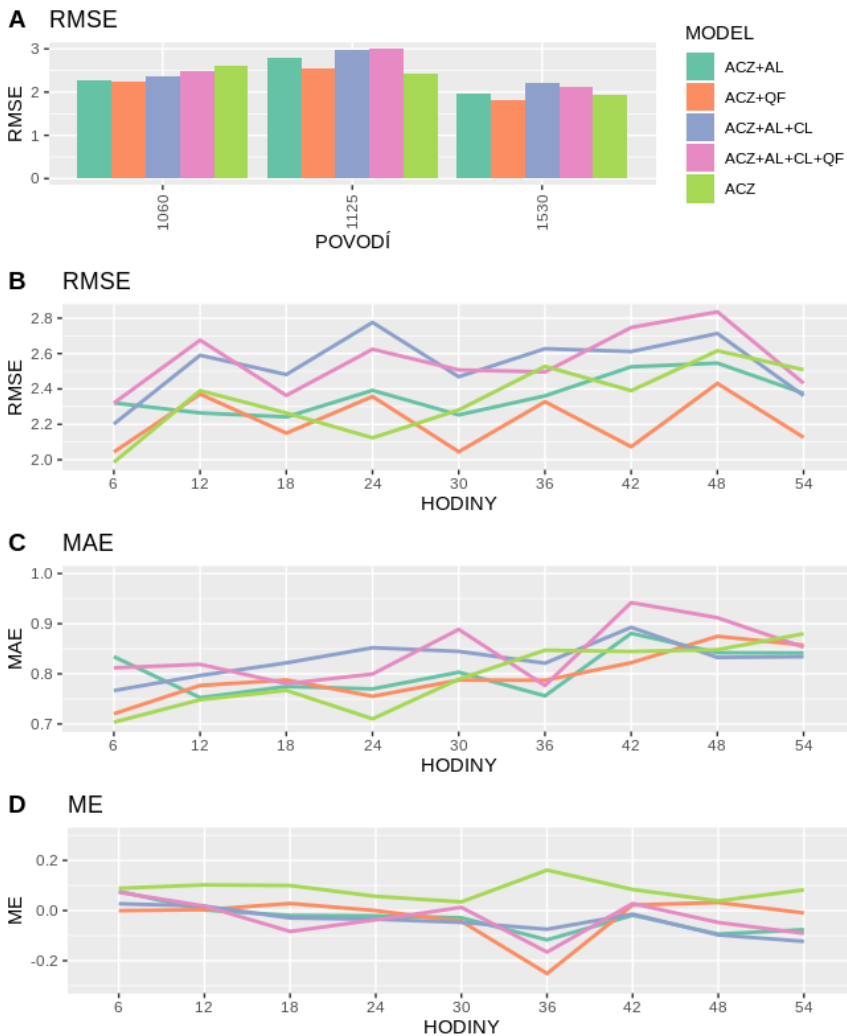
8 Výsledný dopad kalibrace a postprocessingu na přesnost srážkových předpovědí

Kalibrace ensemblových modelů je standardní postup vedoucí k odstranění systematických chyb v souboru předpovědí. V této práci byl zvolen netradiční přístup ke kalibraci testováním kombinací různých postprocessingových metod. Tato kapitola popisuje úspěšnost výsledných postprocesovaných předpovědí srážek 4 různých kombinací typů předpovědí oproti deterministickému modelu ALADIN-CZ, který nebyl nikterak kalibrován. Hodnoceny byly kombinace ALADIN-CZ + ALADIN-LAEF (ACZ+AL), ALADIN-CZ + BMA kvantilová předpověď (ACZ+QF), ALADIN-CZ + ALADIN-LAEF + COSMO-LEPS (ACZ+AL+CL) a ALADIN-CZ + ALADIN-LAEF + COSMO-LEPS + BMA kvantilová předpověď (ACZ+AL+CL+QF). V textu dále budou pro přehlednost uváděny zkratky modelů. Deterministický model ALADIN-CZ je základním pilířem každé kombinace z důvodu jeho využívání pro hydrologickou predikci. Zmíněné kombinace prošly během postprocessingu vývojem, kdy se z vytvořených multimodelů, vzniklých sloučením ensemblů, stala na základě výpočtu neuronové sítě deterministická předpověď. Její možné využití, výhody a nevýhody oproti pravděpodobnostní předpovědi, která je podstatou ensemblu, jsou diskutovány v závěru práce. Verifikovány byly sumarizované předpovědi srážek v 6h kroku pro horizont předpovědi 54h a počátečním časem 00h a 12h. Data pokrývají letní část roku od začátku dubna do konce října. Data z let 2012, 2013, 2017 a 2018 byla využita k trénování neuronových sítí, z tohoto důvodu je verifikace provedena na datech z let 2014, 2015 a 2016, která byla vyčleněna jako validační set. Hodnocení bylo stejně jako ve druhé části práce rozděleno do dvou kategorií. První kategorií je hodnocení kontinuálních veličin pomocí RMSE, MAE a ME. Druhou kategorií jsou předpovědi převedené na binární hodnoty dle stanovených srážkových prahů pro 1, 2.5, 5 a 10 mm a skóre BIAS, ETS, POD a FAR. Charakteristiky těchto verifikačních metrik jsou podrobně popsány v kapitole 3.3.

8.1 Verifikace postprocesovaných předpovědí srážek a modelu ALADIN-CZ

Vztah mezi modelem ALADIN-CZ a ALADIN-LAEF je podrobně charakterizován ve druhé kapitole této práce. Metodologický rozdíl mezi verifikací v této a ve druhé kapitole je zejména prostorové rozlišení, kdy nyní jsou data agregována do menších povodí. Dalším zásadním rozdílem je rozsah dat, kdy ve druhé kapitole byly vybrány pouze srážkové situace na základě měřených dat, v této kapitole byla verifikována kompletní data obsahující i bezsrážková období. Na obrázku č.35 jsou zobrazeny chybové metriky pro kontinuální ve-

ličiny v závislosti na oblasti (A) a horizontu předpovědi (B,C,D). Část A je popisem střední kvadratické chyby v jednotlivých povodích. Z výsledků je patrné, že nejnižší chybovosti bylo dosaženo v povodí č. 1530, které je nížinného charakteru, polohou ve vnitrozemí a s nižším průměrným úhrnem srážek. Naopak nejvyšší chybovost v průměru vykazuje povodí 1125. Zajímavostí je, že právě v tomto povodí je ACZ nejúspěšnější v porovnání s ostatními kalibrovanými předpověďmi. V povodí 1060 dosahuje nejnižší chybovosti model ACZ+QF (stejně jako v povodí 1530), zatímco ACZ je v tomto případě nejhorší. Úspěšnost modelu ACZ v tomto případě klesá s rostoucí průměrnou výškou povodí.



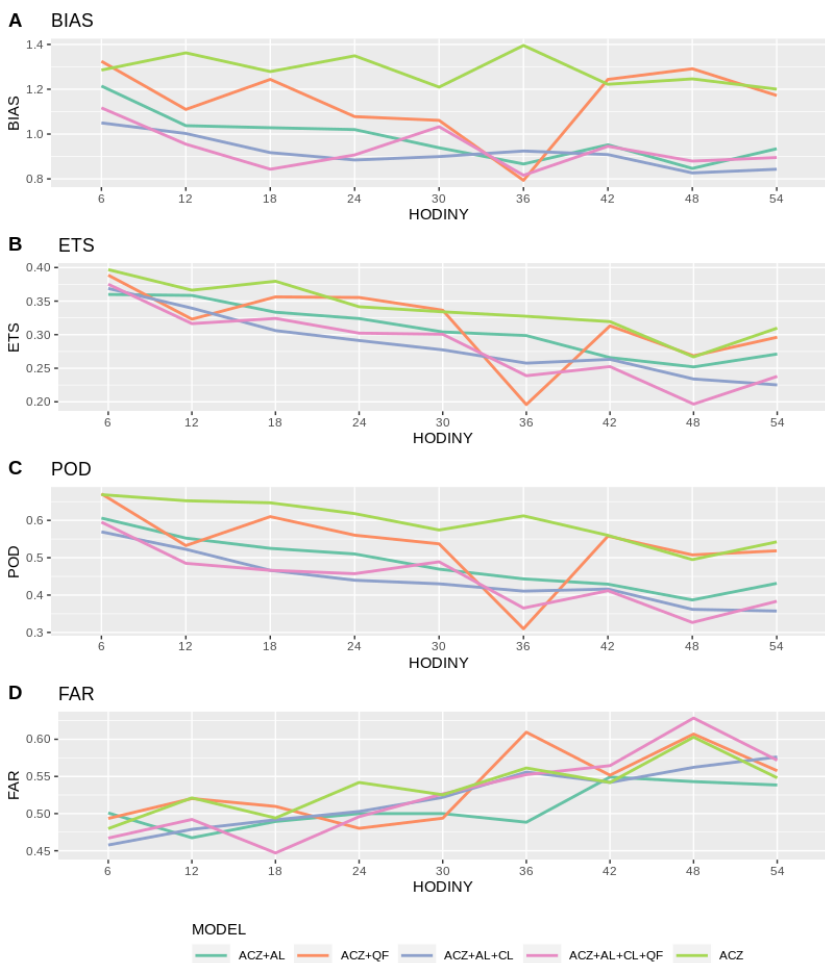
Obrázek 35: Grafické znázornění výsledků verifikace kontinuálních veličin. Graf A zobrazuje výsledky RMSE pro jednotlivé kombinace modelů v jednotlivých povodích. Graf B, C a D zobrazuje skóre RMSE, MAE a ME v závislosti na horizontu předpovědi.

Na obr. č.35 B je zobrazeno RMSE pro všechna povodí dohromady, stejně jako u následujících grafů. Chybovost s rostoucím časem má mírně rostoucí trend, vyjma modelu ACZ-QF. Stejně jako v jednotlivých povodích, nejhůře hodnocená je dvojice modelů ACZ+AL+CL a ACZ+AL+CL+QF. Je však

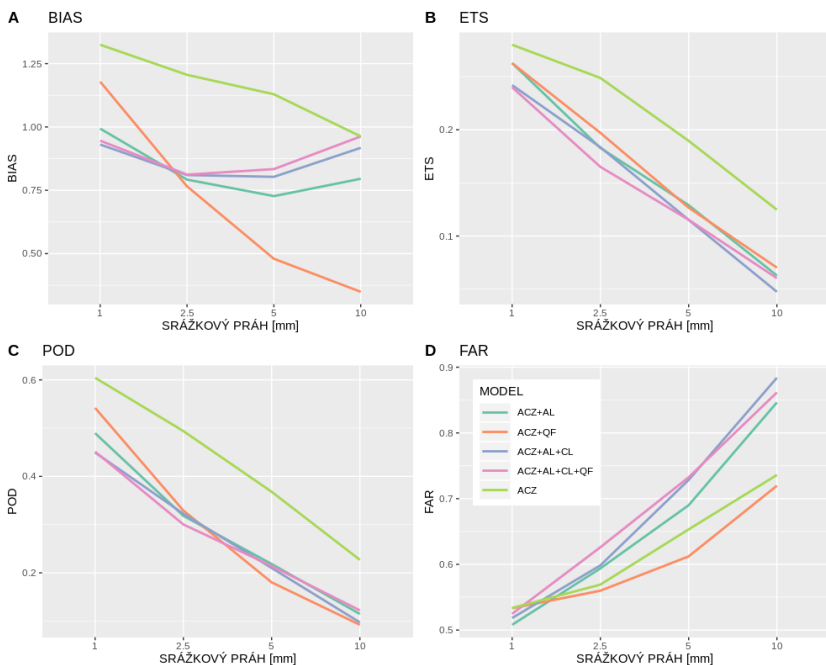
třeba podotknout, že odchylky v této kvadratické metrice se pohybují v řádu pouze několika desetin mm. Ještě vyrovnanější výsledky lze vyčíst z grafů C-MAE a D-ME. Růst chybovosti v závislosti na čase je potvrzen i v případě MAE. Na pozoruhodnou anomálii v datech modelu ACZ poukazují výsledky ME. Model vykazuje vyšší kladné odchylky na horizontu předpovědi 36h. Resp. právě na 36h se v letech 2012, 2013 a 2015 vyskytují silně pozitivní odchylky, kdy je modelem predikován vysoký úhrn, ačkoliv měřené hodnoty srážek jsou často nulové. Tyto chyby se negativně promítli do trénování neuronové sítě a jsou patrné nejvíce na datech modelu ACZ+QF. Důvodem je nejnižší počet členů (ACZ-1, QF-5) a tedy i vyšší váha modelu ACZ. Vysoká pozitivní chybovost měla opačný dopad na učení neuronové sítě, která chybu kompenzuje nižšími hodnotami právě na horizontu 36h. Tato anomálie je podrobněji popsána v textu níže. Ze skóre ME lze vyčíst, zda model nadhodnocuje nebo podhodnocuje své předpovědi. Pouze model ACZ v celém předpovědním horizontu mírně nadhodnocuje, zatímco ostatní modely mají z počátku chybovost vyrovnanou (hodnoty blízko 0) a s rostoucím časem začínají mírně podhodnocovat.

Obr. č.36 zobrazuje výsledky verifikačních skóre binárních hodnot a to pro všechny srážkové prahy (1, 2.5, 5 a 10 mm) dohromady v závislosti na rostoucím časovém horizontu předpovědi. Graf A - znázorňuje skóre pro BIAS, kde ideální skóre je 1. Vyšší hodnoty znamenají nadhodnocování modelu, v tomto případě se jedná opět o model ACZ a ACZ-QF. Ostatní modely s rostoucím časovým horizontem opět tíhnou k podhodnocování, což odpovídá výsledkům skóre ME. ETS skóre cílí na správně predikované hodnoty a jeho ideální skóre je 1. Stejně jako v případě POD, které cílí na předpověď vyskytlých jevů, nejlepších výsledků dosahují modely ACZ a ACZ+QF. Patrná je opět anomálie na 36h. Opakem k POD skóre je FAR skóre, které se zaměřuje na falešné alarmy. Ideální skóre je 0 a i přes velmi vyrovnané výsledky je zřejmé, že v tomto případě není ACZ úspěšný. To odpovídá jeho tendenci nadhodnocovat předpovědi a tím pádem větší pravděpodobnosti falešného alarmu, tedy předpovídání úhrnu, který nebyl ve skutečnosti dosažen.

Obr. č.37 doplňuje informace ohledně závislosti přesnosti předpovědi na velikosti úhrnu. Je patrné, že s rostoucím srážkovým prahem klesá rovnoměrně úspěšnost všech predikcí. Výsledky jsou oproti hodnocení závislosti úspěšnosti na horizontu předpovědi zkrácené tím, že čím vyšší je srážkový práh, tím méně nenulových hodnot je k dispozici k výpočtu skóre.



Obrázek 36: Grafické znázornění výsledků verifikace binárních veličin v závislosti na horizontu předpovědi. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.



Obrázek 37: Grafy výsledků verifikace binárních veličin v závislosti na rostoucím srážkovém prahu. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.

Jelikož rozdíly ve výsledcích nejsou velké a z grafů nelze jednoznačně stanovit celkovou úspěšnost jednotlivých modelů, byla pro přehlednost vytvořena tabulka č.4. V této tabulce je vždy uvedena jedna výsledná hodnota skóre pro každý model. Zelenou barvou jsou označeny nejlepší hodnoty. Výsledky jsou poměrně jednoznačné. Ze sedmi hodnotících kritérií je hned čtyřikrát nejlepší model ACZ+QF, a to v případech RMSE, MAE, ME a BIAS. Dvakrát byl nejúspěšnější deterministický nekalibrovaný model ACZ v případě ETS a POD. Pouze pro skóre FAR dosáhl nejlepšího výsledku model ACZ+AL+CL+QF a to zřejmě z toho důvodu, že jeho predikce více podhodnocují skutečný stav. Tím pádem je snížena pravděpodobnost falešného alarmu. Model ACZ dosáhl nejlepších hodnot v případě binárních skóre ETS a POD, kde k úspěchu pomohlo převedení na binární data a vyšší pozitivní odchylky nemají váhu. Například pro srážkový práh 10 mm má přiřazenou hodnotu "1" model předpovídající 11 mm stejně jako model předpovídající například 50 mm. Takto vysokých predikcí není mnoho, nemělo smysl volit vyšší srážkové prahy než 10 mm.


Skóre	ACZ+AL	ACZ+QF	ACZ+AL+CL	ACZ+AL+CL+QF	ACZ
RMSE	2.315	2.159	2.509	2.515	2.384
MAE	0.785	0.777	0.811	0.821	0.799
ME	-0.015	-0.006	-0.0196	-0.014	0.127
BIAS	0.571	0.857	0.429	0.714	1.286
ETS	0.308	0.362	0.050	0.431	0.515
POD	0.428	0.571	0.143	0.571	0.856
FAR	0.249	0.333	0.665	0.200	0.333

Tabulka 4: Tabulkový přehled výsledků verifikace. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.

8.2 Verifikace na příkladu vybraných událostí

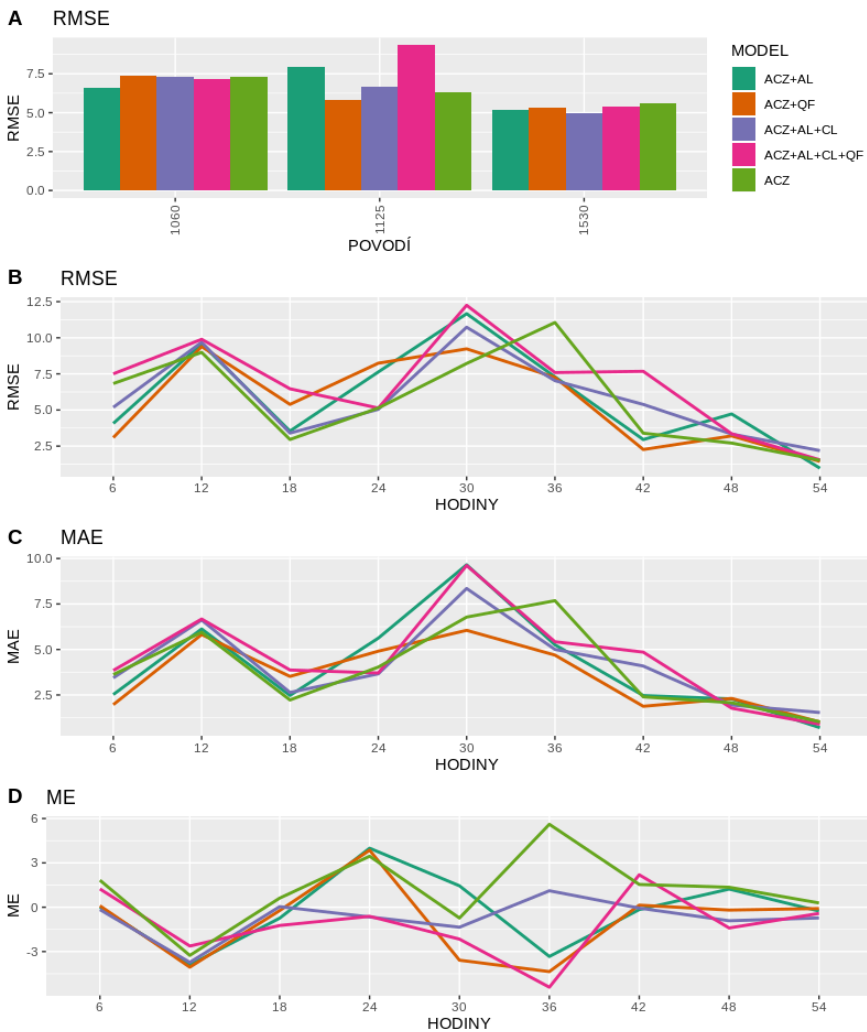
Hodnocení v kapitole 8.1 bylo provedeno na kompletním datasetu předpovědí, který obsahoval jak srážkové události tak bezdeštná období. V této kapitole jsou podrobněji podrobeny verifikaci tři vybrané srážkové události za účelem porovnání výsledků z kapitoly 8.1 a výsledků hodnocení modelů při situacích, kdy jsou jejich predikce nejvíce důležité pro hydrologické modelování.

Události byly vybrané na základě kritéria výskytu významných srážek ve všech třech povodích ve stejný termín. Tuto podmínku splňovalo pouze několik událostí, přičemž vybrány byly události začínající v termínech 27.5.2014, 22.10.2014 a 19.5.2015. Vybrán byl vždy jeden běh kalibrovaného modelu a modelu ALADIN-CZ s horizontem předpovědi 54 h. K dispozici byly tedy opět čtyři varianty kalibrovaných předpovědí a ACZ. Srovnání sumarizovaných predikcí s měřenými srážkami je zobrazeno na obr. č. 38. Srážkové úhrny ve vybraných událostech se pohybovaly od 19 do 57 mm. Vybrány byly plošné události, jednalo se tedy o přechod rozsáhlejších srážkových pásem pod vlivem tlakových níží a nejednalo se o lokální konvektivní jevy. Již na první pohled je patrná proměnlivá úspěšnost jednotlivých modelů. Modely se střídají v nadhodnocování i podhodnocování sumy srážek, v případě události 27.5.2014 dochází například k situaci, kdy pro povodí 1225 všechny modely srážkové úhrny nadhodnocují, zatímco pro povodí 1530 všechny modely srážkový úhrn podhodnotily. Dokazuje to vysokou prostorovou variabilitu srážek, ale také časovou. Jako například v události 22.10.2014 v povodí 1125, kde dochází k přesné predikci celkové sumy modelem ACZ+AL+CL+QF, ale je evidentní časový posun, kdy srážky byly predikovány o přibližně 6 h dříve. Abychom mohli úspěšnost modelů během těchto vybraných situací posoudit komplexně, byly predikce podrobeny metodologicky stejné verifikaci, jako celý dataset v kapitole 8.1.

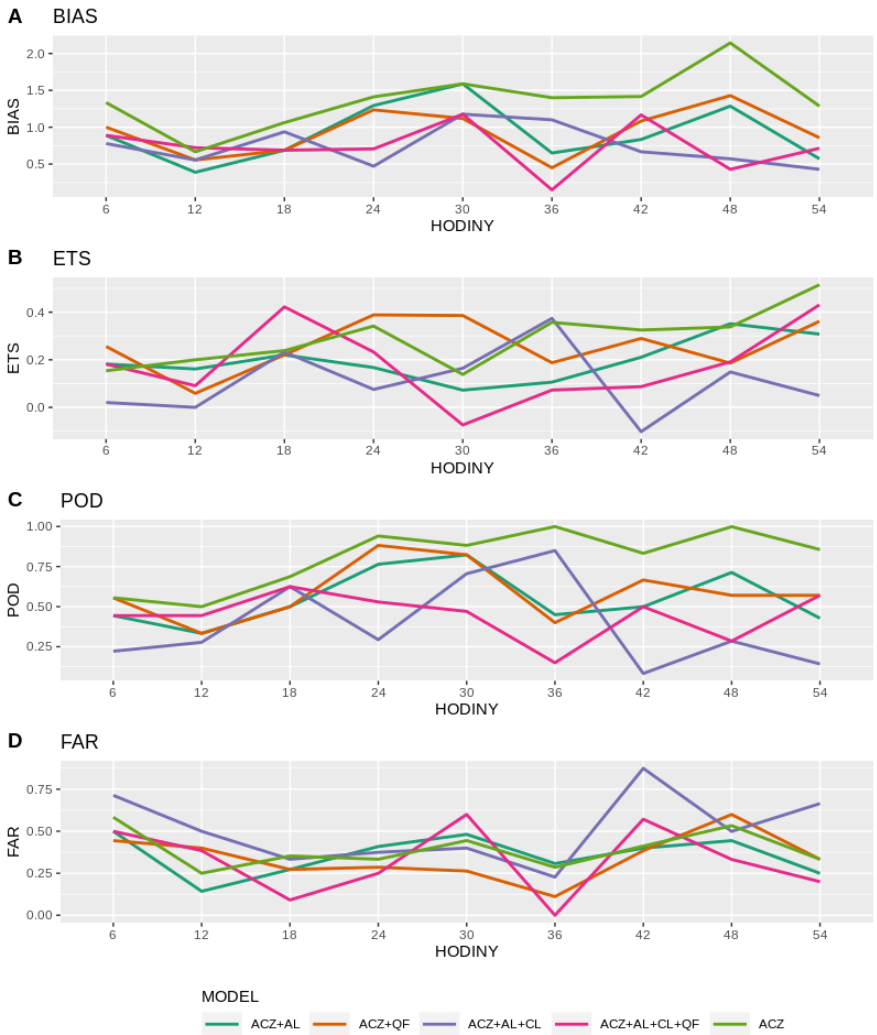


Obrázek 38: Sumarizace srážek pro vybrané události 27.5.2014, 22.10.2014 a 19.5.2015 pro povodí 1060, 1125 a 1530. Tmavě žlutou barvou jsou znázorněny měřené srážky.

Tři vybrané srážkové události byly nejprve hodnoceny verifikačními metodami pro kontinuální veličiny. Data byla sloučena do jednoho datasetu a kromě grafu A na obr. č. 39 nebylo mezi událostmi a povodími rozlišováno. Z grafu A lze vyčíst, že chybovost během srážkových událostí logicky vzrostla, a to přibližně dvojnásobně. Hodnoty RMSE jsou pro povodí 1060 a 1530 velmi vyrovnané. Výraznější chybovost oproti ostatním modelům vykazují pouze modely ACZ+AL a ACZ+AL+CL+QF v povodí 1125. Pro toto povodí odpovídá přibližně hodnocení událostí celkovému hodnocení, pořadí si prohodily pouze dva nejlepší modely ACZ+QF a ACZ. Ještě jednou zajímavou změnou je model ACZ+AL+CL, který byl v celkovém hodnocení pro povodí 1530 hodnocen jako nejhorší, dosáhl v případě událostí nejlepšího výsledku.



Obrázek 39: Grafické znázornění výsledků verifikace kontinuálních veličin vybraných srážkových událostí. Graf A zobrazuje výsledky RMSE pro jednotlivé kombinace modelů v jednotlivých povodích. Graf B, C a D zobrazuje skóre RMSE, MAE a ME v závislosti na horizontu předpovědi.

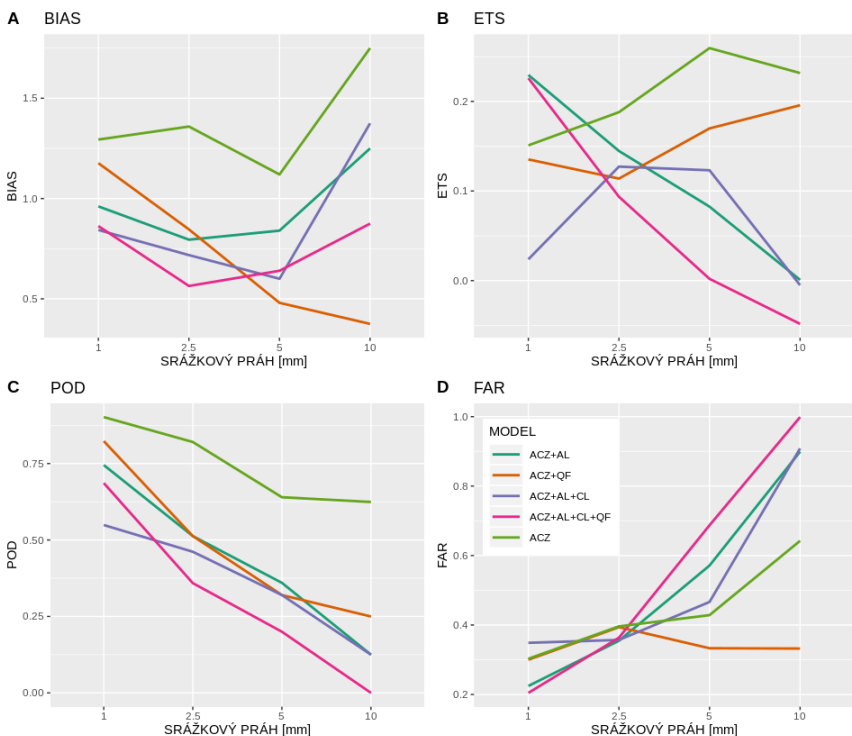


Obrázek 40: Grafické znázornění výsledků verifikace binárních veličin vybraných srážkových událostí v závislosti na horizontu předpovědi. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.

Skóre RMSE, MAE a ME prezentují opět velmi vyrovnané výsledky. Z dat je evidentní zvýšená chybovost u modelu ACZ, která je nejspíše způsobená nadhodnocením úhrnu srážek během události 19.5.2015. V případě událostí je evidentní zvýšená chybovost také u ostatních modelů, ale na horizontu 30 h, v tomto případě se jedná o čas, kdy srážkové události vrcholily a srážkové úhrny dosahovaly nejvyšších hodnot. Následná sestupná tendence chybovosti až k 54 h je způsobena, tím, že v této době již události doznávaly a srážkové úhrny nebyly tak vysoké. Důležitost různých pohledů a prezentací výsledků verifikace je vidět na příkladu ME. Model ACZ+AL+CL se jeví v tomto hodnocení jako nejvíce konzistentní v čase a s nejmenšími odchylkami od ideálního skóre 0. V tabulce č.5 má ale celkové skóre nejlepší model ACZ+AL., který v grafu D na rozdíl od modelu ACZ+AL+CL střídá výraznější kladné a záporné odchylky. Střídáním však ve výsledném výpočtu dojde ke zprůměrování chyby. Při pohledu na graf D je ovšem jasné, že vyšší hodnotu má v tomto případě předpověď modelu ACZ+AL+CL.

Verifikace událostí pomocí skóre pro binární veličiny nepřináší žádné výraznější rozdíly od verifikace celého datového souboru. Z výsledků skóre BIAS lze odvodit, že modely z počátku událostí podhodnocují srážky. Shodně nejnižších hodnot dosahují na 12 h, poté rozptyl odchylek narůstá s rostoucím časovým horizontem. Model ACZ dosahuje jednoznačně nejlepších výsledků pro skóre POD, důvodem je ale opět vysoký BIAS, tedy častější nadhodnocování předpovědi a tím četnější úspěšná detekce výskytu události. Ruku v ruce je s tím ale spojený horší výsledek pro FAR, kde je znát vyšší četnost falešných alarmů.

V případě hodnocení závislosti vybraných událostí na srážkovém prahu (obr. č.41) je dosaženo výrazně odlišných výsledků pouze pro skóre ETS. ETS je komplexnější skóre než POD a FAR, které jsou zaměřeny na konkrétní vlastnosti modelů. ETS zohledňuje i falešné alarmy (false alarms) a nepredikované události (misses), proto jsou výsledky pro jednotlivé modely velmi rozdílné. Pro celkové výsledky je potřeba opět nahlédnout do tabulky č.5, která prezentuje pro každý model a skóre jednu výslednou hodnotu. V porovnání s výsledky v tabulce pro celý datový soubor se tyto výsledky výrazně neliší. Jako nejúspěšnější opět vychází model ACZ+QF, který dosáhl nejlepších hodnot tentokrát pro skóre RMSE, MAE, BIAS a FAR. Model ACZ dosáhl nejlepších hodnot opět pro skóre ETS a POD. V jednom případě byl nejúspěšnější model ACZ+AL, a to pro skóre ME. Úspěchu modelu ACZ v případě ETS a POD mohlo opět napomocť zaměření těchto skóre, které opomíjejí falešné alarmy. Porovnáním výsledků obou tabulek hodnotící celý datový soubor a vybrané události se jeví jako nejúspěšnější model ACZ+QF. Výraznější rozdíly v hodnocení samotných událostí nebyly nalezeny, naopak potvrdily výsledky hodnocení v kapitole 8.1.




Obrázek 41: Grafy výsledků verifikace binárních veličin v závislosti na rostoucím srážkovém prahu. Graf A zobrazuje výsledky BIAS, graf B ETS, graf C POD a graf D FAR.

Skóre události	ACZ+AL	ACZ+QF	ACZ+AL+CL	ACZ+AL+CL+QF	ACZ
RMSE	6.671	6.236	6.388	7.473	6.443
MAE	4.122	3.572	4.142	4.516	3.974
ME	-0.191	-0.934	-0.716	-1.160	1.189
BIAS	1.250	0.375	1.375	0.875	1.750
ETS	0.209	0.263	0.142	0.162	0.306
POD	0.552	0.585	0.447	0.439	0.805
FAR	0.387	0.333	0.433	0.393	0.385

Tabulka 5: Tabulkový přehled výsledků verifikace vybraných událostí. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.

Vypočtené předpovědi srážek události 27.5.2014 byly upraveny a pou-

žity jako vstup do hydrologického modelu. Průtoky byly modelovány stejným modelem a postupem, jaký se používá při tvorbě operativní předpovědi v ČHMÚ. Výsledkem jsou 4 varianty hydrologické predikce v podobě, v jaké by byly vypočítány před zmíněnou událostí, pokud by do hydrologického modelu vstupovaly právě tyto postprocesované hodnoty. Na obr. č.42 jsou zobrazeny predikce pro 3 vybraná povodí. V grafu je také znázorněna predikce vydaná ČHMÚ na tento termín Q_m a měřený průtok Q . Proměnlivost charakteristik predikcí v jednotlivých povodích pro tuto událost je výrazná. V povodí 1060 je rozptyl předpovědi příliš veliký. Predikce vypočtená z dat modelu ACZ-QF a predikce Q_m dosahují nejvyšší odchylky. Nejbližší je model ACZ-AL, který ale nepodchytil nástup růstu průtoku a ani dobu kulminace. Celkově nejlepších výsledků dosáhly predikce průtoků na základě postprocesovaných srážek v povodí 1125, kde naopak úplně propadla predikce Q_m , která nepředpokládala žádný nárůst průtoku. A nakonec v povodí 1530 je rozptyl predikcí příliš malý a u všech došlo k podhodnocení průtoku. S ohledem na všechna tři povodí, se zdá být v případě této události nejméně úspěšná predikce vycházející z postprocesovaných dat ACZ+AL (tmavě zelená linie) a naopak nejméně úspěšná se jeví predikce Q_m . Na této jediné epizodě je evidentní vysoká proměnlivost výsledků a proto nelze vyvodit konkrétní závěry. Zřejmý je však potenciál postprocesovaných předpovědí srážek, zejména pak v porovnání s predikcemi Q_m .




Obrázek 42: Modelová předpověď průtoku při srážkové události 27.5.2014. Průtoky byly spočteny na základě 4 variant postprocesovaných predikcí srážek. Světle zelená linie Q_m představuje předpověď ČHMÚ a žlutá linie měřený průtok Q .

9 Využití neuronových sítí k výpočtu hydrologických předpovědí

V praxi nejčastěji využívané metody výpočtů hydrologických předpovědí jsou založeny na modelech popisující fyzikální procesy, které se dějí v rámci povodí a generují určitý odtok. Jedná se nejčastěji o hydrodynamické modely (tzv. "White-box") a konceptuální modely (tzv. Grey-box). Třetí metoda využitá v této práci nehledí na fyzikální podstaty děje a využívá statistické zpracování historických dat. Tento přístup je označován jako Black-box a jsou jím právě neuronové sítě. Cílem této kapitoly není nalezení postupu tvorby hydrologické předpovědi, která by byla ve všech ohledech nejlepší. Cílem je najít uplatnění statistického postprocesingu pro možnou detekci a eliminaci statistických či fyzikálních odchylek v hydrologických predikcích. V podstatě najít takovou formu statistické predikce průtoků, která může sloužit jako nástroj s odlišným přístupem k posouzení nejistoty vydávané předpovědi.

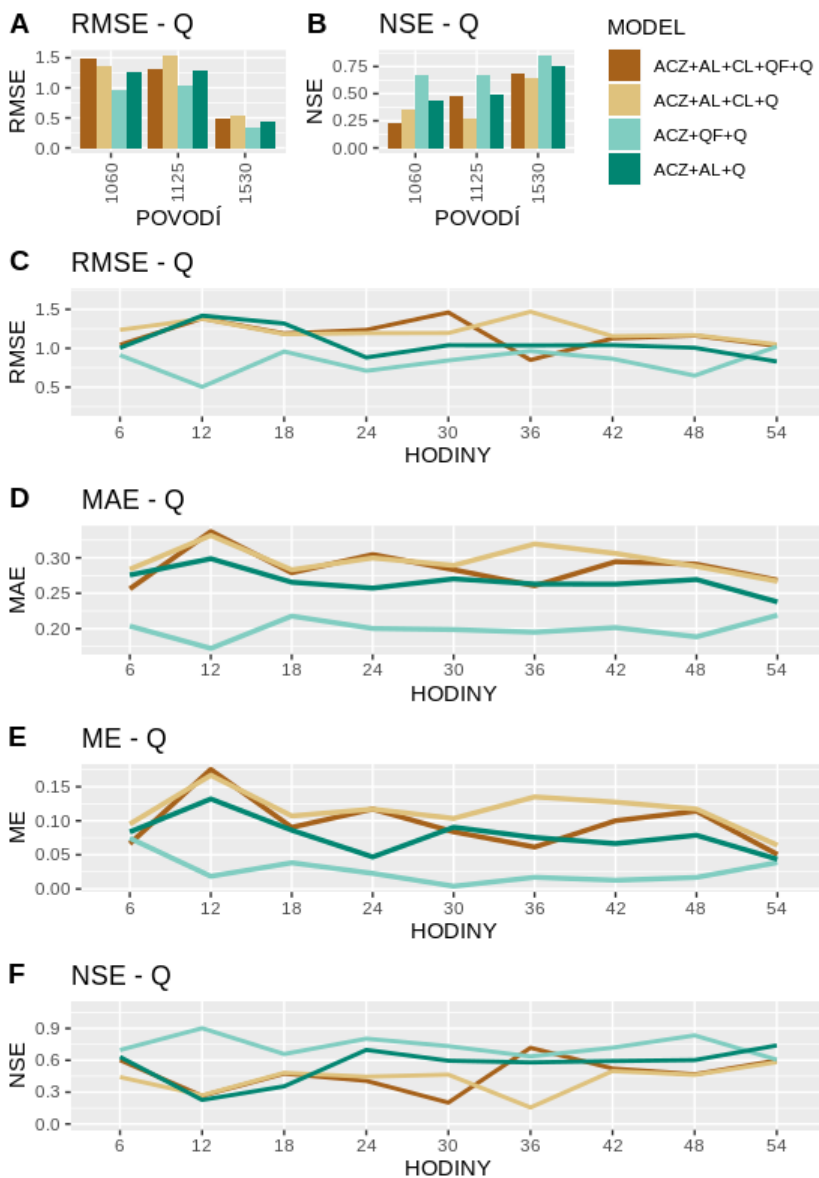
Pro výpočet průtoků pomocí neuronové sítě (NS) byly jako vstupní data pro trénování NS použity kombinace předpovědi srážek modelů a kvantilové předpovědi ve stejné struktuře, jako v kapitole č. 8. Trénování bylo založeno na předpokladu vztahu mezi srážkovým úhrnem a následnou odezvou na odtoku vody z povodí. Přímá závislost mezi těmito veličinami je prokazatelná, avšak do nevýhodné pozice NS stavěl postup výpočtu, kdy jsou vždy vyhodnocovány predikce srážek a k nim měřený průtok, pro jeden termín, bez návaznosti na data přílehlých termínů. V praxi to znamená, že pokud NS nedostane informaci o průtoku či srážkách v předešlém časovém intervalu, její odhad může být zkreslený. A to tím způsobem, že v případě růstu odtoku bude odhad podhodnocován a stejně tak v případě poklesu odtoku z vyššího stavu během již bezsrážkového období. Z tohoto důvodu byly k souboru předpovědí srážek přiřazeny i hodnoty průtoků v předešlém intervalu -6h. Efekt zvýšení úspěšnosti predikce NS po přidání informace o aktuálním průtoku jsou patrné na obrázku č.43, kde jsou modrou barvou zobrazeny modely ACZ+AL+CL a ACZ+AL+CL+QF. Chybovost je výrazně nižší, v případě těch samých modelů doplněných o informaci Q, na obrázku jsou zelenou barvou. Verifikace je opět rozdělena na část hodnocení celého datového souboru a poté pouze vybraných srážkových událostí, které jsou v tomto případě stejné jako u verifikace předpovědi srážek. Na rozdíl od hodnocení srážek, pro průtoky nebyla predikce převáděna na binární hodnoty, proto jsou popsány výsledky pouze pro skóre hodnotící kontinuální veličiny. Jedná se o RMSE, MAE, ME a nyní navíc o Nash-Sutcliffe efficiency - NSE. Toto skóre je vhodné pro hodnocení veličin průtoků a podrobněji je popsáno v kapitole č. 3.3 rovnicí č.11.



Obrázek 43: Porovnání úspěšnosti výpočtů neuronové sítě trénovaných na vstupech bez informace o aktuálním průtoku (modré linie) a s informací o aktuálním průtoku (zelené a červené linie)(+Q)

9.1 Verifikace průtoků vypočtených neuronovou sítí na základě postprocesingu předpovědi srážek

Hodnocení bylo provedeno pro čtyři kombinace modelů ACZ+AL+Q, ACZ+QF+Q, ACZ+AL+CL+Q a ACZ+AL+CL+QF+Q. Na obrázku č.44 - A jsou sloupcové grafy znázorňující RMSE a NSE v jednotlivých povodích. Tyto výsledky obecně potvrzují vyšší úspěšnost predikce pro povodí 1530, tedy nížinné a naopak horší úspěšnost v horském povodí 1060. Nejlepších hodnot dosahuje jednoznačně model ACZ+QF+Q naopak nejhorších výsledků z porovnávaných modelů dosahuje model ACZ+AL+CL+Q. Tyto výsledky potvrzuje hodnocení úspěšnosti v závislosti na horizontu předpovědi. Zejména pro skóre MAE a ME je úspěšnost ACZ+QF+Q oproti ostatním modelům jednoznačná, ale také pro RMSE a NSE dosahuje nejlepších výsledků ve většině časových horizontů.



Obrázek 44: Grafické znázornění výsledků verifikace průtoků vypočtených neuronovou sítí. Sloupcové grafy A a B zobrazují výsledky RMSE a NSE pro jednotlivé kombinace modelů v každém povodí zvlášť. Grafy C až F zobrazují skóre RMSE, MAE, ME a NSE v závislosti na horizontu předpovědi.

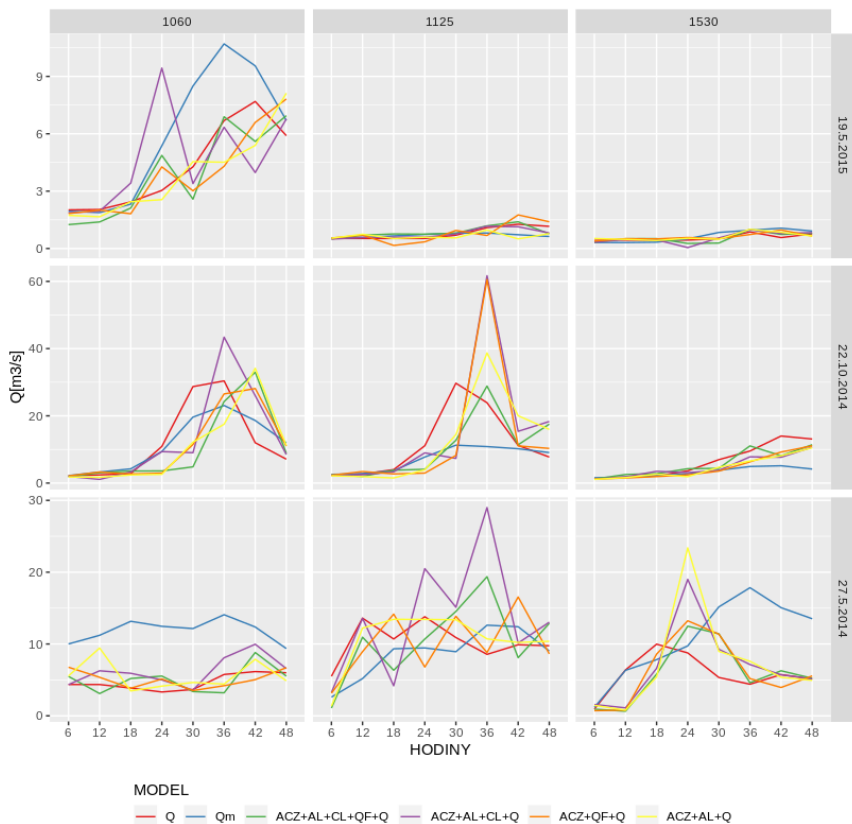
Výsledky z obrázku č. 44 potvrzuje tabulka č.6, kde jsou hodnoty spočteny pro celé datové řady bez členění na povodí nebo časová horizont. Pro všechny 4 skóre vychází nejlépe model ACZ+QF+Q. Výrazně nejlepšího výsledku dosáhl model pro skóre NSE. Skóre ME poukazuje na mírné nadhodnocení průtoků všemi modely. To může být způsobeno povahou ensemblové předpovědi, kdy často několik členů může predikovat srážkový úhrn, ačkoliv pro danou situaci je pravděpodobnost deště velmi nízká. Přesto však pozitivní hodnoty u střední chyby ME jsou velmi nízké.

Skóre	ACZ+AL+Q	ACZ+QF+Q	ACZ+AL+CL+Q	ACZ+AL+CL+QF+Q
RMSE	1.079	0.841	1.231	1.178
MAE	0.267	0.200	0.296	0.286
ME	0.078	0.027	0.114	0.095
NSE	0.558	0.731	0.424	0.472


Tabulka 6: Tabulkový přehled výsledků verifikace vypočtených průtoků. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý sestavený model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.

9.2 Verifikace průtoků vypočtených neuronovou sítí pro vybrané události

Hodnocení odtokových událostí se liší v tom, že do hodnocení je zahrnuta také hydrologická předpověď, která byla pro daný termín vydána ČHMÚ. Odtokové události pro verifikaci byly vybrány na základě srážkových událostí v kapitole 8.2, kde jsou charakterizovány a zdůvodněn jejich výběr. Odtokové charakteristiky těchto událostí jsou zobrazeny na obr. č.45 a č.46. Na prvním z těchto dvou obrázků jsou zobrazeny průtoky v m^3/s v 6h kroku pro vybrané události v jednotlivých povodích. Červenou linií jsou zobrazeny pozorované hodnoty (Q), modrou linií průtoky modelované hydroprognostickým pracovištěm ČHMÚ (Qm). Z obrázků je u některých událostí (např. 27.5.2014 pro oblast 1125) viditelný dopad výpočtu NS v jednotlivých termínech nezávisle na modelovaných hodnotách vypočtených v předešlém kroku. Výsledkem je neplynulý, někdy až harmonický průběh křivky odtoku. Na druhém obrázku č.46 jsou vyobrazeny ty samé události, kde je odtok prezentován formou kumulativní sumy v jednotkách m^3 . Zatímco první zobrazení poskytuje přehled o přesnosti predikce vzhledem k dosažení kulminačního průtoky a jeho času, druhé zobrazení popisuje přesnost predikce z hlediska celkového objemu vody, který během konkrétní události odteče uzávěrovým profilem. Dosažené objemy v jednotlivých událostech jsou rozdílné, některé odezvy toku na srážky nebyly příliš významné, přesto i v těchto situacích lze shledat rozdíly mezi modely.



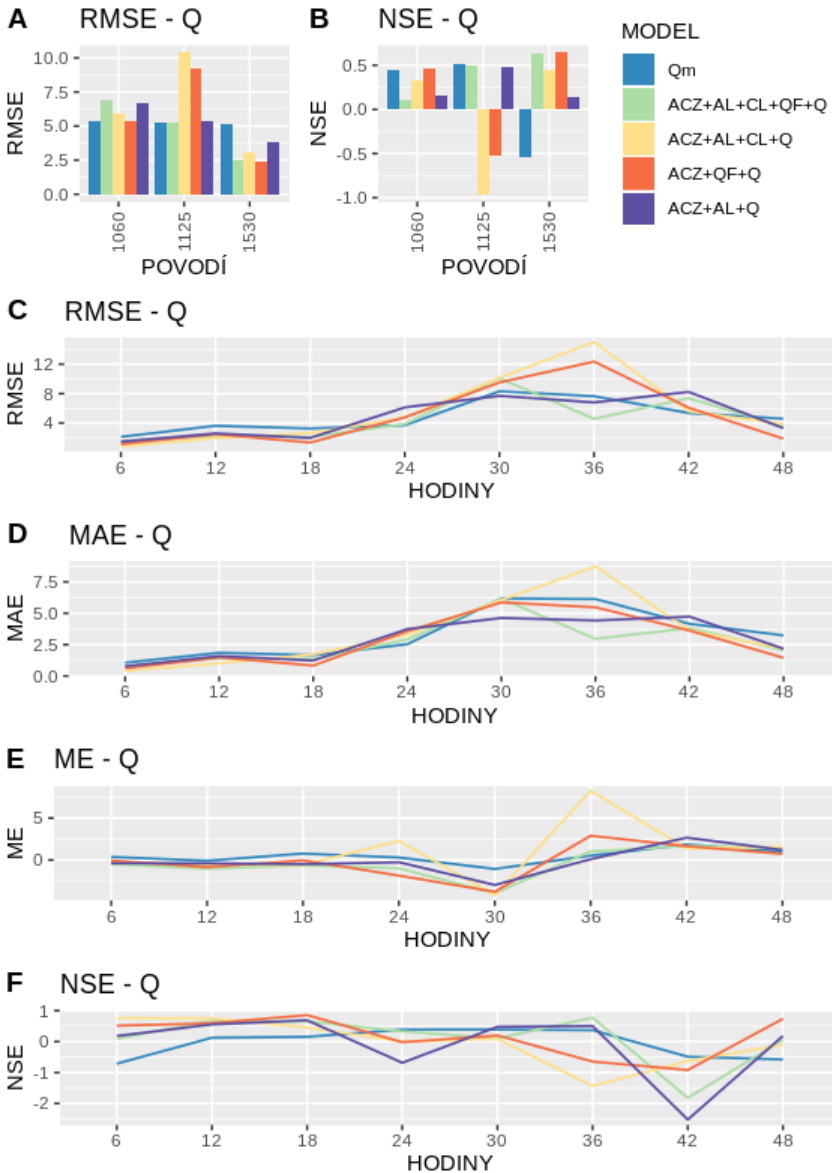
Obrázek 45: Přehled průtoků v m^3/s pro vybrané srážkové události z kapitoly č. 8. (19.5.2015, 22.10.2014 a 27.5.2014) pro profily 1060 - Lenora, 1125 - Ličov a 1530 - Varvažov. Červenou barvou jsou prezentovány měřené průtoky - Q , modrou barvou průtoky modelované Českým hydrometeorologickým ústavem - Q_m .



Obrázek 46: Přehled sum objemu průtoku v m^3 pro vybrané srážkové události z kapitoly č. 8. Červenou barvou jsou prezentovány měřené průtoky - Q , modrou barvou průtoky modelované Českým hydrometeorologickým ústavem - Q_m .

Verifikace průtoků vybraných událostí přináší méně jednoznačné výsledky oproti verifikaci celého datového souboru. Pro události byly opět spočteny verifikační metriky RMSE, MAE, ME a NSE, které jsou vyobrazeny na obr. č.47. Časový horizont byl tentokrát zkrácen z 54 h na 48 h tak, aby odpovídal délce oficiální predikce průtoků Q_m , která byla v té době vydávána pouze na 48 h dopředu. Sloupcové grafy A a B hodnotí úspěšnost predikcí v jednotlivých povodích. Nejlepších výsledků je opět dosaženo v povodí 1530, kde nejmenší chybovost RMSE je prokázána pro model ACZ+QF+Q. Stejný model má i nejlepší výsledek pro skóre NSE. Naopak nejhorších výsledků v obou případech dosáhla předpověď Q_m . Situace se mění u povodí 1060, kde

je stále pro obě skóre nejlepší model ACZ+QF+Q, ale jen nepatrně horší je predikce Qm. Ta je nakonec nejúspěšnější v povodí 1125, a to těsně před modelem ACZ+AL+CL+QF+Q. Model ACZ+QF+Q v tomto povodí vykazuje vyšší nepřesnost a je druhý nejhorší.



Obrázek 47: Grafické znázornění výsledků verifikace průtoků vybraných událostí vypočtených neuronovou sítí. Sloupcové grafy A a B zobrazují výsledky RMSE a NSE pro jednotlivé kombinace modelů v každém povodí zvlášť. Grafy C až F zobrazují skóre RMSE, MAE, ME a NSE v závislosti na horizontu předpovědi.

Z hlediska úspěšnosti předpovědí v závislosti na časovém horizontu jsou výsledky vyrovnané a více se rozcházejí až kolem horizontu 30 h, kde většinou byly průtoky blízko úrovně kulminace. Úspěšnost predikcí se tedy s rostoucím časem zhoršuje a ke konci časového období opět zlepšuje. Důvodem je, stejně jako u hodnocení predikce srážkových událostí, vyvrcholení události a dosažení nejvyšších průtoků právě v časovém horizontu, kdy je úspěšnost nejnižší. Na rozdíl od hodnocení celého datového souboru, střední chyba ME v tomto případě nabývá záporných hodnot u všech modelů na horizontu 30 h. Důvod pravděpodobně můžeme nalézt v události z 22.10.2014, kdy vyšší odtok nastal dříve, než predikovaly všechny modely a kulminace proběhla právě na 30 h.

Celkové zhodnocení nabízí opět verifikační tabulka č.7. Pokud bychom vycházeli z výše popsaných výsledků, předpoklad by zřejmě byl ten, že nejuspěšnějším modelem bude ACZ+QF+Q nebo Qm. Rozkolísanost výsledků v jednotlivých událostech a zejména pak špatné výsledky modelu ACZ+QF+Q v povodí 1125 a predikce Qm v povodí 1530, zapříčinily úspěch modelu ACZ+AL+CL+QF+Q. Ten ač nebyl nejuspěšnější v ani jednom ze tří povodí a nevynikal ani v hodnocení úspěšnosti v závislosti na časovém horizontu, dosáhl v průměru nejnižší chybovosti pro RMSE a MAE a nejvyššího skóre pro NSE. Pouze v hodnocení střední chyby ME se nejvíce blížil nule model ACZ+AL+Q. Tyto výsledky poukazují na dopad jedné nepovedené události, kdy jedna výrazně nepovedená predikce dokáže potlačit zbylé dvě zdařilé. Na druhou stranu je tímto potvrzena užitečnost širšího souboru předpovědí, kde je jednak větší šance popsat skutečný vývoj a zároveň stanovit jeho nejistotu.

Skóre události	ACZ+AL+Q	ACZ+QF+Q	ACZ+AL+CL+Q	ACZ+AL+CL+QF+Q	Qm
RMSE	5.415	6.284	7.147	5.201	5.237
MAE	2.911	2.862	3.378	2.680	3.352
ME	-0.077	-0.174	0.980	-0.378	0.450
NSE	0.329	0.097	-0.168	0.381	0.373

Tabulka 7: Tabulkový přehled výsledků verifikace vypočtených průtoků pro vybrané události. Pro každé skóre je zobrazena jedna výsledná hodnota pro každý sestavený model. Nejlepší dosažené hodnoty jsou zvýrazněny zelenou barvou.

9.3 Souhrn III. části práce

Ve druhé části práce byl podrobně popsán vztah mezi úspěšností deterministického modelu ALADIN-CZ (ACZ) a ensemblového modelu ALADIN-LAEF (AL) pro predikci srážek pro hydrologické modelování. Třetí část práce vychází z faktu, že tyto dva modely jsou základní informací pro modelování průtoků v ČHMÚ a dává si za cíl pomocí postprocesingu najít vhodnou nebo

alternativu k současně využívaným datům. Datový soubor byl rozšířen až do roku 2018 a vzhledem k vývoji operativní hydrologie v ČHMÚ byla data agregována pro nové oblasti, které jsou nyní menší a respektují hranice skutečných povodí. Vzhledem k náročnosti výpočtů byla vybrána tři povodí s názvy 1060 - Lenora, 1125 - Ličov a 1530 - Varvažov. Kromě zmíněných modelů byl datový soubor rozšířen o další regionální model COSMO-LEPS (CL), kde data byla poskytnuta Ústavem fyziky atmosféry AV ČR v.v.i. V kapitole 7.1.4 byly oba ensemblové modely verifikovány porovnány na již upraveném datovém souboru. Přidáním modelu COSMO-LEPS bylo předpokládáno zvýšení úspěšnosti předpovědí na základě rozšíření vstupních informací a nalezení vhodné kombinace predikcí za podmínky, že vzhledem k praxi v ČHMÚ bude vždy základem predikce modelu ACZ a AL. Vzhledem k těmto podmínkám vznikl soubor kombinací modelů ACZ+AL, ACZ+QF, ACZ+AL+CL a ACZ+AL+CL+QF, přičemž QF byla kvantilová predikce vypočtená kalibrační metodou BMA z multimodelu ACZ+AL+CL. Tato kvantilová předpověď by měla být ideální informací o nejistotě predikovaných hodnot a zároveň informací o pravděpodobnosti predikované hodnoty. Pro NS se QF ukázala jako velmi cenná informace.

Kapitola popisuje dva rozdílné postupy, které se liší až v posledním kroku. Vždy bylo využito kalibrační metody BMA a výpočtu neuronové sítě. První postup kalibruje ensemblové predikce srážek do podoby QF a vytváří kombinace multimodelů, ty poté vstupují do NS, která je trénována pomocí těchto predikcí a měřených srážkových dat a výsledkem jsou deterministické varianty předpovědi srážek. Druhý postup přebírá již vytvořené multimodely predikce srážek, ty jsou doplněny o informaci o průtoku a NS je trénována na tomto souboru spolu s měřeními průtoky. Výsledkem jsou deterministické varianty objemových průtoků. Vypočtené predikce byly vždy podrobeny širokému spektru verifikačních přístupů a hodnoceny jak z hlediska celkového datového souboru, tak z hlediska vybraných srážkových situací. Předpovědi srážek byly hodnoceny jak pomocí verifikačních postupů pro kontinuální (RMSE, MAE, ME), tak pro binární veličiny (BIAS, ETS, POD a FAR). Pro potřeby hodnocení průtoků byly aplikovány pouze skóre pro kontinuální veličiny, doplněné o skóre NSE.

Z výsledků kapitoly č. 8 vychází jako nejúspěšnější model ACZ+QF, kdy nejlepších výsledků dosáhl ve čtyřech verifikačních metrikách z celkových sedmi. Ve dvou případech byl nejúspěšnější deterministický model ACZ, který nebyl nikterak postprocesován. Stejněho výsledku bylo dosaženo také při hodnocení vybraných událostí. Při hodnocení výpočtu průtoků v kapitole č. 9 dosáhl model ACZ+QF+Q dokonce nejlepších výsledků ve všech pěti kritériích. Při hodnocení vybraných událostí dopadl nejlépe ve čtyřech kritériích model ACZ+AL+CL+Q. Možné vlivy na výsledek jsou okomentovány v kapitole č. 9.2 a v diskuzi.

Část IV


Diskuze a souhrn výsledků

Tato kapitola obsahuje diskuzi a souhrn výsledků dosažených ve druhé a třetí části disertační práce.

10 Diskuze


Nadhodnocování srážek modelem ALADIN-CZ na 36 h

V kapitole 8.1, hodnotící výsledky postprocesovaných předpovědí srážek, byla zmíněna anomálie v datech modelu ALADIN-CZ (ACZ). Jednalo se o vysoké úhrny v předpovědi na horizontu 36 h, které byly modelem predikovány, ale ve skutečnosti byly měřeny srážky téměř nulové nebo nízkých úhrnů. Tento jev se vyskytuje ve všech třech povodích. Při seřazení 6h srážkových úhrnů od nejvyššího po nejnižší, zaujímají cca prvních 100 hodnot téměř výhradně predikce na 36 h a téměř všechny jako falešné alarmy. Až v následujících nižších hodnotách se začínají objevovat i jiné časové horizonty. Data tohoto modelu nebyla jako jediná nikterak kalibrována, byla pouze agregována z rastrových dat o rozlišení 1km na plochy povodí. Pro přehled jsou na obr. č.48 zobrazeny sumy srážek jednotlivých časových horizontů pro všechna povodí a roky dohromady. Celkové nadhodnocování modelu ACZ je patrné pro každý časový krok a bylo prokázáno i ve verifikaci výsledků, jenže pro časový horizont 36 h je suma predikovaných srážek výrazně vyšší. Zamyšlení nad příčinou této odchylky vedlo nejprve k přezkoumání vlastní chyby během extrakce dat. Data byla znovu přepočtena s naprosto stejným výsledkem. V podstatě chybu v kódu pro extrakci vylučuje i fakt, že pro každý časový horizont byl použit stejný kód v rámci for cyklu a odchylka se vyskytuje pouze u +36 h. Ve verifikaci v první části není tato odchylka zaznamenána vůbec, jelikož výběr dat byl proveden metodou výběru srážkových událostí na základě měřených dat. Tyto falešné alarmy modelu ACZ byly tímto opominuty. Pokud se tedy jedná o chybu v původních datech modelu, měla by se projevit v hydrologických predikcích, které z modelu ACZ vycházejí. V následující tabulce č.8 jsou vybrány predikce z posuzovaných povodí, které obsahovaly jedny z nejvyšších falešných alarmů na +36 h. K tabulce jsou na obr. č.10 vyobrazeny predikce průtoků z archivu předpovědí z hydrologických předpovědních modelů [92].



Obrázek 48: Suma srážek predikovaných modelem ACZ a suma měřených srážek pro jednotlivé horizonty předpovědi modelu ACZ. Použit byl celý datový soubor z let 2012-2018.

Pro podrobnější prozkoumání problému byly z celého datového souboru vybrány predikce pouze pro +36 h a opět načteny do sum spolu s měřenými srážkami, tentokrát ale pro každý rok zvlášť. Z výsledků je patrné, že problém s vysokými úhrny na +36 h měl model zejména v letech 2012, 2013 a 2015. Ostatní roky odpovídají běžné odchylce modelu.






Obrázek 49: Srovnání sum srážek modelu ACZ a měřených srážek z horizontu předpovědi 36 h. Sumy jsou rozděleny do jednotlivých let.

Čas predikce	Predikovaný horizont	Predikovaný čas	Profil	Predikovaný úhrn [mm]	Měřený úhrn [mm]
2013-05-02 00:00:00	+36h	2013-05-03 12:00:00	Ličov	61.4	0.14
2012-07-03 00:00:00	+36h	2012-07-04 12:00:00	Varvažov	60.3	0.1
2013-05-29 12:00:00	+36h	2013-05-31 00:00:00	Lenora	41.5	6.3
2013-05-25 12:00:00	+36h	2013-05-27 00:00:00	Lenora	30.5	0.5

Tabulka 8: Ukázka výrazných kladných odchylek v předpovědi modelu ACZ na +36 h.

Pro profil Ličov je vidět vliv odchylky modelu ACZ na hydrologické předpovědi zobrazené růžovou linií. Pro profil Varvažov je vliv odchylky znázorněn oranžovou linií a pro profil Lenora jsou dvě odchylky z tabulky č.8 zobrazeny zelenou a oranžovou linií. Na základě těchto dat lze určit, že odchylky na +36 h se vyskytují již v původních predikcích modelu ACZ. Tyto odchylky samozřejmě měly vliv i na výsledky kalibrace a postprocesingu neuronovou sítí. Výkyv v úspěšnosti na +36 h je znát zejména u těch skupin modelů, které měly méně členů a tím větší váhu ve výpočtu měl model ACZ, viz. obr. č.35 a 36.



Obrázek 50: Hydrologické předpovědi pro vybraná povodí obsahující vliv falešných alarmů modelu ACZ uvedených v tabulce č.8. Zdroj [92]

Přínos modelu COSMO-LEPS a jiné kombinace multimodelu

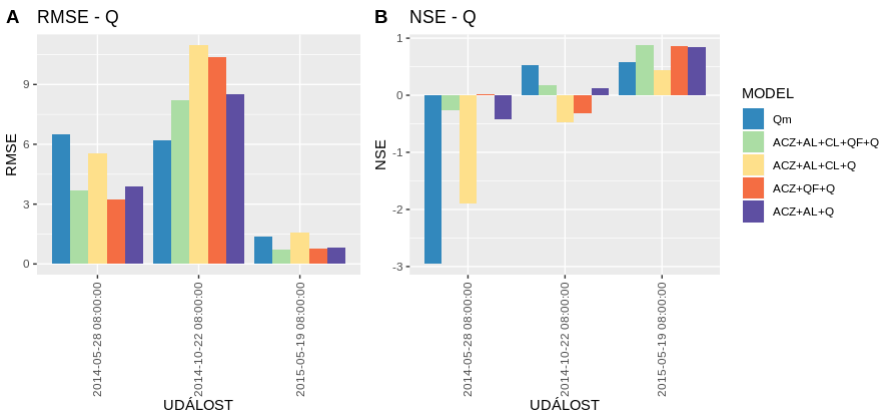
Přínos modelu COSMO-LEPS do jisté míry nenaplnil očekávání a to zejména v tom ohledu, že modely ACZ a AL mají podobné fyziky, asimilační procesy apod. a z tohoto důvodu generují podobné nepřesnosti. Od modelu CL bylo očekáváno, že upozorní na událost, kterou ACZ a ani AL nevidí a naopak, že potlačí falešné alarmy modelů ACZ a AL. Vzhledem k výsledkům je ale možné, že tento přínos byl přenesen do QF, zatímco obsáhlé multimodely ACZ+AL+CL a ACZ+AL+CL+QF, o počtu až 39 členů, přestaly být pro NS čitelné a v některých případech mohlo docházet i k přeučení. Pro ověření by bylo přínosné vytvořit kombinace založené modelu CL, například ACZ+CL nebo CL+QF. S těmito variantami nebylo počítáno vzhledem k upřednostnění modelů ACZ a AL pro hydrologickou prognózu v ČHMÚ.

Problematika výpočtu průtoku neuronovou sítí

V kapitole č.9 je popsána důležitost doplnění vstupního souboru pro výpočet průtoku neuronovou sítí o informaci aktuálním průtokem. To znamená, že vždy v momentě predikce průtoku NS na časový horizont +6 h (6h interval byl zvolen vzhledem k srážkovým datům) dostala NS informaci o aktuálním průtoku. V tomto případě byla NS postavena do výhody tím, že znala vždy hodnotu skutečného průtoku. Tento postup je v praxi při predikci na +54 nereálný, ale lze se k němu přiblížit například tím způsobem, že informaci o aktuálním měřeném průtoku nahradí právě predikce průtoku z předchozího termínu. Jaký velký vliv mělo použití měřených průtoků nelze určit, ale dlouhý časový interval 6 h mezi předpovědmi bude účinek této výhody snižovat, jelikož za tuto dobu dochází k výrazné změně průtoků, zejména pak během srážkových událostí. V případě nevýznamných srážek a malé odezvy na toku nehraje tato informace pro NS tak významnou roli a navíc ji plně zastoupí predikce z předchozího termínu. V budoucnu by bylo vhodné otestovat tento postup na hodinových datech. Významnější nepřesností, která mohla do výpočtu průtoků vstoupit, je doba mezi spadnutím srážky do povodí a následnou odezvou na uzávěrovém profilu. Vzhledem k velikosti povodí a především 6h kroku datového souboru, byla doba odezvy stanovena na +6 h pro všechna povodí. Tzn., že například srážkový úhrn z času 22.10.2014 12:00:00 měl k sobě přiřazený průtok, který nastal o 6h později v čase 22.10.2014 18:00:00 Tento přístup je však velmi zjednodušující a bylo by vhodné odvodit pro každé povodí co nejpřesnější dobu odezvy v rozlišení odpovídajícím vstupním datům, tedy ideálně v případě hodinových dat s přesností na 1 h. Odezva by mohla být definována i na základě velikosti úhrnu nebo aktuálním vodním stavu. Tento problém by odpadl, pokud by se jako informace o aktuálním stavu pro výpočet NS použila predikce Qm.

Výběr srážkových a odtokových událostí

Hodnocení srážkových a potažmo odtokových událostí, může být lehce ovlivněno jednou nepřesnou předpovědí. Resp. čím je datový soubor menší, tím snadněji dojde ke zkreslení obecných výsledků. Srážkové události ve třetí části práce byly vybrány na základě podmínky, že významnější srážky musely být predikovány pro všechny tři povodí. Jejich reálný výskyt nebyl podmínkou, aby nebyly uměle vyloučeny situace s falešným alarmem. Odtokové události byly za účelem porovnání vybrány pro ty samé termíny. Na obr. č.47 byla již popsána rozdílná úspěšnost v rámci povodí. Zde na obrázku č.51 je úspěšnost popsána v závislosti na události. Vidět je například vysoká nepřesnost předpovědi Q_m pro událost 2014-05-28 08:00:00. Model $ACZ+QF+Q$ má opět nejlepší výsledky ve dvou událostech, přesto vyšší nepřesnost v události 2014-10-22 08:00:00 pomohla modelu $ACZ+AL+CL+QF+Q$ k celkově nejlepšímu hodnocení v rámci těchto tří událostí. Z tohoto důvodu mají vyšší váhu výsledky hodnocení celkového datového souboru. Hodnocení jednotlivých události přináší na druhou stranu pohled na věc, jaký by byl jinak v rozsáhlejším verifikovaném souboru ukryt.



Obrázek 51: Hodnocení předpovědí průtoků. Výsledky RMSE a NSE pro jednotlivé události.

Ostatní studie, další postup a využití výsledků

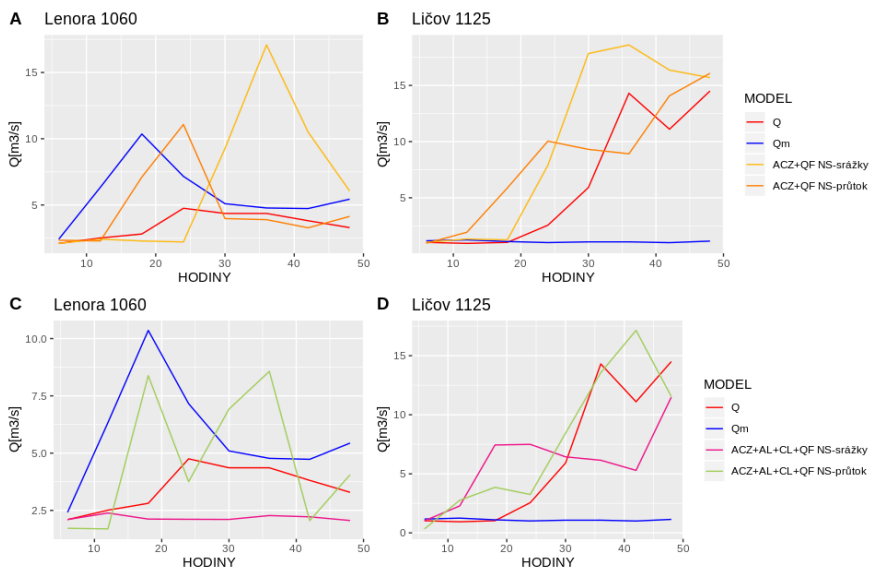
Kalibraci ensemblové předpovědi srážek pomocí neuronové sítě se zatím věnovalo jen několik studií. Mezi ně patří například článek od Yuan H.[93], který potvrdil úspěšné odstranění systematických chyb, zejména pak biasu modelu. Výraznou redukci biasu potvrzuje v obdobném vyžití NS na multi-

modelu Krasnopolsky V.[83]. Celkem devět různých modelů pro dlouhodobou předpověď srážek nad Íránem testoval Pakdaman M.[94] ve studii publikované v roce 2020. Výsledky NS dosáhly lepších výsledků než všech devět modelů. Podobné kalibrační metody jako v této práci, pouze v jiném pořadí, aplikoval Zhong Y.[95]. Ten ve své studii provedl nejprve přepočtení NS na ensemblovou predikci srážek, z té vytvořil ensemblovou předpověď průtoků a tu až poté podrobil metodě BMA. Z výsledků vyplývá pozitivní dopad na výsledky jak aplikace NS, tak metody BMA.

V této vlastní práci nebyla NS trénována pro jednotlivé členy ensembly zvlášť. Tuto metodu však otestoval ve své práci Kim T.[96] a dospěl k výsledku, že z pohledu srážek vzniká příliš velká míra nejistoty, která se negativně podepisuje na úspěšnosti předpovědi.

Všechny metody postprocesingu popsané v této práci jsou aplikovány na predikci srážek. Vzhledem k zaměření na hydrologické modelování se nabízí otázka, do jaké míry rozdílného posunu v kvalitě konečné predikce průtoků by došlo, pokud by byl postprocesing proveden až na hydrologických predikcích. Nad touto otázkou se také zamýšlí v kapitole knihy *Statistical postprocessing of ensemble forecast* Hemri S.[97], který na základě dostupných výsledků preferuje kalibraci především hydrologických modelů nebo kalibraci vstupních dat a hydrologického modelu. Nedoporučuje postup, kdy jsou kalibrována pouze vstupní data do hydrologického modelu.

Další otázkou postupu postprocesingu je přímé srovnání metod aplikovaných v kapitole č.8 a č.9, tedy kalibrace předpovědi srážek a následný přepočtení pomocí neuronové sítě na kalibrovanou predikci srážek nebo přímo na odtok vody z povodí. Pro srovnání byly k dispozici predikce srážek přepočtené hydrologickým modelem na průtoky pouze k jedné srážkové události z 27.5.2014. Na obr. č.52 jsou pro porovnání vybrány modely ACZ-QF (jako obecně nejúspěšnější model) a ACZ+AL+CL+QF+Q (jako nejúspěšnější model přímého výpočtu průtoků ve vybraných událostech). Dále je zde zobrazena předpověď ČHMÚ a měřené průtoky. Rozlišení dat počítaných hydrologickým modelem bylo 1 h a pro potřeby zde uvedeného srovnání bylo sníženo na 6 h, tedy stejný časový krok, jako v případě přímého výpočtu průtoků NS. Z grafů je patrné, že do výsledných průtoků modelovaných hydrologickým modelem vstupují i nejistoty, které je schopen přímý výpočet NS potlačit. Naopak v některých případech může citlivěji reagovat na vyšší množství srážek, které nakonec nevyvolá tak významný odtok. V porovnání s predikcí ČHMÚ - Qm však nejsou tyto odchylky výraznější, spíše naopak. Opět však nelze na základě jedné události vyvozovat závěry, avšak výsledky jsou pozitivní motivací pro podrobnější zaměření využití NS v hydrologické prognóze.



Obrázek 52: Srovnání průtoků modelovaných hydrologickým modelem na základě postprocesovaných srážek - NS-srážky a průtoků přímo vypočtených neuronovou sítí NS-průtok. Pro srovnání byly vybrány modely ACZ+QF, ACZ+AL+CL+QF+Q, předpověď ČHMÚ Qm a měřené průtok Q.

Výsledky této práce budou poskytnuty ČHMÚ, kde by měla být zkonulována využitelnost dosažených výsledků. Další kroky se mohou odvíjet ve dvou rovinách. Zaměření se na praktické užití výsledků v hydrologické prognóze nebo zaměření se na nejúspěšnější postprocesingové metody a modely a testování nových postupů s cílem dalšího zpřesnění jak vstupních dat, tak hydrologických předpovědí.

11 Závěr

11.1 Verifikace

Prvním cílem práce bylo posouzení vhodnosti využívání ensemblového modelu ALADIN-LAEF pro hydrologickou prognózu a provedení podrobné verifikace. Tento záměr a zadání práce vznikl po vzájemné konzultaci na žádost ČHMÚ, který poskytl potřebná data: měřené srážky a predikce modelu ALADIN-CZ a ALADIN-LAEF. Jak je již zmíněno v úvodu práce, model ALADIN-LAEF je kategorizován jako nespolehlivý a operativně je zapojen do hydrologické predikce pouze tehdy, kdy významné srážky predikuje model ALADIN-CZ. Práce hodnotí a porovnává úspěšnost obou modelů v závislosti na horizontu předpovědi, na velikosti srážkového úhrnu, na hydrologické oblasti a typu povětrnostní situace, která se během vybraných srážkových událostí vyskytovala. Technickou komplikací pro toto hodnocení bylo srovnávání deterministického a ensemblového modelu. Bylo třeba se vypořádat s tím, že do výpočtu verifikačních skóre vstupují predikce jako deterministické. Proto byl každý člen ensmbly hodnocen zvlášť a jako reprezentativní predikce byl zvolen vypočtený průměr ensmbly. Naopak pro verifikaci ensmbly slouží skóre pro hodnocení pravděpodobnostní předpovědi. V tomto ohledu byl záměr srovnání těchto dvou modelů vyřešen tak, že bylo počítáno s tzv. "skill scores", které posuzují výkonnost pravděpodobnostní předpovědi oproti referenční deterministické předpovědi. Jako referenční předpověď je obvykle volen klimatický průměr, ale lze proti ensmbly postavit jakoukoliv deterministickou předpověď, v našem případě tedy především ALADIN-CZ. Tímto způsobem byl vypočtením RPSS a BSS ověřen pozitivní skill, neboli pozitivní dovednost ensmbly ALADIN-LAEF oproti modelu ALADIN-CZ. Při hodnocení ostatních metrik a srovnání modelu ALADIN-CZ s průměrem ensmbly MEAN byl předpoklad, že MEAN (jakožto průměr 17 členů) bude mít nad deterministickým ALADIN-CZ navrch v chybových metrikách (ME, MAE, RMSE), ale ztrácet bude v případě binárních skóre, které se zaměřují na konkrétní chování modelu. Jak je ale vidět v tabulce č.2, MEAN byl lepším i v tomto ohledu. Také na obr. č.25 - (a) je patrné, že suma srážek odhadnutá modelem MEAN byla velmi blízko pozorovanému úhrnu, zatímco model ALADIN-CZ situaci podhodnotil o více jak o polovinu. Ze strany predikce srážek nebyl shledán žádný nedostatek, který by bránil kontinuálnímu využití v operativní hydrologii. Je však třeba podotknout, že se jedná o hodnocení jednoho ze vstupů do modelu, kde výsledný modelovaný průtok může být zatížen i jinými nejistotami, než je samotná predikce srážek.

Poněkud nečekané výsledky přineslo hodnocení úspěšnosti předpovědí v jednotlivých hydrologických oblastech. Na obr. č.16 je úspěšnost vyhodnocena na základě 5 verifikačních skóre a je zřejmé, že nejnižší úspěšnosti dosahují modely v povodí Berounky a povodí Labe. Naopak horské oblasti a

severovýchodní část ČR mají úspěšnost vyšší. Důvodem může být reprezentativnější tvar povodí vzhledem k orografii a tím i vyšší přesnost při agregaci srážek. Tvar povodí nejméně zohledňující orografii se vyskytuje v oblasti Krkonoš a Jizerských hor, kde jsou také dosaženy nejhorší nebo jedny z nejhorších výsledků v rámci oblastí. Hodnocena byla také závislost na typu povětrnostní situace, kdy oba modely se nejlépe vypořádaly s předpovědí při situacích Ec-východní cyklonální situace a naopak nejhůře se situací SWc2-jihozápadní cyklonální situace 2. To odpovídá charakteru situací, kdy při Ec je stacionární tlaková níže v oblasti Itálie kolem které se na naše území dostávají frontální systémy od jihovýchodu. Naopak při SWc2 je situace dynamičtější. Tlaková níže postupuje od Britských ostrovů přes severní Evropu a na naše území posílá frontální systémy od severozápadu, po přechodu fronty následuje chladné a vlhké proudění doprovázené dešťovými přeháňkami. Důvěryhodnost předpovědi srážek pro hydrologické modely modelem ALADIN-CZ a ALADIN-LAEF je tedy možné posoudit v závislosti na oblasti výskytu jevu a na typu povětrnostní situace vyskytující se nad oblastí v době výskytu jevu. Důležité je brát v potaz fakt, že výsledky odpovídají pro data, která jsou již upravena (agregována) pro potřeby hydrologického modelování.

11.2 Kalibrace

Další postup práce ve třetí části vyplynul z výsledků druhé části, kde se model AL osvědčil jako vhodný nástroj pro hydrologické modelování. Cílem bylo vzít model ACZ a AL jako základ predikce srážek pro hydrologické modely a pomocí různých kalibračních a statistických postprocesingových metod nalézt postup, který by vedl k přesnějším predikcím srážek a zároveň otestovat tvorbu hydrologické předpovědi čistě na základě statistického přístupu pomocí neuronové sítě a porovnat výsledky, zda mohou konkurovat předpovědi vypočtené konceptuálním modelem v ČHMÚ. Během doby, kdy vznikala tato práce došlo ke změně metodických postupů hydrologického modelování v ČHMÚ a původní hydrologické oblasti byly nahrazeny reálnými povodími vztaženými k uzávěrovým profilům modelovaných povodí. Tyto povodí jsou menší, než původní oblasti, proto vzhledem k náročnosti výpočtů byly vybrány tři povodí (1060 - Lenora, 1125 - Ličov a 1530 Varvažov), pro které byly provedeny všechny výpočty a hodnocení.

V prvním kroku byla provedena kalibrace BMA metodou na souboru modelů ACZ+AL+CL. Tím vznikla kvantilová predikce pro kvantily 0.1, 0.3, 0.5, 0.7 a 0.9. Z těchto dostupných variant předpovědí byly pro postprocesing neuronovou sítí vybrány tyto kombinace modelů: ACZ+AL, ACZ+QF, ACZ+AL+CL, ACZ+AL+CL+QF. Takto sestavené multimodely byly vstupem pro neuronovou síť, která vypočítala deterministickou předpověď srážek pro každý ze čtyř multimodelů. Celkově nejlepších výsledků dosáhl model ACZ+QF, tedy kombinace deterministického modelu ALADIN-CZ a kvan-

tilové předpovědi. Tato kombinace předčila výsledky kombinací obsahujících model CL, ačkoliv předpovědi CL jsou zahrnuty v QF. Důvodem úspěchu modelu ACZ-QF je zřejmě jednoduchost QF, kde je informace z celkového počtu 34 členů multimodelu přenesena do 5 členů QF a zároveň jsou data kalibrována. Tzn., že se jedná o stručnou a přesnou informaci, kterou umí neuronová síť v kombinaci s modelem ACZ úspěšně zpracovat a vyhodnotit. Zejména pak v situacích, kdy ACZ predikuje vyšší kladné či záporné odchylky, dochází k úspěšné korekci předpovědi. Takovýto typ předpovědi může být alternativou pro současné predikce sloužící jako vstupy do hydrologického modelu. Respektive žádná z posuzovaných kombinací modelů nepodávala výrazně horší výkony. Možnost využití by mohla být v podobě tvorby souboru srážkových predikcí o nižším počtu členů, který bude statisticky dopočítáván z nepoměrně většího souboru dat. V takovém případě je nutné postihnout dostatečně rozptýl predikce, to je zaručeno kvantilovou předpovědí, která vymezí pravděpodobnost výskytu jevu. Kvantilová predikce může být poté doplněna několika variantami postprocesovaných předpovědí pomocí neuronové sítě. Co může být považováno za úspěch, je vytvoření deterministické predikce srážek na základě ensemblových modelů (tyto modely disponují nižším rozlišením a nejsou regionálního charakteru), která má srovnatelnou úspěšnost s regionálním modelem ACZ o vysokém rozlišení.

Verifikace výpočtu průtoků pomocí neuronové sítě přinesla podobné výsledky jako verifikace výpočtu srážek. Při hodnocení celého datového souboru dosáhl nejlepších výsledků model ACZ+QF+Q, a to ve všech čtyřech hodnotících kritériích RMSE, MAE, ME a NSE. Bohužel pro celý datový soubor nebyla k dispozici data předpovědi průtoků modelované v ČHMÚ, a tak nelze v tomto případě vyhodnotit, zda by mohla predikce NS na základě modelu ACZ+QF+Q dlouhodobě konkurovat operativní hydrologické předpovědi. Porovnání těchto dvou předpovědí však bylo provedeno v rámci hodnocení vybraných událostí, které byly zvoleny stejné epizody jako u předpovědi srážek. Zde se při hodnocení závislosti na povodí dařilo nejlépe modelu ACZ+QF+Q ve dvou povodích, ve třetím dosáhl výraznější odchylky. Právě v povodí 1125, kde ACZ+QF+Q byl nepřesný, dosáhla nejlepšího výsledku modelová předpověď ČHMÚ Qm. Předpověď Qm vykazovala naopak vyšší nepřesnost v povodí 1530. Kvůli rozkolísanosti úspěšnosti dosáhl v průměru nejlepšího hodnocení v rámci vybraných událostí model ACZ+AL+CL+QF+Q, který nebyl v rámci hodnocení jednotlivých povodí ani jednou nejlepší, vyhnul se však výraznějším odchýlkám. V přímém srovnání pouze dvou modelů ACZ+QF+Q a Qm je výsledek nerozhodný. Skóre RMSE a NSE vychází lépe pro Qm, skóre MAE a ME lépe pro ACZ+QF+Q.

11.3 Shrnutí výsledků

- ALADIN-LAEF vykazuje pozitivní úspěšnost v porovnání s modelem ALADIN-CZ a lze jej doporučit jako zdroj předpovědi srážek pro hydrologické modelování v ČHMÚ.
- Úspěšnost predikce srážek je rozdílná v jednotlivých hydrologických oblastech. Povodí Labe a Berounky vykazuje nižší úspěšnost předpovědi v porovnání se zbytkem ČR.
- Úspěšnost předpovědi srážek je závislá na typu povětrnostní situace. Nejvyšší úspěšnost byla dosažena při E_c-východní cyklonální situaci a nejnižší při SW_{c2}-jihozápadní cyklonální situaci.
- Aplikací kalibrační metody BMA a užitím neuronových sítí bylo dosaženo zvýšení úspěšnosti predikce srážek. V případě vstupu do neuronové sítě kombinace modelu ALADIN-CZ (ACZ) a kvantilové předpovědi (QF) vypočtené z multimodelu (ACZ+AL+CL), bylo dosaženo lepších výsledků předpovědi srážek pro hydrologické modelování ve srovnání s modelem ALADIN-CZ
- Využití metod multimodelu a BMA k tvorbě vstupních dat do neuronové sítě vede k možnosti přímého výpočtu průtoku v kvalitě konkurující konceptuálnímu modelu.
- Testované statistické metody lze využít k tvorbě ensamble predikce srážek, či přímo ensamble predikce průtoku a může sloužit jako doplňková informace, zejména v případě významných srážko-odtokových událostí.

Literatura

- [1] VERKADE, J.S.; BROWN, J.D.; DAVIDS, F.; REGGIANI, P.; WEERTS, A.H. Estimating predictive hydrological uncertainty by dressing deterministic and ensemble forecasts; a comparison, with application to Meuse and Rhine. *Journal of Hydrology*. 2017, roč. 555, s. 257–277.
- [2] RODWELL M. *Comparing and combining deterministic and ensemble forecasts: How to predict rainfall occurrence better*. 2006.
- [3] CLOKE, H.L.; PAPPENBERGER, F. Ensemble flood forecasting: A review. *Journal of Hydrology*. 2009, roč. 375, č. 3-4, s. 613–626. ISSN 0022-1694.
- [4] ALFIERI, Lorenzo; PAPPENBERGER, Florian; WETTERHALL, Fredrik aj. Evaluation of ensemble streamflow predictions in Europe. *Journal of Hydrology*. 2014, roč. 517, s. 913–922.
- [5] BROWN, James D.; HE, Minxue; REGONDA, Satish aj. Verification of temperature, precipitation, and streamflow forecasts from the NOAA/NWS Hydrologic Ensemble Forecast Service (HEFS): 2. Streamflow verification. *Journal of Hydrology*. 2014, roč. 519, s. 2847–2868.
- [6] SCHAAKE, John C.; HAMILL, Thomas M.; BUIZZA, Roberto aj. HEPEX: The Hydrological Ensemble Prediction Experiment. *Bulletin of the American Meteorological Society*. 2007, roč. 88, č. 10, s. 1541–1548.
- [7] PALMER, Tim; BUIZZA, Roberto; HAGEDORN, Renate aj. *Ensemble prediction: a pedagogical perspective*.
- [8] MAŠEK J; VLASÁK T. *Calibration of ALADIN/LAEF precipitation ensembles*. 2011.
- [9] WANG, Yong; BELLUS, Martin; WITTMANN, Christoph aj. The Central European limited-area ensemble forecasting system: ALADIN-LAEF. *Quarterly Journal of the Royal Meteorological Society*. 2011, roč. 137, č. 655, s. 483–502.
- [10] WANG, Yong; BELLUS, Martin; GELEYN, Jean-Francois aj. A New Method for Generating Initial Condition Perturbations in a Regional Ensemble Prediction System: Blending. *Monthly Weather Review*. 2014, roč. 142, č. 5, s. 2043–2059.
- [11] MONTANI, Andrea; CESARI, Davide; MARSIGLI, Chiara; PACCAGNELLA, Tiziana. Seven years of activity in the field of mesoscale ensemble forecasting by the COSMO-LEPS system: main achievements and open challenges. *Tellus A: Dynamic Meteorology and Oceanography*. 2011, roč. 63, č. 3. ISSN 1600-0870.
- [12] DAŇHELKA, Jan. *Operativní hydrologie : hydrologické modely a nejistota předpovědí*. 2007. ISBN 9788086690483.

- [13] HRÁDEK, František; KUŘÍK, Petr. *Hydrologie*. Praha: Česká zemědělská univerzita, 2008. ISBN 978-80-213-1744-4.
- [14] MUSY, André; HINGRAY, Benoit; PICOUET, Cécile. *Hydrology: A Science for Engineers*. První vyd. Boca Raton: CRC Press, 2014. ISBN 978-1-4665-9059-5.
- [15] MASKEY, Shreedhar; GUINOT, Vincent; PRICE, Roland K. Treatment of precipitation uncertainty in rainfall-runoff modelling: a fuzzy set approach. *Advances in Water Resources*. 2004, roč. 27, č. 9, s. 889–898.
- [16] ŘEZÁČOVÁ, Daniela; SOKOL, Zbyněk. Lokální předpověď srážek pomocí statistického zpracování výstupů numerických předpovědních modelů - statistický "postprocessing". *Meteorologické zprávy*. 1998, roč. 51, č. 4.
- [17] NOVAK, Petr. The Czech Hydrometeorological Institute's severe storm nowcasting system. *Atmospheric Research*. 2007, roč. 83, č. 2-4, s. 450–457.
- [18] NOVÁK, Petr; KYZVAROVÁ, Hana. *Obnova meteorologické radarové sítě CZRAD v roce 2015*.
- [19] SOKOL, Zbynek. Nowcasting of 1-h precipitation using radar and NWP data. *Journal of Hydrology*. 2006, roč. 328, s. 200–211.
- [20] SUI, D.Z.; MAGGIO, R.C. Integrating GIS with hydrological modeling: practices, problems, and prospects. *Computers, Environment and Urban Systems*. 1999, roč. 23, č. 1, s. 33–51.
- [21] REZACOVA, Daniela; ZACHAROV, Petr; SOKOL, Zbynek. Uncertainty in the area-related QPF for heavy convective precipitation. *Atmospheric Research*. 2008, roč. 93, s. 238–246.
- [22] BURT, Stephen. *The Weather Observer's Handbook*. First. New York: Cambridge University Press, 2012. ISBN 978-1-107-66228-5.
- [23] KUBÁT, Jan; ČEKAL, Radek; DAŇHLEKA, Jan; MATOUŠEK, Václav. *Odborné pokyny pro provádění hlášené povodňové služby*. 2012.
- [24] ČHMÚ. *Průvodce informacemi pro odbornou vodohospodářskou veřejnost*. 2016.
- [25] AQUALOGIC. *ESP Teorie a referenční příručka*. 2011.
- [26] DAŇHELKA, Jan; KUBÁT, Jan; ŠERCL, Petr; ČEKAL, Radek. *Povodně v České republice v červnu 2013*. 2013.
- [27] ČMES. *Elektronický meteorologický slovník výkladový a terminologický (eMS)*. Dostupný také z: (<http://slovník.cmes.cz>).
- [28] JANOUŠEK, Martin. *Základní pojmy numerických algoritmů*.
- [29] KIMURA, Ryuji. Numerical weather prediction. *Journal of Wind Engineering and Industrial Aerodynamics*. 2002, roč. 90, č. 12-15, s. 1403–1414.

- [30] BAŤKA, Michal. *Předpověď vývoje atmosféry objektivními metodami*. Praha: Matematicko-fyzikální fakulta UK v Praze, 2014.
- [31] GORDON, Charles T.; STERN, William F. A Description of the GFDL Global Spectral Model. *Monthly Weather Review*. 1982, roč. 110, č. 7, s. 625–644.
- [32] ŘEZÁČOVÁ, Daniela; KAŠPAR, Marek; NOVÁK, Petr; SETVÁK, Martin. *Fyzika oblaků a srážek*. 2007. ISBN 9788020015051.
- [33] LEUTBECHER, M.; PALMER, T.N. Ensemble forecasting. *Journal of Computational Physics*. 2008, roč. 227, č. 7, s. 3515–3539.
- [34] ZHU, Yuejian. Ensemble forecast: A new approach to uncertainty and predictability. *Advances in Atmospheric Sciences*. 2005, roč. 22, č. 6, s. 781–788.
- [35] NATIONAL CENTRE FOR METEOROLOGICAL RESEARCH (NCMR). *The ALADIN Project within the European collaborations in Numerical Forecast*.
- [36] WANG, Yong; KANN, Alexander. ALADIN Limited Area Ensemble Forecasting (LAEF). *ALADIN Newsletter*. 2006, s. 1–7.
- [37] BERNER, J.; HA, S.-Y.; HACKER, J. P. aj. Model Uncertainty in a Mesoscale Ensemble Prediction System: Stochastic versus Multiphysics Representations. *Monthly Weather Review*. 2011, roč. 139, č. 6, s. 1972–1995.
- [38] DERKOVA, M; BELLUS, M. Various applications of the blending by digital filter technique in the ALADIN numerical weather prediction system. *Meteorologický časopis*. 2007.
- [39] TOTH, Zoltan; KALNAY, Eugenia. Ensemble Forecasting at NCEP and the Breeding Method. *Monthly Weather Review*. 1997, roč. 125, č. 12, s. 3297–3319.
- [40] JOLLIFFE, I. T.; STEPHENSON, David B. *Forecast verification : a practitioner's guide in atmospheric science*. 2003. ISBN 0470864419.
- [41] CAWCR. *Forecast verification: Issues , Methods and FAQ*. 2015.
- [42] JOLLIFFE, I. T.; STEPHENSON, D. B. *Forecast Verification, A Practitioner's Guide in Atmospheric Science*. 2. vyd., 2012. ISBN 978-0-470-66071-3.
- [43] WILSON, Laurence J; BURROWS, William R; LANZINGER, Andreas. A Strategy for Verification of Weather Element Forecasts from an Ensemble Prediction System. *Monthly Weather Review*. 1999, roč. 127, s. 956–970.
- [44] BUIZZA, Roberto. Potential Forecast Skill of Ensemble Prediction and Spread and Skill Distributions of the ECMWF Ensemble Prediction System. *Monthly Weather Review*. 1997, roč. 125, č. 1, s. 99–119.

- [45] MURPHY, J. M. The impact of ensemble forecasts on predictability. *Quarterly Journal of the Royal Meteorological Society*. 1988, roč. 114, č. 480, s. 463–493.
- [46] KALNAY, Eugenia; DALCHER, Amnon. Forecasting Forecast Skill. *Monthly Weather Review*. 1987, roč. 115, č. 2, s. 349–356.
- [47] WHITAKER, Jeffrey S.; LOUGHE, Andrew F. The Relationship between Ensemble Spread and Ensemble Mean Skill. *Monthly Weather Review*. 1998, roč. 126, č. 12, s. 3292–3302.
- [48] HAMILL, Thomas M.; HAMILL, Thomas M. Interpretation of Rank Histograms for Verifying Ensemble Forecasts. *Monthly Weather Review*. 2001, roč. 129, č. 3, s. 550–560.
- [49] REZACOVA, Daniela; SOKOL, Zbynek; PESICE, Petr. A radar-based verification of precipitation forecast for local convective storms. *Atmospheric Research*. 2007, roč. 83, č. 2-4, s. 211–224.
- [50] WMO. *Recommendations for the Verification and Intercomparison of QPFs and PQPFs from Operational NWP Models*. 2008.
- [51] GUPTA, Hoshin V.; KLING, Harald; YILMAZ, Koray K.; MARTINEZ, Guillermo F. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*. 2009, roč. 377, č. 1-2. ISSN 00221694.
- [52] SCHELLANDER-GORGAS, Theresa; WANG, Yong; MEIER, Florian aj. On the forecast skill of a convection-permitting ensemble. *Geoscientific Model Development*. 2017, roč. 10, č. 1, s. 35–56.
- [53] ŘEZÁČOVÁ, D.; SZINTAI, B.; JAKUBIAK, B.; YANO, J.- I.; TURNER, S. Verification of high resolution precipitation forecast by radar-based data. *Parameterization of atmospheric convection : Current issues and new theories*. 2015, s. 173–214.
- [54] NOVÁK P; KYZVAROVÁ H. MERGE2-MODERNIZOVANÝ SYSTÉM KVANTITATIVNÍCH ODHADŮ SRÁŽEK PROVOZOVANÝ V ČESKÉM HYDROMETEOROLOGICKÉM ÚSTAVU. *Meteorologické zprávy*. 2016, roč. 69, s. 137–144.
- [55] ŠÁLEK M. Operational application of the precipitation estimate by radar and raingauges using local bias correction and regression kriging. In ERAD, Proceedings. National Meteorological Administration of Romania (ed.). *Operational application of the precipitation estimate by radar and raingauges using local bias correction and regression kriging*. Sibiu: ERAD, Proceedings. National Meteorological Administration of Romania, 2010.
- [56] ŠÁLEK, M.; BREZKOVÁ, L.; NOVÁK, P. The use of radar in hydrological modeling in the Czech Republic – case studies of flash floods. *Natural Hazards and Earth System Science*. 2006, roč. 6, č. 2, s. 229–236.

- [57] HYDROMETEOROLOGICKÝ ÚSTAV PRAHA. *Katalog povětrnostních situací pro území ČSSR*. Druhé vyd. 1972.
- [58] HANEL, Martin; MÁČA, Petr. Spatial variability and interdependence of rain event characteristics in the Czech Republic. *Hydrological Processes*. 2013, roč. 28, č. 6, s. n/a–n/a. ISSN 08856087.
- [59] SVOBODA, Vojtěch; HANEL, Martin; MÁČA, Petr; KYSELÝ, Jan. Characteristics of rainfall events in RCM simulations for the Czech Republic. *Hydrology and Earth System Sciences*. 2016.
- [60] WISCHMEIER, W.H.; SMITH, D.D. Predicting rainfall erosion losses: a guide to conservation planning [USA]. *United States. Dept. of Agriculture. Agriculture handbook (USA)*. 1978.
- [61] BAKHSHAI, Atoossa; STULL, Roland. Deterministic Ensemble Forecasts Using Gene-Expression Programming* includes multiple linear regression/-model output statistics (MOS), sequential estimation of systematic error. *American Meteorological Society*. 2009, roč. 24, s. 1431–1451.
- [62] HOGAN, Robin J.; MASON, Ian B. Deterministic Forecasts of Binary Events. In. *Forecast Verification*. Chichester, UK: John Wiley & Sons, Ltd, 2012, s. 31–59.
- [63] WILKS, Daniel S. *Statistical methods in the atmospheric sciences*. 2011. ISBN 9780123850232.
- [64] WEIGEL, Andreas P. Ensemble Forecasts. In. *Forecast Verification*. Chichester, UK: John Wiley & Sons, Ltd, 2012, s. 141–166.
- [65] CANDILLE, G.; TALAGRAND, O. Evaluation of probabilistic prediction systems for a scalar variable. *Quarterly Journal of the Royal Meteorological Society*. 2005, roč. 131, č. 609, s. 2131–2150.
- [66] GRAMS, C. M.; BINDER, H.; PFAHL, S.; PIAGET, N.; WERNLI, H. Atmospheric processes triggering the central European floods in June 2013. *Natural Hazards and Earth System Sciences*. 2014, roč. 14, č. 7, s. 1691–1702.
- [67] BUIZZA, Roberto. Ensemble forecasting and the need for calibration. In. *Statistical postprocessing of ensemble forecast*. 2018, s. 347. ISBN 978-0-12-812372-0.
- [68] LORENZ, Edward. Deterministic nonperiodic flow. *Journal of the Atmospheric Sciences*. 1963, roč. 20, s. 130–141.
- [69] HAMILL, Thomas M.; HAGEDORN, Renate; WHITAKER, Jeffrey S. Probabilistic Forecast Calibration Using ECMWF and GFS Ensemble Reforecasts. Part II: Precipitation. *Monthly Weather Review*. 2008, roč. 136, č. 7. ISSN 1520-0493.

- [70] HAMILL, Thomas M.; WHITAKER, Jeffrey S.; MULLEN, Steven L. Re-forecasts: An Important Dataset for Improving Weather Predictions. *Bulletin of the American Meteorological Society*. 2006, roč. 87, č. 1. ISSN 0003-0007.
- [71] WILKS, Daniel S. On assessing calibration of multivariate ensemble forecasts. *Quarterly Journal of the Royal Meteorological Society*. 2017, roč. 143, č. 702. ISSN 00359009.
- [72] JOHNSON, Christine; SWINBANK, Richard. Medium-range multimodel ensemble combination and calibration. *Quarterly Journal of the Royal Meteorological Society*. 2009, roč. 135, č. 640. ISSN 00359009.
- [73] RAFTERY, Adrian E.; GNEITING, Tilmann; BALABDAOUI, Fadoua aj. Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review*. 2005, roč. 133, č. 5, s. 1155–1174.
- [74] BECKERS, J.V.L.; SPROKKEREEF, E.; ROSCOE, K.L. Use of Bayesian Model Averaging to determine uncertainties in river discharge and water level forecasts. In. *Use of Bayesian Model Averaging to determine uncertainties in river discharge and water level forecasts*. 2008, s. 1–8.
- [75] WILKS, Daniel S. Univariate Ensemble Postprocessing. In. *Statistical post-processing of ensemble forecast*. 2018, s. 49–84.
- [76] SCHEUERER, M. *Spatial Bayesian Model Averaging for Precipitation Forecasts from COSMO-DE-EPS*. 2011.
- [77] HAGEDORN, Renate; DOBLAS-REYES, Francisco J.; PALMER, T.N. The rationale behind the success of multi-model ensembles in seasonal forecasting — I. Basic concept. *Tellus A: Dynamic Meteorology and Oceanography*. 2005, roč. 57, č. 3. ISSN 1600-0870.
- [78] SCHAEYBROECK, Bert Van; VANNITSEM, St0phane. Postprocessing of long-range forecasts. In. *Statistical postprocessing of ensemble forecasts*. 2018, s. 267–286.
- [79] KRISHNAMURTI, T. N.; KISHTAWAL, C. M.; SHIN, D. W.; WILLIFORD, C. Eric. Improving Tropical Precipitation Forecasts from a Multianalysis Superensemble. *Journal of Climate*. 2000, roč. 13, č. 23. ISSN 0894-8755.
- [80] GARCIA-MOYA, Jose-Antonio; CALLADO, Alfons; ESCRIBÀ, Pau aj. Predictability of short-range forecasting: a multimodel approach. *Tellus A: Dynamic Meteorology and Oceanography*. 2011, roč. 63, č. 3. ISSN 1600-0870.
- [81] VOKOUN, Martin; HANEL, Martin. Comparing ALADIN-CZ and ALADIN-LAEF Precipitation Forecasts for Hydrological Modelling in the Czech Republic. *Advances in Meteorology*. 2018, roč. 2018. ISSN 1687-9309.
- [82] RASP, Stephan; LERCH, Sebastian. Neural Networks for Postprocessing Ensemble Weather Forecasts. *Monthly Weather Review*. 2018, roč. 146, č. 11. ISSN 0027-0644.

- [83] KRASNOPOLSKY, V M; LIN, Y. *A Neural Network Nonlinear Multi-model Ensemble for Predicting Precipitations over ConUS*. 2012.
- [84] ADHIKARI, Ratnadip; AGRAWAL, R. K. A Homogeneous Ensemble of Artificial Neural Networks for Time Series Forecasting. *International Journal of Computer Applications*. 2013.
- [85] ZHANG, G Peter. A neural network ensemble method with jittered training data for time series forecasting. *Information sciences*. 2007, roč. 177, č. 23, s. 5329–5346.
- [86] MAIER, Holger R.; DANDY, Graeme C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*. 2000, roč. 15, č. 1, s. 101–124.
- [87] MARSIGLI, C.; BOCCANERA, F.; MONTANI, A.; PACCAGNELLA, T. The COSMO-LEPS mesoscale ensemble system: validation of the methodology and verification. *Nonlinear Processes in Geophysics*. 2005, roč. 12, č. 4. ISSN 1607-7946.
- [88] FRALEY, C.; RAFTERY, A. E.; GNEITING, T.; SLOUGHTER, J. M. *ensembleBMA: An R Package for Probabilistic Ensemble Forecasting using Bayesian Model Averaging*. 2007.
- [89] SLOUGHTER, J. Mc Lean; RAFTERY, Adrian E.; GNEITING, Tilmann; FRALEY, Chris. Probabilistic Quantitative Precipitation Forecasting Using Bayesian Model Averaging. *Monthly Weather Review*. 2007, roč. 135, č. 9. ISSN 1520-0493.
- [90] PERNÍA-ESPINOZA, Alpha V.; ORDIERES-MERÉ, Joaquín B.; MARTÍNEZ-DE-PISÓN, Francisco J.; GONZÁLEZ-MARCOS, Ana. TAO-robust backpropagation learning algorithm. *Neural Networks*. 2005, roč. 18, č. 2.
- [91] CASTEJÓN, M.; ORDIERES, J.; GONZALEZ, A. *AMORE: A MORE flexible neural network package*. 2006.
- [92] VLASÁK, Tomáš. <https://www.chmi.cz/files/portal/docs/poboc/CB/pruvodce/predpovedi.html>. 2021.
- [93] YUAN, Huiling; GAO, Xiaogang; MULLEN, Steven L. aj. Calibration of Probabilistic Quantitative Precipitation Forecasts with an Artificial Neural Network. *Weather and Forecasting*. 2007, roč. 22, č. 6. ISSN 1520-0434.
- [94] PAKDAMAN, Morteza; FALAMARZI, Yashar; BABAEIAN, Iman; JAVANSHIRI, Zohreh. Post-processing of the North American multi-model ensemble for monthly forecast of precipitation based on neural network models. *Theoretical and Applied Climatology*. 2020, roč. 141, č. 1-2. ISSN 0177-798X.

- [95] ZHONG, Yixuan; GUO, Shenglian; BA, Huanhuan aj. Evaluation of the BMA probabilistic inflow forecasts using TIGGE numeric precipitation predictions based on artificial neural network. *Hydrology Research*. 2018, roč. 49, č. 5. ISSN 0029-1277.
- [96] KIM, Taareem; SHIN, Ju-Young; KIM, Hanbeen; HEO, Jun-Haeng. Ensemble-Based Neural Network Modeling for Hydrologic Forecasts: Addressing Uncertainty in the Model Structure and Input Variable Selection. *Water Resources Research*. 2020, roč. 56, č. 6. ISSN 0043-1397.
- [97] HEMRI, Stephan. Application of postprocessing for hydrological forecasts. In. *Statistical postprocessing of ensemble forecast*. 2018, s. 219–240.

A Typizace povětrnostních situací

Popis povětrnostních situací, které jsou nejčastěji příčinou významných srážek na našem území během letní poloviny roku.

B - brázda nízkého tlaku nad střední Evropou

Pro tuto situaci je typická primární cyklóna nad západní Skandinávií. Z této cyklony se rozširuje brázda až ke Středozevnímu moři. Tato brázda se vyskytuje mezi anticyklónami nad Atlantikem a východní Evropou. Postupující frontální zóna postupuje přes Biskajský záliv a přináší studený vzduch do západního Středomoří. Tento pohyb způsobuje proudění teplého vzduchu nad sever Itálie. Na hranici těchto dvou rozdílných vzduchových hmot se formuje nová frontální zóna postupující severovýchodním směrem. Srážky se vyskytují nejčastěji nad západní částí Slovenska a nad východní částí České republiky.

BP - brázda postupující přes střední Evropu

BP, na rozdíl od B, má odlišnou pozici primární cyklony. V tomto případě je primární cyklóna nad Islandem a anticyklóna je situována jižně nad Atlantickým oceánem. Brázda se pohybuje ze západu na východ přes střední Evropu a na její ose se vyskytuje frontální rozhraní. Frontální systémy postupují od jihu na sever po tomto rozhraní. Brázda se pohybuje rychle a tato situace má krátkou dobu trvání.

Cyklóna nad střední Evropou

Hlavním prvkem této situace je stacionární primární cyklóna nad západní Evropou, která se ke konci období pomalu přesouvá východním směrem. Oblast vysokého tlaku vzduchu se rozprostírá nad severovýchodní Evropou a nad Atlantikem. Frontální poruchy v teplém vzduchu postupují z jihu kolem primární cyklóny. Skutečnost, že střed primární cyklóny leží nad západní Evropou, způsobuje nejvýznamnější výskyt srážek na Českou republikou během této situace.

Ec - východní cyklonální situace

Tato povětrnostní situace je charakterizována stacionární primární cyklónou se středem na západní Itálii. Ve vyšších hladinách proudí kolem cyklóny nad střední Evropu teplý vzduch. Oblast vysokého tlaku vzduchu nad Skandinávií způsobuje chladné proudění nad jihozápadní část střední Evropy. Nad Maďarskem se tyto dvě vzduchové hmoty potkávají, vznikají konvekční proudy a formují se frontální poruchy. Tyto fronty poté směřují nad západní Evropu.

NEc - severovýchodní cyklonální situace

Pro tuto situaci je typická oblast vysokého tlaku vzduchu nad Velkou Británií nebo hřeben vysokého tlaku z jihozápadní Evropy přes Velkou Británii až do Skandinávie. V nižších hladinách proudí studený vzduch do střední Evropy. Ve stejnou chvíli proudí teplý vzduch ve vyšších hladinách do střední Evropy okolo cyklóny nad Balkánem. Tato vzduchová hmota přináší trvalé deště. V některých případech může být chladnější vzduch v nižších hladinách a nepříliš teplý vzduch ve vyšších hladinách. Poté se mohou frontální vlny posunout od Azorských ostrovů nad Středozemní moře, kde fronty mohou zesílit dostat se kolem cyklóny přes Balkán nad Polsko a poté do České republiky.

SWc2 - jihozápadní cyklonální situace 2

Hlavním znakem této situace je frontální zóna orientovaná od jihozápadu na severovýchod přes severozápadní Evropu. Teplá anticyklóna nebo její hřeben vysokého tlaku je situován nad Středozemním mořem. Cyklóna jižně od Islandu způsobuje studené proudění od Grónska do střední části Atlantiku, kde se tento chladný vzduch setkává s teplým vzduchem z jihozápadu. Tato frontální zóna produkuje frontální vlny a cyklóny, postupující dále ve směru nad Britské ostrovy, Finsko a Severní moře. Frontální systémy postupují rychle přes střední Evropu a oblast České republiky se střídavě vyskytuje v teplém a studeném sektoru. Situace končí studenou frontou přecházející přes střední Evropu a s větry v severozápadního směru.

B Odborný článek

VOKOUN, M. – HANEL, M. Comparing ALADIN-CZ and ALADIN-LAEF Precipitation Forecasts for Hydrological Modelling in the Czech Republic. *ADVANCES IN METEOROLOGY*, 2018, roč. 2018, č. 5368438, s. 1-14. ISSN: 1687-9309.

Research Article

Comparing ALADIN-CZ and ALADIN-LAEF Precipitation Forecasts for Hydrological Modelling in the Czech Republic

Martin Vokoun ^{1,2} and Martin Hanel¹

¹Department of Water Resources and Environmental Modeling, Faculty of Environmental Sciences, Czech University of Life Sciences Prague, Kamýcká 129, Praha 6, Suchbát 165 21, Czech Republic

²Department of Meteorology, Institute of Atmospheric Physics CAS, Bocni II 1401, Prague 141 31, Czech Republic

Correspondence should be addressed to Martin Vokoun; vokounm@fzp.czu.cz

Received 31 May 2018; Revised 1 August 2018; Accepted 6 August 2018; Published 18 September 2018

Academic Editor: Hiroyuki Hashiguchi

Copyright © 2018 Martin Vokoun and Martin Hanel. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Precipitation forecasting has great significance for hydrological modelling, particularly for issuing flood alerts. This study assesses the high-resolution deterministic model ALADIN-CZ (Aire Limitée, Adaptation Dynamique, Development International–Czech Republic) and the ensemble model ALADIN-LAEF (Limited Area Ensemble Forecasting). Verified precipitation data were modified to the form in which they enter the hydrological model used for flood forecasting in the Czech Republic. ALADIN-LAEF, unlike ALADIN-CZ, is currently not considered to be of any value for hydrological predictions in the Czech Republic. In the present paper, we assess the added value of the ensemble model. The most significant rainfall events from the summer seasons during 2011–2015 were selected for the purpose of this study. The results show that ALADIN-LAEF does not have a lower success rate than ALADIN-CZ in predicting significant rainfall events. In fact, for the most verification scores and metrics, ALADIN-LAEF was assessed as more skilful. Surprisingly, the high-resolution ALADIN-CZ does not yield higher success rates than ALADIN-LAEF even at short prediction lead times. This is due to spatial aggregation into hydrological regions, with an area significantly larger than the resolution of the forecasting models. Furthermore, the relationship between synoptic weather types, hydrological regions, and predictability was considered. It was found that the worst prediction results are related to weather situation C (cyclone over central Europe), which dominantly affects Berounka and Lower Elbe catchments.

1. Introduction

Hydrological modelling in the Czech Republic has received increased attention since destructive floods occurred in the years 1997 and 2002. The hydrological prediction system is operated today by the Czech Hydrometeorological Institute (CHMI). Outflow predictions are based on simulations of the AquaLOG (Elbe River basin) and HYDROG (Morava and Oder river basins) models. The hydrological forecast is generated with a 54 h lead time for 111 river profiles. Precipitation input data are provided by the ALADIN-CZ (Aire Limitée, Adaptation Dynamique, Development International–Czech Republic) deterministic high-resolution regional model. Before entering the hydrological model, these data are aggregated into 37 regions over the Czech Republic (Figure 1). This

preprocessing simplifies computation of the hydrological model and reduces uncertainty in the spatial distribution of rainfall [1]. Since 2011, the ESP (Ensemble Streamflow Prediction) system has been tested using the ALADIN-LAEF (Limited Area Ensemble Forecasting) ensemble precipitation forecast [2]. These ensemble outflow predictions are operationally simulated since 2012, but their practical implementation or public presentation is limited.

Despite improving hydrological forecasting methods, hydrological forecasts are still impaired by inaccuracies in the quantitative precipitation forecast (QPF) caused by initial conditions, boundary conditions, and model itself [3]. The possibility of determining the magnitude of forecast uncertainty is one of the reasons for the increasing popularity of ensemble prediction [4]. An ensemble forecast is

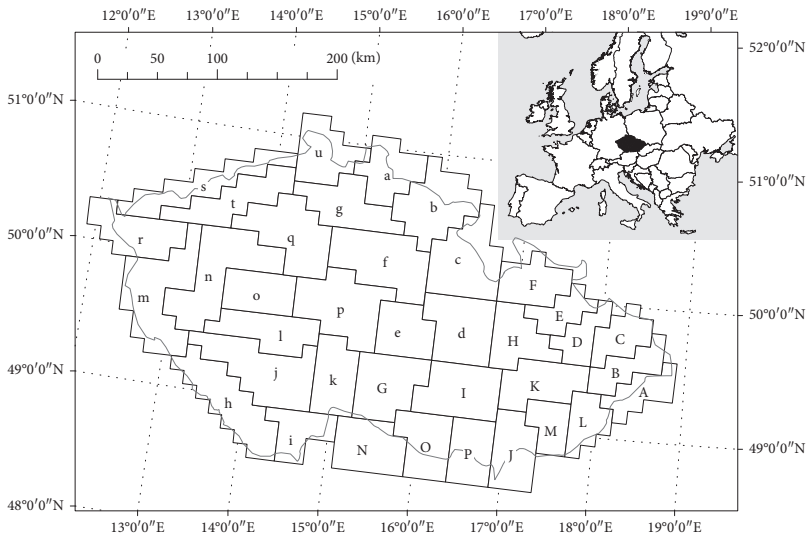


FIGURE 1: Study area. Hydrological regions for rainfall prediction averaging.

a valuable tool for decision making in hydrological prognostication, as stated, for example, by Cloke and Pappenberger [5] and Alfieri et al. [6]. Its growing popularity has led to the development of several international projects [7, 8]. On the other hand, due to the greater simplicity of their interpretation, deterministic forecasts are often more applicable for public users [9].

Verification of ALADIN-LAEF precipitation forecasts made on the 2010 data by CHMI provided unsatisfactory results and no significant benefit for hydroprognosis was found [10]. This verification used data for the whole year, not only for selected rainfall events, as is done in this work. For this reason, ensemble prediction was evaluated as a second-category product. The consequence of this is that until significant rain is predicted by deterministic ALADIN-CZ, the flood alert is not issued even if all ALADIN-LAEF members predict significant rain. The primary purpose of this work is not to assess the quality of each forecast but rather to assess the benefits of ALADIN-LAEF and its usefulness for hydrological prognosis during significant rainfall-runoff events. Of particular interest is the prediction skill in relation to forecast lead time, predicted total rainfall, and weather type during the event. Precipitation data are not verified in the format provided by forecast models, i.e., the original raster values are aggregated into hydrological regions with irregular shape, as is actually done during data preprocessing for hydrological model. This spatial treatment has a proven positive impact on the success [10].

The datasets and study area are introduced in Section 2. The forecast verification methodology for continuous values and binary events is explained in Section 3. This section also

contains some brief description of uncertainties entering into this verification. Section 4 presents the verification results and the case study of extreme rainfall-runoff event on 3 July 2013. Finally, Section 5 summarizes and discusses the results. The weather types under consideration are described in the Appendix section at the end of this paper.

2. Data and Study Area

In the Czech Republic, significant rainfall causing flood events occur in most cases during the warmer part of the year. Therefore, this study is limited to the warm season (April–October). All datasets were available for the years 2011–2015 and were provided by CHMI.

2.1. Precipitation Forecasts. Two different data sources were used. The first model, ALADIN-CZ, is a deterministic model operated by CHMI. The second model, ALADIN-LAEF, is an ensemble forecast running operationally at the European Centre for Medium-Range Weather Forecasts (ECMWF) using the ALADIN-AUSTRIA model configuration. All models are developed within the framework of the LACE (Limited Area modelling Central Europe) international cooperation [11].

2.1.1. ALADIN-CZ Rainfall Data. ALADIN-CZ is a high-resolution hydrostatic spectral limited-area model (LAM). It produces a six-hour precipitation forecast four times daily (00 UTC, 06 UTC, 12 UTC, and 18 UTC) with a forecast range of 54 h (same as hydrological models). The horizontal

resolution is 4.7 km and number of levels used in vertical is 87. Only simulated rainfall amounts from 00 UTC and 12 UTC are postprocessed and used as inputs to the hydrological models. The domain of ALADIN-CZ covers the entire area of the Czech Republic, including the border areas [12, 13].

2.1.2. ALADIN-LAEF Rainfall Data. ALADIN-LAEF is a limited-area ensemble prediction system providing a variety of predictions with initial perturbations that are generated by a breeding-blending method, based on Wang et al. [14] and Wang et al. [11]. This method combines ECMWF-EPS large-scale perturbations and ALADIN-LAEF small-scale perturbations from previous runs using digital filtering. It also contains ARPEGE (Action de Recherche Petite Echelle Grande Echelle) analysis and multiphysics [15]. ALADIN-LAEF contains 17 members, consisting of 16 perturbations and 1 control forecast with horizontal grid spacing of 11 km and 60 levels of vertical resolution. Forecasts are initialized two times per day at 00 UTC and 12 UTC up to lead time 72 h. To match the ALADIN-CZ forecasts, the evaluation presented here was performed on a shorter forecast range of 54 h ahead, and the ALADIN-LAEF domain, covering the whole of Europe and part of the Atlantic [16], was limited to the Czech Republic.

2.2. Rainfall Observations. Adjusted radar rainfall estimates were used for the forecasts verification. One-hour quantitative precipitation estimates that were available for the study are the result of merging rain-gauge and radar measurements [17]. The Czech weather radar network (CZRAD) is operated by CHMI and consists of two C-band radars covering the entire area of the Czech Republic [13]. The rain-gauge network (CLIDATA database) is still growing and today encompasses approximately 500 rain gauges [18]. This gauge network density does not yet guarantee accurate rainfall estimates of convective events, and it provides only a partial view of precipitation's spatial variability. Therefore, conventional ground measurements are used to calibrate radar images, and radar measurements are used to estimate the spatial variability of the process [3]. Merging of radar estimates with rain-gauge measurements at CHMI is done using regression kriging [18, 19]. These data are also applied to several catchments as an alternative precipitation input for hydrological models and, with respect to verification results, they provide the most accurate estimation available of areal rainfall amounts [20]. For the purpose of this study, data were aggregated to 6 h accumulations in the time step corresponding to the forecasts.

2.3. Area of Interest. The area of interest consists of 37 hydrological regions. These regions were proposed by CHMI and are routinely used in operational hydrology. The outer boundary approximately corresponds to the Czech Republic's natural river basins. For this reason, the area of interest extends beyond the Czech boundaries. The shapes of individual areas partly respect the borders of subbasins and

at the same time the landscape orography. These hydrological regions are divided into two groups. The first group, shown in Figure 1, is labelled by lowercase letters (areas covered by the AquaLog hydrological model) and the second group by capital letters (areas covered by the HYDROG hydrologic model) [10]. Sizes of the individual areas vary between 1338.6 km² (region "M") and 4041.3 km² (region "m"), while the average area of a region is 2503.8 km². The rainfall data entering the hydrological model for each region are aggregated, meaning that in each time step, each region has only one input rainfall value.

2.4. Synoptic Weather Types. A calendar of synoptic weather types (SWT) has been continually updated for the territory of the Czech Republic since 1946. These data are freely available on the CHMI webpage (<http://portal.chmi.cz/historicka-data/pocasi/typizace-povetnostnich-situaci>). From the catalogue of 25 synoptic situations [21], exactly one type describing weather over the Czech Republic with respect to the situation over the whole of Europe and part of the Atlantic is determined for each day. For verification of the precipitation predictability depending on the actual synoptic situation, 6 SWTs occurring most frequently during rainfall events in the warm seasons of 2011–2015 were selected (from the total number of 19 SWTs occurring during the events). These 6 types are B—trough of low pressure over central Europe, Bp—trough moving over central Europe, C—cyclone over central Europe, Ec—eastern cyclonic situation, NEC—northeastern cyclonic situation, and SWc2—southwestern cyclonic situation 2. Characteristics of the synoptic weather types are described in detail in the Appendix section.

2.5. Rainfall Events. Based on the measured data, rainfall events with following characteristics were selected. The total number of determined events in individual regions is 824. The highest number of those events (35) was observed in the "h" region, while the lowest number (14) was in the "r" region. The average event duration was 28.5 h. The largest rainfall amount was 145.3 mm, which occurred with 72 h duration in the "a" region on 22 July 2011. This event occurred during a "C" weather type. The smallest rainfall amount from the evaluated events was 15 mm and the average event rainfall was 26 mm. The greatest event length of 96 h was observed from 13 to 17 May 2014 in the "C" region during a "Bp" weather type. The most significant flood occurred on 3 June 2013 and affected the entire river basin of the Vltava and northern part of Bohemia. Some flow rates gained values of 100-year flood. For the verification purpose, all 54 h forecasts overlapping time range of defined events were evaluated.

3. Verification Methodology

3.1. Data Preprocessing. All data were aggregated to 37 regions in the same way as is done for hydrological prediction purposes. This study assesses the performance of ALADIN-CZ and ALADIN-LAEF during events causing significant

rainfall-runoff response. The event selection was performed by applying the USLE definition in a similar way as was done by Hanel and Maca [22] and by Svoboda et al. [23], which means that only events with total depth greater than 12.7 mm and separated by at least a 6 h period without rain or events with maximum intensity greater than 6.35 mm/15 min are considered. Exceeding these thresholds potentially leads to soil erosion and surface runoff [24].

3.2. Verification Scores and Methodology. Given the focus of this work on precipitation data for hydrological modelling in the CHMI with its primary focus on the deterministic forecast, it was necessary to verify the ensemble data expressed as both probabilistic and deterministic forecasts.

ALADIN-CZ and ALADIN-LAEF forecasts were evaluated by verification methods for continuous variables as well as for binary (dichotomous) events (methods are described in the following paragraphs). Within the ensemble verification, all 16 + 1 members were evaluated individually. Moreover, ensemble mean (hereafter referred to as MEAN) and ensemble median (hereafter referred to as MEDIAN) were evaluated as well. Both MEAN and MEDIAN are calculated from 16 ensemble members. The seventeenth member is the control forecast (hereafter referred to as CF), and it is separated from the ensemble because the initial conditions for perturbations are centred around the control analysis, thereby generating the positive and negative perturbations [15, 25]. Forecast results similar to the MEAN can therefore be expected. When deterministic and probabilistic forecasts are compared, it is necessary to transform the probabilistic forecast to deterministic or the deterministic forecast to probabilistic using binary values [26]. With respect to the purpose of this work, MEAN and ALADIN-CZ are the pairs most often compared here as two deterministic predictions.

Verification methods recommended by Jolliffe and Stephenson [27], Wilks [28], and WMO [29] were used in this study. The correspondence between observations and predictions in the form of continuous values was assessed using mean error (ME), mean absolute error (MAE), and root mean squared error (RMSE). The association between observations and predictions was evaluated by Pearson correlation (COR). A verification approach based on binary events was chosen. Continuous values were transformed to binary by setting the probability of the deterministic forecast to 1 if the predicted event will occur and otherwise to set the probability to 0 [4]. Verification of binary events provides an extensive range of binary scores based on a contingency table summarizing the frequency of “yes” (1) and “no” (0) forecasts and occurrences, where rainfalls equal to or greater than a predefined threshold are set to “yes” and smaller rainfalls to “no” (nonevent). The contingency table provides four possible pair combinations of the counted absolute frequencies of yes/no forecasts and observations and is termed joint distribution. These pairs are usually referred to as hits, misses, false alarms, and correct rejections [28, 29]. Because performance was evaluated only for substantial rainfall events, only those scores were selected not focusing on correct rejections.

Binary scores were calculated for the same data as in the case of continuous values. The following binary measures were used: frequency bias (B); threat score (TS); probability of detection (POD), also known as hit rate (H); false alarm ratio (FAR); probability of false detection (POFD), also known as false alarm rate (F); proportion correct (PC); Heidke skill score (HSS); odds ratio (OR); odds ratio skill score (ORSS); Pierce skill score (PSS); Brier score (BS); and ranked probability score (RPS). The latter two are applicable also for probabilistic forecasts [26, 29]. The scores along with the range of possible values and the perfect score are shown in Table 1.

Unlike deterministic forecasts of binary events and continuous values, a probabilistic forecast is expressed as the probability of an event's occurrence having a value between 0 and 1, inclusive. Common summary measures of ensemble (ALADIN-LAEF) forecast skill, Brier skill score (BSS), and ranked probability skill score (RPSS) were calculated [30]. These scores assess the ensemble skill against the reference forecast. The reference forecast is usually obtained from climatology. It is also possible to use a deterministic forecast as a reference forecast. For the purpose of this work, the ALADIN-LAEF probabilistic forecast was compared to the reference forecasts given by ALADIN-CZ, MEAN, MEDIAN, and CF. A different approach to evaluating the ensemble forecast provides a rank histogram (also known as the Talagrand diagram). This graphical method tests ensemble reliability by ranking the observed outcomes with respect to the corresponding ensemble members [30, 31]. In accordance with the histogram's shape, a rank histogram provides information about an ensemble's bias and spread. The best result is indicated by a flat histogram, i.e., by uniform distribution of ranks. A lack of variability (underdispersion) is represented by a U-shaped histogram, a dome-shaped histogram means too large ensemble spread (overdispersion), and an asymmetric histogram indicates underforecasting or overforecasting bias [28, 32].

4. Results

All forecasts were verified from the perspective of dependence on time-ahead and rainfall thresholds. Thresholds were defined with respect to the measured 6 h rainfall accumulations at 1, 2.5, 5, and 10 mm. Calculations of these characteristics were related to the individual hydrological regions and, for the sake of clarity, were averaged to a single value representing all regions. Another perspective was provided by evaluation of forecast accuracy during the weather types occurring most frequently during the selected events. The 6 h precipitation totals were verified for all 16,938 forecast-observation pairs. In the following figures, ALADIN-CZ is referred to as ALADIN, ALADIN-LAEF ensemble mean as MEAN, ALADIN-LAEF ensemble median as MEDIAN, and ALADIN-LAEF ensemble control forecast as CF.

4.1. Continuous Variables. This section compares the dependence of forecasts accuracy on lead time (for a 6 h time

TABLE 1: Comparison of ALADIN and MEAN verification scores for all data together without dependence on lead time or threshold. Bold values indicate better scores.

Score	ALADIN	MEAN	Range	Perfect score
Correlation (COR)	0.0396	0.0774	[-1, 1]	1
Root mean squared error (RMSE)	7.3250	6.6944	[0, +∞]	0
Mean absolute error (MAE)	5.0287	4.5540	[0, +∞]	0
Bias (BIAS)	0.7611	0.7011	[0, +∞]	1
Brier score (BS)	0.3878	0.3630	[0, 1]	0
Ranked probability score (RPS)	0.2440	0.2439	[0, 1]	0
Equitable threat score (ETS)	0.1354	0.1614	[-1/3, 1]	1
Threat score (TS)	0.3915	0.3997	[0, 1]	1
Probability of detection (POD)	0.4955	0.4858	[0, 1]	1
False alarm ratio (far)	0.3489	0.3071	[0, 1]	0
Probability of false detection (POFD)	0.2579	0.2091	[0, 1]	0
Proportion correct (PC)	0.6206	0.6406	[0, 1]	1
Heidke skill score (HSS)	0.2385	0.2779	[-1, 1]	1
Odds ratio (OR)	2.8266	3.5734	[0, +∞]	+∞
Odds ratio skill score (ORSS)	0.4773	0.5627	[-1, 1]	1
Pierce skill score (PSS)	0.2376	0.2767	[-1, 1]	1

step). Figure 2 shows error metrics (ME, MAE and RMSE) and correlation (COR). With the exception of ME, the accuracy does not decrease substantially with increasing time ahead. ALADIN is evaluated as best only for ME. That is in contrast with MAE, where absolute error values are used. It is therefore likely that ALADIN's positive and negative errors compensate one another. ME for all models indicates negative bias (underforecast). MEAN is the best ensemble-based result. Poorer results, albeit still better than those of ALADIN (except for ME), are achieved by MEDIAN and CF.

4.2. Binary Events. As seen in Figure 3, methods for binary events yield less substantial differences between the forecasts compared to the error metrics of continuous variables. POD is the proportion of occurrences that were correctly forecasted [26] and the perfect score is 1. Figure 3 shows a better performance of MEAN in the near lead time but a sizeable drop in the score from the time 48 h ahead, whereas ALADIN's success rate from this time increases. TS also concerns correctly predicted events, as is reflected in the similar increase of score difference between MEAN and ALADIN from 48 h ahead. A different perspective is provided by FAR and POFD, which emphasize mainly the false alarms, and the perfect score is 0 in both cases. FAR evaluates ALADIN best in all time steps. On the other hand, POFD evaluates ALADIN significantly more poorly while MEAN is around the average values, and only in this case does MEDIAN have the best score. The reason for these differences in results is that FAR calculation takes hits into account but POFD takes correct rejections into account.

Figure 4 shows the threshold-dependent POD, TS, FAR, and BS curves. This verification method evaluates insignificant divergence in the forecasts accuracy and the skill levels of all models are similar. Except for BS, all scores have a declining trend of success in dependence on increasing thresholds. In addition, BS (in contrast to other scores) does not consider only binary values. The ensemble probabilistic

forecast is expressed as one probability value (in the range from 0 to 1), while observation is a binary value, i.e., 0 or 1 [30]. For this reason, the ensemble is represented by a single grey line in the BS graph.

Figure 5 compares the ensemble forecast skill with respect to the reference forecast (here ALADIN, MEAN, MEDIAN, and CF are considered as reference forecasts). The perfect score is 1 (with 0 indicating no skill) in both RPSS and BSS. This means that the higher the value, the less successful is the deterministic model vis-à-vis the probabilistic ensemble forecast. RPSS increases with increasing forecast lead time and differs only slightly for different reference forecasts. According to BSS, MEAN is the best deterministic forecast, though still poorer than the probabilistic ensemble forecast. The ensemble shows the greatest skill improvement relative to ALADIN in the middle part of the forecast lead time.

4.3. Rank Histogram. A rank histogram constitutes a verification method providing information about ensemble spread and dispersion characteristics. This method is not suitable for comparing deterministic forecasts, and therefore, only the ALADIN-LAEF ensemble was assessed. In order to obtain the dispersion characteristics for different rainfall amounts, the rainfall was divided into classes with 6 h rainfall amounts of less than 1, 2.5, 5, and 10 mm and greater than 10 mm. Figure 6 shows a U-shaped histogram characterizing too small ensemble spread. Furthermore, due to decomposition, it is obvious that the ensemble overestimates smaller rainfalls and underestimates larger rainfalls.

4.4. Hydrological Regions. For more detailed evaluation, all hydrological regions were verified individually. The success of predictions in each region was determined by application of five verification methods (COR, MAE, RMSE, TS, and POD). Based on the results, the regions were ranked from best to worst for each method separately. The rank values (five for each region) were then summed and divided into

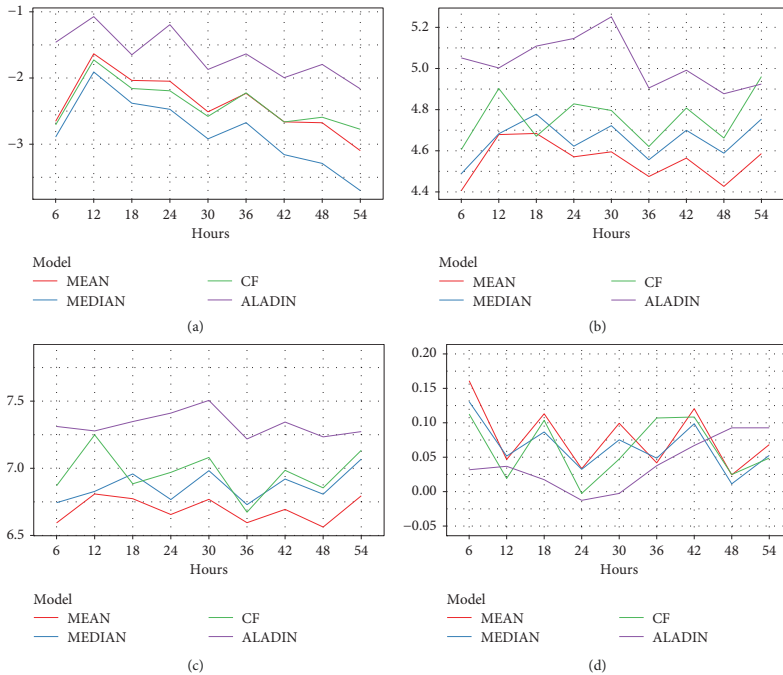


FIGURE 2: Comparison of ALADIN (purple), MEAN (red), MEDIAN (blue), and CF (green) for ME (a), MAE (b), RMSE (c), and COR (d) as a function of lead time. Grey lines represent 16 ensemble members.

five groups representing forecasting skill, where 1 means the best and 5 the worst results, as seen in Figure 7. Forecasts of ALADIN and ensemble MEAN were assessed in dependence on thresholds (1, 2.5, 5, and 10 mm) and, for additional comparison purposes, by the average of these results. Figure 7 shows that some problematic regions are situated in the northwestern part of the Czech Republic. Border and mountain areas provide surprisingly better results in most cases, especially in the western and eastern parts of the country.

4.5. Synoptic Weather Types. The ALADIN and MEAN forecasts during the five most frequently occurring weather types were verified by COR, MAE, RMSE, POD, TS, and BS. As can be seen in Figure 8, predictions during the Ec weather type achieved the highest rate of success. In contrast, the forecast accuracy is lowest during the Swc2 weather type. Differences between ALADIN and MEAN forecast in Figure 8 confirm the conclusions drawn from Figures 2 and 3.

4.6. Flood Event on 3 June 2013. At the end of May, the territory of the Czech Republic was affected by several waves

of heavy rainfall causing strong soil saturation. The strongest precipitation wave came on 1 June, however. This was due to a trough of low pressure moving from the east over the Czech territory (synoptic weather type “C”) [33]. An area of high pressure over Northern Europe and a ridge of high pressure over Western Europe prevented the trough of low pressure from advancing further west. This resulted in retrograde movement of waved frontal systems over Central Europe and total precipitation sporadically exceeding 100 mm day^{-1} [34]. Figures 9(a) and 9(c) display the measured (OBS) and predicted rainfall amounts aggregated from 1 June 00 UTC in areas “k” and “l”. These two areas are both in the southeastern part of the South Bohemia Region. The areas were selected due to availability of data from the ensemble hydrological forecast and also because they were in the main precipitation belt. Figures 9(b) and 9(d) show the measured flows (OBS) and hydrological forecasts from the same date as the precipitation forecast created on the basis of data from the ALADIN-LAEF ensemble and from the deterministic ALADIN-CZ forecast for the Pílař and Lásenice measuring profiles. The Pílař profile is located on the River Lužnice in region “i” with a watershed area of 935.23 km^2 . The Lásenice profile is on the River Nežárka in region “k”

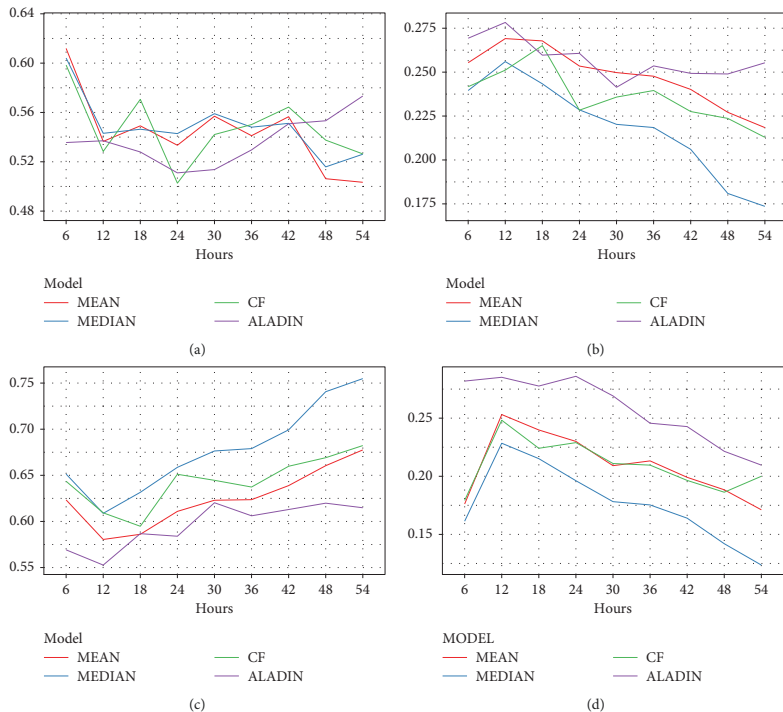


FIGURE 3: Comparison of ALADIN (purple), MEAN (red), MEDIAN (blue), and CF (green) for POD (a), TS (b), FAR (c), and POFD (d) as a function of lead time. Grey lines represent 16 ensemble members.

with a watershed area of 684.66 km². For more information, see Table 2.

Total precipitation estimates generally were being underestimated in all areas, which also affected flow predictions. In the case of regions “j” and “k”, as well as in other areas, the rains started earlier than expected. Nevertheless, the hydrological models successfully estimated the onset of the flood wave. As time passed, the effect of the underestimation of precipitation became apparent and predicted flows started to be lower than measured values. The models produced greater inaccuracies in the case of the Lásenice measuring profile, where culmination flow was reached at an earlier time than that was in the Pilař profile. Even though the ensemble average was worse than the deterministic forecast, its distribution of predicted flows affected the measured culmination values. This extreme precipitation outflow event corresponds with the results of verification in this study, where use of the mean precipitation ensemble model suitably complements the simultaneous deterministic forecast. It also indicates the suitability of applying an ensemble forecast in operational

hydrology in order more accurately to describe the uncertainty of hydrological forecasting.

5. Summary and Conclusions

In this paper, two different models providing precipitation forecasts are verified and compared. The first of these is the ALADIN-CZ regional deterministic model. Precipitation predictions of this model are used operationally for hydrological forecasting at CHMI. The second of these is ALADIN-LAEF. This model provides an ensemble precipitation forecast and, even though the data is available, it is considered not to be beneficial for hydrological forecasting. This study was undertaken to assess potential benefits of using ALADIN-LAEF precipitation forecasts for hydrological modelling, especially in cases of significant rainfall events. The results from this paper will be used in developing effective postprocessing methods for hydrological prognostication.

Various verification methods were applied in evaluating the two models. For comparison with the deterministic

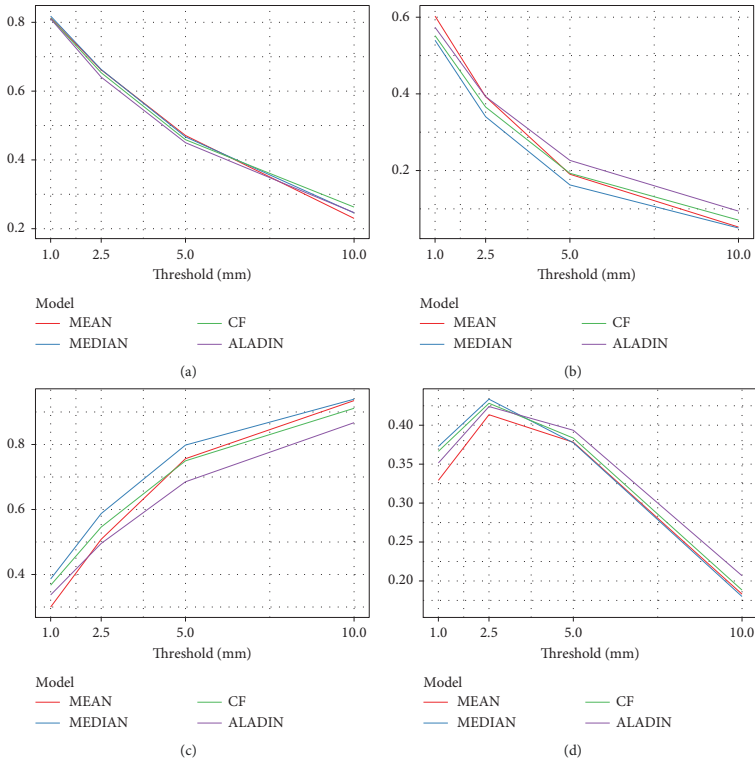


FIGURE 4: Comparison of ALADIN (purple), MEAN (red), MEDIAN (blue), and CF (green) for POD (a), TS (b), FAR (c), and BS (d) as a function of thresholds. Grey lines represent 16 ensemble members. In case of BS, the ensemble is represented by single grey line.

ALADIN-CZ (ALADIN), the ALADIN-LAEF ensemble (consisting of 16 members) was in most cases represented by simple mean (MEAN), median (MEDIAN), and control forecast (CF). According to ME, both models tend to underestimate precipitation. In the case of the ensemble forecast, the rank histogram shows increasing underestimation with increasing rainfall. It is necessary to point out, however, that verified rainfall events were determined using observations, not model predictions. ME is also the only score that clearly evaluates ALADIN as best. This could be caused by error compensation. The results are different in the case of MAE, where absolute values are used. MAE, RMSE, and COR evaluate MEAN as the best. Verification scores for binary and discrete values provide less-clear results. MEAN performed more poorly compared to ALADIN as measured by FAR, which means that ALADIN deals better with false alarms. On the other hand, MEAN performed better according to POFD,

indicating poorer performance of ALADIN in correct rejections. POD and TS indicate no significant divergence between ALADIN and MEAN. It is noteworthy that ALADIN predictions improved at the end of the lead time. It is generally assumed that due to the higher resolution of the deterministic model compared to the ensemble, the deterministic model is more valuable in the first few hours of prediction. Effect of data aggregation into hydrological regions, with an area significantly larger than the models' resolution, leads to the results that even in the early hours, ALADIN-CZ does not yield higher success rate.

In addition to the deterministic approaches, probabilistic forecasts were also assessed by RPSS and BSS. Figure 5 shows the positive skill of the ensemble forecast relative to ALADIN, MEAN, MEDIAN, and CF, which were used as reference forecasts. This method also allowed for comparison of the reference forecasts themselves. Especially in the case of




FIGURE 5: Ensemble skill scores using ALADIN (purple), MEAN (red), MEDIAN (blue), and CF (green) as reference forecasts. RPSS (a) and BSS (b) show positive ensemble skill as a function of lead time.




FIGURE 6: Rank histogram for ensemble forecast (ALADIN-LAEF). Bins decomposition is based on 6 h rainfalls <1 mm, <2.5 mm, <5 mm, <10 mm, and >10 mm (white bars).

BSS, it is obvious that the performance of MEAN is better in comparison with ALADIN, meaning that the ensemble forecast has lower positive skill relative to MEAN than to ALADIN.

The influence of weather type on forecast skill was assessed. It is clear from Figure 8 that in the cases of ALADIN and MEAN, the weather types were evaluated similarly. There were greater differences between the individual situations, and especially as measured by RMSE, than

between models. The poorest skill was achieved during SWc2 situations, which are characterized by frontal systems frequently passing from the Atlantic Ocean.

Finally, five verification metrics were used to rank ALADIN and MEAN forecast accuracy in individual hydrological regions. The regions with the poorest forecast accuracy were similar for both models. The same is true for regions where the prediction was most successful. Unfortunately, the poorest-rated regions are among those most

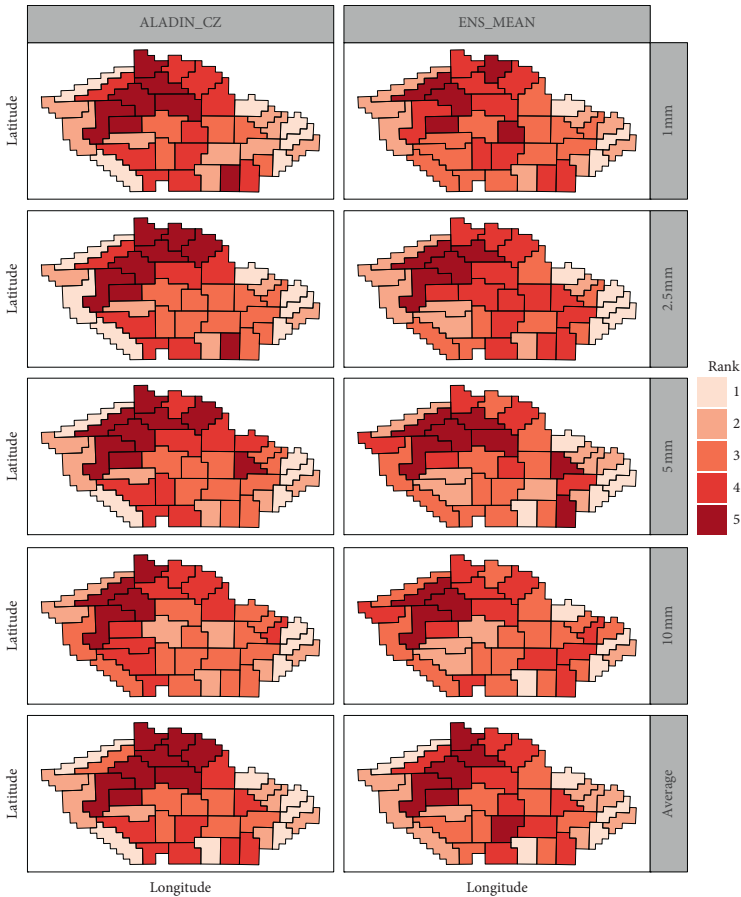


FIGURE 7: Ranking of forecast accuracy in dependence on threshold in the individual hydrological regions. Regions are ranked from 1 to 5, where 1 means the best forecast (light red) and 5 means the poorest forecast (dark red). Results are shown for ALADIN and MEAN. The last row presents average rank of 1, 2.5, 5, and 10 mm thresholds.

often hit by floods in the last 60 years. However, the success rate of predictions in the individual areas corresponds to the results of the evaluation of synoptic weather types. Predictions during the weather situation Ec and NEc reach the highest accuracy. This situation brings in most cases significant rainfall to the east part of Czech Republic, where the success rate of the forecast compared to the rest of the territory is higher. On the other hand, the worst-rated weather situation C brings the most rainfall to the area between the southwestern and northern parts of the Czech Republic, where the poorest-rated regions are situated.

Finally, the influence of weather type on forecast skill was assessed. It is clear from Figure 8 that in the cases of ALADIN and MEAN, the weather types were evaluated similarly. There were greater differences between the individual situations, and especially as measured by RMSE, than between models. The poorest skill was achieved during SWc2 situations, which are characterized by frontal systems frequently passing from the Atlantic Ocean.

Whether the deterministic ALADIN-CZ is or is not more skillful than the simple ensemble mean is not so clear. Although for most verification scores and metrics, MEAN

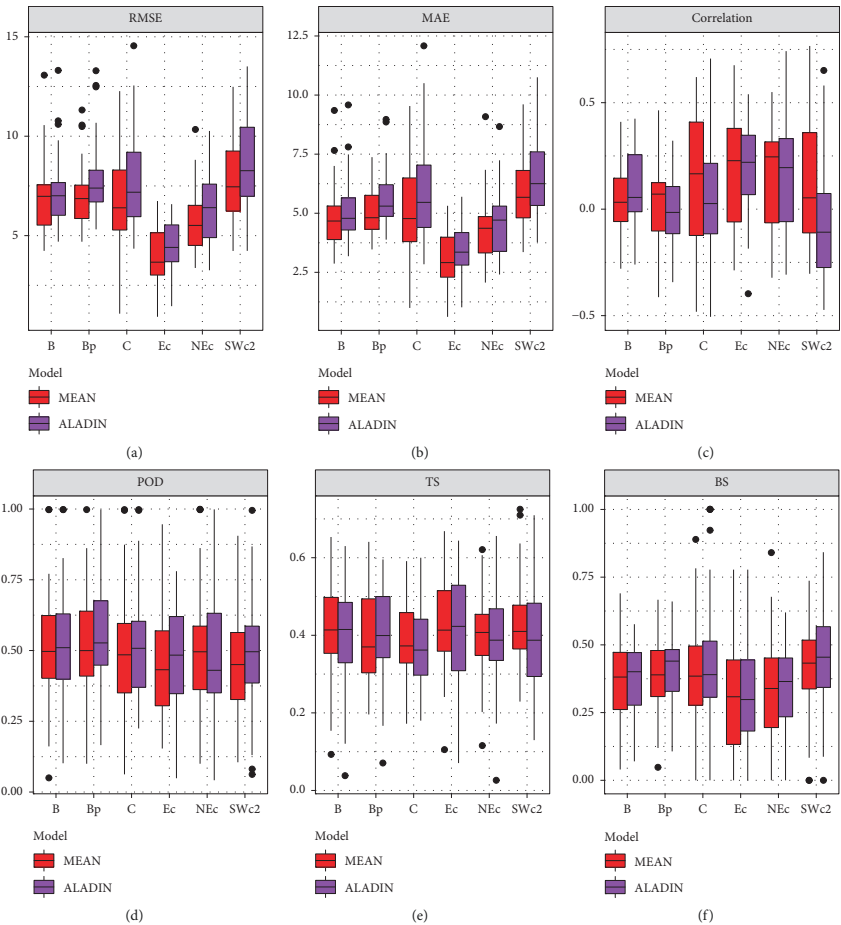


FIGURE 8: Boxplots of RMSE (a), MAE (b), COR (c), POD (d), TS (e), and BS (f) dependence on weather types. ALADIN results are plotted with purple boxes, MEAN with red boxes.

was assessed as more skilful (Table 2), and the differences were often not substantial. RMSE and MAE were examples of exceptions in which ALADIN reached a markedly greater error rate, but its applicability from the perspective of use in hydrological forecasting was verified. From the results reported above, it can be seen that ALADIN-LAEF could at least be used as an additional data source for hydrological forecasting, especially in the form of a probabilistic forecast. ALADIN-LAEF is at least an equally valuable source in comparison to deterministic ALADIN-CZ, and it should be considered as a relevant source of information for

hydrological prediction. In general, ensemble systems are commonly used to determine the degree of uncertainty of predictions. However, it is clear from the results that the mean of the ensemble is also beneficial, and therefore, it would be appropriate to include it in the form of deterministic prediction alongside the current ALADIN-CZ prediction. A suitable form for combining high-resolution deterministic forecasting and an ensemble prediction system has been described by Rodwell [4] and termed the combined prediction system. This method produces probabilistic forecasts while including a deterministic model as an

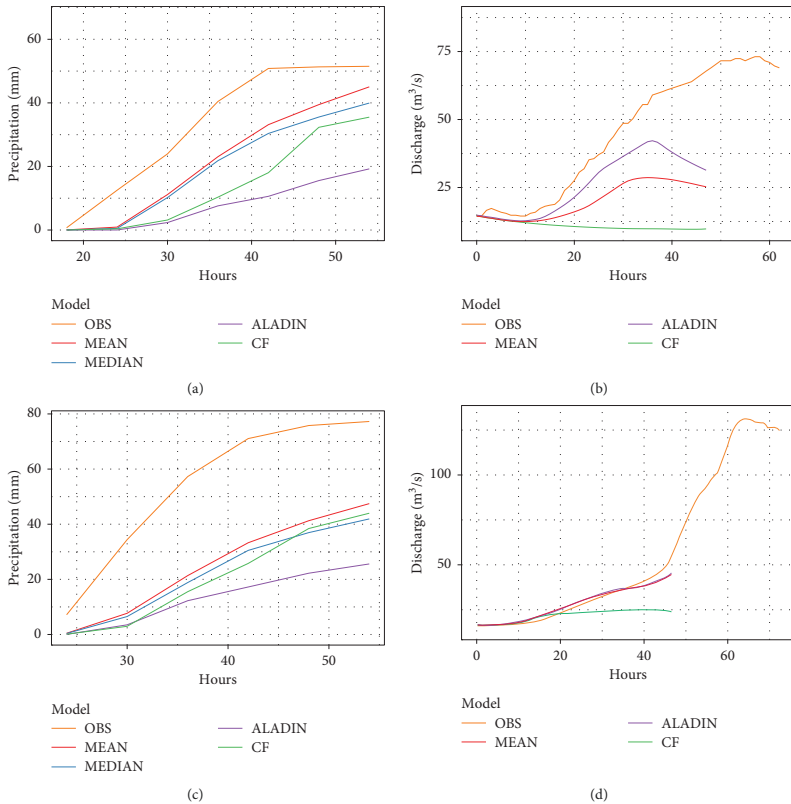


FIGURE 9: Comparison of ALADIN (purple), MEAN (red), MEDIAN (blue), CF (green), and measured data-OBS (orange). Lines with measured flows are extended to the culmination time. (a) region k, (b) Lásenice, (c) region i, and (d) Pilař.

TABLE 2: Hydrological characteristics for regions “k” and “i” during the flood event on 3 June 2013.

Region	Observed rainfall (mm)	ALADIN-CZ (mm)	ALADIN-LAEF MEAN (mm)	ALADIN-LAEF maximum (mm)	Gauging station/river	Gauging station basin area (km ²)	Maximum outflow (m·s ⁻¹)
K	51.5	19.2	45.0	62.4	Lásenice/Nežárka	684.7	73.1
I	77.3	25.6	47.4	66.7	Pilař/Lužnice	935.2	133.0

ensemble member with weight determined by the count of equivalent ensemble members.

Appendix

Synoptic Weather Types

B: Trough of Low Pressure over Central Europe. The characteristic feature of this situation is a primary cyclone over Western Scandinavia. From this cyclone a trough extends

as far as the Mediterranean Sea. This trough is in the area between anticyclones over the Atlantic and Eastern Europe. A dissipating frontal zone moves over the Bay of Biscay and brings cold air to the Western Mediterranean. This movement causes an inflow of warm air from the southeast over the north of Italy. At the boundary of these two different air masses, there forms a new frontal zone, which moves to the northeast. Precipitation occurs most often over Western Slovakia and the eastern part of the Czech Republic.

BP: Trough Moving over Central Europe. The Bp type differs from B by the primary cyclone position. In the Bp type, there is a cyclone over Iceland and an anticyclone situated further south over the Atlantic Ocean. The trough moves from west to east over central Europe, and the frontal boundary is located within its axis. Frontal systems move from south to north by this boundary. The trough moves quickly, and this situation is of short duration.

C: Cyclone over Central Europe. The main feature of this situation is a stationary primary cyclone over Western Europe, which at the end of the period moves slowly eastward. A high-pressure area is over northeastern Europe and over the Atlantic Ocean. The frontal disturbances in the warm air pass from the south around the primary cyclone. The fact that the centre of the primary cyclone is positioned over Western Europe causes the greatest occurrence of precipitation over the Czech Republic during this situation.

Ec: Eastern Cyclonic Situation. This weather type is characterized by a stationary primary cyclone with its centre over the Tyrrhenian Sea (to the west of Italy). At higher levels around the cyclone, warm air flows from the southeast over Central Europe. A high-pressure area is over Scandinavia and causes cold air to flow southwest to Central Europe. Over Hungary, where these two air masses meet, convection currents develop and form frontal disturbances. These fronts shift to Western Europe.

NEC: Northeastern Cyclonic Situation. The NEC situation is typified by an area of high pressure over Great Britain or a ridge of high pressure from southwest Europe, over Great Britain, and up to Scandinavia. At lower levels, cold air flows to Central Europe. At the same time, warm air flows to Central Europe at higher levels around the cyclone over the Balkans. This air brings persistent rainfall. In some situations, there may be colder air at lower levels and not too warm air at higher levels. The frontal waves can then shift from the Azores over the Mediterranean Sea, where fronts may intensify and shift around the Balkan cyclone to Poland and then to the Czech Republic.

SWc2: Southwestern Cyclonic Situation 2. The main feature of this situation is a frontal zone oriented from southwest to northeast over northwestern Europe. A warm anticyclone or only a ridge of high pressure is situated over the Mediterranean Sea. A cyclone to the south of Iceland causes cold air to flow from Greenland to the middle part of the Atlantic Ocean, where this cold air meets up with warm air from the southwest. This frontal zone produces frontal waves, and cyclones continue to move in a direction over the British Isles, Finland, and the North Sea. Frontal systems frequently pass over Central Europe. An area over the Czech Republic is alternately in a cold and a warm sector. The situation ends with a cold front passing through Central Europe and with wind in a northwesterly direction.

The forecasts and observed data used to support the findings of this study were supplied by Czech Hydrometeorological Institute under license and so cannot be made freely available. Requests for access to these data should be made to chmi@chmi.cz.

Data Availability

The forecasts and observed data used to support the findings of this study were supplied by Czech Hydrometeorological Institute under license and so cannot be made freely available. Requests for access to these data should be made to chmi@chmi.cz.

Disclosure

The abstract of this paper was presented in EMS Annual Meeting Abstracts, 2017.

Conflicts of Interest

The authors declare that they have no conflicts of interest.

Acknowledgments

This project was supported by the Internal Grant Agency of the Faculty of Environmental Sciences (Project no. 20164225), Czech University of Life Sciences Prague. We also acknowledge the Czech Hydrometeorological Institute for providing all data.

References

- [1] J. Daňhelka, "Operativní hydrologie: hydrologické modely a nejistota předpovědi," *Sborník prací Českého Hydrometeorologického Ústavu*, vol. 51, p. 104, 2007.
- [2] Aqualogic, *ESP Teorie a Referenční Příručka*, Aqualogic, Prague, 2011.
- [3] A. Musy, B. Hingray, and C. Picouet, "Data required for hydrological analysis and modeling," in *Hydrology: A Science for Engineers*, CRC Press, Boca Raton, FL, USA, 2014.
- [4] M. Rodwell, "Comparing and combining deterministic and ensemble forecasts: how to predict rainfall occurrence better," *ECMWF Newsletter*, vol. 106, pp. 17–23, 2006.
- [5] H. I. Cloke and F. Pappenberger, "Ensemble flood forecasting: a review," *Journal of Hydrology*, vol. 375, no. 3–4, pp. 613–626, 2009.
- [6] L. Alfieri, F. Pappenberger, F. Wetterhall, T. Haiden, and D. Richardson, "Evaluation of ensemble streamflow predictions in Europe," *Journal of Hydrology*, vol. 517, pp. 912–922, 2014.
- [7] J. D. Brown, L. Wu, M. He, S. Regonda, H. Lee, and D. Seo, "Verification of temperature, precipitation, and streamflow forecasts from the NOAA/NWS Hydrologic Ensemble Forecast Service (HEFS): 1. Experimental design and forcing verification," *Journal of Hydrology*, vol. 519, pp. 2869–2889, 2014.
- [8] J. C. Schaake, T. M. Hamill, R. Buizza, and M. Clark, "HEPEX: the hydrological ensemble prediction experiment," *Bulletin of the American Meteorological Society*, vol. 88, no. 10, pp. 1541–1547, 2007.

- [9] T. Palmer, R. Buizza, R. Hagedorn et al., "Ensemble prediction: a pedagogical perspective," in *ECMWF Newsletter*, pp. 10–17, 2006.
- [10] J. Mašek and T. Vlasák, *Calibration of ALADIN/LAEF Precipitation Ensembles*, RC LACE predictability, 2011.
- [11] Y. Wang, M. Bellus, J.-F. Geleyn, X. Ma, W. Tian, and F. Weidle, "A new method for generating initial condition perturbation in a regional ensemble prediction system: blending," *Monthly Weather Review*, vol. 142, no. 5, pp. 2043–2059, 2014.
- [12] A. Bučánek, P. Benáček, and A. Trojáková, *Operational Implementation of BlendVar Scheme at CHMI*, RC LACE, 2015.
- [13] P. Novak, "The Czech Hydrometeorological Institute's severe storm nowcasting system," *Atmospheric Research*, vol. 83, no. 2–4, pp. 450–457, 2005.
- [14] Y. Wang, M. Bellus, C. Wittmann et al., "Central European limited-area ensemble forecasting system: ALADIN-LAEF," *Quarterly Journal of the Royal Meteorological Society*, vol. 137, no. 655, pp. 483–502, 2011.
- [15] Y. Wang and A. Kann, "ALADIN Limited Area Ensemble Forecasting (LAEF)," in *ALADIN Newsletter*, pp. 1–7, Météo-France, Toulouse, France, 2006.
- [16] T. Schellander-Gorgas, Y. Wang, F. Meier, F. Weidle, C. Wittmann, and A. Kann, "On the forecast skill of a convection-permitting ensemble," *Geoscientific Model Development*, vol. 10, no. 1, pp. 35–56, 2017.
- [17] D. Rezacova, B. Szintai, B. Jakubiak et al., "A radar-based verification of precipitation forecast for local convective storms," in *Parameterization of Atmospheric Convection: Current Issues and New Theories*, pp. 173–214, Imperial College Press, London, UK, 2015.
- [18] P. Novak and H. Kyznarova, "MERGE2—modernizovaný systém kvantitativních odhadu srážek provozovaný v Českém hydrometeorologickém ústavu," *Meteorologické Zpravy*, vol. 69, pp. 137–144, 2016.
- [19] M. Salek, "Operational application of the precipitation estimate by radar and rain gauges using local bias correction and regression kriging," in *Proceedings of the Sixth European Conference on Radar in Meteorology and Hydrology (ERAD 2010)*, National Meteorological Administration of Romania, Sibiu, Romania, 2010.
- [20] M. Salek, L. Brezkova, and P. Novak, "The use of radar in hydrological modeling in the Czech Republic—case studies of flash floods," *Natural Hazards Earth System Sciences*, vol. 6, no. 2, pp. 229–236, 2006.
- [21] Hydrometeorological Institute Prague, *Katalog Povětrnostních Situací Pro Území ČSSR*, Hydrometeorologický ústav Praha, SNTL, Prague, Czech Republic, 1968.
- [22] M. Hanel and P. Maca, "Spatial variability and interdependence of rain event characteristics in the Czech Republic," *Hydrological Processes*, vol. 28, no. 6, 2013.
- [23] V. Svoboda, M. Hanel, P. Máca, and J. Kyselý, "Characteristics of rainfall events in regional climate model simulations for the Czech Republic," *Hydrology and Earth System Sciences*, vol. 21, no. 2, pp. 963–980, 2017.
- [24] W. H. Wischmeier and D. D. Smith, *Predicting Rainfall Erosion Losses—A Guide to Conservation Planning*, Agriculture Handbook, 1978.
- [25] A. Bakhshaii and R. Stull, "Deterministic ensemble forecasts using gene-expression programming," *Weather and Forecasting*, vol. 24, no. 5, pp. 1431–1451, 2009.
- [26] J. H. Hogan and I. B. Mason, "Deterministic forecasts of binary events," in *Forecast Verification: A Practitioner's Guide in Atmospheric Science*, I. T. Jolliffe and D. B. Stephenson, Eds., John Wiley & Sons, Hoboken, NJ, USA, 2nd edition, 2011.
- [27] I. T. Jolliffe and D. B. Stephenson, *Forecast Verification: A Practitioner's Guide in Atmospheric Science*, John Wiley & Sons, Hoboken, NJ, USA, 2012.
- [28] D. S. Wilks, *Statistical Methods in the Atmospheric Sciences*, Elsevier, Oxford, UK, 3rd edition edition, 2011.
- [29] World Meteorological Organization, *Recommendations for the Verification and Intercomparison of QPFS and PMPFS from Operational NWP Models*, World Meteorological Organization, Geneva, Switzerland, World Weather Research Programme, 2008.
- [30] A. P. Weigel, "Ensemble forecast," in *Forecast Verification: A Practitioner's Guide in Atmospheric Science*, I. T. Jolliffe and D. B. Stephenson, Eds., John Wiley & Sons, Hoboken, NJ, USA, 2nd edition, 2012.
- [31] T. M. Hamill, "Interpretation of rank histogram for verifying ensemble forecast," *Monthly Weather Review*, vol. 129, no. 3, pp. 550–560, 2001.
- [32] O. Talagrand, R. Vautard, and B. Strauss, "Evaluation of probabilistic prediction systems," in *Proceedings of the ECMWF Workshop on Predictability*, ECMWF, Reading, UK, October 1997.
- [33] Czech Hydrometeorological Institute Prague, *Povodně v České Republice v Červnu 2013*, Český hydrometeorologický ústav Praha, Prague, Czech Republic, Czech Hydrometeorological Institute, 2014.
- [34] C. M. Grams, H. Binder, S. Pfah, N. Piaget, and H. Wernli, "Atmospheric processes triggering the central European floods in June 2013," *Natural Hazards and Earth System Sciences*, vol. 14, no. 7, pp. 1691–1702, 2014.