

Česká zemědělská univerzita v Praze

Fakulta životního prostředí

Katedra vodního hospodářství a environmentálního modelování



Česká zemědělská univerzita v Praze  
**Fakulta životního  
prostředí**

# **Verifikace předpovědi srážek pro hydrologické modelování**

Validation of precipitation forecast for  
hydrological modelling

Diplomová práce

Vedoucí práce: Ing. Martin Hanel Ph.D.

Diplomant: Martin Vokoun

**2014**

**ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE**  
Katedra vodního hospodářství a environmentálního  
modelování  
Fakulta životního prostředí  
**ZADÁNÍ DIPLOMOVÉ PRÁCE**

Vokoun Martin

Voda v krajině

Název práce

**Verifikace předpovědi srážek pro hydrologické modelování**

Anglický název

**Verification of precipitation forecast for hydrological modelling**

---

**Cíle práce**

Cílem práce je verifikace krátkodobých předpovědí srážek na vybraných epizodách. Vyhodnocení závislosti úspěšnosti předpovědi na prostorové agregaci rastrových dat.

**Metodika**

1. Zmapování dostupných meteorologických předpovědí (spolupráce s oddělením hydrologie ČHMU)

Zjištěno bude zejména:

- jaké předpovědi jsou operativně k dispozici (prostorové a časové rozlišení, použití ensemblových přístupů, atp.)
- jak jsou tyto předpovědi využívány
- jak jsou archivovány

2. Výběr zájmového území, data

Ve spolupráci s oddělením hydrologie ČHMU bude vybráno zájmové území, pro které budou získány archivované předpovědi spolu s pozorovanými meteorologickými a hydrologickými daty.

3. Vyhodnocení úspěšnosti předpovědi

Bude využito více kritérií včetně kvalitativních. Vyhodnocen bude zejména vztah prostorové agregace předpovědních dat k úspěšnosti předpovědi dle vybraných kritérií.

4. Případová studie - verifikace na vybraných událostech. Dokumentace výsledků.

**Harmonogram zpracování**

březen-červen 2013

- rešerše problematiky, konzultace ČHMU - získání dat

červenec-prosinec 2013

- získání dat, analýza

Česká zemědělská univerzita v Praze \* Kamýčká 129, 165 21 Praha 6 - Suchbát

---

**Rozsah textové části**

cca 40 stran

**Klíčová slova**

ALADIN; rastrová data; indexy úspěšnosti předpovědi; prostorová agregace

---

**Doporučené zdroje informací**

Jolliffe, I. T., Stephenson, D. B. (2003) Forecast verification. A practitioner's guide in atmospheric science. Wiley, UK.

---

**Vedoucí práce**

Hanel Martin, Ing., Ph.D.

**Konzultant práce**

RNDr. Radek Čekal, Ph.D.

---

Elektronicky schváleno dne 11.4.2014

**prof. Ing. Pavel Pech, CSc.**

Vedoucí katedry

---

Elektronicky schváleno dne 11.4.2014

**prof. Ing. Petr Sklenička, CSc.**

Děkan fakulty

Prohlášení:

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně, pod vedením Ing. Martina Hanela Ph.D. a že jsem uvedl všechny literární prameny a publikace, ze kterých jsem čerpal.

V Praze dne 23. 4. 2014

.....

Martin Vokoun

**Poděkování:**

Mé poděkování patří vedoucímu práce Ing. Martinu Hanelovi Ph.D. za ochotu a pomoc při tvorbě této práce a panu RNDr. Radku Čekalovi Ph.D. za spolupráci a pomoc při výběru dat.

**Abstrakt:**

Práce se zaměřuje na verifikaci numerické předpovědi srážek z modelu ALADIN, které jsou důležitými vstupními daty do hydrologických modelů ČHMÚ. Pro studii bylo vybráno šest srážkových epizod z roku 2013, při kterých byla srážkami zasažena většina území ČR. V současnosti do hydrologických modelů vstupují srážková data interpolována do 37 jednotlivých oblastí. Cílem práce je pomocí statistické verifikace odhadnout nejvhodnější měřítko rozlišení pro zpřesnění hydrologické předpovědi na základě podrobnějších vstupních dat. Verifikace byla provedena pomocí měřených srážkových dat.

**Klíčová slova:** ALADIN, rastrová data, úspěšnosti předpovědi, prostorová agregace

**Abstract:**

This thesis is focuses on the verification of numerical precipitation forecast in model ALADIN, which is important input data into CHMI hydrological models. Six rainfall events from 2013 were selected for the study, where the rainfall hit most of the Czech Republic area. Currently rainfall data which is interpolated into 37 single areas enters in hydrological models. The aim of this work is to estimate the most appropriate resolution by using statistical verification for more accurate hydrological forecast based on more detailed input data. Verification was performed using measured rainfall data.

**Key words:** ALADIN, raster data, success rate of forecast, spatial aggregation

# Obsah

Abstrakt:.....	6
Úvod.....	10
Cíle práce .....	11
1. Literární rešerše.....	12
1.1 Hydrologické modely a jejich kategorie .....	12
1.1.1 Teoretické modely.....	13
1.1.2 Konceptuální modely .....	13
1.1.3 Empirické modely .....	15
1.1.4 Výběr vhodného modelu .....	16
1.2 Tvorba krátkodobé hydrologické předpovědi .....	18
1.2.1 Vstupní data .....	18
1.2.1.1 Hydrologická data .....	18
1.2.1.2 Meteorologická data.....	19
1.2.1.3 Fyzicko-geografická data.....	20
1.2.2 Kalibrace .....	21
1.2.3 Nejistoty v hydrologickém modelování .....	21
1.2.3.1 Nejistoty předpovědi a měření srážek .....	22
1.2.4 Hydrologické předpovědi v ČHMÚ.....	23
1.2.4.1 Manuální hydrometrické předpovědi .....	24
1.2.4.2 Zpracování modelové deterministické předpovědi .....	25
1.3 Numerická předpověď počasí, ALADIN .....	29
1.3.1 Princip numerické předpovědi počasí .....	29
1.3.2 ALADIN-CZ.....	30
1.4 Radarová síť CZRAD .....	31
1.4.1 Princip měření.....	31
1.4.2 CZRAD .....	31

1.5	Verifikace numerické předpovědi .....	33
1.5.1	Data pro verifikaci.....	33
1.5.1.1	Kvalita dat a předpovědi .....	34
1.5.1.2	Kvalita a hodnota předpovědi .....	35
1.5.2	Binární události .....	35
1.5.2.1	Metody hodnocení binárních událostí.....	36
1.5.3	Předpovědi kontinuálních veličin.....	38
1.5.3.1	Metody hodnocení kontinuálních veličin.....	38
1.5.4	Pravděpodobnostní předpovědi .....	41
1.5.4.1	Metody hodnocení pravděpodobnostních událostí .....	42
1.5.5	Prostorové předpovědi .....	45
1.5.5.1	Fuzzy metody .....	45
2.	Metodika .....	48
2.1	Charakteristika a způsob zpracování dat.....	48
2.1.1	Popis verifikovaných srážkových událostí.....	48
2.1.2	Způsob zpracování dat .....	48
2.1.3	Statistiky dat srážkových událostí.....	49
2.1.4	Vstupní oblasti do hydrologických modelů .....	53
2.1.4.1	Časové charakteristiky dešťů ve vstupních oblastech.....	54
2.1.4.2	Odchyly skutečnosti od předpovědi.....	56
2.2	Verifikace.....	58
2.2.1	Korelace .....	58
2.2.2	Root Mean Square Error (RMSE).....	60
2.2.3	Equitable Threat Score (ETS), False Alarm Ratio (FAR), False Alarm Rate (F) a Probability of Detection (POD) .....	61
3.	Výsledky .....	62
3.1	Korelace a RMSE.....	62



3.2	ETS, FAR a POD .....	65
4.	Diskuze.....	74
5.	Závěr .....	76
6.	Literatura.....	77
8.	Přílohy.....	80
	Skripty pro zpracování rastrových dat a výpočty verifikačních skóre.....	88

## Úvod

V oblasti numerické kvantitativní předpovědi srážek dochází rok od roku k zpřesňování předpovědí. Příčinou jsou například kvalitnější vstupní data, dokonalejší počítače schopné provádět složitější výpočty a v neposlední řadě dochází také ke zvyšování horizontálního a vertikálního rozlišení, ve kterém jsou předpovědi počítány. I přesto stále zůstává předpověď srážek velice obtížným úkolem, zejména kvůli své vysoké časové a prostorové variabilitě.

Hydrologické modely poskytují důležité informace, především při povodňových situacích, kdy povodňové orgány realizují krizové plány na základě hydrologických predikcí. Složky IZS a další zapojené orgány organizují všechna bezpečnostní opatření právě na základě předpokladu vývoje průtoku na tocích v nejbližších hodinách. Jelikož ČR zasáhly ničivé povodně hned několikrát v posledních letech, je zapotřebí využít všech možností ke zpřesňování hydrologické předpovědi. Jednou z těchto možností je zpřesnění vstupních dat, v tomto případě kvantitativní předpověď srážek. V současnosti nevstupují data modelu ALADIN do hydrologických modelů ČHMÚ ve stejném rozlišení v jakém jsou počítány výstupy. Celá republika je rozdělena do 37 oblastí a vždy pro celou oblast je spočten jeden průměrný úhrn. Toto hrubé rozčlenění vnáší chyby v odhadu srážek, a to například z důvodu velice variabilní orografie ČR. Stejně tak použití předpovědi v nejvyšším možném rozlišení 1 x 1km (v současnosti se nevyužívá), by bylo zdrojem velkého množství nejistot. Proto je potřeba nalézt nejvhodnější kompromis mezi současným rozčleněním na velké oblasti a vysokým rozlišením výstupů modelu ALADIN. Jeden ze způsobů verifikace za účelem nalezení nejpříjemnějšího rozlišení předpovědi srážek pro hydrologické modely, je nastíněn v této práci.

V diplomové práci nejsou vystiženy všechny možné způsoby dosažení požadovaného výsledku. Je zde popsána možná varianta, jejíž hlubšímu rozboru a případně jiným způsobům verifikace může být věnována pozornost v disertační práci.

## Cíle práce

Cílem práce je odhad co nejvhodnějšího rozlišení vstupních dat předpovědi srážek do hydrologických modelů využívaných v ČHMÚ. Toho lze dosáhnout verifikací kvantitativní předpovědi srážek modelu ALADIN a údajů z pozemního a radarového měření. Ke zpracování dat a provedení verifikace je vhodné prostředí R programu.

Smyslem práce není nalézt všechna možná řešení, nýbrž jeden ze způsobů postupu, který vede k výsledku. Pro definitivní a co nejpřesnější výsledek je potřeba podrobnější analýza, například vlivu návětrných svahů apod. Tato práce může sloužit jako podklad pro následné analýzy nebo jako zdroj pro ověření výsledků dosažených jinými metodami.

Od práce očekávám přínosy v podobě rozšíření znalostí v oboru hydrologie a meteorologie a nabytí praxe v oblasti zpracování dat. Práce je vytvořena ve spolupráci s ČHMÚ, kde doufám, že nalezne uplatnění. Zároveň bych se rád tomuto tématu věnoval i v budoucnu.

# 1. Literární rešerše

## 1.1 Hydrologické modely a jejich kategorie

Hydrologické modely lze rozdělit do několika druhů a kategorií v závislosti především na přístupu k výpočtu předpovídaného odtoku z určitého území. Podstatou modelu je zjednodušená simulace skutečného procesu. V případě hydrologických modelů se nejčastěji jedná o srážko-odtokový proces, který je v modelu deterministicky vyjádřen algoritmem řešení soustavy rovnic, popisujících chování celého systému na základě znalosti fyzikálních procesů a vstupních dat. Výstupem modelu jsou veličiny predikující budoucí průběh odtoku vody z povodí s určitou mírou nejistoty závisící na mnoha faktorech (kvalita vstupních dat, parametry modelu apod.). Postup modelového výpočtu lze rozdělit do tří částí (Daňhelka, 2007). První částí je získání vstupních dat, těmi jsou výsledky měření potřebných veličin a případné předpokládané bilanční změny v povodí, způsobené například manipulací na nádržích. Ve druhé části probíhá zpracování těchto dat a výpočet výsledných hodnot. Ty jsou ve třetí části interpretovány například v podobě grafických výstupů vhodných pro potřeby dalšího využití.

Za nejnadřazenější rozdělení hydrologických modelů lze považovat rozdělení podle způsobu využití (účelu aplikace) na 3 kategorie (Jeníček, 2005):

- Modely používané v operativní hydrologii
- Modely aplikované pro návrhovou a projekční činnost v oblasti vodního hospodářství
- Modely využívané ve výzkumu

Druhý a třetí příklad aplikace je využíván jako nástroj pro výpočty do projektových studií při navrhování vodních staveb, úprav krajiny, čistíren odpadních vod nebo například protipovodňových opatření. Využití ve výzkumu za účelem zdokonalení a vývoje modelu bývá aplikováno na experimentálním povodí s dostatečně hustou sítí měření vstupních dat. První kategorie je předmětem této práce, jelikož pracuje s aktuálními daty a vytváří krátkodobou předpověď vodních stavů pro jednotlivé profily. Výsledkem je dosažení spoluprací více specializovaných

modelů a programových prostředků, které dohromady tvoří předpovědní povodňový systém (Jeníček, 2005).

Matematické neboli deterministické modely se dělí do třech kategorií podle míry zohlednění skutečných fyzikálních procesů a jejich zjednodušení do popisu charakteristik povodí vybranými indexy (Máca, 2010).

- Teoretické
- Konceptuální
- Empirické

### **1.1.1 Teoretické modely**

Označované také jako „white-box“ modely, jsou založeny na řešení parciálních diferenciálních rovnic, které přesně popisují skutečné fyzikální procesy v reálném hydrologickém systému. Tento přístup je velice náročný na výpočty a vstupní data, a proto se neřadí mezi nejpoužívanější modely (Máca, 2010). Nejúplnějším hydrodynamickým přístupem se podle (Kulhavý, Kolář, 2000) prezentuje model SHE (Système Hydrologique Européen). SHE může najednou pracovat až s 2000 výpočetními body ve vodorovné rovině a s 30 vertikálními úrovněmi. Komplexní přístup zahrnuje například jednorozměrné proudění soustředného odtoku, dvourozměrné svahové proudění, dvourozměrné proudění v nasycené zóně apod. Nevýhodou podrobnosti modelu je nedostupnost vstupních dat a to zejména v případě plošné a časové variability rozložení srážek nebo variabilita fyzikálních vlastností půd. S ohledem na datovou náročnost patří teoretické modely mezi nejméně používané (Kulhavý, Kovář, 2000).

### **1.1.2 Konceptuální modely**

Označované také jako „grey-box“ modely, zjednodušují fyzikální procesy a vztahy a částečně je nahrazují empiricky odvozenými vztahy. Dochází zde k potlačení prostorové složky a diskretizaci spojitého vnímání prostoru. Předpokládané prostorové změny jsou vyjádřeny pouze v těchto bodech pomocí diferenciálních rovnic s neznámou proměnnou času. Parametrizované hodnoty prostorových souřadnic mohou být kvantifikovány například optimalizací modelu a prostorově rozloženy konstantním nebo pravděpodobnostním rozdělením. Konceptuální modely propojují tři hlavní hydrologické procesy ovlivňující odtok vody z povodí (Kulhavý, Kovář, 2000) :


**Povrchové procesy:** intercepce, evapotranspirace, retence a akumulace, vznik povrchového odtoku a další transportní procesy

**Podpovrchové procesy:** infiltrace, základní odtok, nasycené a nenasycené zóny, proudění podzemní vody, vláhová dynamika

**Korytové procesy:** vznik soustředěného odtoku, transformace odtoku v údolnici

Mezi nejrozšířenější a nejpoužívanější koncepční modely patří srážko-odtokový model Sacramento (SAC-SMA), odvozen pro simulaci odtoku dešťových srážek. Pro dosažení přesnějších výsledků bývá kombinován s modelem SNOW17 (model pro tání sněhu). V SAC-SMA je povodí charakterizováno jako soustava horizontálně a vertikálně uspořádaných zón (nádrží) různých vlastností, simulujících skutečné procesy (intercepce, evapotranspirace, perkolace atd.). Model rozlišuje zásoby vody na dolní dlouhodobou (půdní vlhkost, podzemní voda) a horní krátkodobou. Při srážkách dochází v horní zásobní zóně nejprve k vyplnění prostor vazajících vodu (póry), poté se naplní prostory nevazajících vodu půdními částicemi. Tato volná voda se pohybuje ve směru gravitace, tzn., že dochází k perkolaci do dolní vrstvy nebo k podpovrchovému odtoku. Srážky, které přesáhnou kapacitu volné a vázané vody tvoří rychlou odezvu v povodí v podobě rychlého odtoku (Steinhart, 2010).

Celkový odtok určený modelem SAC-SMA se skládá celkem z pěti dílčích odtoků. Prvním je přímý odtok z nepropustných a dočasně nepropustných ploch přímo do recipientu. Druhou složkou je povrchový odtok při saturaci, který nastává v momentu, kdy je intenzita srážek vyšší než rychlost infiltrace (přímý odtok). Třetí složku představuje podpovrchový (hypodermický) odtok vznikající gravitačním pohybem nevázané vody v horní zóně. Čtvrtou a pátou složku tvoří základní odtok rozdělený na primární a doplňkový. V rámci primárního odtoku je základní odtok uplatňován kontinuálně i v suchém období, na rozdíl od doplňkového odtoku, který slouží především k zpřesnění simulace po ukončení srážkové periody. V suchém období není generován (Daňhelka 2007).



Obr. č1. : Schéma modelu Sacramento (SAC-SMA). ET-evapotranspirační ztráta, UZTW-horní zóna vázané vody, LZFP-spodní zóna volné vody primární, LZFS-spodní zóna volné vody doplňková, RIVA-ztráta evapotranspirací příbřežní vegetace, SIDE-odtok mimo měrný profil povodí. Označení složek celkového odtoku v modelu Sacramento: 1-odtok z nepropustných ploch, 2-přímý odtok z ploch dočasně nepropustných, 3-povrchový odtok, 4-hypodermický odtok, 5-dodatkový podzemní odtok, 6-primární podzemní odtok (Daňhelka, 2007)

Pro zanesení vlivu sněhové pokrývky do hydrologické předpovědi je v ČHMÚ používán konceptuální model SNOW17, který simuluje množství vody akumulované ve sněhové pokrývce pro jednotlivé výškové zóny. Model hodnotí úbytek (tání) či akumulaci sněhu na základě energetické bilance a výměny energie na rozhraní sněhové pokrývky a atmosféry. Výsledná konstanta  $\Delta Q$  je celková změna zásoby tepla ve sněhové pokrývce složená z energie spotřebované k přeměně skupenství ve sněhové pokrývce. Při kladné změně  $\Delta Q$  dochází k tání a naopak při záporné změně  $\Delta Q$  dochází k případnému mrznutí kapalné vody ve sněhu (Daňhelka, 2007).


### 1.1.3 Empirické modely

Označované také jako „black-box“ modely, nevycházejí při svých výpočtech z fyzikální podstaty a definice hydrologických vztahů a parametrů (Daňhelka, 2007). Jejich využití je vhodné především u hydrologických systémů s jednotným chováním a jednoduchou strukturou, jelikož zkoumají především průběh procesu z hlediska

transformační funkce systému. Pro identifikaci chování systému je nezbytné mít k dispozici kromě vstupních dat i data výstupní, za účelem odvození předpovědi na základě jejich vztahu. Geometrické a jiné atributy a charakteristiky povodí jsou popsány jednotlivými indexy, které je třeba průběžně optimalizovat (Jeníček, 2005).

#### 1.1.4 Výběr vhodného modelu

Výběr vhodného modelu se odvíjí od kombinace technických parametrů modelu, vlastnostech povodí, dostupnosti a kvalitě vstupních dat a v neposlední řadě od nároků na model a typ požadované předpovědi. Obecné zásady výpočtu hydrologického modelu probíhají v tomto pořadí (obr. č. 2)



Obr. č. 2: Zásady výpočtu hydrologického modelu

Cílem výběru je najít takový model, který byl již při vývoji sestavován pro námi požadované fyzicko-geografické podmínky. To samé platí i pro model známé srážko-odtokové procesy, které by měly být tematicky podobné. Dalším kritériem je schopnost simulovat odtokový proces ve vhodném časovém a prostorovém kroku, v závislosti na velikosti povodí. Na výběr je například mezi epizodními modely, které simulují pouze jednu událost (povodeň, sucho) nebo kontinuálními modely, které provádí výpočty pro delší časová období. Pro menší povodí jsou vhodnější epizodní modely, které se prezentují lepší simulací v případě přívalových lokálních srážek. Důležitou vlastností je schopnost spolupráce s dalšími modely, které slouží pro upřesnění předpovědi nebo doplnění výpočtu chybějící složky srážko-odtokového procesu, která určitým způsobem ovlivňuje výsledek. Dále je třeba dbát na kompatibilitu vstupních dat a modelu, zejména pak na datové formáty a databáze hydrologických parametrů půd. Výhodou může být vazba na podpůrné programy. Například zapojení GIS při analýze směru a rychlosti proudění využití softwarových prostředků pro sběr a databázové zpracování dat v hydrologické prognóze.



V neposlední řadě je důležitá komerční dostupnost modelu a dostupnost systémové podpory, stejně tak i reference a oblíbenost u uživatelů (Jeníček, 2005).

Správně zvolený model však není zárukou dobrých výsledků. Výsledná simulace se z velké části odvíjí od kvality vstupních a datových souborů z přímého měření na povodí. Zejména pak u konceptuálních a empirických modelů, u kterých se pomocí těchto dat provádí optimalizace.

## 1.2 Tvorba krátkodobé hydrologické předpovědi

### 1.2.1 Vstupní data

Vstupní data jsou pro výpočet modelu důležitou součástí, ovlivňující ve velké míře výsledky. Podle (Daňhelka, 2007) lze rozdělit vstupní data do tří skupin: hydrologická, meteorologická, fyzicko-geografická.

#### 1.2.1.1 Hydrologická data

Z hydrologických měření, je nejvýznamnější pro simulaci odtoku 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 (Hrádek, Kuřík, 2008). Data jsou automaticky odesílána v časovém intervalu 1 hodiny, v případě povodňové situace se interval zkracuje na 10 minut. V případě extrémních průtoků může nastat, 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) (Daňhelka, 2007).

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. (Daňhelka, 2007)

### 1.2.1.2 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 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 (Maskey et. al, 2004). 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 (Sokol, Řezáčová, 1998).

Stejně jako předpověď srážek je důležitý i odhad skutečných úhrnů. Jelikož srážkoměrné stanice podávají pouze diskrétní 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 Brdy a Skalky, které měří v C pásmu v intervalu 10 minut. Pro odhad se používají data odrazivosti z výšky 2000m 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. (Sokol, 2005). 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 (výpočet metodou inverze distance pro buňky gridové sítě). Více o metodách plošné distribuce srážek v (Hrádek, Kuřík, 2008) nebo (Daňhelka, 2007).

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 (Daňhelka, 2007). Výpočet PET vychází jednak z meteorologických činitelů (teplota vzduchu, vlhkost vzduchu, proudění vzduchu, sluneční radiace atd.), charakteristik půdy a pokryvu půdy (Hrádek, Kuřík 2008).

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 (Daňhelka, 2007). Samotnému odtoku vody při tání sněhu předchází tzv. fáze zrání sněhu, kdy se teplota sněhové pokrývky blíží k 0°C 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 (Máca, 2007).

### **1.2.1.3 Fyzicko-geografická data**

Tento typ dat je využíván především ve spojení hydrologického modelu s GIS. V základě se jedná o mapové podklady koncepčně irelevantní k základům hydrologického modelování. V posledních letech je GIS využíván stále více a ve vývoji dochází při integraci s modely ke snižování nejistot. Výhodou jsou vlastní hydrologické funkce (ArcHydro), které usnadňují práci s digitálním modelem terénu (odtokové linie, rozvodnice, atd.) (Sui, 1999). Z ostatní geografických dat je používány například vrstvy hydrologických charakteristik půd, objekty a překážky proudění a vegetační pokryv a využití území (vliv na odtok a evapotranspiraci) (Daňhelka, 2007).

## 1.2.2 Kalibrace

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 (horní zóny). U bilančních modelů je důležitější nastavení parametrů pro bazální odtok, evapotranspiraci apod. Obě metody je možné samozřejmě kombinovat vzhledem ke konkrétním vlastnostem modelu a účelem kalibrace (Daňhelka, 2007).


## 1.2.3 Nejistoty v hydrologickém modelování

Největší nejistoty do hydrologické předpovědi vnáší právě předpověď srážek, která zahrnuje nejistotu v predikovaném množství, časovém a prostorovém rozložení. V současnosti při vysokém rozlišení QPF 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 ansámblové předpovědi (Rezacova et. al, 2009).

Obecně lze nejistoty deterministických hydrologických, ale také meteorologických modelů, klasifikovat do 4 skupin (Maskey, 2004).

- 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 (obr. č. 3), poruchy systémových komponentů, chybějící data apod.



Obr. č. 3: *Nepředvídatelná událost v povodí z kategorie operativních nejistot (Daňhelka, 2007)*

### 1.2.3.1 Nejistoty předpovědi a měření srážek

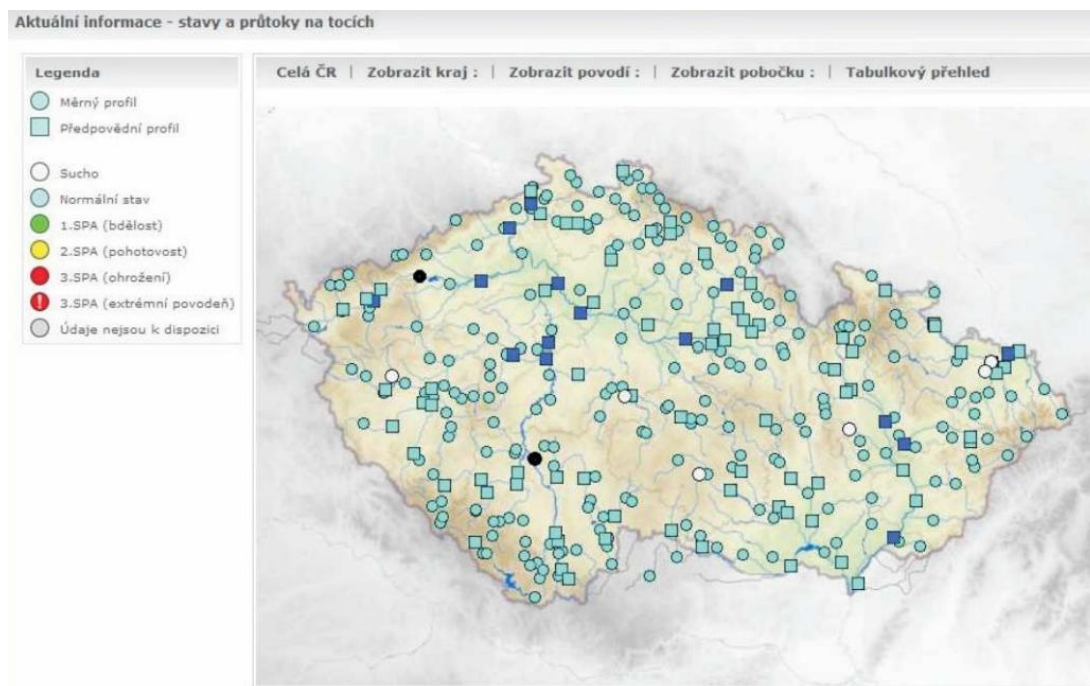
Tato práce se nejvíce dotýká právě předpovědi srážek (QPF), která tvoří hlavní část ze všech vstupních nejistot. V případě lokalizace predikovaných srážek roste nejistota v hydrologickém modelu v závislosti na velikosti povodí. Platí, že čím je povodí menší, tím je větší riziko, že srážky spadnou do 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 apod., dochází k vyhlazení rozdílů a celkovému zploštění reliéfu. Tento problém se citelně projevuje například v pohoří Krkonoš. Obdobně může být také opomíjen zvýšený úhrn srážek na návětrných svazích (Daňhelka, 2007).

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.1.2.1.2). 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 0,1mm 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.

#### **1.2.4 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. 4) 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 88 modelových předpovědí na 48 hodin dopředu (ČHMÚ, 2007).



Obr. č. 4: 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 (ČHMÚ, 2007)

#### 1.2.4.1 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 modelovou předpovědí se liší diskrétností, kdy výsledkem předpovědi je hodnota vodního stavu v konkrétním termínu. Nelze tedy vyčíslit jedinečný průběh vodního stavu či průtoku. K základním metodám manuální předpovědi patří *Metoda tendencí* a *Metoda odpovídajících si průtoků* (ČHMÚ, 2007).

*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 (ČHMÚ, 2007).

*Metoda odpovídajících průtoků* předpovídá průtok pro určitou stanici na základě měření průtoku na stanici umístěné výše na toku. Je třeba určit postupovou

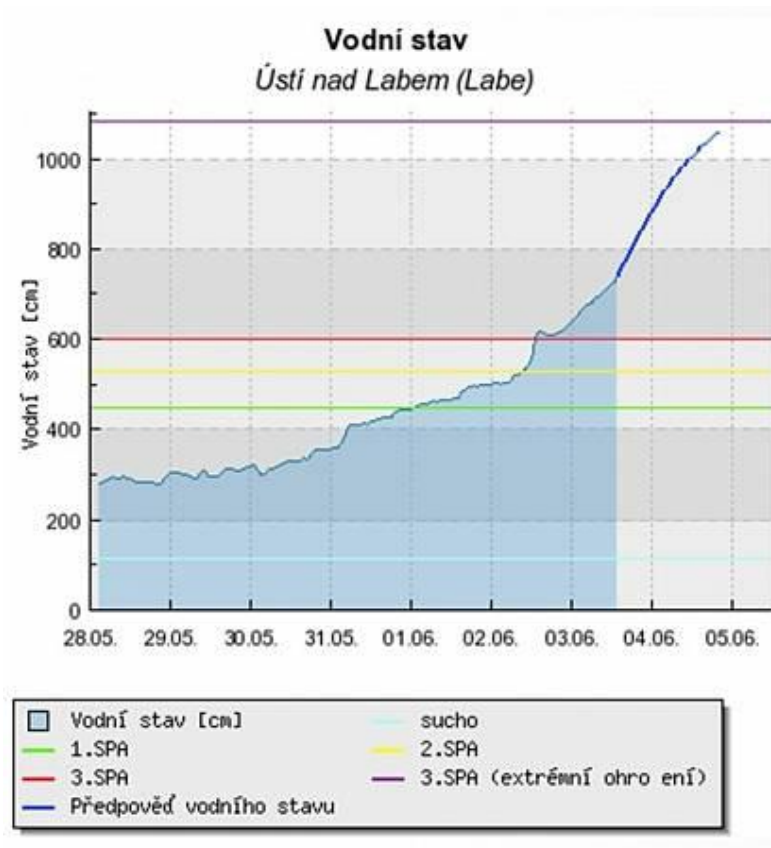


dobu průtoků, což je doba, za kterou se dostane voda z horního profilu k profilu, kde určíme předpověď. Je třeba brát v úvahu příbytek vody v úseku mezi profily z tzv. bočního přítoku. Tato voda je zdrojem z přítoků, výronu podpovrchových vod a povrchového odtoku.

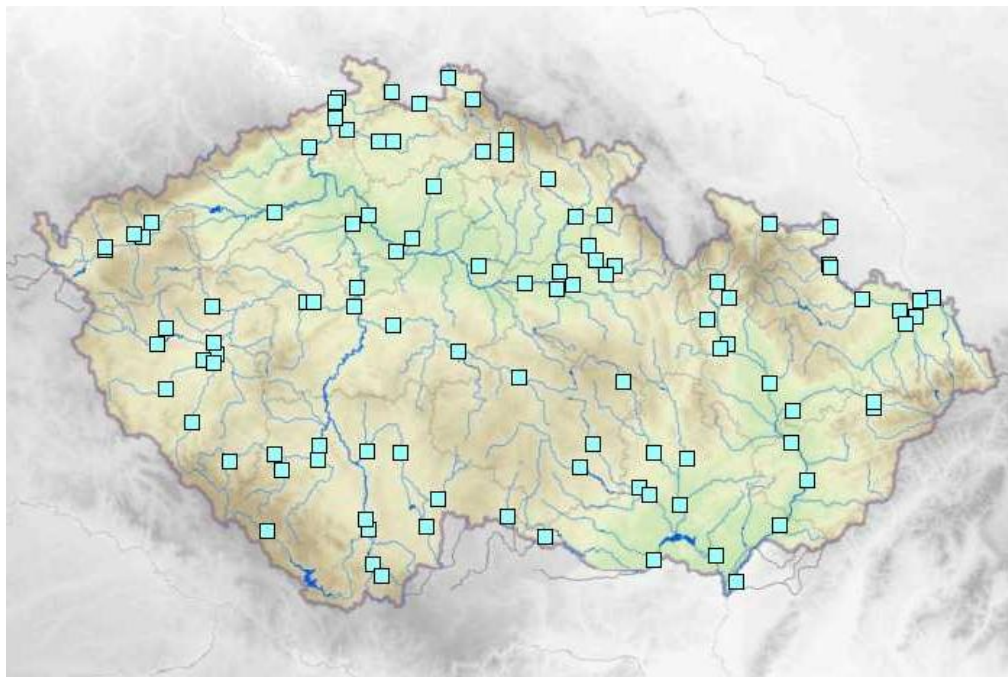
#### **1.2.4.2 Zpracování modelové deterministické předpovědi**

V České republice jsou pro hydrologickou předpověď používány dva předpovědní systémy. Pro celé povodí Labe je používán předpovědní systém AQUALOG 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 18 vybraných vodoměrných profilů (obr. č. 6)(ČHMÚ, 2007).

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. AQUALOG 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 mohou negativně ovlivnit předpověď. 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). 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. 5)) distribuovány uživatelům.

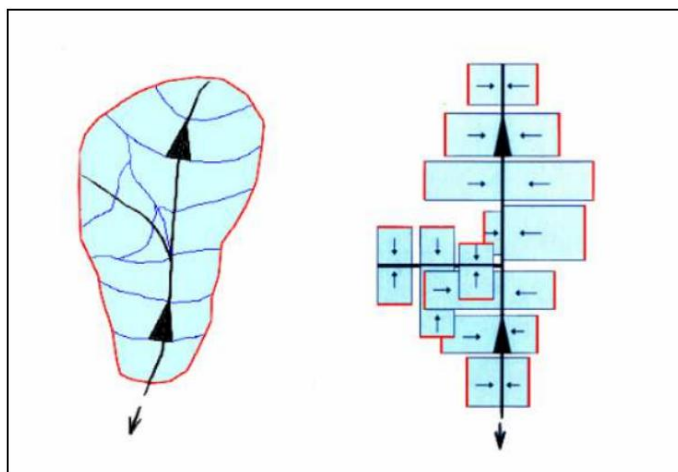


Obr. č. 5: Hydrologická předpověď v grafické podobě pro profil Ústí nad Labem ze dne 3. 6. 2013 (zdroj: <http://hydro.chmi.cz> )



Obr. č. 6: Mapa hydrologických profilů hlásné a předpovědní sítě ČHMÚ, pro které je počítána modelová hydrologická předpověď. (zdroj: ČHMÚ)

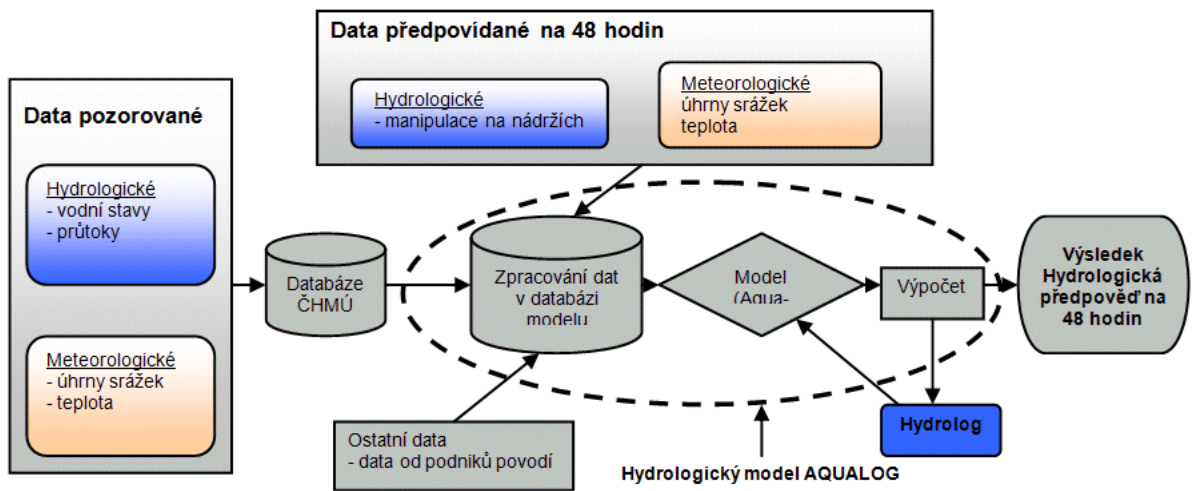
- i) **Předpovědní systém HYDROG-S:** schematizace povodí je v tomto srážko-odtokovém semidistribuovaném modelu popsána prostřednictvím grafů tzv. zavěšených ploch, hran a vrcholů (obr. č. 7). Hrany grafu představují koryta toku, zatímco vrcholy reprezentují uzly říční sítě a plochy odpovídají jednotlivým 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 bazální odtok je řešen koncepčním regresním modelem, za předpokladu, že v povodí je pouze jedna podzemní nádrž (Daňhelka, 2007)



Obr. č. 7: Princip schematizace povodí v modelu HYDROG-S  
(ČHMÚ, 2007)

- ii) **Předpovědní systém AQUALOG:** zpracování vstupních dat z různých zdrojů probíhá ve speciální databázi AquaBase, napojené na operativní datovou základnu ČHMÚ (obr. č. 8 ). AquaBase připravuje vstupní datový soubor pro chod modelu a zároveň umožňuje jeho kontrolu a editaci. AQUALOG se skládá z následujících dílčích modulů, určených pro simulaci jednotlivých hydrologických procesů v povodí (ČHMÚ, 2007):

- 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)



Obr. č. 8: Schéma hydrologické předpovědi pomocí předpovědních systémů AQUALOG a HYDROG-S (ČHMÚ, 2007)

## 1.3 Numerická předpověď počasí, ALADIN

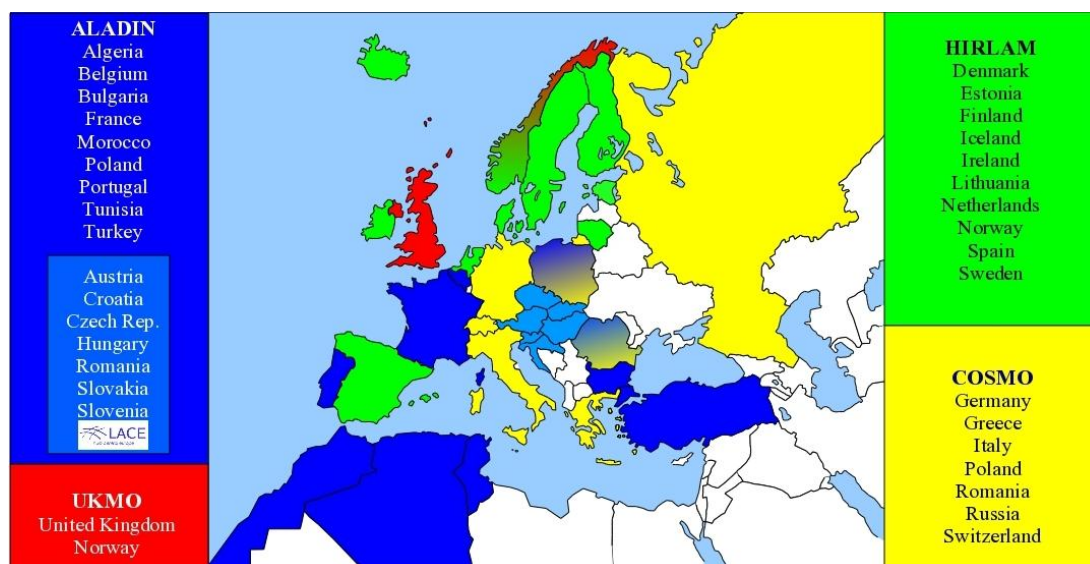
### 1.3.1 Princip numerické předpovědi počasí

Jak uvádí Meteorologický slovník, numerická předpověď je předpověď polí meteorologických prvků, která je výsledkem časové integrace prognostických rovnic některého fyzikálního modelu atmosféry, prováděné na samočinných 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 měřítka a zpřesňování časového i prostorového rozlišení modelu a zdokonalování metod numerické integrace (Kolektiv, 1993). 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. (Janoušek, 2004).

Kvalita předpovědi neustále roste, díky zvyšování rozlišení modelu a zvyšování množství vstupních dat. 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 slabin 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 ansámblová předpověď. Jde o provedení výpočtů předpovědi s odlišnými vstupními podmínkami a daty (Řezáčová et al., 2007).

### 1.3.2 ALADIN-CZ

Model ALADIN (Air Limitée, Adaptation Dynamique, Development International) byl vyvinut mezinárodním týmem vedeným Météo-France. Jedná se o prostorově omezený model zaměřený na krátkodobou předpověď (+54h) atmosférických procesů v mezo-gama měřítku. Horizontální rozlišení dosahuje v současnosti až 1km, ale pro operativní synoptickou předpověď se prozatím využívá 2 km rozlišení. Řada nejen evropských zemí využívá regionální verzi modelu ALADIN (obr. č. 9), 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 (NCMR).



Obr. č. 9: Přehled Evropské Síť Koordinace Krátkodobé Numerické Předpovědi Počasí

(zdroj: NCMR)

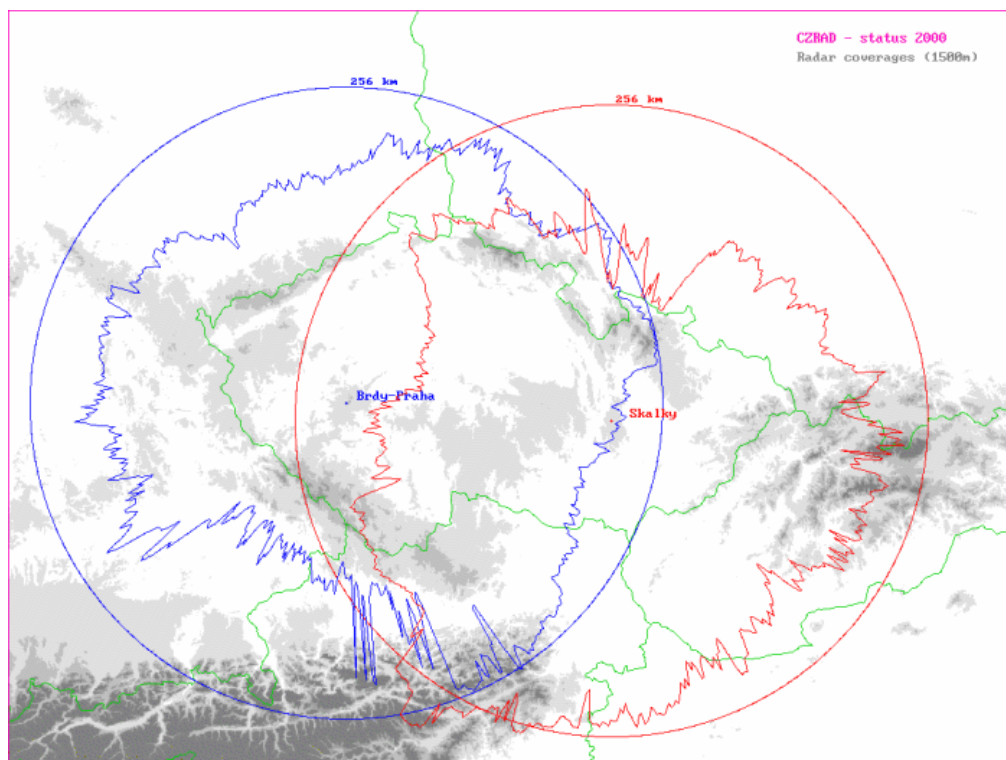
Výpočet modelu ALADIN probíhá na principu zpřesnění předpovědi globálního modelu ARPEGE v cílové oblasti (ČR). Výpočet globálního modelu ARPEGE probíhá v Météo-France (Toulouse). Odtud jsou data pro oblast modelu ALADIN-CZ přenesena do ČHMÚ. Následně probíhá interpolace polí z rozlišení ARPEGE na vyšší rozlišení modelu ALADIN a příprava dat metodou blendingu digitálním filtrem. V průběhu vlastní předpovědi modelu ALADIN na 54h jsou průběžně zapisovány výsledky v hodinovém kroku. V posledním kroku jsou výsledky zpracovány do podoby map, datových souborů apod.

## 1.4 Radarová síť CZRAD

### 1.4.1 Princip měření

Principem radarového měření je zachycení odražených vln, vyslaných vysílačem, od oblačných částic. Vysokoenergetické pulsy jsou anténou formovány do úzkého kužele. V případě nárazu pulsu do částice, dochází k pohlcení malé části elektromagnetické energie a její následné rozptýlení do všech směrů (i zpět k anténě). Analogový signál zpracovaný radarovým přijímačem je digitalizován a softwarově zpracován do výsledné podoby (Řezáčová et al., 2007)

### 1.4.2 CZRAD

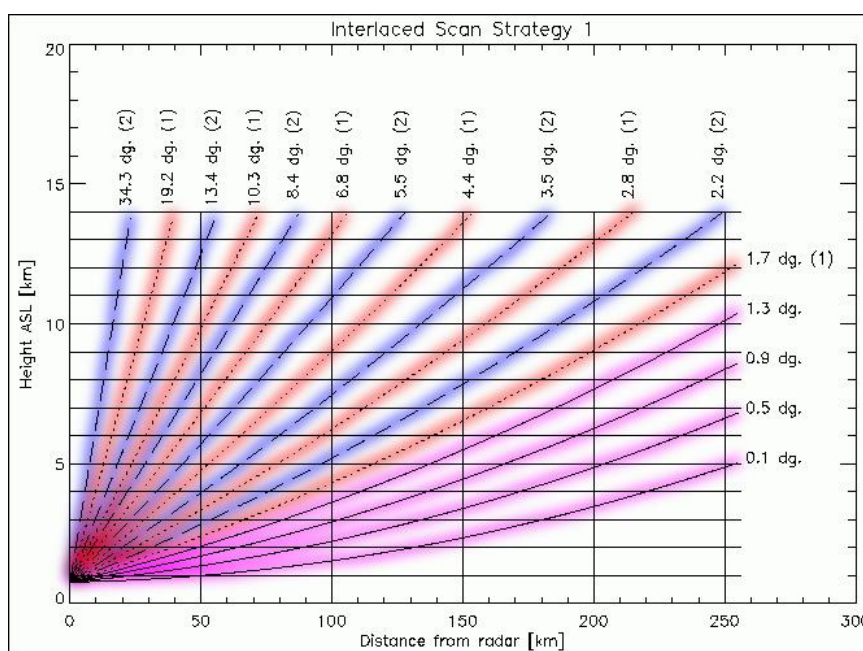


Obr. č. 10: Pokrytí území radary CZRAD. Kružnice ukazují max. dosahy radarů a lomené čáry vyznačují oblasti vhodné pro určování intenzit srážek (oblast maximální výšky paprsku 1500m nad terénem) (Zdroj: ČHMÚ)

Česká radarová síť (CZRAD) je provozována Českým Hydrometeorologickým Ústavem. Mimo meteorologické účely, poskytuje data také pro hydrologické předpovědi, leteckou dopravu a soukromé sektory (TV, mobilní operátoři). Skládá se ze dvou dopplerovských C-pásmových radarů (obr. č. 10)

Gematronic METEOR 360AC na vrchu Skalky a EEC DWSR – 2501C na vrchu Praha v Brdech. Pozice radarů jsou vybrány tak, aby při svém dosahu 256 km pokryly celou plochu České republiky a zároveň aby v blízkosti radaru nebyla žádná terénní překážka (Novak, 2005).

V současnosti je výstupem měření hodnota odrazivosti v intervalu 10 minut, přičemž tento údaj je kombinací dvou dílčích měření v intervalu 5 minut. Tento způsob měření a jejich kombinace, umožňuje rychlejší aktualizaci dat měření z nižších výšek. První měření pokrývá čtyři nejnižší výškové vrstvy (neboli elevace) a šest vyšších elevací. Druhé měření pokrývá opět první čtyři nejnižší elevace shodné s prvním měřením a poté šest vyšších elevací, avšak v rozdílných hladinách než při prvním měření (obr. č. 11). Výsledek měření se tedy skládá z šestnácti elevací, kde spodní čtyři jsou radarem měřeny dvakrát. Toto vertikální rozlišení poskytuje dostatečnou přesnost (zejména ve spodní části oblačnosti) pro operativní hydrologii a synoptickou meteorologii.



Obr. č. 11: Závislost nadmořské výšky jednotlivých elevací na vzdálenosti od radaru. Červené elevace jsou měřeny pouze v prvním měření, modré elevace jsou měřeny ve druhém měření a fialové elevace jsou měřeny v obou měřeních. Z grafu lze například vyčíst, že ve vzdálenosti 250 km nelze detekovat cíle v hladině nižší než 5 km. (Řezáčová, 2007)



## 1.5 Verifikace numerické předpovědi

Verifikace numerické předpovědi je rozšířena jako vhodný způsob 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. Lze tímto způsobem také identifikovat určité nedostatky modelu za účelem jejich nápravy, případně jakým směrem by se měl zaměřit budoucí vývoj. Na druhou stranu je možné určit výhody a silné stránky modelu, tzn. například situace, ve kterých je předpověď velice přesná. (Jolliffe, Stephenson, 2003)

### 1.5.1 Data pro verifikaci

Typ dat závisí na druhu předpovědi, účelu její prezentace a typu veličiny nebo procesu, který je popisován. Pro vyhodnocení úspěšnosti modelu je třeba mít k porovnání dva typy dat, předpovídané a pozorované (naměřené). Druhy předpovědi schematicky rozděluje například Stephenson, 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) srážek, vyjádřenou v konkrétních hodnotách a pravděpodobnostní předpověď (PCF – Probabilistic Complex Forecast), kde je vyjádřena pravděpodobnost výskytu srážek (Stephenson, 2002).

CAWCR (The Centre for Australian Weather and Climate Research) řadí druhy předpovědí do třech kategorií v závislosti na jejich způsobu získávání, časoprostorové charakteristice a specifčnosti předpovědi (v závorkách jsou příklady z dané kategorie) (CAWCR, 2013):

### **i) Druh předpovědi**

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

#### **1.5.1.1 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 (Daňhelka, 2007). 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. Na tyto a podobné vlivy na podobu dat je třeba dát pozor, jelikož ve výsledku mohou citelně ovlivnit kvalitu verifikace (Jolliffe, Stephenson, 2003).

### 1.5.1.2 Kvalita a hodnota předpovědi

Primárním smyslem verifikace je ověření kvality předpovědi porovnáním předpovídaných 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 dat 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 (Jolliffe, Stephenson, 2003). 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“) (CAWCR, 2013).

### 1.5.2 Binární události

Mezi binární, neboli dichotomní jevy, lze zařadit mnoho z pozorovaných meteorologických událostí, jako například déšť, povodně, mlha a jiné. Tyto jevy buďto nastaly nebo ne, na základě čehož lze ohodnotit předpověď. Tento druh předpovědi je také někdy nazýván jako „ano/ne“ předpověď. Existují tedy čtyři různé kombinace výsledných výstupů, které mohou nastat. Výsledky jsou nejčastěji prezentovány pomocí kontingenční tabulky. Způsob zápisu úspěšných prognóz je *hit* (událost byla předpovězena a nastala) nebo *correct rejection* (událost nebyla předpovězena a nenastala) a neúspěšných prognóz jako *false alarm* (událost byla předpovězena a nenastala) nebo *miss* (událost nebyla předpovězena a nastala) (tab. č. 1) (Jolliffe, Stephenson, 2003).

Event forecast	Event observed	
	Yes	No
Yes	Hit	False alarm
No	Miss	Correct rejection

Tab. č. 1: Kontingenční tabulka

### 1.5.2.1 Metody hodnocení binárních událostí

Následující kategorické statistiky jsou výběrem možností hodnocení, vycházejícího ze čtyř hodnot četností v kontingenční tabulce. Prvky *hits*, *false alarms*, *misses* a *correct rejections* představují počet událostí  $n$ , kolikrát daná situace nastala. V následujících řádcích jsou popsány nejvíce využívané statistiky. (Jolliffe, Stephenson, 2003) (Ebert, 2008).

**Frequency Bias (BIAS):** poměr mezi počtem předpovědi výskytu události a skutečným počtem výskytu události. Vzhledem k tomu, že pracuje pouze četnostmi, z výsledku nezjistíme přesnost předpovědi. Smyslem je určit zda model podhodnocuje nebo nadhodnocuje předpověď. Nejlepší skóre je 1.

$$BIAS = \frac{hits + false\ alarms}{hits + misses} \quad (1)$$

**Probability of Detection (POD):** bývá také často označován jako hit rate (H). Vyjadřuje podíl správně předpokládaných událostí, na které se zaměřuje. Naopak úplně opomíjí *false alarms*. Nejlepší skóre je 1.

$$POD = \frac{hits}{hits + misses} \quad (2)$$

**False Alarm Ratio (FAR):** zjišťuje k jakému podílu předpovídaných „yes“ ve skutečnosti nedošlo. Měl by být využit v souvislosti s POD. FAR je vzorek odhadu podmíněné pravděpodobnosti falešného poplachu tím, že předpovídaná událost nenastala. Nejlepší skóre je 0.

$$FAR = \frac{\text{false alarms}}{\text{hits} + \text{false alarms}} \quad (3)$$

**False alarm rate (F):** popisuje podíl nenaplněných předpovědí, které byly předpovídaný. Jindy se také nazývá Probability Of False Detection (POFD). Ideální výsledek je 0 a lze jej vylepšit snížením počtu vydaných „yes“ předpovědí.

$$F = \frac{\text{false alarms}}{\text{correct rejections} + \text{false alarms}} \quad (4)$$

**Threat score (TS):** snaží se postihnout, do jaké míry korespondují „yes“ předpovědi s „yes“ měřeními. Často je také uváděn jako Critical Success Index (CSI). Nerozlišuje zdroj chyby předpovědi a postihuje stejnou mírou *misses* a *false alarms*. TS statistika je široce používána pro hodnocení odhadu vzácných událostí, protože k výpočtu není třeba znát frekvenci správných zamítnutí (*correct rejections*).

$$TS = \frac{\text{hits}}{\text{hits} + \text{misses} + \text{false alarms}} \quad (5)$$

**Equitable Threat Score (ETS):** stejné jako TS, upraveno pro počet shod, které byly náhodně vybrány, kde:  $\text{hits}_{\text{random}} = \frac{1}{N}(\text{observed yes} \times \text{forecast yes})$ . ETS je často používána při verifikaci srážek v NWP (Numerical Weather Prediction) modelech. Jako přednost je uváděna rovnovážnost hodnocení, která umožňuje provádět spravedlivá porovnání mezi různými režimy. Ideální skóre je 1.

$$ETS = \frac{hits - hits_{random}}{hits + misses + false\ alarms - hits_{random}} \quad (6)$$

**Hanse nand Kuipers diskriminant (HK):** vypočítává se rozdílem POD hodnocení a F hodnocení a měří schopnost předpovědi odlišit pozorované „yes“ případy od „no“ případů. K výpočtu jsou využity všechny čtyři možné výsledky z kontingenční tabulky. Ideální skóre je 1.

$$HK = POD - F \quad (7)$$

### 1.5.3 Předpovědi kontinuálních veličin

Do této kategorie se řadí reálné spojité (kontinuální) skalární veličiny, jako například teplota, tlak nebo srážky. Kontinuální reálné veličiny jsou běžně výsledkem numerické předpovědi a kategorické předpovědi (předchozí kapitola) jsou často získávány pomocí prahových hodnot pro spojité veličiny. Příkladem může být teplotní řada měřených a předpovídaných hodnot. Mimo souhrnných skóre lze použít pro verifikaci také řadu grafických posouzení (bodové a krabicové grafy) (Jolliffe, Stephenson, 2003).

#### 1.5.3.1 Metody hodnocení kontinuálních veličin

**Mean Absolute Error (MAE) :** nevýhodou střední systematické chyby je ta, že záporné chyby (odchylky) se kompenzují těmi kladnými. To znamená, že i dobře hodnocená předpověď nemusí být tak přesná, jak by se zdálo. Tomuto jevu se snaží předejít právě MAE, která je definována jako průměr absolutních hodnot. Z tohoto důvodu však nelze určit směr odchylky.  $F_i$  představuje předpovídanou hodnotu a  $O_i$  naměřenou hodnotu. Ideální skóre je 0 (Jolliffe, Stephenson, 2003).

$$MAE = \frac{1}{N} \sum_{i=1}^N |F_i - O_i| \quad (8)$$


**Mean Squared Error (MSE)** : patří mezi jedno z nejpoužívanějších hodnocení. Díky druhé mocnině je MSE daleko více citlivé na větší odchylky předpovědi, než MAE. Výsledkem je suma druhých mocnin rozdílů mezi předpovědí a měřením.

$$MSE = \frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2 \quad (9)$$

**Root Mean Square Error (RMSE)** : stejně jako MSE klade důraz na větší chyby. RMSE měří rozsah průměrný rozsah chyby (výsledná odchylka je na rozdíl od MSE ve stejné jednotce jako vstupní hodnoty) a z čehož plyne, že stejně jako v případě MSE je ideální skóre 0.


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2} \quad (10)$$

**Scatter plot:** jednoduchý graf stavějící proti sobě předpovídané a měřené hodnoty (obr. č. 12 ). V případě ideální shody jsou všechny body seřazené na 45° diagonále s počátkem v bodu 0. Z grafu lze například vyčíst, zda předpověď nadhodnocuje nebo podhodnocuje, odlehle hodnoty nebo tendence.



Obr. č. 12: Scatter plot (bodový graf) závislosti měřených a predikovaných hodnot (CAWCR, 2013)


**Quantile plot:** v grafu jsou vyneseny proti sobě vybrané kvantily měřených a predikovaných hodnot. Matematicky se jedná o bodový graf podmíněný kvantily měřených a predikovaných hodnot pro vybranou pravděpodobnost (obr. č. 13). Nejlepšího výsledku je opět dosaženo, pokud body leží na nebo v těsné blízkosti  $45^\circ$  diagonály. Pokud se nacházejí dále od diagonály, ale stále pohromadě, je potřeba nekalibrovat model. Závažnější problémem je větší vzdálenost v grafu například mezi body 0,25 kvantilu a 0,75 kvantilu.



*Obr. č. 13: Quantile plot – závislost kvantilů měřených a predikovaných hodnot (Casati, 2009)*

**Box plot:** poskytuje vhodným způsobem přehled marginální distribuce měřených a předpovídaných dat. Popisuje charakteristiku rozložení dat, například medián, variabilitu a symetrii dat (obr. č. 14). Horní a dolní hranice boxu je horní a dolní kvantil (0,75 a 0,25). Variabilitu lze posoudit podle výšky boxu nebo celého rozpětí grafu, které popisuje minimální a maximální hodnoty. Medián je znázorněn vodorovnou čarou uvnitř boxu ( Murphy, Brown, Chen, 1989).





Obr. č. 14: Box plots (krabicové grafy) měřených dat (OBS) a predikovaných dat (FCST)  
(Casati, B., 2009)

### 1.5.4 Pravděpodobnostní předpovědi

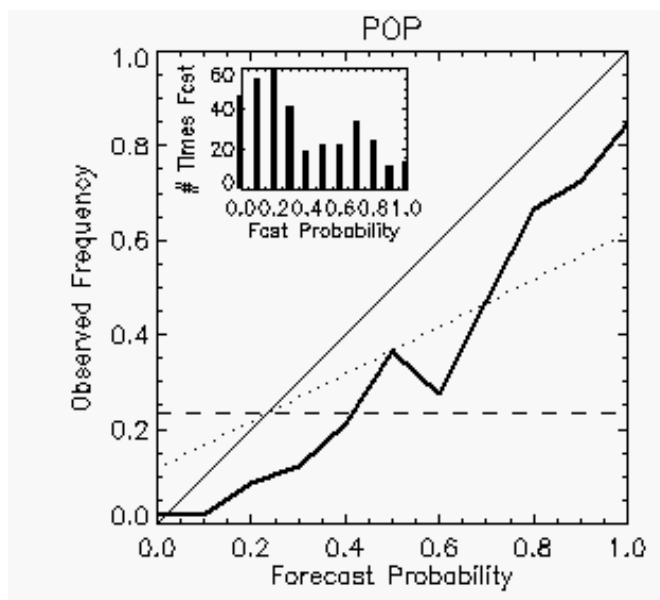
Předchozí metody verifikace byly zaměřeny na hodnocení dat ve formě jedné hodnoty (z kontinua) nebo diskrétní kategorie. Pro pravděpodobnostní předpověď je typická prezentace dat v určitých intervalech nebo třídách (kategoriích). To znamená, že na základě očekávané pravděpodobnosti výskytu předpovídané události je určena pravděpodobnostní hodnota jevu  $P$  v rozmezí 0 až 1. Pravděpodobnostní předpověď může být také založena na souboru několika deterministických předpovědí platných pro stejný čas, které jsou nezávislé a podléhají náhodnému procesu. Odhad pravděpodobnosti prognózované události poskytuje podíl předpovědí predikujících určitou událost ze všech uvažovaných předpovědí. Tato metoda je známá jako ansámblová předpověď a je stále rozšířenější (Jolliffe, Stephenson, 2003).

Na rozdíl od kategorické předpovědi není výstupem předpovědi například „výskyt deště v určitý časový interval: yes“, nýbrž kupříkladu tvrzení, že déšť se vyskytne s 40% pravděpodobností. V tomto případě je třeba provádět verifikaci pro jednotlivé míry pravděpodobnosti (40%). Stejně tak lze v pravděpodobnostní předpovědi hodnotit také binární události a to opět principem přiřazení hodnot, zda k události došlo (1) nebo se nevyskytla (0).

### 1.5.4.1 Metody hodnocení pravděpodobnostních událostí


K hodnocení pravděpodobnostní předpovědi lze kromě empirických metrik využít také grafické zpracování výsledků. Jednou z možností je *Spolehlivostní křivka* (Reliability Curve- RC) nebo *Křivka Relativní Operační Charakteristiky* (Relative Operating Characteristic – ROC) (CAWR, 2013).

**Spolehlivostní křivka:** znázorňuje přesnost předpovědi v přímé závislosti na naměřené hodnoty (obr. č. 15). Spolehlivostní křivku představuje plná čára, získaná vnesením hodnot  $f(q)$  frekvence události proti  $q$  pravděpodobnosti předpovědi. V ideálním případě se spolehlivostní křivka překrývá s diagonální linií. Horizontální přerušovaná linie představuje klimatologickou frekvenci popisované události a tečkovaná linie vedoucí středem mezi diagonální a horizontální linií značí tzv. „no skill“ ve vztahu ke klimatologii. To znamená, že pouze hodnoty nad touto tečkovanou čarou přikládají vyšší schopnost předpovědi, než pokud bychom vycházeli pouze z klimatologických podkladů. V zobrazeném příkladě se nachází spolehlivostní křivka napravo od diagonály. To znamená, že předpověď byla nadhodnocena. Histogram v levém horním rohu ukazuje četnost jednotlivých hodnot pravděpodobností, které byly predikovány (CAWR, 2013).



Obr. č. 15: Spolehlivostní křivka

**Relativní Operační Charakteristika (ROC):** křivku dostaneme vykreslením výsledků charakteristik POD proti F pro události definované pomocí řady rozhodovacích prahových hodnot. Prahovou hodnotou bývá pravděpodobnost a „yes“ událost nastane, pokud pravděpodobnost předpovědi přesáhne prahovou hranici (Ebert, 2008). Křivka v případě přesné předpovědi začíná v levé spodní části a následuje osu Y směrem do levého horního rohu ( $F=0$ ). Dále následuje horní osu směrem k pravému hornímu rohu ( $POD=1$ ). Výsledkem je plocha vzniklá pod křivkou, kdy ideální hodnota je 1, „no skill“ hodnota je 0,5 (obr. č. 16) (CAWR, 2013).



Obr. č. 16: ROC křivka zobrazující verifikaci předpovědi na 2,4,6 a 8 dní  
(Jolliffe, Stephenson, 2003)

**Brier Score (BS)** : Brier navrhl několik metod hodnocení kvantitativních pravděpodobnostních binárních prognóz, založených na kvadratickém bodování. Jednou z těchto metod je právě BS, kde  $N$  je počet realizací předpovídaného procesu, přes které je validace prováděna (Jolliffe, Stephenson, 2003). Pro každou realizaci  $i$ , existuje pravděpodobnost výskytu predikované události  $p_i$ , a stejně tak hodnota  $o_i$  nabývající hodnoty 1 nebo 0, podle toho, zda se událost vyskytla nebo ne. BS poměřuje střední kvadratickou pravděpodobnostní chybu při  $N$  událostech. Ideální skóre je 0 (Ebert, 2008).

$$BS = \frac{1}{N} \sum_{i=1}^N (p_i - o_i)^2 \quad (11)$$

**Brier Skill Score (BSS)** : na rozdíl od BS je BSS kladně orientováno, tedy čím vyšší hodnota, tím lepší přesnost předpovědi a navíc bere v úvahu klimatologickou frekvenci ( $B_{ref}$ ). Stejně jako BS je vhodnější pro delší datové sady a především v případě výskytu extrémní události, je potřeba více dat pro dosažení relevantních výsledků.

$$BSS = 1 - \frac{BS}{BS_{ref}} \quad (12)$$

**Ranked Probability Score (RPS)** : měří sumu kvadratický rozdílů v kumulativním kvadratickém prostoru pro multi-kategoriální pravděpodobnostní předpověď.  $CDF_{y,m}$  je kumulativní pravděpodobnost předpovědi, že bude překročena definovaná hranice pro  $m$ . Pokud je překročena,  $o_m$  nabývá hodnoty 1, pokud ne, 0.  $M$  představuje počet kategorií předpovědi.

$$RPS = \frac{1}{M-1} \sum_{m=1}^M (CDF_{y,m} - o_m)^2 \quad (13)$$

## 1.5.5 Prostorové předpovědi

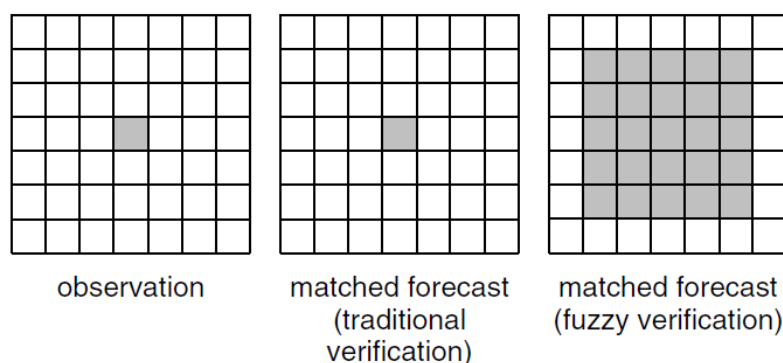
Předchozí typy předpovědí jsou pouze funkcí času. To znamená, že předpověď byla vypočtena několikrát pro jediný parametr (srážky, teploty apod.) v jednom prostorovém bodě. Kdežto prostorová předpověď počítá stejný parametr nad vymezeným prostorem. Prediktandy mohou být spojité nebo diskrétní veličiny 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, analýzy a předpovědi dat, který 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 v případě srážkových dat, kde je nutné provádět analýzu a asimilaci dat odděleně. Důvodem je, že zejména v oblastech s významnou topografií a variabilním rozmístěním měřících stanic se velice komplikuje analýza srážkových dat (*Jolliffe, Stephenson, 2003*).

K verifikaci NWP modelů o vysokém rozlišení je potřeba zvolit netradiční verifikační techniky, zejména kvůli výskytu drobných prvků (lokální konvektivní buňky). V poslední době se začínají rozvíjet metody, u kterých není požadováno, aby pozorovaná data byla přesně ve stejném měřítku jako předpověď. Jednou z nich je fuzzy metoda.

### 1.5.5.1 Fuzzy metody

Techniky fuzzy metod jsou víceměřítkové, posuzující kvalitu předpovědi jako funkci prostorové blízkosti. A to tím způsobem, že jsou hledány shody v prostoru okolí bodu zájmu. Původně byly vyvinuty pro verifikaci srážkových předpovědí o vysokém rozlišení proti radarovým odhadům a měření pozemních srážkoměrů. V podstatě je lze aplikovat na jakékoliv předpovědi o vysokém rozlišení, které mají dostupná data pozorování. Zvláštností je používání odlišných identifikačních pojmů, jako „*useful*“ (vhodné) a „*close enough*“ (dostatečně blízko). Některé fuzzy metody hodnotí velkoryse a jako dobrou předpověď mohou považovat situaci, kdy pozorovaná událost a alespoň jedna předpovídaná udáost (například překročení mezní hodnoty pro srážkový úhrn v určitém gridu) se nacházejí ve stejném blízkém okolí. Jiné jsou naopak více omezující a požadují navíc v blízkém okolí stejnou frekvenci předpovědi a pozorování (Ebert, 2008).

Klasická prostorová verifikace předpovědi v rastrovém formátu srovnává pozorované hodnoty v určitém bodu (gridu), s předpovědí pro tentýž bod a následně počítá různé metriky pro shodný soubor všech měření a předpovědí. Fuzzy verifikace připouští, že předpověď, která je mírně odchýlená v prostoru, může být stále vhodně použitelná. Úroveň prostorové chyby je definována tzv. *lokálním okolím (local neighbourhood)*. Tento přístup lze aplikovat i na časové odchylky. Velikost *local neighbourhood* se určuje na základě několika parametrů, například časového a prostorového rozlišení, druhu meteorologické situace apod. (Ebert, 2008). Mezi nejpoužívanější fuzzy metody patří Fraction Skill Score (FSS), která hodnotí dílčí pokrytí srážkovým úhrnem, který překročil stanovenou prahovou hodnotu (Rezacova, et al., 2009)



Obr. č.17: Příklad porovnávání měřených hodnot (*observation*) s předpovědí (*matched forecast*) tradičním způsobem (*traditional verification*) a fuzzy metodou (*fuzzy verification*) (Ebert, 2008)

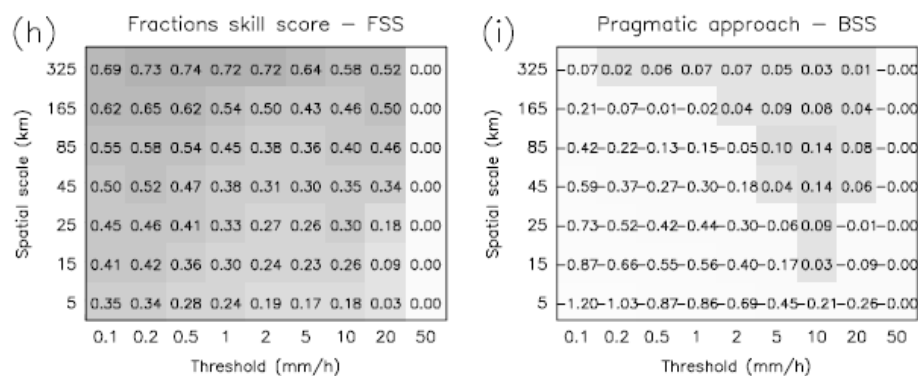
**Fractions Skill Score (FSS):** v tomto případě je model hodnocený jako úspěšný, pokud frekvence predikovaných událostí je blízká frekvenci měřených událostí. FSS mezi sebou přímo porovnává frakční pokrytí grid boxů událostmi (předpovědi proti měření) v prostoru o rostoucí velikosti. Nabývá skóre 0-1, přičemž 1 je nejlepší výsledek (Ebert, 2008).

$$FSS = 1 - \frac{FBS}{\frac{1}{N} [\sum_N P_f^2 + \sum_N P_o^2]} \quad (14)$$

V čitateli je dosazeno **Fraction Brier Score (FBS)**, které je počítáno sumou druhých mocnin rozdílu frakce předpovědi  $P_f$  a frakce měření  $P_o$ . Parametr  $N$  je v obou případech počet grid boxů ve verifikované oblasti (Rezacova et al., 2009).

$$FBS = \frac{1}{N} \sum_N (P_f - P_o)^2 \quad (15)$$

Za nejsmysluplnější využití fuzzy verifikace je považováno vyhodnocování prognostických sad za účelem posuzování typického chování předpovědi. Lze ji využít pro verifikaci lokálních konvektivních srážek i rozsáhlých srážkových polí. Existují i klasické metody hodnocení upravené pro porovnání hodnot předpovědi ve vysokém rozlišení a hodnot naměřených v blízkém okolí. Například (Rezacova et al., 2007) uvádí tzv. *Area-related RMSE*. Tato metoda předpokládá, že úspěšná předpověď má podobné rozložení intenzit srážek jako naměřené hodnoty. Výpočet probíhá tak, že predikované a měřené hodnoty jsou seřazeny od nejmenších po největší a z těchto dvou seřazených řad je počítáno RMSE. Fuzzy metodu lze uplatnit i na další z klasických metod, jako například POD, BSS, FAR apod. Výsledky lze prezentovat například pomocí diagramu závislosti intenzity na měřítku (obr. č. 18). (Ebert, 2008)



Obr. č. 18: Výsledky fuzzy verifikace konvektivní události metodami FSS a BSS. Tmavší odstín šedé znamená dobré výsledky, světlý odstín nepřesné výsledky. Na ose X jsou hodnoty prahových hodnot pro srážkové úhrny (mm/h) a na ose Y prostorové měřítko (km) (Ebert, 2008)

## 2. Metodika

### 2.1 Charakteristika a způsob zpracování dat

#### 2.1.1 Popis verifikovaných srážkových událostí

Cílem práce je statistický odhad nejhodnějšího rozlišení vstupních dat (numerické předpovědi srážek modelem ALADIN) do hydrologických modelů používaných v ČHMÚ. Ke zpracování bylo vybráno 6 nezávislých srážkových událostí v následujících termínech:

- 1) 1. 6. 2013
- 2) 2. 6. 2013
- 3) 23. 6. 2013
- 4) 9. 8. 2013
- 5) 19. 8. 2013
- 6) 18. 9. 2013

Pro vyhodnocení byly použity výstupy numerické předpovědi srážek modelu ALADIN, které byly k dispozici v hodinovém kroku. Počátek integrace předpovědi byl vždy v den výskytu události v 00:00:00 UTC. Rozsah předpovědi (+48h) vyžadoval selekci (respektive zkrácení) pouze pro dobu výskytu srážkové události, z důvodu možnosti zkreslení výpočtů hodnotami předpovídaných srážek v období mimo posuzovanou událost. Ve všech šesti případech došlo k redukci předpovědi na +48h, čímž se délkou shodovala s měřenými daty. Jedním z kritérií pro výběr vhodných srážkových epizod byl výskyt srážek na většině území ČR. Důvodem je rozmanitost orografie a specifičnost jednotlivých částí republiky vzhledem k výskytu a průběhu srážkové činnosti.

#### 2.1.2 Způsob zpracování dat

Data byla zpracována v prostředí R, které poskytuje širokou škálu možností zpracování a prezentace rastrových dat. Pro práci s rastrovými daty byl použit především balíček *raster* a pro jejich grafickou prezentaci balíčky *ggplot2*, *maptools* apod.



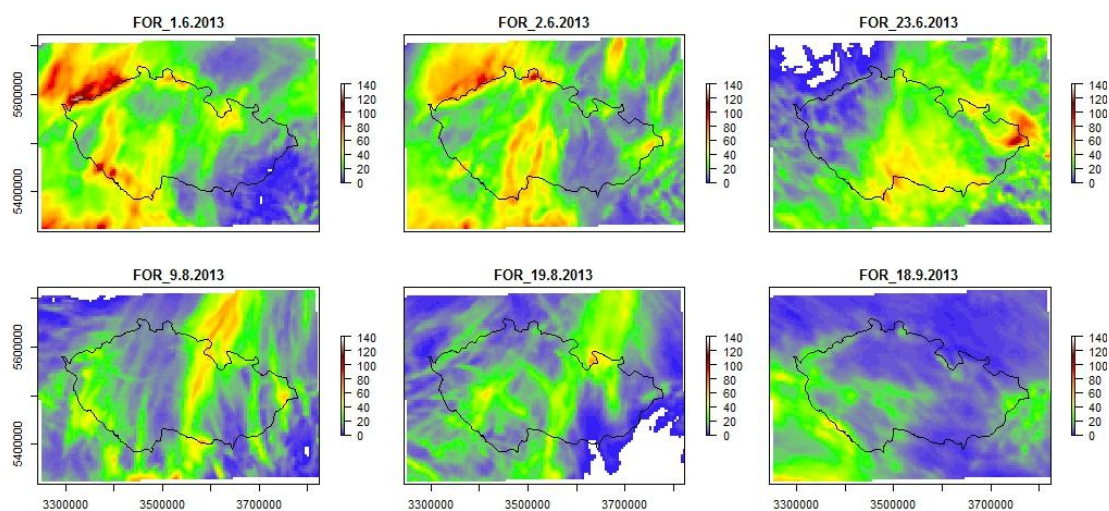
Rastr je prostorová datová struktura rozdělující určitou oblast do rektangulárních buněk neboli pixelů, které mohou mít přiřazenu jednu nebo více hodnot. Obecně tento typ dat nazývá jako gridová data. Funkce balíčku *raster* poskytují schopnost manipulace, úpravy a vytváření dat. Princip práce s rastrem a většina funkcí je zde na podobném principu jako v programu GIS (Geographical Information Systems). V balíčku *raster* existují tři základní způsoby prezentace rastrových vrstev v závislosti na typu dat a smyslu jejich využití. *RasterLayer* je nejjednodušším z nich a reprezentuje jednovrstvá rastrová data. V případě separovaných rastrových dat z několika vrstev se nabízí jako vhodnější prezentace pomocí *RasterStack*. Data pro *RasterStack* jsou v podstatě souborem *RasterLayer* objektů se stejným prostorovým rozsahem a měřítkem. Třetím způsobem, který je využit v této práci, je *RasterBrick*. Jeho výstupem může být pouze jednovrstevný soubor dat a v praxi bývá účinnější než *RasterStack* a často je využíván právě pro analýzu klimatických a meteorologických dat, jako jsou například satelitní snímky nebo výstupy klimatického modelu (Hijman, 2014).

### 2.1.3 Statistiky dat srážkových událostí

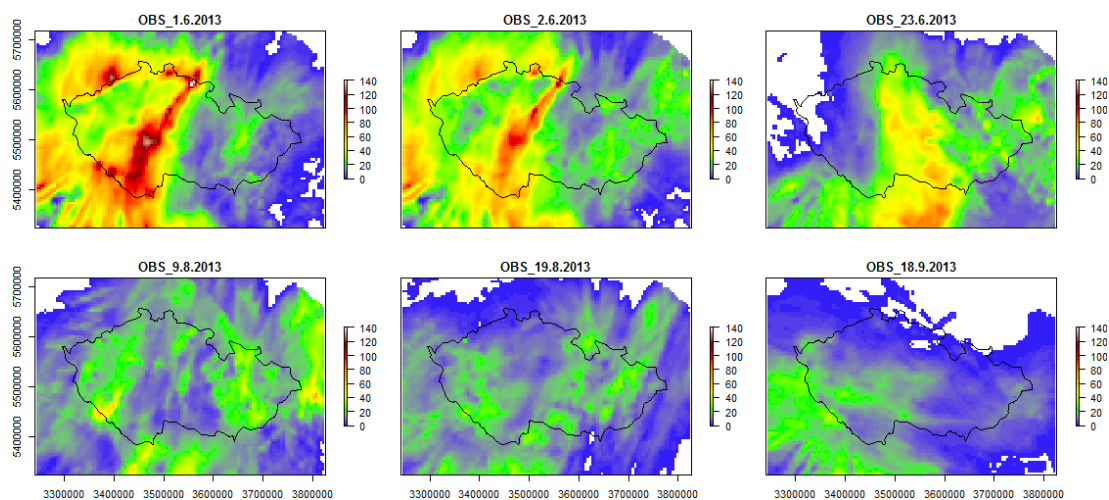
V případě předpovědních dat bylo k dispozici 320 rastrových vrstev pro šest výstupů z výše uvedených termínů. Každá z vrstev měla rozlišení 82x122 bodů, tedy celkem 10 004 bodů. Pro lepší manipulaci a prezentaci dat v R programu, byla data převedena do souřadnicového systému S-42, které má při zobrazení výhodu nulového úhlového zkreslení. Na obr. č. 19 jsou zobrazeny celkové sumy srážek (+48h) z jednotlivých výstupů modelu ALADIN. Pro jednotlivé výstupy byly predikovány maximální a minimální úhrny uvedené v tabulce č. 2. V příloze jsou dále vyobrazeny sumy predikovaných srážek pro 1h maxima a dále 3h, 6h, 12h a 24h maxima jednotlivých událostí, vypočítána klouzavou sumarizací hodinových dat. Prezentovány jsou tedy součty 3, 6, 12 a 24 vrstev hodinových dat, ve kterých je po sečtení v určitém bodě dosaženo nejvyšší možné hodnoty.

Měřená data jsou výsledkem kombinace radarových odrazů a pozemního měření. K dispozici byla ve stejném prostorovém a časovém rozlišení jako data předpovědi. Z důvodu časové délky dat (48h) dochází v termínu 2. 6. 2013 k překrývání dvou shodných datových sad, určených pro předpověď z 1. 6. 2013

00UTC a 2. 6. 2013 00UTC. Tato skutečnost způsobuje při výpočtu maximálních vícehodinových sum pro termíny 1. 6. 2013 +48h a 2. 6. 2013 +48h (viz příloha), že je pro oba termíny vypočtena téměř shodná maximální suma. Při verifikaci to není problém, jelikož měřená data z termínu 2. 6. 2013 jsou přiřazena ke dvěma odlišným předpovědím pro toto období. V tabulce č. jsou porovnány maximální a minimální hodnoty.



Obr. č. 19: Sumarizace srážek z jednotlivých výstupů modelu ALADIN (+48h)



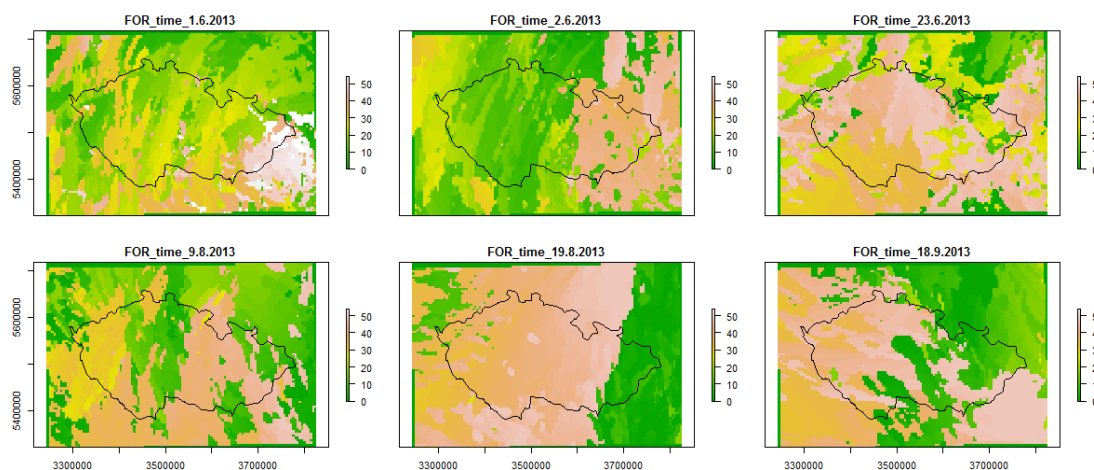
Obr. č. 20: Sumarizace měřených srážek z kombinace radarového a pozemního měření (48h)

V tabulce č. 2 jsou porovnány maximální a minimální hodnoty předpovědi a měření. V prvních dvou termínech došlo v předpovědi k podhodnocení maximálního úhrnu, ve zbylých čtyřech naopak k nahodnocení. Výraznější rozdíl v maximech se vyskytuje v předpovědích z 23. 6. 2013 00UTC a 19. 8. 2013 00UTC. Nejvyšší naměřený úhrn dosáhl hodnoty 144,4 mm dne 1. 6. 2013.

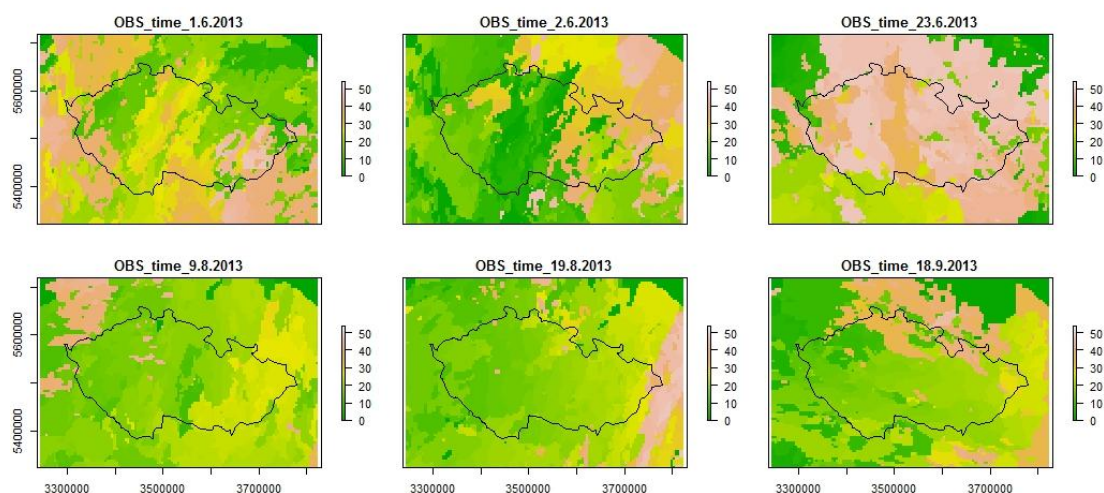
<b>Termín</b>	1.6.2013	2.6.2013	23.6.2013	9.8.2013	19.8.2013	18.9.2013
<b>předpovědi</b>	00UTC	00UTC	00UTC	00UTC	00UTC	00UTC
<b><u>Předpověď:</u></b>						
Max (mm)	127,6	110,2	117,6	81,2	71,8	58,4
Min (mm)	0,4	2,3	0,0	0,1	0,0	0,9
<b><u>Měření:</u></b>						
Max (mm)	144,4	116,1	83,4	75,1	36,0	40,8
Min (mm)	0,0	0,0	0,0	0,0	0,0	0,0

*Tabulka č. 2: Maximální a minimální hodnoty predikované a měřené pro zobrazenou oblast pro +48h*

V obrázku č. 21 a č. 22 je zobrazeno časové rozložení maximálních srážek, odvozené z předpovědi modelu ALADIN a z měřených dat, v závislosti na hodině výskytu (0-48h) maximální 1h srážky v jednotlivých gridových bodech. To znamená, že například grid, ve kterém podle předpovědi nastane maximální srážka ve 12h předpovědi, má přidělenou barvu odpovídající na stupnici hodnotě 12. Z výsledné mapy lze kromě časové charakteristiky maximálních srážek také určit, kterým směrem a v jakých hodinách se pohybovalo hlavní srážkové pásmo.

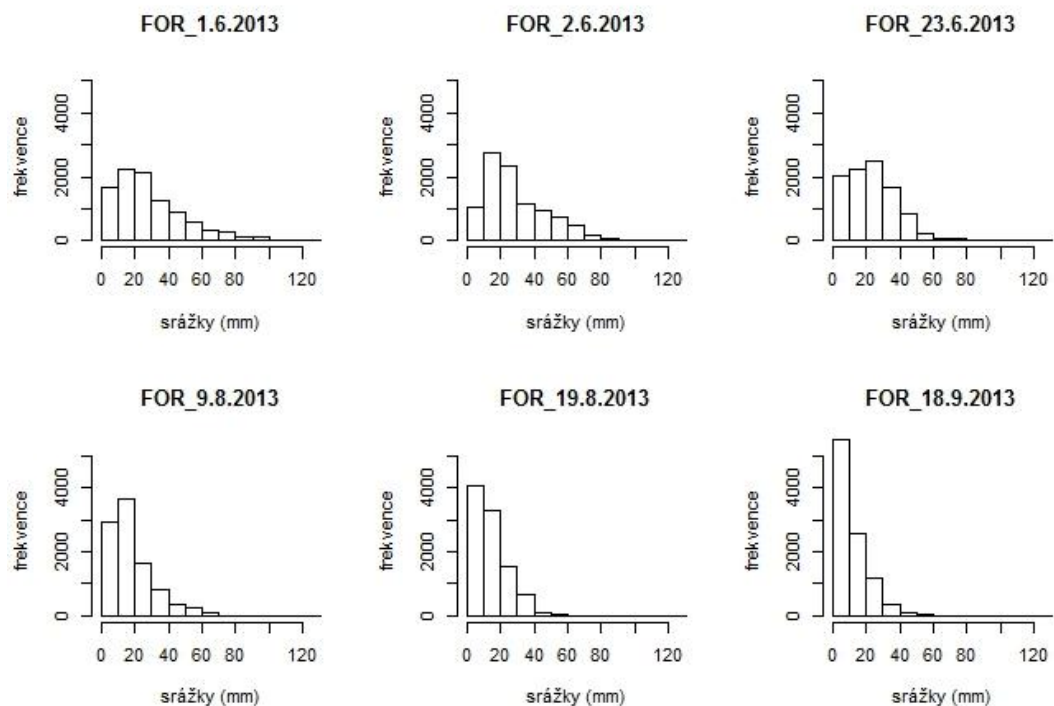


*Obr. č. 21: Časová charakteristika maximálních 1h predikovaných srážek*



Obr. č. 22: Časová charakteristika maximálních 1h měřených srážek

Celkovou vydatnost šesti vybraných dešťových epizod lze porovnat v mapovém výstupu na obr. č. 20. Určitou představu o celkové výšce srážkových úhrnů může poskytnout také histogram popisující četnosti (frekvence) pro přidělené třídy hodnot. V našem případě (obr. č. 23) jsou vyjádřeny četnosti výskytu hodnot predikovaných srážkových úhrnů, rozdělených do tříd po 10 mm. Zdrojem pro tyto histogramy jsou rastrové vrstvy, které představují výsledek 48h integrace každé události. Jako předpověď predikující v celkovém součtu nejnižší srážkové úhrny, lze na základě histogramu hodnotit předpověď z termínu 18. 9. 2013. Důvodem je nadpoloviční zastoupení gridových boxů s hodnotou 0-10mm, které způsobuje, že těžiště histogramu se nachází v těsné blízkosti osy y. Jinak tomu je v případě předpovědi z termínu 1. 6. 2013, kdy jsou srážky více rovnoměrně rozloženy po ose x a nejvyšší četnosti nabývají úhrny v rozmezí 20-30mm. Stejně tak i předpokládané těžiště histogramu je situováno dále od osy y.

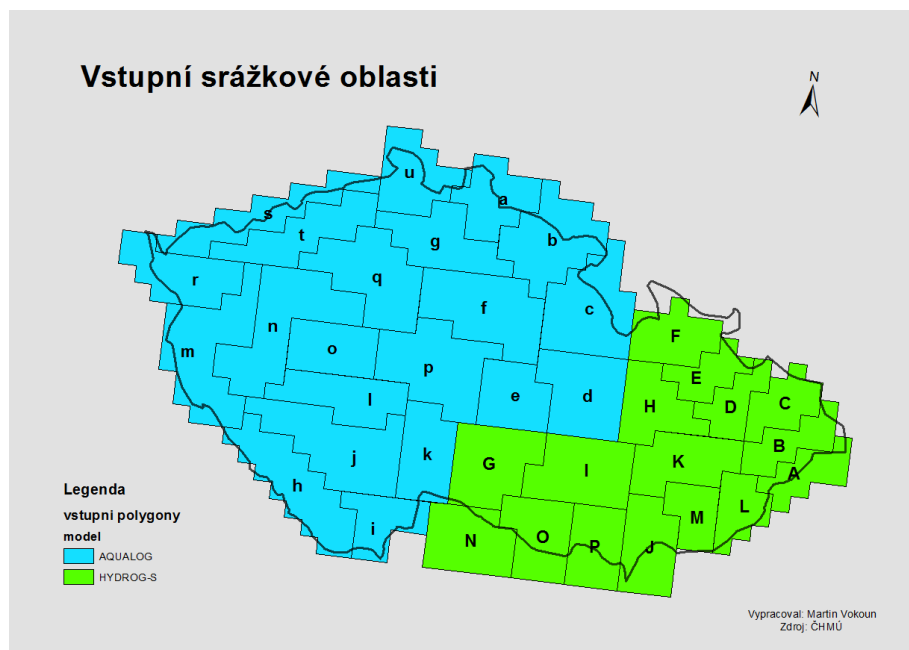


Obr. č. 23: Četnosti tříd sumarizovaných predikovaných srážkových úhrnů +48h

### 2.1.4 Vstupní oblasti do hydrologických modelů

Numerická předpověď srážek nevstupuje do hydrologických předpovědních systémů ve stejném rozlišení, v jakém je vytvářena v modelu ALADIN. Oblasti povodí českých řek jsou rozděleny do 37 jednotlivých oblastí, přičemž pro jednu oblast je vyhodnocována jedna vstupní hodnota srážek. V případě použití pro vstupní data stejného rozlišení, v jakém je předpověď, docházelo by k vnášení vysoké míry nejistoty, a to především vzhledem k prostorové variabilitě srážek. Avšak s rostoucí přesností předpovědi srážek přestává být současné rozdělení do větších oblastí dostatečně uspokojivé. Problémové jsou zejména horské partie nebo například oblasti s vyšším vlivem návětrných svahů na celkový úhrn srážek. Za účelem zpřesnění hydrologických předpovědí je nejspíše potřeba zjemnit rozlišení celoplošně.

Na obr č. 23 je zobrazena mapa všech vstupních srážkových oblastí. Barevně jsou odlišeny barvy polygonů vstupujících do předpovědního systému AQUALOG (modrá barva) a HYDROG-S (zelená barva). Polygony jsou navrženy tak, aby pokrývaly plochu českých povodí.



Obr. č. 23: Vstupní srážkové oblasti do předpovědních systému AQUALOG A HYDROG-S

#### 2.1.4.1 Časové charakteristiky dešťů ve vstupních oblastech


V následujících obrázcích č. 25 a č. 26 je graficky zobrazeno časové rozložení šesti posuzovaných srážkových epizod pro predikci a měřená data v jednotlivých vstupních oblastech. Z důvodu velkého počtu vstupních oblastí, byly rozděleny do čtyř skupin podle hranic povodí, a to povodí Vltavy, Labe a Ohře, Moravy a Odry (obr č. 24). V textu práce jsou prezentovány časové charakteristiky pro oblast povodí Vltavy, jelikož právě zde byl sumárně nejvyšší výskyt srážek. Časové charakteristiky pro zbylé tři oblasti jsou vyobrazeny v příloze. Na první pohled je zřejmé, že například v případě první dešťové epizody došlo k poměrně výraznému podhodnocení intenzity srážek ve všech polygonech v povodí Vltavy, naopak jejich časové rozložení předpověď vystihuje poměrně přesně. Zbýlých pěti předpovědí již nevykazuje z grafů viditelné výraznější odchylky.



Obr. č. 24: Rozčlenění vstupních polygonů do 4 skupin podle hranic povodí



Obr. č. 25: Hyetogramy **predikovaných** srážek v jednotlivých polygonech povodí Vltavy

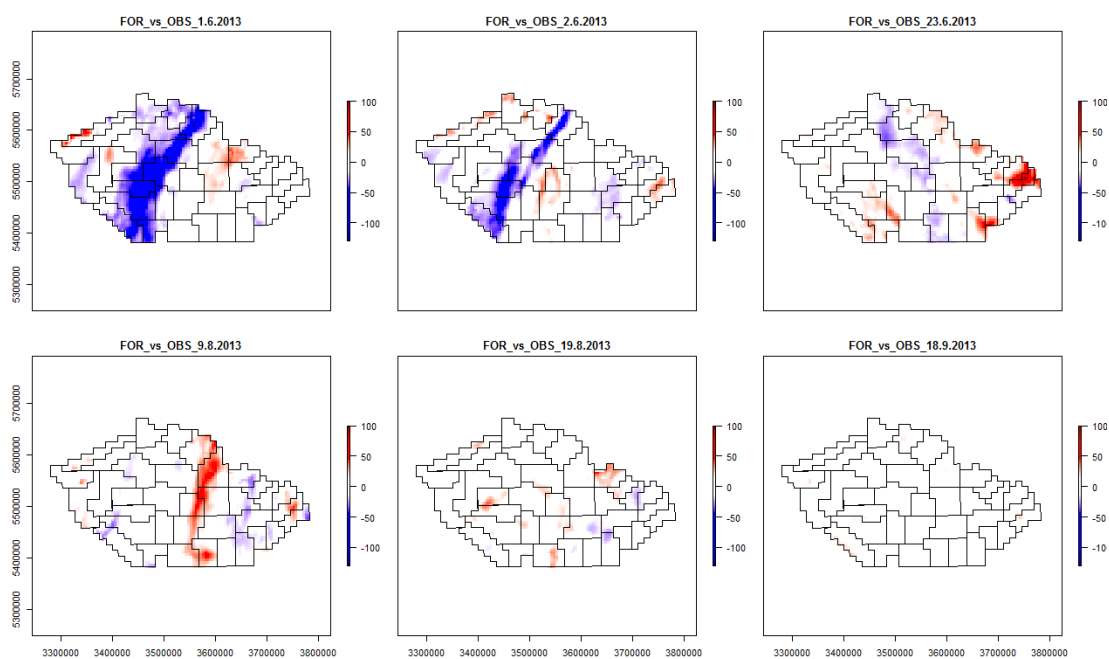


Obr. č. 26: Hyetogramy *měřených* srážek v jednotlivých polygonech povodí Vltavy

#### 2.1.4.2 Odchyly skutečnosti od předpovědi

Obr. č. 27 potvrzuje domněnku ohledně podhodnocení srážek modelem ALADIN v předpovědi z 1. 6. 2013 00UTC. Každá jednotlivá mapa prezentuje výsledek rozdílu 48h sumy predikovaných srážek, od kterých je odečtena 48h suma měřených dat. Barevná škála odpovídá rozmezí hodnot od -121mm (1. 6. 2013) do 97,4 mm (23. 6. 2013). Přičemž nejnižším hodnotám (podhodnocení modelu) odpovídá modrá barva a nejvyšším hodnotám (nadhodnocení modelu) červená barva. Nižší odchyly, cca +/- 15mm jsou prezentovány bílou barvou. V tomto případě se jako nejlepší zdá být předpověď z 18. 9. 2013. Zde se však jednalo o epizodu s nižšími úhrny a prostorově rovnoměrným výskytem, tedy snadněji předpověditelnou událost. Za zmínku jistě také stojí značné nadhodnocení modelu v předpovědi z 9. 8. 2013 00UTC.





Obr. č. 27: Rozdíl predikovaných srážek (+48h) a měřených srážek (48h)

<b>Termín</b>	1.6.2013	2.6.2013	23.6.2013	9.8.2013	19.8.2013	18.9.2013
	00UTC	00UTC	00UTC	00UTC	00UTC	00UTC
<b>Odchytky</b>						
Max + (mm)	67,3	44,3	97,4	59,4	47,6	24,4
Max - (mm)	-121,1	-88,2	-35,1	-36,9	-27,8	-14,0


Tab. č. 3 : Maximální kladné a záporné odchytky rozdílu předpovědi a měření

## 2.2 Verifikace


Cílem verifikace je pomocí statistických metod odhadnout, při jakém rozlišení (resp. Velikosti) vstupních srážkových oblastí dosahuje agregace předpovědi srážek nejvyšší shody s měřenými daty. Rozměr jednoho gridového bodu použitých dat předpovědi je 4,8km x 4,8km (22,56km<sup>2</sup>), zatímco průměrná rozloha jednoho vstupního polygonu je 50,04km x 50,04km (2504,25km<sup>2</sup>). To znamená, že polygon o průměrné velikosti zaujímá plochu 111 gridových bodů předpovědi a pokud by vstupní oblasti měly čtvercový tvar, jedna strana by byla tvořena přibližně 11 gridovými body. Pro verifikaci bylo vybráno několik rozdílných verifikačních metod tak, aby výsledky poskytly co nejširší spektrum charakteristik. Použity byly jednak všeobecně vyžívaná skóre pro hodnocení srážek, jakými jsou RMSE, ETS ale také korelace, FAR a POD.

### 2.2.1 Korelace

Korelace byla počítána v R programu pro všech 288 vrstev předpovědi a měření, přičemž bylo potřeba ošetřit (resp. vyloučit z výpočtu) přibližně 5 dvojic vrstev, u kterých byly chybně zaznamenány data, zřejmě z důvodu výpadku radaru. Závislost korelace na prostorovém rozlišení byla provedena dvěma způsoby. Prvním způsobem je postupná agregace rastru, kdy jsou predikované hodnoty průměrovány do zvětšujících se oblastí (2x2 pixely, 3x3 pixely, 4x4 pixely atd.) a dále porovnávány s předpovědí, u které zůstává původní rozlišení. Pro správný chod korelace rastrových vrstev bylo potřeba agregované oblasti opět rozdělit na primární rozlišení shodné s měřenými daty pomocí funkce *resample*, přičemž hodnoty předpovědi prostorově zůstaly přepočítané podle určené agregace. Druhým způsobem je klouzavá agregace, kdy pomocí fokální funkce je každému gridovému bodu přidělen počet sousedních bodů a takto postupně agregován celý rastr. V tomto případě byly body agregovány rovnoměrně ve čtvercovém rozložení, kde strana čtverce měla vždy lichý počet bodů, jelikož ve středu této plochy je vždy bod, ke kterému se daná agregace vztahuje.




Obr. č. 28: Příklad korelace dat při rozlišení 4,8km (1bod)




Obr. č. 29: Příklad korelace dat při agregaci předpovědi do ploch 11x11 bodů

## 2.2.2 Root Mean Square Error (RMSE)

Metoda RMSE byla aplikována stejným způsobem, jako metoda korelace, tzn. vyhodnocení jak pro obyčejnou, tak i klouzavou agregaci. Liší se pouze použitím celého rastrového pole, nikoliv jen oblasti vstupních polygonů, a to z důvodu lepší prostorové aplikovatelnosti metody.



Obr. č. 30: Příklad RMSE pro rozlišení 4,8km (1bod)



Obr. č. 30: Příklad RMSE při agregaci předpovědi do ploch 11x11 bodů

### **2.2.3 Equitable Threat Score (ETS), False Alarm Ratio (FAR), False Alarm Rate (F) a Probability of Detection (POD)**

Následující tři metody verifikace byly vybrány z důvodu možnosti nastavení hranic srážkových úhrnů. Díky tomu je možné provést verifikaci předpovědi pouze pro určité intenzity deště, respektive různé třídy srážkových úhrnů. ETS je všeobecně oblíbená metoda při verifikaci srážek. V této práci bylo ETS stanoveno dvěma způsoby pro dvě různé sady srážkových prahů. V prvním případě pro každou jednotlivou vrstvu (288x) a následně zprůměrováno do jedné výsledné hodnoty pro každý z pěti vybraných srážkových prahů. Ve druhém případě pro bylo ETS vypočteno pro šest rastrů, sumarizovaných podle dešťových epizod (resp. předpovědi +48h), a následně opět zprůměrováno do jedné hodnoty. Jelikož jednotlivé rastry předpovědi nabývají znatelně nižších hodnot, než sumarizované rastry, bylo potřeba zvolit pro hodnocení nižší srážkové prahy, tedy v tomto případě 0,2mm, 0,5mm, 1mm, 3mm a 5mm. Ve druhém případě byly srážkové prahy nastaveny na 5mm, 10mm, 20mm, 30mm a 50mm. Například hodnota ETS pro 10mm hodnotí předpověď úhrnu 10mm a vyšší. I v případě ETS bylo provedeno hodnocení pro agregované oblasti v rozlišení 1x1 až 20x20 bodů a pro celou plochu dostupné předpovědi, nikoliv pouze pro vstupní polygony.

FAR poskytuje představu o tom, jak neúspěšný byl model v předpovědi námi určených tříd srážkových předpovědí, jelikož je zaměřen na chybné předpovědi. Naopak POD se zaměřuje na úspěšné předpovědi. Tyto dvě metody byly aplikovány na 48h sumy jednotlivých předpovědí. Srážkové prahy byly v tomto případě určeny na 2,5mm, 5mm, 10mm, 20mm a 30mm. Aplikace nižšího prahu než 2,5mm postrádala smysl, neboť úhrny okolo 2mm byly během 48h dosaženy vždy na naprosté většině území, naopak srážky vyšší než 30 mm byly ve třech událostech dosaženy jen v několika bodech, či vůbec. Pro stejné srážkové prahy bylo vypočítáno také F, jelikož výsledky F a POD mohou být podkladem pro další výpočty nebo pro vyhotovení ROC křivek.

### 3. Výsledky

#### 3.1 Korelace a RMSE

Výsledky korelace a RMSE potvrzují, že současné velikosti polygonů mají vzhledem k přesnosti předpovědi poměrně vyhovující velikost. Samozřejmě je třeba brát v úvahu fakt, že agregované oblasti měli pravidelný čtvercový tvar, který se v praxi u vstupních polygonů nevyskytuje. Avšak podstata vlivu velikosti plochy (nikoliv tvaru) odpovídá následujícím výsledkům. V tabulkách č.4 a č.5 a v grafech v obrázcích č. 31 a č. 32, představuje hodnota agregace počet bodů jedné strany čtvercové agregované plochy. To znamená, že hodnota 1, je původní rozlišení a plocha obsahuje jeden bod. Hodnota 2 znamená agregaci na plochu 2x2 body, hodnota 3 na plochu 3x3 body atd., přičemž jak již bylo zmíněno, průměrná plocha současných vstupních polygonů je přibližně 11x11 bodů.

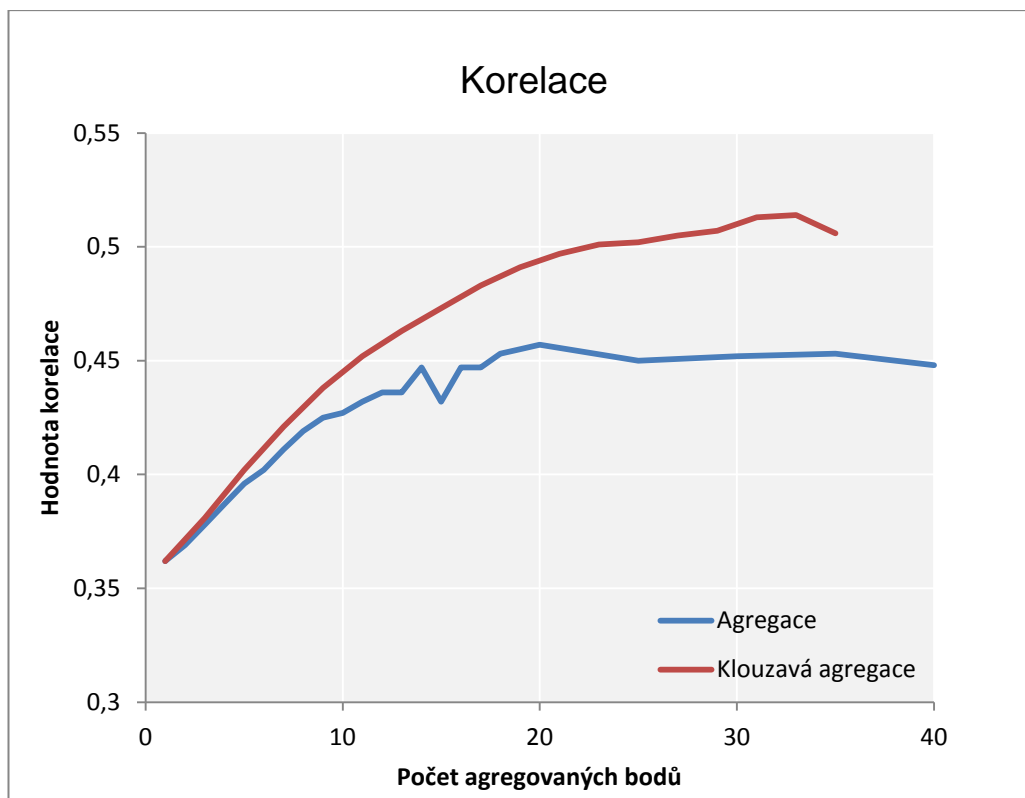
Agregace	Korelace	RMSE	Agregace	Korelace	RMSE
1	0,362	2,277	15	0,432	2,267
2	0,369	2,271	16	0,447	2,271
3	0,378	2,263	17	0,447	2,321
4	0,387	2,259	18	0,453	2,305
5	0,396	2,25	19	0,455	2,276
6	0,402	2,251	20	0,457	2,28
7	0,411	2,247	25	0,450	2,277
8	0,419	2,256	30	0,452	2,231
9	0,425	2,24	35	0,453	2,375
10	0,427	2,251	40	0,448	2,394
11	0,432	2,262	45	0,445	2,401
12	0,436	2,255	50	0,442	2,419
13	0,436	2,257	60	0,449	2,473
14	0,447	2,263			

Tab. č. 4: Prostá agregace Korelace a RMSE

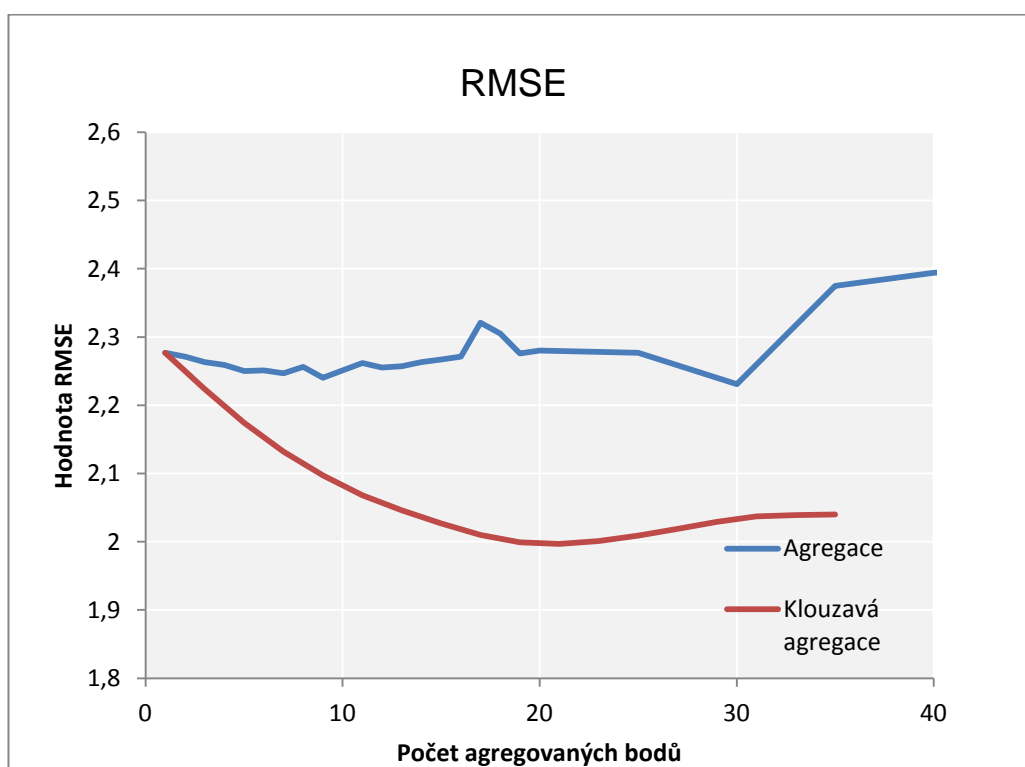
Klouzavá agregace	Korelace	RMSE
1	0,362	2,277
3	0,381	2,224
5	0,402	2,174
7	0,421	2,132
9	0,438	2,097
11	0,452	2,068
13	0,463	2,046
15	0,473	2,027
17	0,483	2,010
19	0,491	1,999
21	0,497	1,997
23	0,501	2,001
25	0,502	2,009
27	0,505	2,019
29	0,507	2,029
31	0,513	2,037
33	0,514	2,039
35	0,506	2,040

*Tab. č. 5: Klouzavá agregace Korelace a RMSE*

Korelace a RMSE poskytují poměrně shodné výsledky. V případě klouzavé agregace dochází k růstu úspěšnosti předpovědi přibližně do hodnoty agregace 21 bodů. RMSE od této hodnoty vykazuje zhoršení přesnosti a korelace značně zpomaluje růst a hodnoty začínají kolísat. O něco rozdílnější výsledky vykazuje prostá agregace, kde RMSE nabývá nejlepšího skóre při agregaci o straně plochy 9 bodů a poté dochází ke zvyšování hodnot vyšší rozkolísanosti. Naproti tomu hodnoty korelace rostou až do agregace 20 bodů, poté nastává mírný pokles a ustálení na jedné hodnotě.



Obr. č. 31: Graf závislosti korelace na velikosti agregace




Obr. č. 32: Graf závislosti RMSE na velikosti agregace




### 3.2 ETS, FAR a POD

Rozdíly mezi výsledky ETS pro předpověď v hodinovém kroku a 48h sumě poukazují na časovou variabilitu srážek, kdy v případě hodinového kroku jsou výsledky verifikace znatelně horší. Ve 48h sumě se tyto nepřesnosti vyhlazují. Do hydrologických modelů však vstupují vyšší než 1h sumy, proto tyto výsledky jsou přínosné zejména pro pochopení vlastností a chování předpovědi.



Obr. č. 33: ETS hodinového kroku předpovědi pro agregaci 1 – 20 v závislosti na definovaném srážkovém prahu




Obr. č. 34: ETS hodinového kroku. Zobrazení závislosti hodnoty ETS na velikosti agregace pro jednotlivé srážkové prahy


ETS 1h	0,2	0,5	1	3	5	$\Sigma/n$
1	0,159	0,131	0,122	0,060	0,042	0,103
2	0,159	0,132	0,123	0,062	0,042	0,104
3	0,157	0,131	0,123	0,061	0,041	0,102
4	0,158	0,133	0,124	0,064	0,046	0,105
5	0,159	0,133	0,126	0,066	0,041	0,105
6	0,157	0,134	0,125	0,067	0,048	0,106
7	0,156	0,137	0,127	0,066	0,039	0,105
8	0,157	0,138	0,130	0,072	0,047	<b>0,109</b>
9	0,155	0,136	0,128	0,067	0,036	0,104
10	0,158	0,138	0,130	0,072	0,032	0,106
11	0,155	0,139	0,129	0,077	0,037	0,107
12	0,153	0,138	0,127	0,068	0,045	0,106
13	0,152	0,139	0,132	0,069	0,050	0,108
14	0,154	0,139	0,129	0,057	0,036	0,103
15	0,147	0,136	0,130	0,070	0,027	0,102
16	0,150	0,140	0,132	0,060	0,047	0,106
17	0,150	0,138	0,127	0,050	0,033	0,099
18	0,145	0,138	0,129	0,071	0,052	0,107
19	0,146	0,139	0,128	0,058	0,050	0,104
20	0,150	0,139	0,132	0,047	0,051	0,104

Tab. č. 6: Výsledky ETS hodinového kroku

Z grafů (obr. č. 33 a č. 34) je patrné, že v tomto případě bylo dosaženo nejlepších výsledků pro srážkové úhrny od 0,2 mm. Závislosti na míře agregace jsou celkem vyrovnané, přičemž pouze v pro srážkový práh 0,2mm vychází jako nejlepší předpověď v rozlišení 1x1 bod. V ostatních případech se hodnota ETS pozvolna zvyšuje přibližně do hodnoty agregace 8 a poté začíná kolísat. V tabulce č. 6 jsou v posledním sloupci zobrazeny průměrné hodnoty ETS pro každou agregaci. Nejlepšího průměrného skóre (0,109) bylo dosaženo při agregaci 8x8 bodů, avšak nelze vyvodit jednoznačný závěr, jelikož výsledky jsou velice vyrovnané a bez jednoznačného trendu.



Obr. č. 35: ETS 48h sumarizací předpovědi pro agregaci 1 – 20 v závislosti na definovaném srážkovém práhu

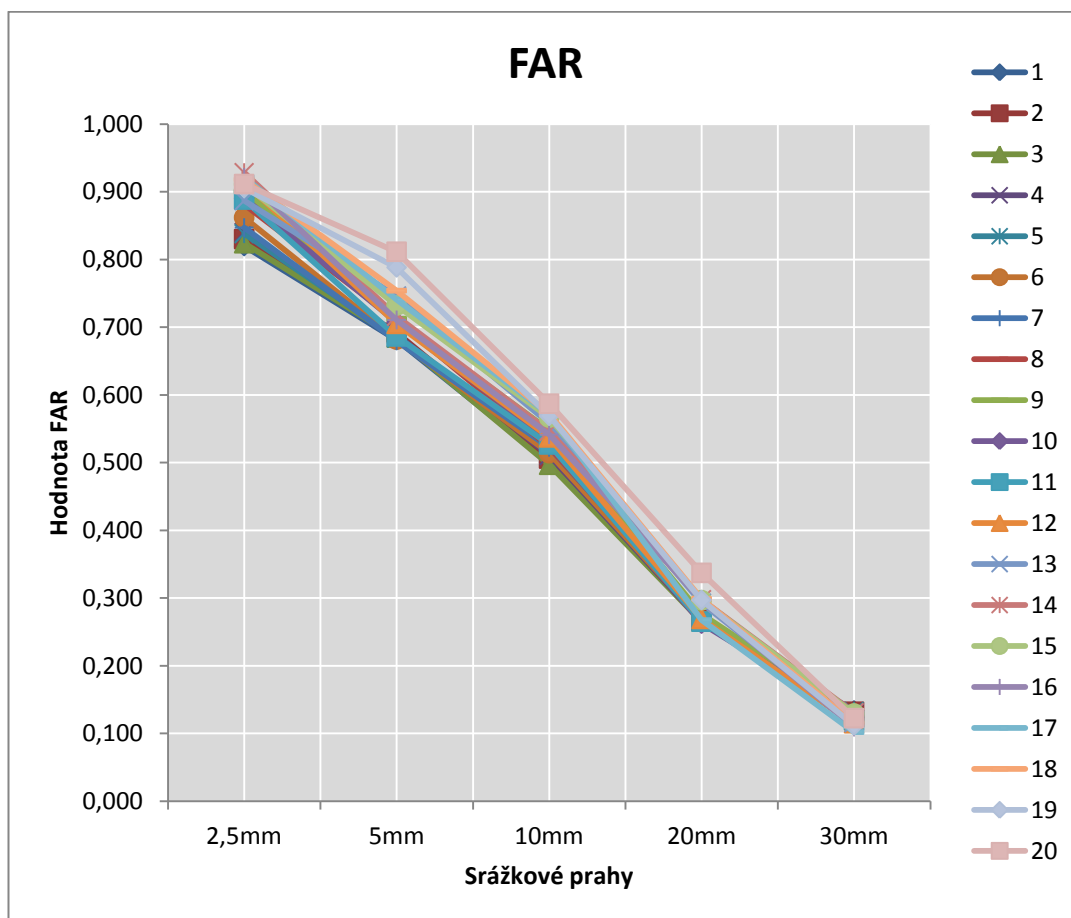


Obr. č. 36: ETS 48h sumarizací. Zobrazení závislosti hodnoty ETS na velikosti agregace pro jednotlivé srážkové prahy

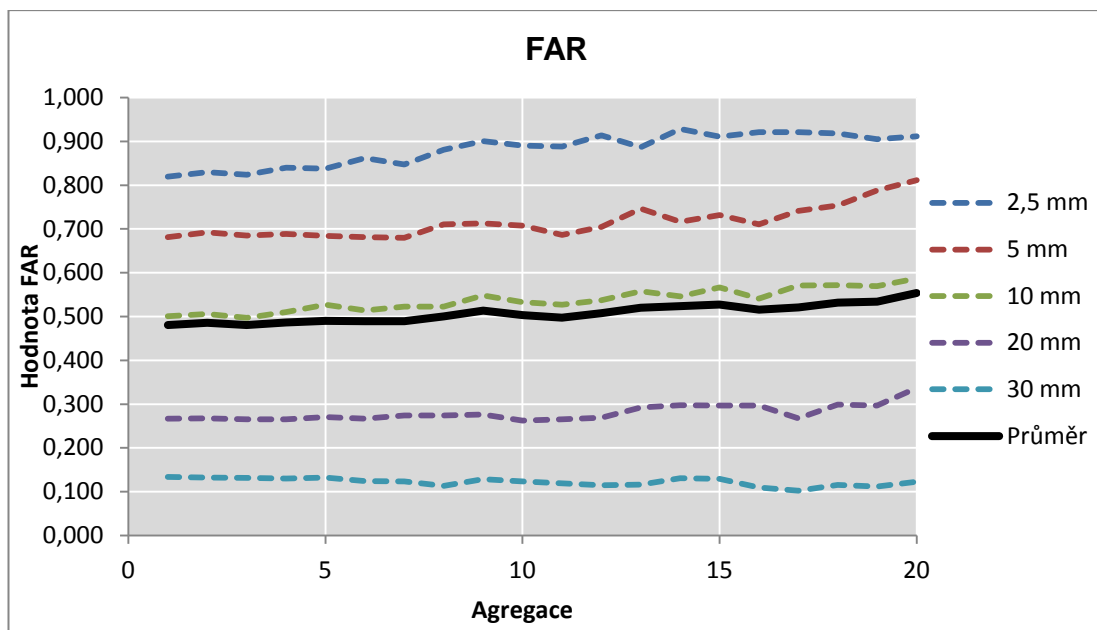
ETS 48h	5mm	10mm	20mm	30mm	50mm	$\Sigma/n$
1	0,157	0,229	0,189	0,164	0,096	0,167
2	0,147	0,226	0,229	0,167	0,094	0,173
3	0,137	0,222	0,230	0,162	0,087	0,168
4	0,142	0,221	0,234	0,163	0,089	0,170
5	0,147	0,210	0,230	0,165	0,090	0,168
6	0,143	0,213	0,232	0,170	0,094	0,170
7	0,144	0,212	0,243	0,164	0,097	0,172
8	0,128	0,226	0,238	0,168	0,072	0,166
9	0,129	0,206	0,254	0,154	0,081	0,165
10	0,134	0,222	0,246	0,179	0,085	0,173
11	0,152	0,222	0,243	0,170	0,086	<b>0,175</b>
12	0,128	0,214	0,257	0,170	0,065	0,167
13	0,079	0,185	0,235	0,161	0,073	0,146
14	0,116	0,209	0,219	0,150	0,066	0,152
15	0,103	0,184	0,239	0,162	0,046	0,147
16	0,136	0,214	0,267	0,202	0,027	0,169
17	0,096	0,195	0,267	0,146	0,015	0,144
18	0,083	0,184	0,243	0,154	0,020	0,137
19	0,058	0,190	0,229	0,152	0,025	0,131
20	0,040	0,189	0,216	0,166	0,056	0,133

Tab. č. 7: Výsledky ETS 48h sumarizací

ETS skóre 48h sumarizací dosahuje nejlepších výsledků pro srážkový práh 20mm. Rozptyl výsledných hodnot pro jednotlivé srážkové prahy je širší než v případě 1h kroku a viditelně horších výsledků dosahují hodnoty agregací blížících se rozlišení 20x20 bodů. Na obě strany od prahu 20 mm úspěšnost předpovědi klesá. Zajímavostí je, že úspěšnost předpovědi pro srážkový práh 50 mm roste směrem od největší agregace po nejmenší, přičemž nejvyšších hodnot je dosaženo při agregaci 1 a 7. V celkovém průměru hodnot vykazuje nejlepší výsledky agregace 11 bodů (stejně rozlišení jako průměr současných polygonů) s hodnotou 0,175. Tomuto výsledku se přibližují agregace 10, 7 a 2. Celkově lepších výsledků dosahují agregace od 1 do 12, od vyšší agregace nastává citelný pokles hodnot ETS. Z obrázku č. 36 je patrné, že s rostoucí agregací roste i rozkolísanost úspěšnosti předpovědi a střídání vyšších kladných a záporných odchylek. Z těchto důvodů lze přisoudit menší váhu úspěšnosti hodnotě 0,169 pro agregaci 16, než hodnotě 0,168 agregace 5, jelikož okolní hodnoty agregace 16 jsou výrazněji nižší.



Obr. č. 37: FAR pro agregace 1-20 a definované srážkové prahy




Obr. č. 38: Závislost FAR na agregaci pro jednotlivé srážkové prahy


FAR	2,5mm	5mm	10mm	20mm	30mm	$\Sigma/n$
1	0,820	0,681	0,501	0,267	0,134	0,4806
2	0,830	0,692	0,506	0,267	0,132	0,4855
3	0,824	0,685	0,497	0,265	0,132	<b>0,4804</b>
4	0,840	0,689	0,510	0,265	0,130	0,4868
5	0,838	0,684	0,527	0,271	0,133	0,4905
6	0,862	0,682	0,514	0,267	0,124	0,4897
7	0,847	0,680	0,523	0,274	0,123	0,4893
8	0,881	0,710	0,523	0,274	0,113	0,5004
9	0,901	0,713	0,548	0,276	0,129	0,5132
10	0,891	0,707	0,533	0,262	0,124	0,5034
11	0,888	0,686	0,527	0,265	0,119	0,4972
12	0,914	0,705	0,537	0,269	0,115	0,5080
13	0,887	0,746	0,558	0,293	0,116	0,5198
14	0,928	0,716	0,546	0,298	0,131	0,5238
15	0,911	0,732	0,566	0,297	0,129	0,5272
16	0,921	0,711	0,541	0,297	0,109	0,5159
17	0,921	0,741	0,571	0,267	0,102	0,5205
18	0,918	0,754	0,572	0,299	0,116	0,5317
19	0,905	0,788	0,569	0,297	0,112	0,5343
20	0,911	0,811	0,587	0,337	0,123	0,5539

Tab. č. 8: Hodnoty FAR pro jednotlivé agregace a srážkové meze

FAR určuje pravděpodobnost falešného poplachu (false alarm). Z toho vyplývá, že čím jsou hodnoty nižší, tím je menší pravděpodobnost, že model chybně předpoví srážky, které se nevyskytnou. V případě FAR jsou výsledky rovnoměrné, bez větších odchylek. Z grafů i tabulky je zřejmé, že lepších výsledků bylo dosaženo v agregacích 1-7, poté hodnoty FAR rostou strměji. Nejlepší průměrná hodnota FAR (0,4804) náleží agregaci o rozlišení 3x3 bodu. Na rozdíl od ETS, s rostoucím srážkovým prahem se zlepšují také výsledky FAR. To znamená, že v předpovědi srážek 30 mm a více bylo ve vztahu k správným předpovědím nejméně falešných alarmů. Zároveň hodnoty FAR pro 30 mm jsou velmi vyrovnané pro všechny agregace.



Obr. č. 39: POD pro agregace 1-20 a definované srážkové prahy



Obr. č. 40: Závislost POD na agregaci pro jednotlivé srážkové prahy


POD	2,5mm	5mm	10mm	20mm	30mm	$\Sigma/n$
1	0,970	0,952	0,879	0,660	0,489	0,7899
2	0,971	0,954	0,882	0,661	0,492	0,7920
3	0,971	0,954	0,882	0,668	0,485	0,7921
4	0,972	0,958	0,888	0,663	0,469	0,7901
5	0,976	0,960	0,892	0,676	0,487	0,7982
6	0,973	0,961	0,894	0,671	0,472	0,7943
7	0,972	0,961	0,904	0,681	0,468	0,7974
8	0,972	0,964	0,907	0,668	0,430	0,7883
9	0,979	0,971	0,917	0,697	0,438	<b>0,8005</b>
10	0,979	0,968	0,914	0,676	0,446	0,7964
11	0,980	0,970	0,917	0,681	0,480	0,8057
12	0,983	0,966	0,924	0,713	0,403	0,7978
13	0,983	0,967	0,917	0,703	0,404	0,7948
14	0,988	0,969	0,914	0,671	0,360	0,7803
15	0,980	0,972	0,917	0,692	0,425	0,7972
16	0,979	0,972	0,925	0,723	0,405	0,8006
17	0,980	0,972	0,925	0,719	0,331	0,7854
18	0,985	0,972	0,939	0,701	0,388	0,7970
19	0,983	0,981	0,930	0,668	0,394	0,7912
20	0,986	0,976	0,933	0,718	0,388	0,8001

Tab. č. 9: Hodnoty FAR pro jednotlivé agregace a srážkové meze



POD své hodnocení zaměřuje na správně předpovídané události. Pro hodnocení bylo opět vybráno 5 srážkových prahů. Stejně jak v případě FAR mají lepší hodnocení předpovědi nižších srážkových úhrnů. To by například znamenalo, že čím je menší míra agregace, tím je více správně předpovídaných úhrnů nad 30 mm. Větší nejistota nastává u prahů 20 mm a 30mm přibližně od agregace 11, kde hodnoty POD v porovnání s ostatními liniemi zřetelně kolísají. V průměru bylo nejlepšího skóre POD dosaženo v agregaci 9, avšak opět nikterak jednoznačným rozdílem.

V posledním obrázku č. 41 jsou vyobrazeny ROC křivky, popisující závislost POD na F. Prostor v grafu pod každou křivkou představuje hodnotu skóre, tudíž max. dosažitelná hodnota je 1. V tomto případě všechny agregace vykazují podobné výsledky. Okem lze odhadnout, že nejlepších hodnot dosahují agregace 12, 11, 10 a 17. Naopak jako nejhorší se jeví agregace 18, 19 a 20.



Obr. č. 41: ROC křivka

## 4. Diskuze

Cílem práce bylo odhadnout co nejvhodnější rozlišení pro vstupní srážkové oblasti do hydrologických modelů. V rámci rozsahu diplomové práce byla zpracována a upravena data a následně verifikována několika metodami používanými pro srážkové předpovědi. Verifikace byla provedena postupně pro rozlišení 1x1 bod až 20x20 bodů (1 bod = 4,8x4,8km), v některých případech (korelace a RMSE) i více (až 60x60 bodů). Jelikož současné vstupní oblasti nemají pravidelný tvar (oproti verifikovaným agregovaným plochám ve tvaru čtverce), je třeba k výsledkům přistupovat jako k vodítkům pro další výpočty, nikoliv jako k podkladům pro stanovení konkrétních závěrů. Srážkové předpovědi byly průměrovány pro jednotlivé oblasti agregací (stejným způsobem jsou upravovány srážky vstupující do hydrologických modelů) a tyto oblasti byly pro výpočet převáděny zpět do původního rozlišení (1x1bod) s ponecháním zprůměrovaných hodnot pro agregace. Z výsledků plyne, že maximální zvolená velikost agregace 20x20 bodů byla dostatečná, jelikož výsledky pro agregace blíží se 20 jsou již neuspokojivé. Také vzhledem k současné velikosti vstupních oblastí nemá smysl zkoumat takto velké oblasti, jde spíše o zjištění odhadu trendu pro tyto větší plochy.

Výsledky korelace a RMSE, které byly získány obyčejnou i klouzavou agregací, hodnotí současné velikosti vstupních oblastí jako vyhovující. Ostatní kritéria nevykazují jednoznačnou tendenci zhoršování přesnosti předpovědi od určité velikosti agregace. Přesto však lze říci, že v rozmezí agregace 1 – 12 převažují lepší skóre, v porovnání s vyššími agregacemi. Tento fakt je motivací pro hlubší zkoumání. Také z výsledků FAR je možné vypozařovat menší míru chybování předpovědi při menší agregaci. Dále například ETS (48h) a POD hodnotí kvalitněji předpověď vyšších úhrnů při agregaci v rozmezí 5-7 bodů, přičemž právě předpověď vyšších úhrnů je pro hydrologické modely velice důležitou vstupní informací. Pro výpočet ETS by bylo vhodné použít ještě jiný způsob výpočtu v programu R, respektive použít sumarizace rastrových hodnot již ve výpočtu ETS. Tím by bylo zřejmě dosaženo vyšších hodnot ETS, avšak trend změny ETS v závislosti na srážkových prazích by byl velice podobný. V práci bylo spočítáno ETS pro každou vrstvu zvlášť a poté průměrováno a například tvar křivky pro 48h sumy je velice

podobný grafu ETS pro dlouhodobé sumy ALADINa prezentovaný A. Trojákovou na školení ČHMÚ 11/2007 (Trojáková, 2007).

Zajímavé je srovnání výsledků obyčejné a klouzavé agregace v případě korelace a RMSE. Klouzavá agregace vykazuje výsledky bez větších výkyvů a bylo by jistě vhodné provést výpočty ostatních verifikačních skóre i pro ni. Tyto výpočty jsou časově náročné, a proto nebyly zařazeny do této práce.

Pro zpřesnění výsledků by bylo vhodné analyzovat více srážkových epizod. V jejich jednotlivém hodnocení jsou značné rozdíly. Například hodnoty ETS šesté události (18. 9. 2013) pro 10 mm se pohybují okolo 0,5, naproti tomu druhá událost (2. 6. 2013) dosahuje pro stejný srážkový práh hodnot kolem nuly.

Pro návrh změny velikosti některého ze vstupních polygonů je nutná analýza širšího spektra vlivů na úhrny srážek. Hlavní vliv náleží kvalitě předpovědi a dalšími činiteli, kteří mohou ovlivnit velikost vstupních oblastí, může být například podrobnější orografie nebo prozkoumání vlivu návětrných svahů vzhledem ke směru větru při obvyklých srážkových situacích. Tyto a další faktory je třeba vyhodnotit pro každou vstupní oblast jednotlivě.

## 5. Závěr

Výsledky dosažené v této práci mohou sloužit jako podklad pro disertační práci. Vzhledem k obsáhlosti tohoto tématu je mimo rozsah DP stanovení jednoznačných výsledků, přesto byl naznačen směr, jakým by se měli ubírat další statistiky prostorové závislosti srážkových předpovědí.

Z doposavadních výsledků lze předpokládat, že existují možnosti zmenšení vstupních ploch za účelem zpřesnění vstupní předpovědi. Zároveň současné velikosti vstupních oblastí se řadí do kategorie lepších výsledků. Pro konkretizaci možných změn velikostí ploch je třeba zvolit individuální přístup k jednotlivým polygonům.

Práce byla vypracována ve spolupráci s ČHMÚ, kde je nyní také předmětem zkoumání možnost změn velikosti vstupních oblastí použitím modelových metod. Perspektivou této práce je využití pro ověření modelových výsledků ČHMÚ.

Práce mi byla přínosem díky rozšíření znalostí v oblasti verifikace srážek a zpracování dat v programu R. Bohužel pro podrobnější analýzu nebyl čas a prostor, proto bych se chtěl tomuto tématu věnovat i v budoucnu, například v disertační práci.

## 6. Literatura

**Casati, B., (2009):** Verification of continuous predictands, [online]: [http://www.swpc.noaa.gov/forecast\\_verification/](http://www.swpc.noaa.gov/forecast_verification/) , cit. : 3. 3. 2014

**CAWCR (The Centre for Australian Weather and Climate Research), (2013):** Forecast Verification: Issues, Methods and FAQ, [online]: [http://www.cawcr.gov.au/projects/verification/#Types\\_of\\_forecasts\\_and\\_verifications](http://www.cawcr.gov.au/projects/verification/#Types_of_forecasts_and_verifications), cit.: 21. 2. 2014

**ČHMÚ, (2007) :** Průvodce informacemi pro odbornou vodohospodářskou veřejnost, Závěrečná zpráva, ČHMÚ, Praha, 45 s.,

**Daňhelka, J., (2007):** Operativní hydrologie: Hydrologické modely a nejistota předpovědí, Sborník prací ČHMÚ, 51, Praha

**Ebert, E., E., (2008):** Fuzzy verification of high-resolution gridded forecasts: a review and proposed framework, Meteorological Applications 15, str. 51-54, Royal Meteorological Society, Austrálie

**Hijman, J., R., (2014) :** Introduction to the ‚raster‘ package (version 2.2-31), 27 s.

**Hrádek, F., Kuřík, P., (2008):** Hydrologie, ČZU, Praha, 280 s.

**Janoušek, M., (2004) :** ALADIN@chmu, ČHMÚ, [online] : <http://old.chmi.cz/meteo/ov/aladin/index.php>, cit.: 8. 3. 2014

**Jeníček, M., (2005) :** Možnosti využití srážko-odtokových modelů na malých a středně velkých povodích, In Langhammer, J. (ed.): Vliv změn přírodního prostředí povodí a údolní nivy na povodňové riziko. PřF UK, Praha. s. 112-126

**Jolliffe, I., T., Stephenson, D., B., (2003) :** Forecast Verification, A Practitioner's Guide in Atmospheric Science, John Wiley & Sons Ltd, England

**Kolektiv, (1993) :** Meteorologický slovník výkladový a terminologický, Academia, Praha

**Kulhavý, Z., Kovář, P., (2000) :** Využití modelů hydrologické bilance pro malá povodí, VÚMOP, Praha, 123 s.

**Máca, P., (2007)** : Hydrologie pro bakaláře, Přednáška 5, ČZU, Praha, [online] : [http://petr.kvhem.cz/Hydrologie\\_bak/lec/h1\\_lec\\_5\\_h.pdf](http://petr.kvhem.cz/Hydrologie_bak/lec/h1_lec_5_h.pdf) , cit. 10. 2. 2014

**Máca, P., (2010)** : Jednotkový hydrogram, ČZU, VÚV, Praha, 104s.

**Maskey et al., (2004)** : Treatment of precipitation uncertainty in rainfall-runoff modelling: a fuzzy set approach, *Advances in water Resources* 27, s. 889-898

**Murphy, A., H., Brown, G., B., Chen, Y., (1989)**: Diagnostic Verification of Temperature Forecast, *Weather and Forecasting*, Volume 4, str. 485-501, Oregon

**National Centre for Meteorological Research (NCMR)** : ALADIN, [online]: <http://www.cnrm.meteo.fr/aladin/> , cit.: 13. 3. 2014

**Novak, P., (2005)** : The Czech Hydrometeorological Institute's severe storm nowcasting system, *Atmospheric Research* 83, s. 450-457, CHMI, Praha

**Rezacova et al., (2007)** : A radar-based verification of precipitation forecast for local convective storm, *Atmospheric Research* 83, s. 211-224, ÚFA, Praha

**Rezacova et al., (2009)**: Uncertainty in the area-related QPF for heavy convective precipitation, *Atmospheric Research* 93, s. 238-246, ÚFA, Praha

**Řezáčová et al., (2007)** : Fyzika oblaků a srážek, Academia, Praha, 576 s.

**Sokol, Z., (2005)** : Nowcasting of 1-h precipitation using radar and NWP data, *Journal of Hydrology* (2006) 328, ÚFA AV ČR, Praha, s. 200-211

**Sokol, Z., Řezáčová, D., (1998)** : Lokální předpověď srážek pomocí statistického zpracování výstupů numerických předpovědních modelů – statistický „postprocessing“, *Meteorologické Zprávy* 4, 51, ÚFA AV ČR, Praha

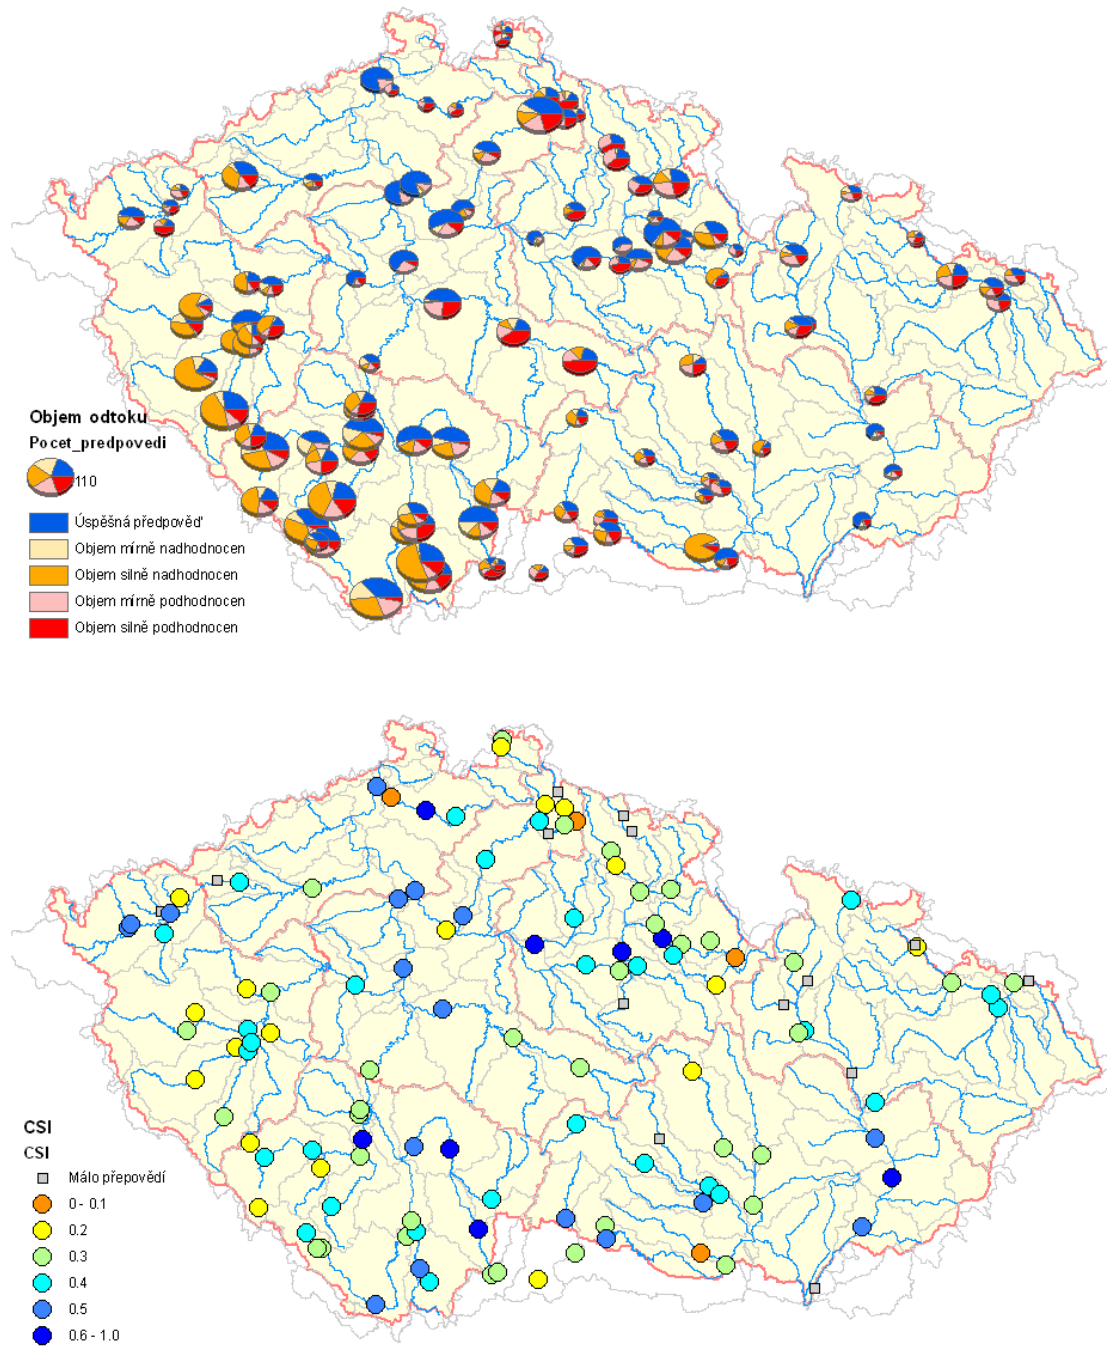
**Steinhart, M., (2010)** : Aplikace srážko-odtokového modelu Boussmo, Diplomová práce, ČZU, Praha, nep.

**Stephenson, D., B., (2002)** : Classification scheme for forecast, [online]: <http://www.cawcr.gov.au/projects/verification/forecast-types.pdf>, cit. 20. 2. 2014-02-20

**Sui, D., Z., Maggio, R., C., (1999) :** Integrating GIS with hydrological modeling: practices, problems, and prospects, Computers, Environment and Urban Systems, 23, s. 33-51

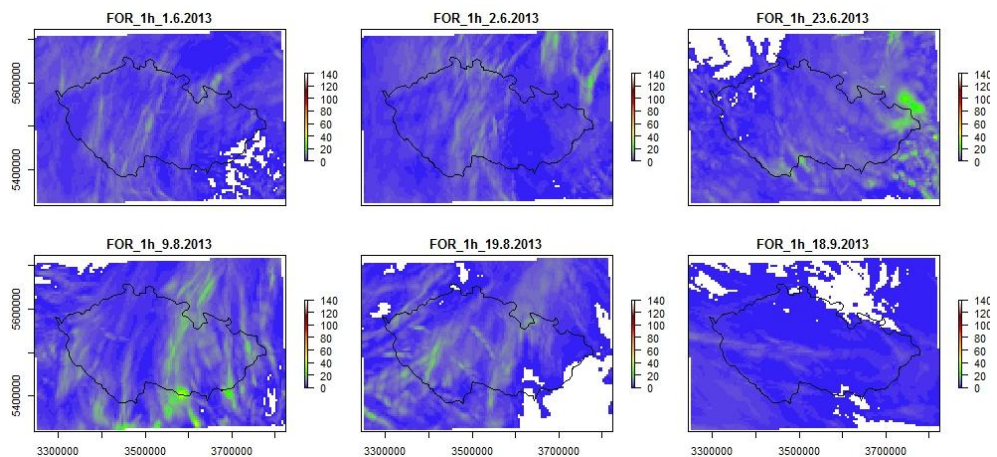
**Trojáková, A., (2007) :** Analýza zemského povrchu, ČHMÚ [online]: [http://portal.chmi.cz/files/portal/docs/meteo/ov/skolnwp/L10\\_asimilace\\_3.pdf](http://portal.chmi.cz/files/portal/docs/meteo/ov/skolnwp/L10_asimilace_3.pdf) , cit. 22. 4. 2014

## 8. Přílohy

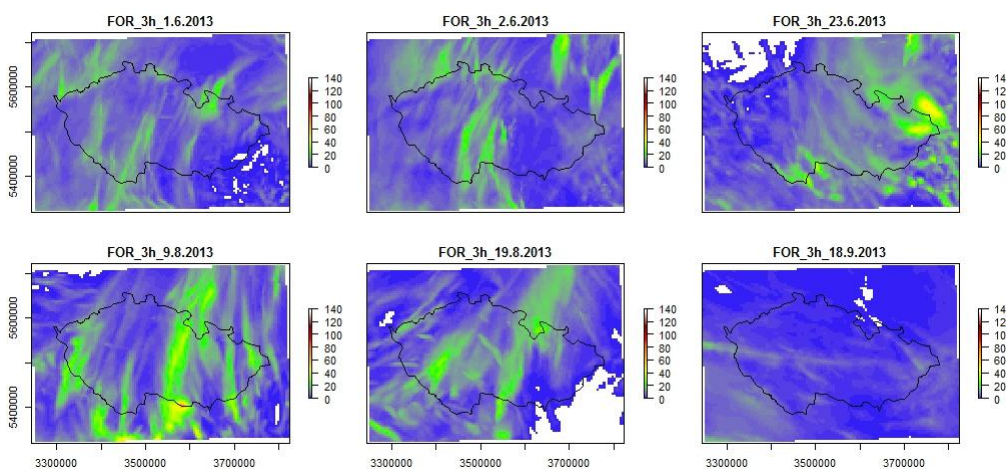


*Příloha č. 1: Úspěšnost předpovědi hydrologických modelů. Může sloužit k určení problematických vstupních srážkových oblastí*

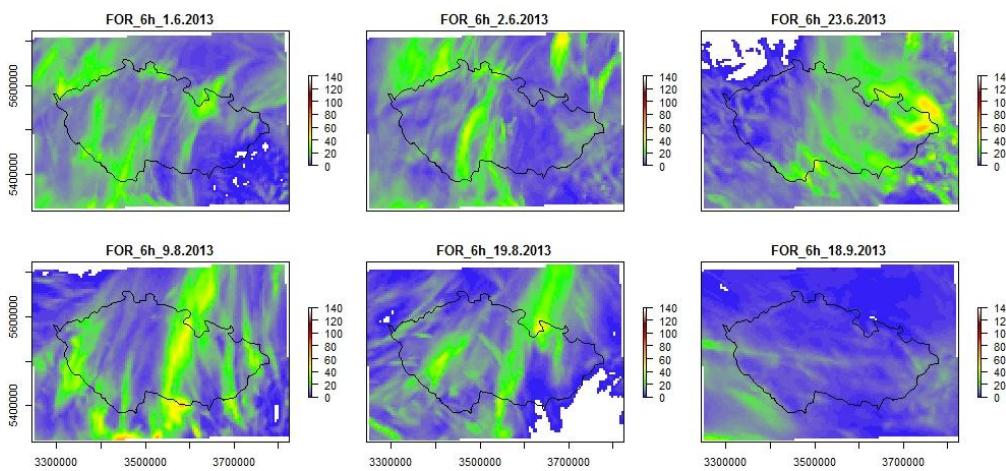




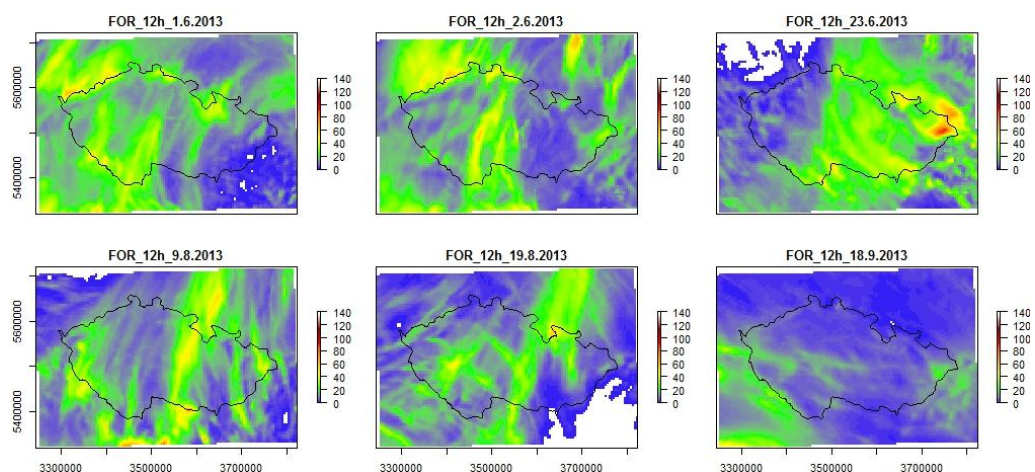
*Příloha č.2: 1h maximální předpovědi pro jednotlivé události*



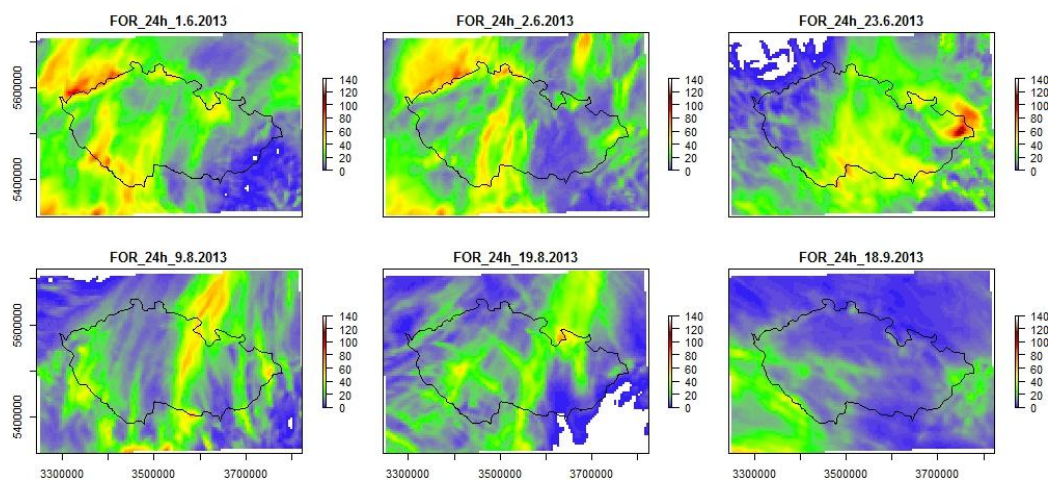
*Příloha č. 3: 3h maximální predikovaná suma srážek pro jednotlivé události*



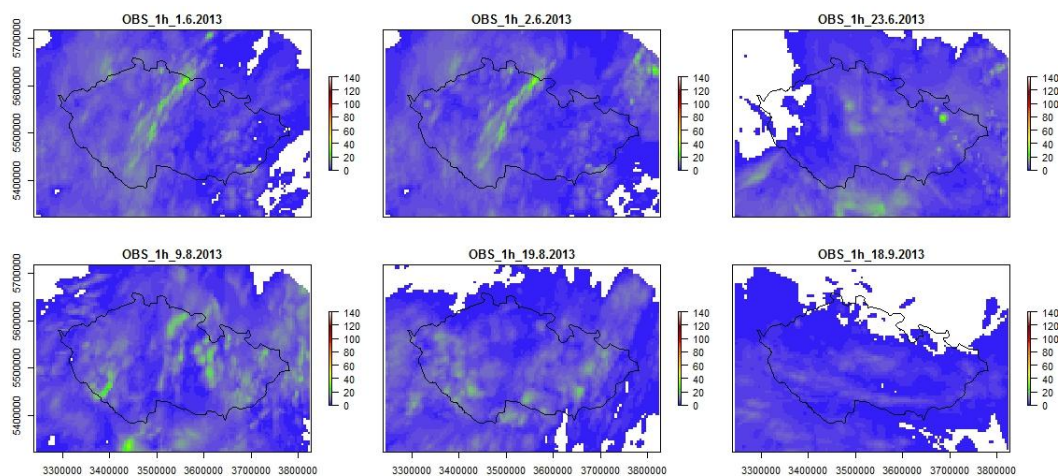
*Příloha č. 4: 6h maximální predikovaná suma srážek pro jednotlivé události*



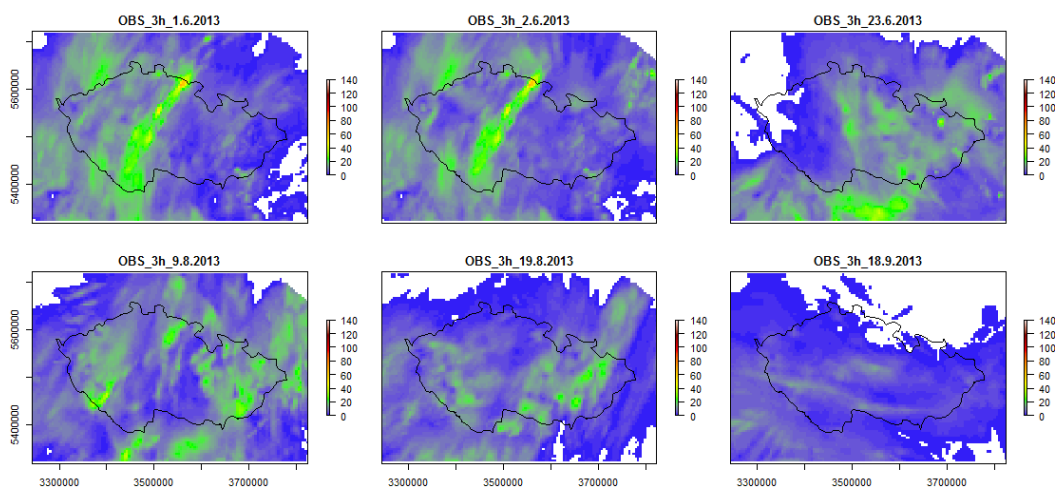
*Příloha č.5: 12h maximální predikovaná suma srážek pro jednotlivé události*



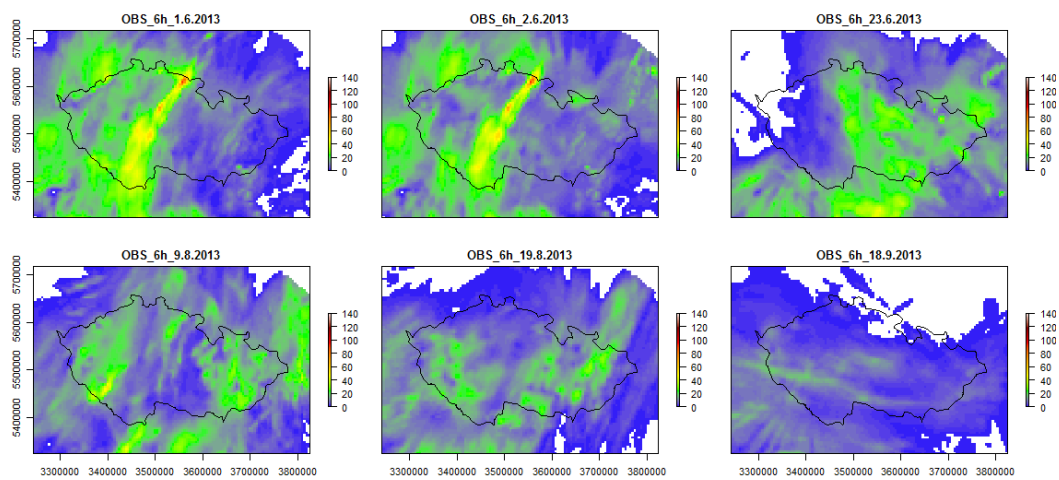
*Příloha č. 6: 24h maximální predikovaná suma srážek pro jednotlivé události*



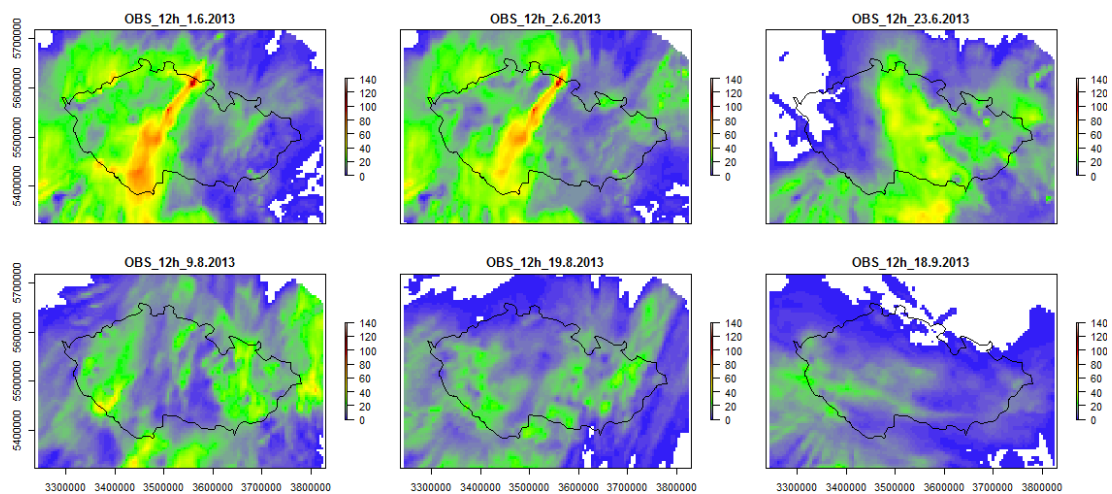
*Příloha č. 7: 1h maximální měřené srážky pro jednotlivé události*



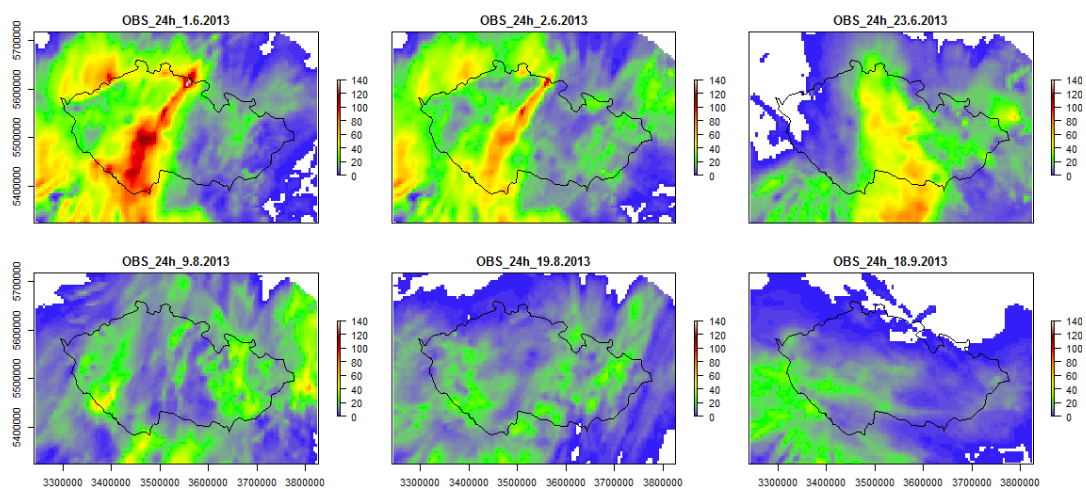
*Příloha č. 8: 3h maximální měřená suma srážek pro jednotlivé události*




*Příloha č. 9: 6h maximální měřená suma srážek pro jednotlivé události*




*Příloha č. 10: 12h maximální měřená suma srážek pro jednotlivé události*




*Příloha č. 11: 24h maximální měřená suma srážek pro jednotlivé události*




Příloha č. 12: Hyetogramy **predikovaných** srážek v jednotlivých polygonech povodí Labe a Ohře




Příloha č.13: Hyetogramy **měřených** srážek v jednotlivých polygonech povodí Labe a Ohře




Příloha č. 14: Hyetogramy **predikovaných** srážek v jednotlivých polygonech povodí Moravy



Příloha č. 15: Hyetogramy **měřených** srážek v jednotlivých polygonech povodí Moravy



Příloha č. 16: Hyetogramy **predikovaných** srážek v jednotlivých polygonech povodí Odry



Příloha č. 17: Hyetogramy **měřených** srážek v jednotlivých polygonech povodí Odry

F	2,5mm	5mm	10mm	20mm	30mm	Σ/n
1	0,820	0,681	0,501	0,267	0,134	0,481
2	0,830	0,692	0,506	0,267	0,132	0,486
3	0,824	0,685	0,497	0,265	0,132	<b>0,480</b>
4	0,840	0,689	0,510	0,265	0,130	0,487
5	0,838	0,684	0,527	0,271	0,133	0,490
6	0,862	0,682	0,514	0,267	0,124	0,490
7	0,847	0,680	0,523	0,274	0,123	0,489
8	0,881	0,710	0,523	0,274	0,113	0,500
9	0,901	0,713	0,548	0,276	0,129	0,513
10	0,891	0,707	0,533	0,262	0,124	0,503
11	0,888	0,686	0,527	0,265	0,119	0,497
12	0,914	0,705	0,537	0,269	0,115	0,508
13	0,887	0,746	0,558	0,293	0,116	0,520
14	0,928	0,716	0,546	0,298	0,131	0,524
15	0,911	0,732	0,566	0,297	0,129	0,527
16	0,921	0,711	0,541	0,297	0,109	0,516
17	0,921	0,741	0,571	0,267	0,102	0,520
18	0,918	0,754	0,572	0,299	0,116	0,532
19	0,905	0,788	0,569	0,297	0,112	0,534
20	0,911	0,811	0,587	0,337	0,123	0,554

*Príloha č. 18: Tabuľka výsledků False Alarm Rate. Nejlepší skóre náleží agregaci 3.*

## **Skripty pro zpracování rastrových dat a výpočty verifikačních skóre**

```
require(ggplot2)
require(data.table)
require(raster)
require(sp)
require(maptools)
require(scales)
require(lubridate)
require(zoo)
require(rasterVis)
require(rgl)
```

```
ID = names(p)
dID = data.table(ID)
dID[, BASE:=ymd(substr(gsub("\\.','-'," , ID)), 1, 10))]
dID[, LEAD:=as.integer(substr(gsub("\\.','-'," , ID)), 12, 13))]
d = readRDS('key.rds')
```



```

setkey(d, BASE, LEAD)
setkey(dID, BASE, LEAD)
d = d[dID]

# vypocty pro kazdou vrstvu
mB = overlay(B, fun = function(x) x^2)

# vypocty napric vrstvami
mxB = calc(B, max)
wmxB = calc(B, which.max)

# nebo
mxB = max(B)
plot(mxB, addfun = function()plot(cr, add=TRUE))

#### pocitej napric vrstvami pro udalosti #####ALADIN#####
#casove rozlozeni srazek
mmB = stackApply(p, fun = function(x, ...)if(all(is.na(x)))(0)else(which.max(x)), indices= d[, factor(BASE)],
na.rm=TRUE)
names(mmB)=c("FOR_time_1.6.2013", "FOR_time_2.6.2013", "FOR_time_23.6.2013", "FOR_time_9.8.2013", "F
OR_time_19.8.2013", "FOR_time_18.9.2013")
plot(mmB, col = terrain.colors(nb), zlim=c(0,54), colNA = 'white', bty = 'n', addfun =
function()plot(cr, add=TRUE))

#Prevedeni souřadnicového sztemu
spTrans=function(spobj, from=NA, to='wgs'){

require(rgdal)
# require(raster)

if ((is.na(spobj@proj4string@projargs)) & (is.na(from))) stop("No proj4string and no "from" argument defined
for spobject.")

switch (from,
'wgs' = {spobj@proj4string = CRS('+proj=longlat +ellps=WGS84 +datum=WGS84 +no_defs') },
'krov' = {spobj@proj4string = CRS('+proj=krovak +lat_0=49.5 +lon_0=24.83333333333333 +alpha=0
+k=0.9999 +x_0=0 +y_0=0 +ellps=bessel +units=m +no_defs') },
's42' = {spobj@proj4string = CRS('+proj=tmerc +lat_0=0 +lon_0=15 +k=1 +x_0=3500000 +y_0=0
+ellps=krass +units=m +no_defs')} # +init = epsg:28403)

switch (to, 'wgs' = {crs = CRS('+proj=longlat +ellps=WGS84 +datum=WGS84 +no_defs') },
'krov' = {crs = CRS('+proj=krovak +lat_0=49.5 +lon_0=24.83333333333333 +alpha=0 +k=0.9999
+x_0=0 +y_0=0 +ellps=bessel +units=m +no_defs') },
's42' = {crs = CRS('+proj=tmerc +lat_0=0 +lon_0=15 +k=1 +x_0=3500000 +y_0=0 +ellps=krass
+units=m +no_defs')})

```

```

)

#     res = if (class(sproj) == 'SpatialGridDataFrame') (
#         projectRaster(raster(sproj), crs=crs, res=attr(sproj@grid, 'cells.dim'))
#     ) else (
#         spTransform(sproj,crs)
#     )

return(spTransform(sproj,crs))

}

cr = readShapePoly('cr0')
cr = spTrans(cr, from = 'wgs', to = 's42')
vp = readShapePoly('vstupol_all')
vp = spTrans(vp, from = 'krov', to = 's42')

#1h max
mmb=stackApply(p, fun = function(x, ...)max(rollsum(x, 1), na.rm=TRUE), indices= d[, factor(BASE)])
names(mmb)=c("FOR_1h_1.6.2013","FOR_1h_2.6.2013","FOR_1h_23.6.2013","FOR_1h_9.8.2013","FOR_1h_
19.8.2013","FOR_1h_18.9.2013")
plot(mmb, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

# 3h max
mmB3 = stackApply(B, fun = function(x, ...)max(rollsum(x, 3), na.rm=TRUE), indices= d[, factor(BASE)])
names(mmB3)=c("FOR_3h_1.6.2013","FOR_3h_2.6.2013","FOR_3h_23.6.2013","FOR_3h_9.8.2013","FOR_3
h_19.8.2013","FOR_3h_18.9.2013")
plot(mmB3, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#6h max
mmB6 = stackApply(B, fun = function(x, ...)max(rollsum(x, 6), na.rm=TRUE), indices= d[, factor(BASE)])
names(mmB6)=c("FOR_6h_1.6.2013","FOR_6h_2.6.2013","FOR_6h_23.6.2013","FOR_6h_9.8.2013","FOR_6
h_19.8.2013","FOR_6h_18.9.2013")
plot(mmB6, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#12h max
mmB12 = stackApply(B, fun = function(x, ...)max(rollsum(x, 12), na.rm=TRUE), indices= d[, factor(BASE)])
names(mmB12)=c("FOR_12h_1.6.2013","FOR_12h_2.6.2013","FOR_12h_23.6.2013","FOR_12h_9.8.2013","F
OR_12h_19.8.2013","FOR_12h_18.9.2013")
plot(mmB12, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#24h max
mmB24 = stackApply(B, fun = function(x, ...)max(rollsum(x, 24),align='right', na.rm=TRUE), indices= d[,
factor(BASE)])

```

```

names(mmB24)=c("FOR_24h_1.6.2013","FOR_24h_2.6.2013","FOR_24h_23.6.2013","FOR_24h_9.8.2013","FOR_24h_19.8.2013","FOR_24h_18.9.2013")
plot(mmB24, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

mmBall = stackApply(p, fun = function(x, ...)sum(x), indices= d[, factor(BASE)])
names(mmBall)=c("FOR_1.6.2013","FOR_2.6.2013","FOR_23.6.2013","FOR_9.8.2013","FOR_19.8.2013","FOR_18.9.2013")
plot(mmBall, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#### vypocet napric vrstvami pro udalosti ####RADAROVA DATA#####
#casove rozlozeni srazek
mmo = stackApply(o, fun = function(x, ...)if(all(is.na(x)))(0)else(which.max(x)),align='right', indices= d[, factor(BASE)], na.rm=TRUE)
names(mmo)=c("OBS_time_1.6.2013","OBS_time_2.6.2013","OBS_time_23.6.2013","OBS_time_9.8.2013","OBS_time_19.8.2013","OBS_time_18.9.2013")
plot(mmo, col = terrain.colors(nb),zlim=c(0,54),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#1h max
mmo1=stackApply(o, fun = function(x, ...)max(x,na.rm=TRUE), indices= d[, factor(BASE)])
names(mmo1)=c("OBS_1h_1.6.2013","OBS_1h_2.6.2013","OBS_1h_23.6.2013","OBS_1h_9.8.2013","OBS_1h_19.8.2013","OBS_1h_18.9.2013")
plot(mmo1, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

# 3h max
mmo3 = stackApply(o, fun = function(x, ...)max(rollapply(x, 3, sum, na.rm=TRUE,align='right')), indices= d[, factor(BASE)])
names(mmo3)=c("OBS_3h_1.6.2013","OBS_3h_2.6.2013","OBS_3h_23.6.2013","OBS_3h_9.8.2013","OBS_3h_19.8.2013","OBS_3h_18.9.2013")
plot(mmo3, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#6h max
mmo6 = stackApply(o, fun = function(x, ...)max(rollapply(x, 6, sum, align='right', na.rm=TRUE)),indices= d[, factor(BASE)])
names(mmo6)=c("OBS_6h_1.6.2013","OBS_6h_2.6.2013","OBS_6h_23.6.2013","OBS_6h_9.8.2013","OBS_6h_19.8.2013","OBS_6h_18.9.2013")
plot(mmo6, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#12h max
mmo12 = stackApply(o, fun = function(x, ...)max(rollapply(x, 12, sum,align='right', na.rm=TRUE )), indices= d[, factor(BASE)])
names(mmo12)=c("OBS_12h_1.6.2013","OBS_12h_2.6.2013","OBS_12h_23.6.2013","OBS_12h_9.8.2013","OBS_12h_19.8.2013","OBS_12h_18.9.2013")

```

```

plot(mmo12, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

#24h max
mmo24 = stackApply(o, fun = function(x, ...)max(rollapply(x, 24, sum,align='right', na.rm=TRUE)), indices= d[,
factor(BASE)])
names(mmo24)=c("OBS_24h_1.6.2013","OBS_24h_2.6.2013","OBS_24h_23.6.2013","OBS_24h_9.8.2013","O
BS_24h_19.8.2013","OBS_24h_18.9.2013")
plot(mmo24, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

mmoall = stackApply(o, fun = function(x, ...)sum(x,na.rm=TRUE),indices= d[, factor(BASE)])
names(mmoall)=c("OBS_1.6.2013","OBS_2.6.2013","OBS_23.6.2013","OBS_9.8.2013","OBS_19.8.2013","OB
S_18.9.2013")
plot(mmoall, col = col,zlim=c(0,140),colNA = 'white', bty = 'n',addfun = function()plot(cr,add=TRUE))

mmo5all = stackApply(o, fun = function(x, ...)sum(x,na.rm=TRUE),indices= dt5[, factor(variable)])
names(mmoall)=c("OBS_1.6.2013","OBS_2.6.2013","OBS_23.6.2013","OBS_9.8.2013","OBS_19.8.2013","OB
S_18.9.2013"
names(mmoall)=c("OBS_1.6.2013","OBS_2.6.2013","OBS_23.6.2013","OBS_9.8.2013","OBS_19.8.2013","OB
S_18.9.2013"

#nastaveni barev
brks <- seq(0, 50, by=0.001)
nb <- length(brks)
cols=topo.colors(nb)

xr = range(values(mmBall), na.rm=TRUE)
rx = rescale(xr, to = c(0,1), from = c(0, 130))

#show_col(gradient_n_pal(c('white', 'red', 'orange'))(seq(rx[1], rx[2], length = 100)))
col = gradient_n_pal(c( 'blue','green','yellow','orange','red','darkred','white'))(seq(rx[1], rx[2], length = 130))
acol = alpha(col, alpha = seq(rx[1], rx[2], length = 120))

nB = overlay(mmBall, fun = function(x)ifelse(x<3,NA,x))

###EXTRAKCE DAT
require(lubridate)
# pro jeden layer
m = extract(B[[1]], rbd, fun = mean, na.rm=TRUE)
# pro jeden polygon
m = extract(B, rbd[1, ], fun = mean, na.rm=TRUE, df = TRUE)

m# pro cely brick
m = extract(B, rbd, fun = mean, na.rm=TRUE, df = TRUE)

```

```
dta = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m[, 2:ncol(m)]))
dta = data.table(melt(dta, id.vars=c('LEAD', 'BASE')))
```

```
#####
```

```
### GRAFICKA SUMARIZACE
```

```
require(ggplot2)
```

```
###Načtení polygonů povodí
```

```
pvl= readShapePoly('povodi_vltavy')
pvl = spTrans(pvl, from = 'krov', to = 's42')
```

```
pl= readShapePoly('povodi_labe_ohre')
pl = spTrans(pl, from = 'krov', to = 's42')
```

```
pm= readShapePoly('povodi_moravy')
pm = spTrans(pm, from = 'krov', to = 's42')
```

```
pod= readShapePoly('povodi_odry')
pod = spTrans(pod, from = 'krov', to = 's42')
```

```
# pro jeden layer
```

```
m = extract(B[[1]], rbd, fun = mean, na.rm=TRUE)
```

```
# pro cely brick - predpoved
```

```
#vltava
```

```
m1 = extract(B, pvl, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#labe
```

```
m2 = extract(B, pl, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#morava
```

```
m3 = extract(B, pm, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#odra
```

```
m4 = extract(B, pod, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#celé povodí
```

```
m5 = extract(p, vp, fun = mean, na.rm=TRUE, df = TRUE)
```

```
# pro cely brick - mereni
```

```
#vltava
```

```
o1 = extract(o, pvl, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#labe
```

```
o2 = extract(o, pl, fun = mean, na.rm=TRUE, df = TRUE)
```

```
#morava
```

```
o3 = extract(o, pm, fun = mean, na.rm=TRUE, df = TRUE)
```

```

#odra
o4 = extract(o, pod, fun = mean, na.rm=TRUE, df = TRUE)
#celé povodí
o5 = extract(o, vp, fun = mean, na.rm=TRUE, df = TRUE)

# pro jeden polygon
m = extract(B, rbd[1, ], fun = mean, na.rm=TRUE, df = TRUE)
# atributovaa tabulka
rbd@data

#datove tabulky - predpoved
require(reshape2)
dta1 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m1[, 2:ncol(m1)]))
dta1 = data.table(melt(dta1, id.vars=c('LEAD', 'BASE')))
dta1[,POVODI :=factor(variable, labels=c('m','h','n','j','l','o','q','p','k','i','e'))]

dta2 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m2[, 2:ncol(m2)]))
dta2 = data.table(melt(dta2, id.vars=c('LEAD', 'BASE')))
dta2[,POVODI :=factor(variable, labels=c('r','s','t','u','g','a','b','f','c'))]

dta3 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m3[, 2:ncol(m3)]))
dta3 = data.table(melt(dta3, id.vars=c('LEAD', 'BASE')))
dta3[,POVODI :=factor(variable, labels=c('d','N','G','O','T','P','J','K','H','M','L'))]

dta4 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m4[, 2:ncol(m4)]))
dta4 = data.table(melt(dta4, id.vars=c('LEAD', 'BASE')))
dta4[,POVODI :=factor(variable, labels=c('F','E','D','A','B','C'))]

dta5 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(m5[, 2:ncol(m5)]))
dta5 = data.table(melt(dta5, id.vars=c('LEAD', 'BASE')))
dta5[,POVODI :=factor(variable, labels=c('F','E','D','A','B','C'))]

#datove tabulky - mereni

dt1 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(o1[, 2:ncol(o1)]))
dt1 = data.table(melt(dt1, id.vars=c('LEAD', 'BASE')))
dt1[,POVODI :=factor(variable, labels=c('m','h','n','j','l','o','q','p','k','i','e'))]

dt2 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(o2[, 2:ncol(o2)]))
dt2 = data.table(melt(dt2, id.vars=c('LEAD', 'BASE')))
dt2[,POVODI :=factor(variable, labels=c('r','s','t','u','g','a','b','f','c'))]

dt3 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(o3[, 2:ncol(o3)]))

```

```

dt3 = data.table(melt(dt3, id.vars=c('LEAD', 'BASE')))
dt3[,POVODI :=factor(variable, labels=c('d','N','G','O','T','P','J','K','H','M','L'))]

dt4 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(o4[, 2:ncol(o4)]))
dt4 = data.table(melt(dt4, id.vars=c('LEAD', 'BASE')))
dt4[,POVODI :=factor(variable, labels=c('F','E','D','A','B','C'))]

dt5 = data.table(LEAD = d[, LEAD],BASE = d[, as.character(BASE)], t(o5[, 2:ncol(o5)]))
dt5 = data.table(melt(dt5, id.vars=c('LEAD', 'BASE')))
dt5[,POVODI :=factor(variable, labels=c('F','E','D','A','B','C'))]

#grafy pro predpoved
require(ggplot2)
ggplot(dt1) + geom_line(aes(x = LEAD, y = value, col = variable))

ggplot(dta4) + geom_line(aes(x = LEAD, y = value, col = variable)) + facet_grid(~BASE)

ggplot(dta4) + geom_line(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE)

ggplot(dta4) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3", "V4", "V5", "V6"),
                        labels=c("F", "E", "D", "A", "B", "C"))

ggplot(dta3) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3", "V4", "V5", "V6", "V7", "V8", "V9", "V10", "V11"),
                        labels=c('d','N','G','O','T','P','J','K','H','M','L'))

ggplot(dta2) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3", "V4", "V5", "V6", "V7", "V8", "V9"),
                        labels=c('r','s','t','u','g','a','b','f','c'))

ggplot(dta1) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3", "V4", "V5", "V6", "V7", "V8", "V9", "V10", "V11"),
                        labels=c('m','h','n','j','l','o','q','p','k','i','e'))

#grafy pro mereni

ggplot(dt4) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3", "V4", "V5", "V6"),

```

```

labels=c("F","E","D","A","B","C"))

ggplot(dt3) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3","V4","V5","V6","V7","V8","V9","V10","V11"),
                        labels=c('d','N','G','O','T','P','J','K','H','M','L'))

ggplot(dt2) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3","V4","V5","V6","V7","V8","V9"),
                        labels=c('r','s','t','u','g','a','b','f','c'))

ggplot(dt1) + geom_step(aes(x = LEAD, y = value, col = variable)) + facet_grid(variable~BASE) +
scale_colour_discrete(name="Polygony",
                        breaks=c("V1", "V2", "V3","V4","V5","V6","V7","V8","V9","V10","V11"),
                        labels=c('m','h','n','j','l','o','q','p','k','i','e'))

###KORELACE

o = brick('all_obs.grd')
p = brick('all_pre.grd')
p = mask(p,vp)
o = mask(o,vp)

#rozdiel predpoved - mereni
roz=mmBall-mmoall
names(roz)=
c("FOR_vs_OBS_1.6.2013","FOR_vs_OBS_2.6.2013","FOR_vs_OBS_23.6.2013","FOR_vs_OBS_9.8.2013","F
OR_vs_OBS_19.8.2013","FOR_vs_OBS_18.9.2013")
cl=gradient_n_pal(c('darkblue','blue','blue','blue','white','white','red','red','darkred'))(seq(rx[1], rx[2], length =
230))
plot(roz,col=cl, zlim=c(-130,100),addfun = function()plot(vp,add=TRUE))

plot(o[[10]]-p[[10]], colNA = 'white')
#odstranění NA vrstev
z = !is.na(o)
lna = function(x, ...) length(which(x==FALSE))
exclude = cellStats(z, stat = 'lna')>108
plot(z[[which(names(z)=='X2013.08.19.37')]])

d[, COMPLETE:=!exclude]

x = x[[which(!exclude)]]
y = y[[which(!exclude)]]
sum(x*y)

```



```

nlayers(x)
calc(x, sd)
calc(y, sd) # atp

# funkce pocitajici korelacni koeficient mezi dvema bricky
corBricks = function(x, y, exclude){
  x = x[[which(!exclude)]]
  y = y[[which(!exclude)]]
  (sum(x*y) - nlayers(x)*mean(x)*mean(y)) / ((nlayers(x)-1) * calc(x, sd) * calc(y, sd))
}

focalBrick = function(x, ...){
  R = list()
  for (i in 1: nlayers(x)){
    r = suppressWarnings( focal(x[[i]], ...) )
    R = c(R, list(r))
  }
  return(brick(R))
}

c = corBricks(o, p, exclude)

# zavislost korelace (nebo jineho krit) na prostorovem rozliseni
# agregace rasteru

p2 = aggregate(p, fact = 2)
rp10 = resample(p10, p, method = 'ngb')
cr10 = corBricks(rp10, o, exclude)
cellStats(cr10, stat=mean)

p11 = aggregate(p, fact = 11)
rp11 = resample(p11, p, method = 'ngb')
cr11 = corBricks(rp11, o, exclude)

# klouzave okno-

w1 = focalWeight(o, d = 10000, type = 'rectangle')
fo1 = focalBrick(o, w=w)
fp1 = focalBrick(p, w=w1)
cf1 = corBricks(o, fp1, exclude)
cellStats(cf1, stat=mean)

###RMSE
RMSE = function(x, y, exclude){
  x = x[[which(!exclude)]]

```

```

y = y[[which(!exclude)]]
(((sum(x-y))^2) / (nlayers(x)))^0.5
}

focalBrick = function(x, ...){
  R = list()
  for (i in 1: nlayers(x)){
    r = suppressWarnings( focal(x[[i]], ...) )
    R = c(R, list(r))
  }
  return(brick(R))
}

rmse = RMSE (o, p,exclude)
plot(rmse)

cellStats(rmse,stat=mean)

#resample RMSE (resample p rp* nacist z korelace)
rmser2=RMSE(o, rp2, exclude)
cellStats(rmser2,stat=mean)

#Klouzava agregace

w = focalWeight(o, d=3000, type = 'rectangle')
fp = focalBrick(p, w=w)
rmsef = RMSE(o, fp25,exclude)
cellStats(rmsef, stat=mean)

### ETS
#reklasifikace p (nastavení hranice pro srážky (5mm))
rh=c(-1,5,0, 5,150,1)
rclmat=matrix(rh,ncol=3, byrow=TRUE)
hp=reclassify(p,rclmat)
plot(hp)
hp

#reklasifikace o
hito=reclassify(o,rclmat)
plot(hito)

#určení počtu HITS, MISSES, FALSE ALARMS, CORRECT REJECTIONS a "YES" hodnot v "o" a "p"

hp=reclassify(p,rclmat)

```

```

hit=hp+hito
csh=cellStats(hit, function(x, ...) length(which(x==2))) # a = HITS

corr_rej=cellStats(hit,function(x, ...) length(which(x==0))) # d = CORRECT REJECTIONS
bc=cellStats(hit,function(x, ...) length(which(x==1)))

mf=hp-hito
csm=cellStats(mf, function(x, ...) length(which(x==(-1)))) # c = MISSES
csf=cellStats(mf, function(x, ...) length(which(x==1))) # b = FALSE ALARMS
csyp=cellStats(hp, function(x, ...) length(which(x==1))) # "YES" PREDICTION
csyo=cellStats(hito, function(x, ...) length(which(x==1))) # "YES" OBSERVATION
n= csh + csm + csf + corr_rej # total number of predictions (a+b+c+d)
ets=((csh)-((csyp*csyo)/(n)))/(csh+csm+csf-((csyp*csyo)/(n)))
mat1=matrix(ets)

# ETS pro 48h sumarizaci
p=mmBall
o=mmoall

### FAR a POD

#reklasifikace p (nastavení hranice pro srážky (2.5mm))
rh=c(-1,2.5,0, 2.5,150,1)
rclmat=matrix(rh,ncol=3, byrow=TRUE)
hp=reclassify(p,rclmat)
plot(hp)
hp

#reklasifikace o
hito=reclassify(o,rclmat)
plot(hito)

#určení počtu HITS, MISSES, FALSE ALARMS a "YES" hodnot v "o" a "p"
hp=reclassify(rp2,rclmat) #menit rp 1 - 20
hit=hp+hito
csh=cellStats(hit, function(x, ...) length(which(x==2))) # a = HITS
mf=hp-hito
csm=cellStats(mf, function(x, ...) length(which(x==(-1)))) # c = MISSES
csf=cellStats(mf, function(x, ...) length(which(x==1))) # b = FALSE ALARMS

far= csf/(csh+csf)
pod= csh/(csh+csm)

mat1=matrix(far)

```

```
View(mat1)
mat2=matrix(pod)
View(mat2)

### F
hp=reclassify(rp2, rclmat) #menit rp 1 - 20
hit=hp+hito
corr_rej=cellStats(hit,function(x, ...) length(which(x==0))) # d = CORRECT REJECTIONS
mf=hp-hito
csf=cellStats(mf, function(x, ...) length(which(x==1))) # b = FALSE ALARMS
f= csf/(corr_rej+csf)

mat1=matrix(f)
View(mat1)
```