

Disertační práce



Česká zemědělská univerzita v Praze

Fakulta životního  
prostředí

Katedra vodního hospodářství a environmentálního modelování

## Srážkové charakteristiky v pozorovaných datech a simulacích regionálních klimatických modelů

Characteristics of rainfall in observed data  
and regional climate model simulations

Vojtěch Svoboda

Školitel:

prof. Ing. Pavel Pech, CSc.

Školitelé–specialisté:

doc. Ing. Martin Hanel, Ph.D.

doc. Ing. Petr Máca, Ph.D.

Obor:

Environmentální modelování

Srpen 2016



## Poděkování

Na tomto místě bych rád poděkoval prof. Ing. Pavlu Pechovi, CSc., doc. Ing. Petru Mácovi, Ph.D. a doc. Ing. Martinu Hanelovi, Ph.D. za odborné vedení, rady a připomínky a především za podporu a možnost spolupráce při výzkumu a publikační činnosti. V neposlední řadě děkuji také svým rodičům za toleranci a veškerou podporu v průběhu doktorského studia.

## Prohlášení

Prohlašuji, že jsem předloženou disertační práci vypracoval samostatně na základě vlastního výzkumu pod odborným vedením a že jsem citoval veškerou odbornou literaturu a materiály, ze kterých bylo čerpáno.

V Praze, 1. srpna 2016

## Abstrakt

Vzhledem k pozorovaným změnám ve srážkových charakteristikách představují srážky v podobě intenzivních srážkových událostí vyšší potenciální nebezpečí a to nejen z hlediska výskytu bleskových povodní. Přestože informace o charakteristikách individuálních srážkových událostí jsou důležité z pohledu mnoha hydrologických aplikací, individuální srážkové události a jejich charakteristiky nejsou (na rozdíl od jiných ukazatelů denních/subdenních srážkových úhrnů/intenzit) v současné době objektem zájmu mnoha studií. Disertační práce přináší komplexní analýzu charakteristik intenzivních srážkových událostí v České republice založenou na pozorovacích datech a rozsáhlém souboru simulací regionálních klimatických modelů (RCM), která je navíc doplněna o rozbor korelační struktury měřených srážkových dat na příkladu Královéhradeckého kraje. Vzhledem k tomu, že simulace RCM reprezentují prostorový průměr v gridboxech, byl vyhodnocen také efekt prostorového průměrování srážkových dat na charakteristiky událostí. Evaluace srážkových událostí simulovaných RCM pak byla provedena podle několika ukazatelů vzhledem k bodovým a prostorově průměrovaným pozorovaným datům pro kontrolní období 1981–2000. Pro dvojici scénářových období (2020–2049 a 2070–2099) byly následně vyhodnoceny změny v charakteristikách srážkových událostí a to včetně jejich provázanosti s předpokládanými změnami v radiálním působení a teplotě.

**Klíčová slova:** atmosférické srážky, prostorová závislost, klimatické modelování, RCM, změna klimatu, Česká republika

## Abstract

Precipitation in the form of heavy rainfall events is of significant societal concern, not only due to the potential for more frequent flash floods, after evidence of changes in rainfall characteristics has recently strengthened. Despite the importance of individual rainfall events with respect to many hydrological applications, only a few studies dealt with characteristics of individual rainfall events (in contrast with the other daily/sub-daily indices of rainfall depths/intensities). Dissertation thesis presents a comprehensive analysis of heavy rainfall event characteristics for the Czech Republic derived from observed data and large ensemble of regional climate model (RCM) simulations. In addition, spatial correlation structure of observed rainfall data at a mesoscale region of north-eastern Bohemia was analysed. Since an RCM grid box represents a spatial average rather than a point measurement, the effects from areal averaging of rainfall data on characteristics of events were investigated considering the observed data. Characteristics of rainfall events were evaluated according to several indices against the at-site and area-averaged observed data for the control period 1981–2000. The changes of rainfall event characteristics were assessed over two scenario periods (2020–2049 and 2070–2099) with respect to control period. We analysed also relations between changes in simulated rainfall event characteristics and changes in radiative forcing and temperature.

**Keywords:** rainfall, spatial dependence estimation, climate modeling, RCM, climate change, Czech Republic

## Obsah

<b>1 Úvod</b>	<b>1</b>	<b>4 Diskuze a závěr</b>	<b>41</b>
1.1 Cíle disertační práce . . . . .	2	<b>Literatura</b>	<b>47</b>
1.2 Struktura disertační práce . . . . .	2	<b>Seznam použitých symbolů a zkratk</b>	<b>61</b>
<b>2 Literární rešerše</b>	<b>5</b>	<b>Seznam příloh</b>	<b>63</b>
2.1 Měření a zpracování srážkových dat	5	<b>A Spatial correlation structure of monthly rainfall at a mesocale region of north-eastern Bohemia</b>	<b>65</b>
2.1.1 Pozemní měření srážek . . . . .	5	<b>B Characteristics of rainfall events in RCM simulations for the Czech Republic</b>	<b>85</b>
2.1.2 Distanční měření srážek . . . . .	7	<b>C Projected changes of rainfall event characteristics for the Czech Republic</b>	<b>115</b>
2.1.3 Interpolace srážkových dat . . . . .	8		
2.1.4 Korelační struktura ve srážkových datech . . . . .	12		
2.2 Modelování klimatu . . . . .	15		
2.2.1 Scénáře změn klimatu . . . . .	16		
2.2.2 Klimatické modely . . . . .	19		
2.3 Srážkové extrém	22		
2.3.1 Projekce RCM pro srážkové extrém	22		
2.3.2 Individuální srážkové události a jejich charakteristiky . . . . .	23		
<b>3 Soubor publikací</b>	<b>25</b>		
3.1 Řešené území a použitá data . . . . .	25		
3.1.1 Pozemní srážkoměrná data . . . . .	26		
3.1.2 Srážkové řady simulované RCM . . . . .	27		
3.2 Prostorová korelační struktura v měřených srážkových datech . . . . .	27		
3.2.1 Časová variabilita v parametrech korelačních modelů	30		
3.2.2 Prostorová variabilita v parametrech korelačních modelů	31		
3.3 Srážkové události v měřených datech a simulacích RCM . . . . .	31		
3.3.1 Efekt prostorového průměrování srážkových dat . . . . .	32		
3.3.2 Charakteristiky srážkových událostí v simulacích RCM . . . . .	34		
3.3.3 Vliv nadmořské výšky . . . . .	35		
3.4 Simulované budoucí změny v charakteristikách srážkových událostí . . . . .	37		
3.4.1 Vliv radiačního působení a teploty . . . . .	38		

## Obrázky

2.1 Příklad korelačních modelů naftovaných na mezistaniční Pearsonův korelační koeficient v Královéhradeckém kraji. . . . .	14
2.2 2-D korelační mapa k posouzení anizotropie v korelační struktuře srážkových dat. . . . .	15
2.3 Postup pro modelový odhad vývoje klimatu. . . . .	16
2.4 Globální roční radiační bilance Země. . . . .	17
2.5 Základní skupiny SRES scénářů. . . . .	17
2.6 Přibližné změny v celkovém radiačním působení podle zástupců representujících jednotlivé skupiny scénářů SRES a RCP. . . . .	18
3.1 Srážkoměrné stanice v použitých datasetech. . . . .	26
3.2 Pokrytí České republiky gridboxy pro simulace RCM v prostorovém rozlišení 12.5 a 50 km. . . . .	29
3.3 Závislost korelačních koeficientů na vzdálenosti včetně proložení korelačními modely. . . . .	30
3.4 Model Voroného polygonace Královéhradeckého kraje s hodnotami korelačních parametrů pro Exponenciální tříparametrický model aplikovaný na Pearsonův korelační koeficient. . . . .	31
3.5 Průměrné kvantilové poměry pro charakteristiky srážkových událostí ze všech gridboxů simulací RCM. . . . .	35
3.6 Závislost mezi charakteristikami intenzivních srážkových událostí a nadmořskou výškou pro simulace RCM a bodová měřená data. . . . .	36
3.7 Srovnání kvantilových změn pro charakteristiky srážkových událostí simulovaných RCM ve dvou scénářových obdobích. . . . .	39
3.8 Závislost změn charakteristik srážkových událostí na změně teploty. . . . .	40

## Tabulky

2.1 Modely prostorové korelace včetně použitých parametrů: correlation distance $c_0$ , shape $s_0$ , nugget $c_1$ . . . . .	13
3.1 Přehled analyzovaných simulací RCM. . . . .	28
3.2 Počet intenzivních srážkových událostí za sezónu, sezónní srážkový úhrn přinášený intenzivními událostmi a průměrné charakteristiky individuálních srážkových událostí pro kontrolní období 1981–2000 v měřených datech a v simulacích RCM. . . . .	33

# Kapitola 1

## Úvod

Potenciální změny srážkových charakteristik spojené se zesíleným vlivem skleníkového efektu mohou mít závažné dopady na lidskou společnost. Např. střední Evropa byla v posledních desetiletích postižena množstvím povodňových událostí (Kundzewicz et al. 2005; Kundzewicz 2012). Zejména bleskové povodně, způsobené lokalizovanými velmi intenzivními krátkodobými srážkovými událostmi, mohou být v budoucnu ještě intenzivnější díky dynamickým zpětným vazbám (Lenderink et van Meijgaard 2008; Berg et Haerter 2013; Millán 2014). Stále větší množství studií z celého světa upozorňuje na intenzifikaci extrémních hydrologických situací. Nárůst extrémních denních srážkových intenzit je v současné literatuře často zmiňován (např. Alexander et al. 2006; Trenberth 2011; Westra et al. 2014), avšak právě z hlediska bleskových povodní nebo degradace půdy vlivem vodní eroze se jeví důležité sledovat srážkové extrémy v kratším časovém měřítku a ještě lépe z pohledu individuálních srážkových událostí (potenciálně nejnebezpečnější srážkové události o vysoké intenzitě mají zpravidla krátkou dobu trvání v řádu několika hodin).

Charakteristiky individuálních srážkových událostí (jako je srážkový úhrn, doba trvání nebo intenzita) a jejich potenciální změny, a zejména těch extrémních, nejsou v současné literatuře dostatečně řešeným tématem a to hned z několika důvodů. Pro identifikaci individuálních událostí a případných trendů změn v jejich charakteristikách jsou nezbytné kvalitní dlouhodobé řady srážkových dat v alespoň hodinovém kroku, které v současné době neexistují v dostatečném prostorovém pokrytí pro velkou část Země (Westra et al. 2014). Další překážkou se jeví složitost a náročnost řešení fyzikálních procesů tvořících krátkodobé srážkové extrémy (do kterých navíc zasahují ještě lokální vlivy, např. orografie), s nimiž se musí vypořádat klimatické modely (Stocker et al. 2013).

Disertační práce má přispět k tématu srážkových charakteristik a jejich potenciálních změn především analýzou charakteristik intenzivních srážkových událostí pro Českou republiku vycházejících z hodinových dat relativně velkého souboru simulací několika regionálních klimatických modelů (RCM). Před rozborem individuálních srážkových událostí je však nezbytné nejprve plně porozumět pozorovaným srážkovým datům. Z tohoto důvodu byla v pozorovaných datech, kromě efektu prostorového průměrování bodových sráž-

kových dat na srážkové události, analyzována také mezistaniční prostorová korelační struktura srážkových úhrnů v regionálním měřítku (na příkladu Královéhradeckého kraje).

## 1.1 Cíle disertační práce

Disertační práce byla od počátků mého studia zaměřena na analýzu srážkových dat na území České republiky pocházející z několika zdrojů (v návaznosti na diplomovou práci Porovnání srážkových úhrnů předpověděných modelem ALADIN s interpolovanými bodovými měřeními pro oblast Jeseníků). Představovaná studie vychází z pozemních srážkoměrných dat a simulací RCM. Ačkoliv hlavní zaměření studie směřuje k individuálním srážkovým událostem, jejich charakteristikám a budoucím změnám, první část práce byla zaměřena na samotnou prostorovou korelační strukturu měřených srážkových dat, která je nedílnou součástí i pro studium klimatických změn a validace simulací RCM (jako součást projektu IGA ČZU č.20124256 – Studie možných projevů klimatických změn na území Královéhradeckého kraje). Pro druhou část práce se naskytla příležitost využít nově dostupná hodinová data ze simulací několika RCM a zanalyzovat doposud nepříliš probádanou oblast individuálních srážkových událostí odvozených z pozemních měření a simulací RCM. Hlavní cíle disertační práce jsou tedy rozděleny následovně:

1. Prostorová korelační struktura srážkových dat v regionálním měřítku,
  - popis korelační struktury srážkových úhrnů (na příkladu Královéhradeckého kraje a měsíčních dat) třemi různými korelačními metrikami a šesti korelačními modely,
  - vyhodnocení časové variability v parametrech korelačních modelů (sezónní diference, klouzavé desetileté průměry),
  - vyhodnocení prostorové variability v parametrech korelačních modelů (závislost na nadmořské výšce, variabilita v kraji zobrazená pomocí Voronoiových polygonů).
2. Charakteristiky srážkových událostí v České republice,
  - analýza efektu prostorového průměrování měřených srážkových dat na individuální srážkové události,
  - evaluace charakteristik simulovaných srážkových událostí vůči měřeným datům,
  - vyhodnocení budoucích změn v charakteristikách simulovaných srážkových událostí.

## 1.2 Struktura disertační práce

Prezentovaná disertační práce má formát komentovaného souboru publikovaných prací. V rešeršní části práce (Kapitola 2) jsou blíže popsána vybraná



témata týkající se měření a základního zpracování srážkových dat, srážkových extrémů a identifikace srážkových událostí a též klimatického modelování a projekcí budoucích změn ve srážkových datech. Kapitola 3 uvádí publikované články, včetně stručného popisu použitých dat, metodiky a nejvýznamnějších výsledků. Diskuze a vyhodnocení publikovaných poznatků následuje v Kapitole 4. Vlastní publikace v originálním provedení jsou pak obsahem přílohových částí:

- A) Spatial correlation structure of monthly rainfall at a mesoscale region of north-eastern Bohemia (Svoboda et al. 2015),
- B) Characteristics of rainfall events in RCM simulations for the Czech Republic (Svoboda et al. 2016a),
- C) Projected changes of rainfall event characteristics for the Czech Republic (Svoboda et al. 2016b).



## Kapitola 2

### Literární rešerše

#### 2.1 Měření a zpracování srážkových dat

Základním zdrojem získávání srážkových dat využívaných v hydrologii jsou sítě pozemních srážkoměrů. Z těchto bodových dat můžeme pomocí interpolačních metod získat informace o plošném rozložení srážek potřebné pro další hydrologické aplikace. Ovšem samotné měření srážkových úhrnů pozemními srážkoměry je v dnešní době z mnoha pohledů limitující a velmi cennými se stávají informace o prostorovém rozložení srážkových objektů v atmosféře a informace o srážkových úhrnech před jejich dopadem na zemský povrch. Při komplexnosti a proměnlivosti srážkových procesů v prostoru a čase se jedná o velmi složitý úkol, k jehož dosažení je potřebné vytvořit komplexní systém se zahrnutím všech dostupných měřících metod a výpočtových přístupů.

S ohledem na zdroje srážkových dat využitých v práci jsou uvedeny základní informace týkající se měření pozemními srážkoměry (Kapitola 2.1.1), pro komplexnost doplněné také o několik základních informací o distančním měření srážek (Kapitola 2.1.2). Při zpracování měřených srážkových dat pro potřeby studie bylo využito několik interpolačních metod (Kapitola 2.1.3). Teoretické podklady týkající se korelační struktury ve srážkových datech pak poskytuje Kapitola 2.1.4.

##### 2.1.1 Pozemní měření srážek

Měření srážkových úhrnů na se provádí srážkoměry, případně totalizátory na určeném místě, jedná se tedy o tzv. bodové měření. Dingman (2002) uvádí, že přesnost srážkoměrných měření je ovlivněna, kromě vhodného umístění srážkoměru, také ztrátami působením větru, odpařováním, adhezí dešťových kapek na stěnách nádoby nebo ztrátou vyšplouchnutím dešťové vody při dopadu kapek.

Dříve používané ombrografy (Květoň et al. 2004) byly s postupnou automatizací v meteorologických měřeních nahrazeny modernějšími a přesnějšími člunkovými, váhovými nebo nejmodernějšími optickými srážkoměry. V našich podmínkách (a ve srážkoměrné síti Českého hydrometeorologického ústavu) jsou v současné době nepoužívanější člunkové a váhové srážkoměry.

### ■ Člunkové srážkoměry

Princip měření člunkovým srážkoměrem spočívá na pohybu děleného člunku podél středové osy. Dešťové srážky jsou vedeny ze sběrné nádoby (se záchytnou plochou obvykle 500 cm<sup>2</sup>) výtokovým otvorem do horní poloviny překlápěcího člunku. Po naplnění člunku nadefinovaným množstvím srážek (nejčastěji 0.1 mm) dojde k jeho překlopení a začíná se plnit druhý člunek. Každé překlopení je registrováno sepnutím kontaktu a je zaznamenáno v měřicí stanici. Počet překlopení se registruje v minutových intervalech a do databáze jsou zaznamenávány nejčastěji desetiminutové sumy úhrnů. Takto získaný detailní časový průběh srážky je pak možno využít také ke stanovení srážkových intenzit. Nejistoty do měřených dat mohou přinášet mechanické problémy překlápěcího zařízení nebo technické problémy při přenosu dat, pravidelná kontrola a údržba průchodnosti srážkoměru je též důležitá. Při intenzivních deštích může docházet k chybám tak, že do právě překlopeného člunku natéká část srážky určená už druhému člunku a dochází tak ke ztrátě (podhodnocení) měřeného úhrnu (Sevruk 2004). Chyby při měření člunkovými srážkoměry jsou tedy velmi závislé na intenzitě srážek a časovém měřítku záznamu, Ciach (2003) uvádí, že nejvýznamnější chyby vznikají při měření intenzivních srážek v krátkém čase. Z toho důvodu bývá u moderních typů srážkoměru aplikována korekce naměřených hodnot podle okamžité intenzity srážek.

### ■ Váhové srážkoměry

Váhové srážkoměry pracují na principu nepřetržitého záznamu hmotnosti nádoby s akumulovanou srážkou. Vážícím mechanismem jsou tenzometrické váhy, které pracují s vysokou přesností a rozlišením. Tomu odpovídá i citlivost měření srážek, až 0,01 mm srážky. Váha je připojena na řídicí jednotku, která kontinentálně vyhodnocuje měření a řídí další části srážkoměru. V letním období je do sběrné nádoby přidán olej nebo jiná látka, která zabraňuje evaporaci, v zimním období je nádoba plněna nemrznoucí směsí. Tímto typem srážkoměru lze měřit spolehlivě i pevné srážky bez prodlevy nutné pro jejich roztátí. Přesnost váhového srážkoměru není, oproti člunkovým srážkoměrům, negativně ovlivněna při velkých srážkových intenzitách. Ovlivnění vážení vzorku větrem lze do jisté míry eliminovat instalací protivětrných zábran, někteří výrobci doporučují současně měřit rychlost větru u srážkoměru a provádět potom korekci na měřený vítr. Nevýhodou váhového srážkoměru je složité odfiltrování jevů, které mimo vlastní srážku ovlivňují hmotnost vzorku.

### ■ Kvalita srážkových řad

Zavedení automatizovaných měření však může být také zdrojem nehomogenit v měřených meteorologických řadách, což je potřeba brát v potaz zejména při současných požadavcích na kvalitu srážkových řad a jejich případné homogenizaci s ohledem na problematiku studia změn klimatu (Kněžíková et al. 2010). Právě pro studium změn klimatu jsou využívány srážkové řady, které jsou z velké části založeny na záznamech ombrografů. Nezbytnou součástí

digitalizace ombrogramů (analogový zápis měření z ombrografu) je také kontrola kvality zaměřená na doplnění poškozených nebo chybějících záznamů za využití dalších dostupných zdrojů srážkových dat. Podrobný postup používaný pro digitalizaci a kontrolu historických srážkových záznamů v České republice udává Květoň et al. (2004). Přesný popis konkrétních srážkových řad použitých v prezentované práci je uveden dále v Kapitole 3.1.1.

## 2.1.2 Distanční měření srážek

Mezi nástroje pro distanční pozorování srážek se zařazují meteorologické družice a meteorologické radiolokátory.

### Meteorologické družice

Meteorologické satelity se mohou v rámci tzv. Světového meteorologického kosmického systému rozdělit do dvou základních skupin, na polární (např. NOAA – National Oceanic and Atmospheric Administration), se střední výškou letu kolem 1000 km a oběžnou dobou nejčastěji od 100–120 minut a geostacionární (např. METEOSAT), obíhající Zemi ve výšce necelých 36 tisíc kilometrů v rovině zemského rovníku jednou za 24 hodin. Přednosti meteorologických družic jsou využitelné především pro krátkodobé meteorologické předpovědi, monitorování nebezpečných hydrometeorologických jevů mezosynoptického měřítka, ale také pro numerické modelování a studium variability klimatu.

### Meteorologické radiolokátory

Pokroky ve vývoji radarových technologií umožňují ideální využití radaru pro přesné monitorování srážek na sledovaném území, meteorologický radar je schopen zachytit prostorově kontinuální rozložení srážkových polí včetně jejich trojrozměrné struktury a pohybu. Funkce radaru spočívá ve vyzařování elektromagnetické energie v omezených pásmech (viz např. Doviak et Zrníč 1993). Při zasažení srážky je energie částečně absorbována, rozptýlena a odražena. Část odražené energie se vrací zpět k vysílači v čase  $2t$  (za čas  $t$  dosáhne signál objektu odrazu), přičemž elektromagnetické vlny se šíří rychlostí světla. Kvůli útlumu signálu při interakci s deštěm musí být odražená energie upravena a zesílena tak, aby se daly porovnat odrazy z různých dosahů (vzdáleností od vysílače k cíli odrazu), přičemž i v období před a po srážce se v pozadí vyskytuje ruch, který je nutno odfiltrovat. Srážkový úhrn ( $R$ ) poté souvisí s měřenou odrazivostí radaru ( $Z$ ) podle základního vztahu  $Z = aR^b$ , kde  $a$ ,  $b$  jsou experimentálně zjištěné konstanty závislé na lokaci, druhu srážky, velikosti kapek a dalších parametrech (přehled konstant odvozených dle různých autorů udává např. Bras 1990).

Radarová pozorování však ukazují pouze okamžitá rozložení intenzit srážek v diskrétních časech. Potřebujeme-li určovat množství srážek za delší období (řádově hodiny), musíme počítat s kumulací chyb. Z důvodu velké prostorové i časové proměnlivosti intenzit srážek je nutné používat co nejkratší interval

měření (5 minut a méně). Celkové chyby určování intenzit srážek pomocí radaru jsou řádu desítek až stovek procent, částečně mohou být sníženy vhodným zpracováním dat (Kráčmar 2002). Pro získání co nejpřesnějších dat je důležitá konfigurace radaru s ohledem na výsledky měření ze sítě pozemních bodových srážkoměrů (Chumchean et al. 2006).

### ■ 2.1.3 Interpolace srážkových dat

Procesem interpolace lze dosáhnout odhadu daného jevu v libovolných bodech nebo celé ploše na základě využití měření jevu ve vybraných místech v zájmové oblasti. Z hlediska matematicko-statistického řešení existují dvě základní skupiny interpolačních metod: deterministické a statistické. U deterministických metod je interpolace neznámé hodnoty založena na měřeních v okolí neznámé hodnoty a je určována pomocí vhodné deterministické funkce buď na základě stupně podobnosti hodnot nebo stupně vyhlazení ve vztahu k sousedním datovým bodům. Druhá skupina interpolačních metod je tvořena geostatistickými metodami, jež jsou založeny na statistickém modelu, který v sobě obsahuje společně s prostorovou autokorelací jevu rovněž apriorní předpoklad neurčitosti mezi měřenými body.

Interpolační metody mohou být klasifikovány jako lokální nebo globální. Lokální interpolační metody řeší odhad hodnoty podle dat ze sousedních měřících bodů na menších plochách než je celková zájmová oblast. Naopak globální interpolační metody využívají k odhadu všech dostupných bodů v celé zájmové oblasti (Burrough et McDonnell 1998; Kraus 2007). Burrough et McDonnell (1998) dále zmiňují rozlišení na interpolační metody exaktní a inexaktní, podle srovnatelnosti odhadu s měřenými hodnotami. Rozdíl mezi odhadovanou a měřenou hodnotou se využívá jako statistický podklad pro vyhodnocení odhadu kvality interpolačního modelu.

V průběhu řešení disertační práce byly při zpracování srážkových dat využity dvě základní deterministické metody, konkrétně běžný aritmetický průměr (při vyhodnocování efektu prostorového průměrování srážkových dat na srážkové události, Kapitola 3.3.1) a Inverse Distance Weighting (IDW; pro doplnění chybějících srážkoměrných záznamů, Kapitola 3.1.1). Dále při posuzování anizotropie v prostorové korelační struktuře (viz následující Kapitola 2.1.4) byla pro tvorbu 2-D korelačních map využita metoda Ordinary Kriging (OK). Tyto interpolační metody jsou popsány v textu dále. Metoda optimální interpolace (využívající prostorovou korelační strukturu srážkových dat), která je v dalším textu zmiňována jen doplňkově, byla podrobněji popsána v diplomové práci (Svoboda 2010).

### ■ Průměrové metody

Průměrové metody vychází z rovnice 2.1, kde odhad srážkového úhrnu  $P$  je dán jako:

$$P = \sum_{g=1}^G w_g p_g, \quad (2.1)$$

kde  $w_g$  je váha hodnoty srážky a  $p_g$  hodnota srážky v bodě  $g$ , přičemž musí být splněna podmínka 2.2:

$$\sum_{g=1}^G w_g = 1; \quad 0 \leq w_g \leq 1, \quad (2.2)$$

Aritmetický průměr je nejjednodušší přímá, deterministická metoda. Váha hodnot  $w_g$  z rovnice 2.1 je zde nahrazena hodnotou  $1/G$  pro všechna měření ve zvolené oblasti, čímž dostáváme aritmetický průměr všech hodnot. V případě potřeby může být zahrnuta do průměru i stanice sousedící se zájmovou oblastí. Nevýhodou této základní metody je, že sledovaný jev může být výrazně zkreslený.

### Metoda IDW

Interpolační metoda inverzních vzdáleností neboli IDW (Inverse Distance Weighting) je deterministická, exaktní metoda. Základy výpočtu popisují např. Tabios et Salas (1985). Metoda IDW předpokládá, že vliv každého naměřeného bodu na interpolované hodnoty se vzdáleností klesá, váhy hodnot jsou tedy určeny na základě vzdáleností mezi bodem stanovení hodnoty srážky  $j$  a body naměřené hodnoty  $g$ . Potom je váha měřicího bodu  $g$  dána podle rovnice 2.3 jako:

$$w_{jg} = \frac{f(d_{jg})}{\sum_{g=1}^G f(d_{jg})}, \quad (2.3)$$

za předpokladu, že funkce je závislá jen na vzdálenosti bodů  $j$  a  $g$  potom můžeme vyjádřit  $f(d_{jg})$  podle rovnice 2.4:

$$f(d_{jg}) = d_{jg}^{-r}, \quad (2.4)$$

kde  $d_{jg}$  je vzdálenost mezi body  $j$  a  $g$  a  $r$  exponent definovaný uživatelem. Pro exponent  $r$  se často používá hodnota 2 (pak se jedná o Inverse Distance Square Interpolation). Vyšší hodnota exponentu  $r$  znamená větší vliv nejbližších hodnot (Juříková 2009).

Po získání odhadů srážky  $p'_j$  (rovnice 2.5) v pravidelné síti bodů je možno stanovit plošný průměr v dané oblasti.

$$p'_j = \sum_{g=1}^G w_{jg} p_g. \quad (2.5)$$

Bartier et Keller (1996) udávají ještě zjednodušený binární způsob stanovení vah, kdy se stanoví  $w_{jg} = 1$  pro  $g$  nejbližších bodů k interpolovanému bodu, nebo pro  $g$  bodů ležících do stanovené vzdálenosti od interpolovaného bodu a pro ostatní případy bude  $w_{jg} = 0$ , tento případ je ve své podstatě použit u interpolací, kde je zahrnut pouze vliv jedné nejbližší stanice. Metoda IDW má nevýhodu, že nevytváří „hladkou“ plochu, protože neexistuje derivace funkce ve všech jejích bodech (Kraus 2007).

## ■ Kriging

Krigováním označujeme soubor geostatistických metod určování lokálního odhadu buď v bodě, kde nebylo provedeno měření (bodový odhad) nebo v relativně malé ploše (blokový odhad). Existuje celá řada modifikací krigovacích schémat, přičemž nejběžnějšími typy krigování jsou: základní (ordinary) kriging (OK), jednoduchý (simple) kriging a univerzální (universal) kriging (Horák 2011).

Tabios et Salas (1985) popisují základní OK jako geostatistickou interpolační techniku podobnou optimální interpolaci, kde je prostorová korelační funkce nahrazena tzv. variogramem. Stejně jako optimální interpolace, Krigování vyžaduje, aby sledovaný jev byl stacionární druhého řádu. Takže za předpokladu homogenity středních hodnot, variancí a kovariancí navíc předpokládáme izotropní prostorovou strukturu kovariance. Bodová variance je reprezentována jako  $var(p_g) = \sigma^2$ , pro  $g = 1, 2, \dots, G$  stanic a kovariance mezi stanicemi  $g$  a  $h$  je dána jako  $cov(p_g p_h) = cov(d_{gh})$ . Potom je semivariogram homogenní a izotropní a je definován jedním z tvarů 2.6.

$$\begin{aligned}\gamma(d_{gh}) &= \frac{1}{2}var[p_g - p_h], \\ \gamma(d_{gh}) &= \sigma^2 - cov(d_{gh}),\end{aligned}\tag{2.6}$$

kde  $\gamma(d_{gh})$  je semivariogram jako funkce vzdálenosti mezi body  $g$  a  $h$ .

Vycházíme-li z metody optimální interpolace v níž jsou váhy hodnot  $w_{jg}$  odvozené minimalizací rozptylu interpolační odchylky  $\sigma_\varepsilon^2$ , tedy  $\sigma_\varepsilon^2 = var[p_j - p'_j]$ , kde  $p'_j$  je odhad hodnoty srážky  $p_j$  (viz rovnice 2.5), dostaneme po rozepsání rovnici 2.7:

$$\sigma_\varepsilon^2 = \sigma^2 - 2 \sum_{g=1}^G w_{jg} cov(p_j p_g) + \sum_{g=1}^G \sum_{h=1}^G w_{jg} w_{jh} cov(p_g p_h),\tag{2.7}$$

do které můžeme místo kovariancí mezi stanicemi dosadit vztah podle rovnice 2.6, čímž dostáváme tvar 2.8:

$$\sigma_\varepsilon^2 = \sigma^2 - 2 \sum_{g=1}^G w_{jg} [\sigma^2 - \gamma(d_{jg})] + \sum_{g=1}^G \sum_{h=1}^G w_{jg} w_{jh} [\sigma^2 - \gamma(d_{gh})].\tag{2.8}$$

Po minimalizaci rovnice vzhledem k vahám získáme základní vztah (2.9), který musí být řešen souběžně pro stanovení vah  $w_{jh}$ ,

$$\sum_{h=1}^G w_{jh} [\gamma(d_{gh}) - \sigma^2] = \gamma(d_{jg}) - \sigma^2; \quad g = 1, 2, \dots, G.\tag{2.9}$$

Rozptyl odchylky interpolace (2.10) vychází z rovnic 2.8 a 2.9:

$$\hat{\sigma}_\varepsilon^2 = \sigma^2 \left[ 1 - \sum_{g=1}^G w_{jg} \right] + \sum_{g=1}^G w_{jg} \gamma(d_{jg}),\tag{2.10}$$



kdy opět z důvodu nestrannosti odhadu musí platit podmínka pro součet vah 2.11:

$$\sum_{g=1}^G w_{jg} = 1. \quad (2.11)$$

Po zavedení Lagrangeova multiplikátoru  $\lambda$  do výpočtu získáme minimalizovanou rovnici 2.12 s podmínkou 2.13:

$$\sum_{h=1}^G w_{jh} \gamma(d_{gh}) + \lambda = \gamma(d_{jg}), \quad (2.12)$$

$$\sum_{h=1}^G w_{jh} = 1, \quad (2.13)$$

které musí být řešeny souběžně pro určení vah. Rozptyl interpolační odchylky je poté dán podle vztahu 2.14:

$$\hat{\sigma}_\varepsilon^2 = \sum_{g=1}^G w_{jg} \gamma(d_{jg}) + \lambda. \quad (2.14)$$

V případě nesplnění podmínek stacionarity střední hodnoty a strukturní funkce, Delfiner et Delhomme (1975) doporučují použití univerzálního krigování, kde je střední hodnota jevu  $\bar{p}_j$  v interpolovaném bodě  $(x_j, y_j)$  reprezentována jako lineární kombinace středních hodnot měřících bodů  $\bar{p}_g$ .

Jak bylo řečeno v úvodu, kriging pro vyjádření prostorové závislosti využívá variogramu. S ohledem na homogenitu a izotropii, Delhomme (1978) udává řadu modelů proložení variogramu  $\gamma(d)$ . Nejvýznamnější modely variogramu (lineární, polynomický, exponenciální, Gaussův a sférický model) popisují Tabios et Salas (1985). Flexibilní Matérnuv model pak představují Minasny et McBratney (2005).

K aplikaci modelového proložení je nejprve třeba odvodit vzorový (tzv. sample) variogram podle vztahu 2.15 (Tabios et Salas 1985):

$$\hat{\gamma}(d_{gh}) = \frac{1}{2N} \sum_{t=1}^N \{ [p_g(t) - \bar{p}_g] - [p_h(t) - \bar{p}_h] \}^2, \quad (2.15)$$

kde  $p_g(t)$ ,  $p_h(t)$  jsou naměřené hodnoty srážek v bodě  $g$ , resp.  $h$  v intervalu  $t$  při  $t = 1, 2, \dots, N$ , kde  $N$  je počet naměřených hodnot a  $\bar{p}_g$ ,  $\bar{p}_h$  jsou průměrné hodnoty srážek naměřených v bodě  $g$ , resp.  $h$ . Pro celkový počet  $G$  stanic tedy dostaneme  $G(G-1)/2$  hodnot, které vytvoří vhodný podklad pro proložení modelovým variogramem.

Podle Borga et Vizzaccaro (1997) činí přirozená variabilita srážek použití krigingu jako vhodné techniky zejména při interpolacích kdy máme k dispozici jen omezené množství měřících bodů, u vysokého pokrytí měřícími body již zvýšení přesnosti není tak výrazné oproti jiným technikám.

### 2.1.4 Korelační struktura ve srážkových datech

Korelační struktura srážkových dat je důležitý prvek při popisu distribuce srážkových polí. Popis srážkových polí a jejich proměnlivost v čase pak poskytuje informace pro studium klimatických změn (New et al. 1999, 2000; Alexander et al. 2006), je nedílnou součástí při evaluaci klimatických modelů (Osborn et Hulme 1997; Hofstra et al. 2010) a vyhodnocování nejistot v klimatických scénářích (např. Kyselý et Beranová 2009).

Prostorová korelační struktura srážkových dat sumarizuje vztah mezi měřenými bodovými záznamy a je běžně užívaným konceptem pro vyjádření prostorové závislosti srážkových polí (Šen et Habib 2001; Ciach et Krajewski 2006). Závislost je vyjádřována pomocí korelogramu, který udává vztah mezistaniční korelace a vzdálenosti. Postup sestává ze stanovení korelačních odhadů, jež jsou následně proloženy vhodnou modelovou korelační funkcí.

#### Vyjádření korelace – korelační koeficienty

Široce používanou mírou korelace pro popis prostorových závislostí ve srážkových procesech je Pearsonův korelační koeficient (Pearson's product-moment correlation coefficient; např. Habib et al. 2001; Krajewski et al. 2003; Ciach et Krajewski 2006; Villarini et al. 2008). Pearsonův korelační koeficient ( $r$ ) udává sílu lineární závislosti mezi dvěma veličinami a je definován jako kovariance dvou proměnných  $(x, y)$  dělená součinem jejich směrodatých odchylek:

$$r(x, y) = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y}. \quad (2.16)$$

Při použití Pearsonova korelačního koeficientu je předpokladem podmínka normálního rozdělení obou proměnných  $(x, y)$ , pokud se distribuce datových řad od normálního rozdělení příliš odlišuje Pearsonův korelační odhad může být značně zkreslený (Hutchinson 1997; Habib et al. 2001; Krajewski et al. 2003). V těchto případech Habib et al. (2001) navrhuje použití alternativních neparametrických pořadových odhadů závislosti jako je Spearmanův koeficient pořadové korelace (Spearman's  $\rho$  rank-order correlation coefficient) nebo Kendallův koeficient konkordance (Kendall's  $\tau$  rank correlation coefficient). Spearmanův koeficient ( $\rho$ ), stejně jako Kendallův koeficient ( $\tau$ ) udávají míru monotónní závislosti v případech, kdy závislost mezi veličinami není lineární (předpoklad monotónní závislosti není tolik omezující jako případ lineární závislosti u Pearsonova korelačního koeficientu). Protože jsou tyto odhady vzhledem k monotónní transformaci neměnné, při aplikacích na pořadovou statistiku jsou oproštěny od podmínek na distribuční rozdělení (Navarro et Balakrishnan 2010). Spearmanův ( $\rho$ ) a Kendallův ( $\tau$ ) koeficient jsou úzce spjaté a zároveň nejpoužívanější neparametrické odhady závislosti dvou náhodných proměnných.

Spearmanův koeficient pořadové korelace ( $\rho$ ) lze vyjádřit jako Pearsonův korelační koeficient, kde jsou proměnné  $(x, y)$  převedeny na hodnoty jejich pořadí  $(x_i, y_i)$ . Někdy je udáván pouze zjednodušený vztah, který dává velmi

dobrý odhad v případech kdy se v datech vyskytuje minimální počet stejných hodnot:

$$\rho(x, y) = 1 - \frac{6 \sum_{i=1}^n (x_i - y_i)^2}{n(n^2 - 1)}, \quad (2.17)$$

kde  $(x_i - y_i)$  je rozdíl v pořadí daný každému z  $n$  pozorování ve dvou časových řadách srážkových dat  $(x, y)$ .

Kendallův koeficient konkordance ( $\tau$ ) poskytuje korelační odhad na základě vzájemné podobnosti pořadí veličin  $(x, y)$ . Jestliže uvažujeme dvojici pozorování  $(x_i, y_i)$  a  $(x_j, y_j)$  z řady  $n$  pozorování dvou veličin  $(x, y)$ , potom páry  $(x_i, y_i)$  a  $(x_j, y_j)$  lze nazvat dle jejich pořadí konkordantní pokud  $(x_i - x_j)(y_i - y_j) > 0$  a diskordantní pokud  $(x_i - x_j)(y_i - y_j) < 0$ . Kendallovo  $\tau$  je potom definováno jako rozdíl mezi pravděpodobnostmi konkordance a pravděpodobností diskordance jako:

$$\tau(x, y) = \frac{c_n - d_n}{0.5n(n - 1)}, \quad (2.18)$$

kde  $c_n$  je počet konkordantních párů a  $d_n$  počet diskordantních párů.

### Teoretické korelační modely

Mezistaniční korelační odhady mohou být popsány pomocí teoretických korelačních modelů (přehled modelů testovaných v článku Svoboda et al. 2015 uvádí Tabulka 2.1). Tvar modelové křivky ovlivňují korelační parametry, které je nutno vhodně stanovit optimalizační metodou, např. adaptivní nelineární metodou nejmenších čtverců (Dennis et al. 1981).

Parametr vzdálenosti  $c_0$  (correlation distance) je základním parametrem korelačních modelů charakterizující pokles korelace a u exponenciálních modelů je přímo definován vzdáleností ve které prokládaná korelační křivka klesá


Model	Korelační funkce	Parametry
Square root	$r(d) = \frac{1}{\sqrt{1 + \frac{d}{c_0}}}$	$c_0$
Reciprocal	$r(d) = \frac{1}{1 + \frac{d}{c_0}}$	$c_0$
Exponential 1P	$r(d) = \exp\left(-\frac{d}{c_0}\right)$	$c_0$
Exponential 2P	$r(d) = \exp\left[-\left(\frac{d}{c_0}\right)^{s_0}\right]$	$c_0, s_0$
Exponential 3P	$r(d) = c_1 \exp\left[-\left(\frac{d}{c_0}\right)^{s_0}\right]$	$c_0, s_0, c_1$
Matérn	$r(d) = \frac{-1}{2^{s_0-1}\Gamma(s_0)} \left(\sqrt{2s_0} \frac{d}{c_0}\right)^{s_0} K_{s_0}\left(\sqrt{2s_0} \frac{d}{c_0}\right)$	$c_0, s_0$

**Tabulka 2.1:** Modely prostorové korelace včetně použitých parametrů: correlation distance  $c_0$ , shape factor  $s_0$ , nugget  $c_1$ ;  $d$  je vzdálenost mezi dvojicí stanic. U Matérnova modelu (Handcock et Wallis 1994),  $\Gamma$  je gamma funkce a  $K_{s_0}$  je modifikovaná Besselova funkce druhého druhu pro  $s_0$  (Abramowitz et Stegun 1972).

pod hodnotu  $1/e$  (viz Obr. 2.1). U exponenciálních modelů je tento parametr nazýván též correlation decay distance (CDD; např. Dai et al. 1997; New et al. 2000; Hofstra et New 2009) a udává vzdálenost ve které prostorově zprůměrovaná mezistaniční korelace není dále statisticky významná na hladině 0.05.

Parametr tvaru  $s_0$  (shape factor) znatelně ovlivňuje chování modelu v malých vzdálenostech. Hodnoty menší než jedna, běžné pro víceparametrické modely, indikují rychlejší pokles korelační funkce v malých vzdálenostech a naopak pomalejší pokles ve velkých vzdálenostech (viz srovnání jedno a dvouparametrického exponenciálního modelu na Obr. 2.1). Parametr  $s_0$  také udává závislost mezi exponenciálními modely a Matérn modelem, pokud je  $s_0 = 1$  exponenciální model se dvěma parametry je totožný s jednoparametrickým modelem a totéž platí pro Matérn model při  $s_0 = 0.5$  (Minasny et McBratney 2005).

Nugget parametr  $c_1$  poskytuje informace o variabilitě srážek ve vzdálenostech blízkých nule a může poskytnout informace o možných chybách měření. Čím blíže je  $c_1$  hodnotě 1 tím menší je variabilita a chyba měření (Villarini et al. 2008).

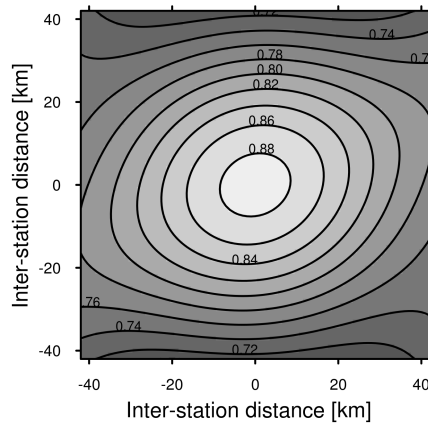


**Obrázek 2.1:** Příklad korelačních modelů naitovaných na mezistaniční Pearsonův korelační koeficient ( $r$ ) v Královéhradeckém kraji. U exponenciálních modelů je CDD dáno jako bod, kde křivka proložení má korelační koeficient roven  $1/e$  (vodorovná plná čára).

Při aplikaci korelačních modelů je důležitým předpokladem izotropie v korelační struktuře (předpoklad, že korelace klesá se vzdáleností nezávisle na směru; Jones et al. 1997). K určení anizotropie v korelační struktuře se využívají 2-D korelační mapy (např. Sharon 1978, 1979; Velasco-Forero et al. 2009; Mandapaka et Qin 2013), které popisují prostorovou strukturu korelačních koeficientů mezi stanicemi jen pomocí rozdílů v jejich vzájemné vektorové vzdálenosti nezávisle na jejich přesném umístění. Korelační koeficienty se tak stávají pouze funkcí vzdálenosti a směru mezi všemi stanicemi vzájemně a korelační mapy jsou pak symetrické okolo nulového počátku.

Pro tvorbu 2-D korelačních map v pravidelné síti je využívána metoda OK,

jakožto metoda široce používaná pro odhady ve srážkových polích (Velasco-Forero et al. 2009). Příklad výsledné podoby 2-D korelační mapy (s prostorovým rozlišením 1 km) je pak zobrazen na Obr. 2.2, kde je patrná začínající mírná anizotropie ve směru jihozápad-severovýchod v mezistaničních vzdálenostech kolem 20 km.



**Obrázek 2.2:** 2-D korelační mapa k posouzení anizotropie v korelační struktuře srážkových dat spočítaná na základě mezistaničních korelací pro Pearsonův korelační koeficient na měsíčních srážkových úhrnech v Královéhradeckém kraji.

## 2.2 Modelování klimatu

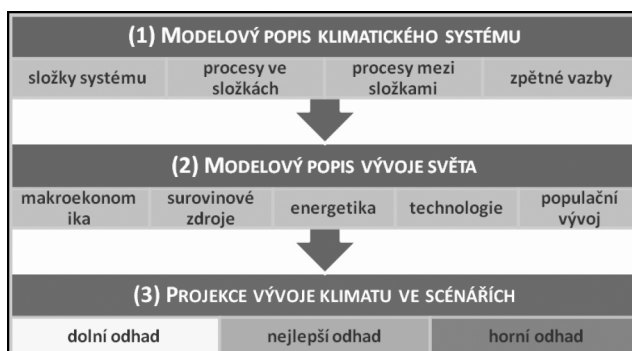
Klima je charakteristický dlouhodobý režim počasí v dané oblasti podmíněný bilancí energie, atmosférickou a oceánskou cirkulací, vlastnostmi zemského povrchu a činností člověka. Klimatický systém je velmi složitý nelineární systém, mezi jehož složkami probíhá neustálá výměna hmoty a energie (podrobněji ho popisuje např. Neelin 2011). Změny klimatu probíhají po celé období vývoje Země a mohou být vyvolány řadou vnějších i vnitřních faktorů. Zjednodušeně je možné tyto vlivy rozdělit na přirozené (sluneční činnost, změny orbitální dráhy Země, rozložení pevnin a oceánů, či sopečné činnosti) a antropogenní (zejména emise skleníkových plynů a aerosolů, změny ve využívání krajiny, zásahy do hydrologického režimu a další). Zásahy člověka do klimatického systému jsou neoddiskutovatelné, vzhledem ke složitosti celého systému a vzájemným vazbám je však obtížné přesněji stanovit podíl člověka na celkové změně klimatu.

Nejvýznamnější organizací zabývající se globální změnou klimatu je Mezivládní panel pro změnu klimatu (IPCC), který pravidelně vydává hodnotící zprávy, technické a speciální zprávy, zaměřené na klíčové problémy v oblasti změny klimatu a poskytuje nejnovější informace o vědeckých, technických a sociálně-ekonomických aspektech změny klimatu. Podle studií IPCC je jednoznačný trend růstu teploty a redistribuce srážkových úhrnů v posledních desetiletích (IPCC 2007, 2014).

### 2.2.1 Scénáře změn klimatu

Odhad budoucího vývoje klimatu je obecně nazýván klimatickým scénářem a jedná se o popis klimatu při zahrnutí předpokládaných důsledků antropogenních vlivů. K odhadům vývoje klimatu v budoucnosti ale i rekonstrukci vývoje minulého jsou využívány klimatické modely (je ale možné využít i jiné postupy jako přírůstkové scénáře nebo časové a prostorové analogy).

Postup pro vytvoření modelového odhadu budoucího vývoje klimatu je schematicky zobrazen v bodech (1) až (3) na Obr. 2.3. Odezva klimatického systému na určitý scénář emisí (nebo koncentrací) skleníkových plynů a aerosolů (odvozený na základě bodu (2) z Obr. 2.3) simulovaná klimatickými modely, se poté nazývá projekce klimatu. Klimatické scénáře jsou založeny na těchto projekcích, které představují rozdíl mezi tzv. referenčním obdobím (často bylo bráno 1961–1990 jako normálové období podle Světové meteorologické organizace) a budoucím modelovým klimatem pro určitý časový horizont (obvykle bývá třicetiletý), a které mohou za určitých předpokládaných okolností nastat. Praktická aplikace klimatických scénářů na regionální úrovni je pak nastíněna v článku Svoboda et Kalecký (2013).




**Obrázek 2.3:** Postup pro modelový odhad vývoje klimatu. Zdroj: ČHMÚ (2011)

Globální emise skleníkových plynů vedou ke změnám v koncentracích v atmosféře a následně ke změnám v radiačním působení které způsobuje změny klimatu. Radiační působení (vyjadřující rozdíl mezi energií kterou Země obdrží z vnější a kterou odrazí zpět, viz Obr. 2.4) reflektuje vlivy nejen koncentrace skleníkových plynů, ale i troposférického ozonu, aerosolů nebo změny albeda Země. Hodnoty radiačního působení jsou obvykle vztaženy k předindustriálnímu období (roku 1750) a jsou vyjadřovány jako  $[W \cdot m^{-2}]$ . Skleníkové plyny mají různé fyzikální vlastnosti a tudíž i různý vliv na radiační působení, z tohoto důvodu byla zavedena jednotka  $CO_2\text{-eq}$  (ekvivalent  $CO_2$ ) udávající míru množství skleníkového plynu který by měl stejný účinek na klimatický systém jako samotný oxid uhličitý.

### Emisní scénáře – SRES

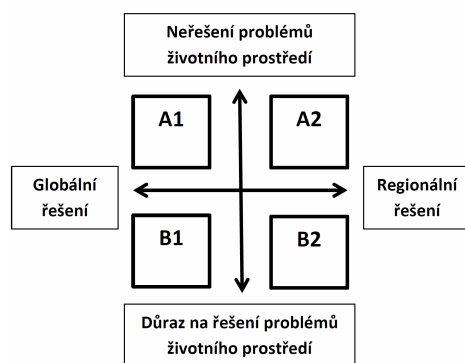
Nárůst globální průměrné teploty pozorovaný od poloviny 20. století, ale i jiné změny v klimatickém systému, mají velmi pravděpodobně souvislost



**Obrázek 2.4:** Globální roční radiální bilance Země. Zdroj: Kiehl et Trenberth (1997), upraveno

s pozorovaným nárůstem koncentrací skleníkových plynů (Rogner et al. 2007). Nejistota v budoucím vývoji emisí skleníkových plynů vedla IPCC k vytvoření Speciální zprávy o emisních scénářích (scénáře SRES; Nakicenovic et Swart 2000) v závislosti na předpokladech vývoje světa. Tyto emisní scénáře jsou tvořeny čtyřmi základními skupinami (Obr. 2.5) a jejichž stručný popis je následující.

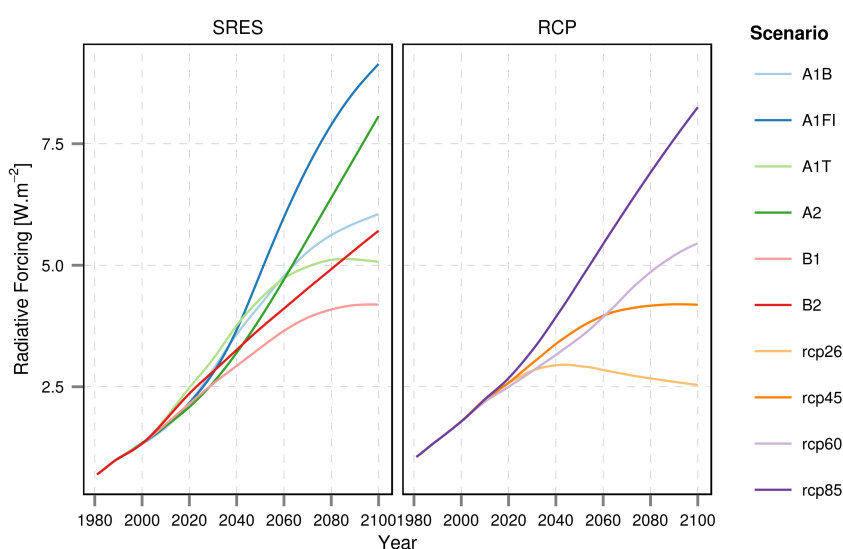
Scénář skupiny A1 popisuje svět s velmi rychlým růstem ekonomiky, vývojem nových technologií a s populací rostoucí do roku 2050. Tato skupina se dělí na 3 podskupiny dle převažujícího zdroje energie: A1FI – fosilní paliva, A1T – bez fosilních paliv a A1B – rovnováha ve využívání všech paliv. Ve scénáři A2 populace roste až do roku 2100. Veškerá opatření jsou činěna na úrovni regionů a ekonomika roste pomaleji v porovnání se scénářem A1. Scénář B1 popisuje svět s širokou spoluprací. Populace roste do roku 2050 a následně začíná klesat. Je předpokládán rychlý rozvoj informatiky, služeb a



**Obrázek 2.5:** Základní skupiny SRES scénářů.

nových technologií a středně rychlý růst ekonomiky. Scénář B2 představuje budoucnost s orientací na regionální řešení a trvale udržitelný rozvoj. Nárůst populace je nižší než v A2 a ekonomický pokrok pomalejší než v A1 a B1. Pro tyto skupiny scénářů bylo vybráno 6 reprezentujících zástupců podle nichž byly scénáře změny klimatu modelovány.

V levé části Obr. 2.6 je zobrazeno srovnání předpokládaných změn v celkovém radiačním působení pro SRES scénáře od roku 1980 (podle Houghton et al. 2001). Přibližným koncentracím CO<sub>2</sub>-eq odpovídajícím simulovanému radiačnímu působení díky antropogenním skleníkovým plynům a aerosolům by v roce 2100 pro zástupce SRES scénářů (B1, A1T, B2, A1B, A2 and A1FI) odpovídalo 600, 700, 800, 850, 1250 and 1550 ppm (IPCC 2007).



**Obrázek 2.6:** Přibližné změny v celkovém radiačním působení podle zástupců reprezentujících jednotlivé skupiny scénářů SRES a RCP.

### Koncentrační scénáře – RCP

Emisní scénáře byly v páté hodnotící zprávě IPCC (IPCC 2014) nahrazeny konceptem scénářů koncentrací, tzv. reprezentativní směry vývoje koncentrací (RCP; Moss et al. 2010) definované vědeckou komunitou.

Skupiny RCP scénářů jsou přímo označeny podle jejich přibližného celkového radiačního působení v roce 2100 vztáženému k předindustriálnímu období roku 1750, tedy  $2.6 \text{ W}\cdot\text{m}^{-2}$  pro RCP2.6,  $4.5 \text{ W}\cdot\text{m}^{-2}$  pro RCP4.5,  $6 \text{ W}\cdot\text{m}^{-2}$  pro RCP6.0 a  $8.5 \text{ W}\cdot\text{m}^{-2}$  pro RCP8.5. Z každé skupiny byl opět definován reprezentativní zástupce. RCP2.6 předpokládá vrchol koncentrací většiny skleníkových plynů do roku 2020 a následný pokles (Meinshausen et al. 2011). Zbývající trojice skupin RCP scénářů víceméně pokrývá rozptyl odhadovaných koncentrací do roku 2100 podle scénářů SRES. Porovnání změn v radiačním působení od roku 1980 mezi zástupci scénářů SRES (Houghton



et al. 2001) a RCP (Meinshausen et al. 2011) znázorňuje opět Obr. 2.6. Celkovému radiačnímu působení podle zástupců RCP scénářů (v pořadí RCP2.6, RCP4.5, RCP6 a RCP8.5) by v roce 2100 pak odpovídaly přibližné koncentrace skleníkových plynů a aerosolů následovně: 450, 650, 850 a 1370 ppm CO<sub>2</sub>-eq (IPCC 2014).

### 2.2.2 Klimatické modely

Úkolem klimatických modelů je prostřednictvím řešení pohybových a termodynamických rovnic metodami numerické matematiky dostatečně přesně popsat základní fyzikální i chemické procesy probíhající v klimatickém systému. Elementárním nástrojem modelování klimatu jsou cirkulační globální klimatické modely (GCM). Tyto modely mají tři základní složky, model atmosféry, model oceánu a model kryosféry (podrobněji např. McGuffie et Henderson-Sellers 2005), které byly (a stále jsou) postupně doplňovány o další modelované složky klimatického systému (síranové částice, aerosoly, uhlíkový cyklus, vegetace nebo atmosférická chemie). Kromě toho ale dochází samozřejmě i ke zpřesňování procesů v rámci složek a jejich vzájemných vazeb. V devadesátých letech se začaly používat modely, ve kterých je model atmosféry (AGCM) propojen s trojrozměrným modelem oceánu (OGCM), tyto modely se pak nazývají spojené (coupled) modely atmosféra-oceán (AOGCM). Samotné numerické řešení probíhá v síti buněk reprezentovanými gridovými body a v několika vertikálních hladinách. Běžné horizontální rozlišení GCM, tedy vzdálenost mezi gridovými body v atmosférické části modelu bývá 2 až 5° zeměpisné šířky a délky a vertikální rozdělení atmosféry bývá více než 20 hladin (v oceánické části modelu bývá rozlišení větší, zpravidla 0.5–1°; ČHMÚ 2011).

GCM jsou schopny úspěšně simulovat jevy velkých měřítek, zejména ve volné atmosféře, ale úspěšnost při simulování přízemních proměnných v menších měřítkách, které je požadováno pro studie dopadů změn klimatu, není dostatečná. Pro procesy menších měřítek, jako jsou např. konvektivní procesy a s nimi související srážkové události, je nutné využívat tzv. parametrizace, tedy vyjádření pomocí empirických vztahů.

Existuje několik metod jak přenést informace z GCM do menších měřítek, souhrnně se tyto metody nazývají downscaling. Vedle statistických metod (komplexní přehled poskytuje Maraun et al. 2010), kam patří např. statistický downscaling (Huth 2002) nebo stochastický generátor (Dubrovský 1997), je tu dynamický downscaling v podobě regionálních klimatických modelů (RCM). U RCM probíhá výpočet pouze na omezených oblastech (jedná se o tzv. Limited Area Models), čímž je umožněno dosáhnout s danou výpočetní kapacitou vyššího rozlišení, které se u současných modelů pohybuje nejčastěji od 50 do 10 km, ale i méně. Jedná se o modely vnořené do GCM, který je v této souvislosti nazýván jako řídicí model a který udává okrajové podmínky. RCM má nejen fyzikálně konzistentním způsobem interpolovat data z řídicího modelu do své podrobnější sítě, ale i vytvářet své vlastní cirkulace menších měřítek a zpětné vazby, vyvolané např. lokální orografií (Huth et al. 2003).

Srovnání globálních a regionálních modelů ukazují, že RCM lépe simuluje prostorové rozložení přízemní teploty a zejména srážek a také lépe zachycují vznik a postup synoptických systémů (Murphy 1999).

V posledních letech je stále větší pozornost věnována klimatickému modelování ve velmi vysokém rozlišení (horizontální rozlišení  $< 4$  km), které umožňuje řešení konvektivních procesů (jedná se o tzv. Convection-Permitting Models; např. Kendon et al. 2012, 2014; Ban et al. 2014; Prein et al. 2015). Tyto RCM nemusí spoléhat na parametrizační schematizace konvektivních procesů (avšak přes vysokou výpočetní náročnost), která jsou častým zdrojem nejistot a chyb v simulacích (Brockhaus et al. 2008; Hohenegger et al. 2008; Kendon et al. 2012; Westra et al. 2014).

### ■ Nejistoty v simulacích klimatických modelů

Simulace klimatických modelů jsou zatíženy řadou nejistot. Tyto nejistoty jsou spojeny zejména s počátečními a okrajovými podmínkami klimatických modelů a s jejich strukturou a parametry. Okrajovými podmínkami simulací globálních klimatických modelů jsou zejména množství dopadajícího slunečního záření a množství emisí/koncentrací skleníkových plynů (nejistota SRES/RCP scénáře), u modelů regionálních je okrajovou podmínkou průběh veličin simulovaných globálním klimatickým modelem. Nejistota spojená s počátečními podmínkami je dána tím, že pro inicializaci klimatického modelu nejsou k dispozici pozorování stavových veličin v dostatečném časovém a prostorovém rozlišení. Navíc, kvůli chaotické povaze klimatického systému, jsou výsledky simulace závislé na počátečním stavu systému (Hanel et al. 2011).

Pretel et al. (2011) udávají, že rozptyl změn v sezónních průměrných teplotách a srážkových úhrnech mezi jednotlivými RCM i mezi GCM postupně roste s časovým horizontem scénářů. Tento nárůst rozptylu se projevuje podobně pro RCM i GCM, z toho je usuzováno, že větší nejistoty do scénářů vnáší GCM, ze kterých pak RCM tyto nejistoty přebírají. Výsledek simulace je pak těmito nejistotami často ovlivněn více než volba vlastního SRES/RCP scénáře. Z pohledu srážkových extrémů dle Kyselý et al. (2011) je to patrné především v zimním období, kdy je vliv GCM, přesněji části popisující atmosférickou cirkulaci, zřetelnější než v letních měsících. V letním období pak hraje důležitější roli RCM a parametrizace procesů v menším měřítku.

Obecně je možno věrohodnost jednotlivé projekce klimatického modelu hodnotit podle schopnosti simulovat kontrolní klima nebo dle odchylky projekce daného klimatického modelu od projekcí ostatních klimatických modelů pro budoucí klima. Validace porovnáním simulovaných a naměřených dat odhalí systematické chyby v simulacích sledovaných klimatických prvků, tyto systematické chyby je poté možno redukovat pomocí postprocessingu, tedy aplikací statistických korekčních funkcí (aplikace některých metod lze nalézt např. v Déqué 2007). Bohužel schopnost modelu věrohodně simulovat současné klima ještě neznamená úspěšnost při simulaci budoucího klimatu.

Jedna samotná simulace, nebo nízký počet simulací může poskytovat zavádějící výsledky, proto se věrohodnost budoucí simulace analyzuje z celkového

souboru modelových běhů (tzv. ensemble). Modelové nejistoty je možno vyhodnotit na základě technik obyčejného či váženého průměrování (Weigel et al. 2010) nebo odvozením pravděpodobnostních scénářů (Harris et al. 2010).

Klimatické modely mají často tendence podhodnocovat vysoké srážkové úhrny a teplotní extrémy, což přímo souvisí s jejich rozlišením a numerickými přepočty mezi jednotlivými buňkami, které zajišťují stabilitu výpočtu v dlouhodobém běhu, čímž musí nutně docházet k omezování rozsahu variability simulovaných prvků (Déqué 2007).

Současný trend zpřesňování scénářů změn klimatu spočívá především v analýze fyzikálně realističtějších klimatických modelů, které mají zpravidla vyšší rozlišení, jež umožňuje lepší zachycení orografie a jejího vlivu. Samo o sobě zpravidla nevede k zužování rozpětí projekcí klimatických modelů, ale spíše k lepšímu popisu nejistot. Výzkum Kendon et al. 2012 zaměřený na klimatické modelování s velmi vysokým rozlišením (1.5 km) se specializací na extrémní srážky naznačuje, že pro zachycení konvektivních událostí je nezbytný přesnější popis lokální dynamiky oblačnosti, která je u současných modelů parametrizována. Představovaný RCM řešící termické konvekce je schopen simulovat kontrolní klima realističtěji než RCM s parametrizovanou konvekcí. Problematika simulace srážkových extrémů je podrobněji rozebrána v samostatné Kapitole 2.3.1.

## ■ Ensemblové simulace

Řada mezinárodních projektů po roce 2000 byla zaměřena na regionální klimatické modelování. Jedná se především o projekty PRUDENCE (Christensen et Christensen 2007), ENSEMBLES (van der Linden et Mitchell 2009) a CORDEX (Jacob et al. 2014), v jejichž rámci vznikly řady simulací RCM pro Evropu do konce 21. století.

Projekt PRUDENCE byl zaměřen na snížení nejistot v projekcích RCM a poskytl simulace RCM (řádově 70) pro kontrolní (1961–1990) a scénářové období (2070–2099) dle scénářů SRES A2 a B2 v rozlišení 50 a 25 km. Do projektu ENSEMBLES byla zapojena řada evropských institucí a bylo provedeno množství simulací GCM a RCM pro Evropu (ale i západní Afriku). Simulace RCM byly řízeny reanalýzou ERA40 (Uppala et al. 2005) pro čtyřicetileté období do roku 2000 nebo GCM pro období 1950–2100 (u některých simulací jen do roku 2050) dle scénáře SRES A1B v rozlišení 50 nebo 25 km. Cílem navazujícího projektu CORDEX (Coordinated Regional Climate Downscaling Experiment) bylo přispět k rozvoji downscalingu zpřístupněním kvalitních výstupů RCM s globálním pokrytím (Giorgi et Gutowski 2015). Simulace RCM provedené v rámci projektu jsou řízené reanalýzami minulého klimatu ERA-Interim (Dee et al. 2011) a různými GCM z projektu CMIP5 (Coupled Model Intercomparison Project; Taylor et al. 2012) dle scénářů koncentrací (RCP2.6, RCP4.5 a RCP8.5). Pro Evropskou doménu byly simulace prováděny ve dvou rozlišeních, 50 a 12.5 km. Konkrétní simulace RCM analyzované v disertační práci jsou blíže popsány v Kapitole 3.1.2.

## 2.3 Srážkové extrémy

Komplexní přehled o metodologii a výsledcích studií posuzujících trendy ve srážkových extrémech a povodňových situacích napříč Evropou uvádí Madsen et al. (2014). Pro 175 srážkoměrných stanic na území České republiky za období 1961–2005 vyhodnotil sezónní trendy v denních extrémních srážkách Kyselý (2009). Především v zimním období a západní části republiky byl znatelný statisticky významný nárůst ve všech indexech posuzující intenzivní srážky (většinou mezi 20 a 30 % za pozorované období). V letním období byly zjištěné trendy méně významné a prostorově nejednotné, nicméně i v letním období převládal nárůst v intenzivních srážkách. Naopak klesající trendy (spojené s poklesem sezónních úhrnů) byly pozorovány v jarním období.

Množství Evropských studií posuzující sub-denní srážkové extrémy je stále znatelně nižší v porovnání s analýzami dat v denním kroku (např. Lenderink et al. 2011). Hanel et al. (2016) analyzovali trendy intenzivních srážek v agregacích od 30 min do 24 h pro 17 stanic v ČR za období květen–září v letech 1961–2011. Pozorované trendy v posuzovaných indexech (sezónní srážkové maximum, index intenzity a podíl srážek přinášený v intervalech s vysokými úhrny) byly statisticky významné a pozitivní pro velkou část stanic (průměrný růst 2–9 % za 10 let pro všechny indexy).

Extrémní srážkové události s vysokými úhrny a krátkou dobou trvání (několika hodin) jsou nejčastěji spojovány s konvektivními bouřemi (Hand et al. 2004; Westra et al. 2014). Právě intenzivní srážkové události znatelně přispívají k celkovým srážkovým úhrnům v teplejší části roku, podle Rulfová et Kyselý (2013) konvektivní srážky představují zhruba 50 % celkových srážek v letním období. Na datech z 11 srážkoměrných stanic napříč ČR pro období 1982–2010, Rulfová et Kyselý (2014) posuzovali odděleně charakteristiky konvektivních a stratiformních srážek a zjistili pozitivní trendy (v prostorovém průměru) v konvektivních srážkách z pohledu celkového srážkového úhrnu a počtu srážkových dní pro období jara, léta a podzimu. Přestože trendy v extrémních konvektivních srážkách (6h a 24h sezónní maxima) byly více prostorově proměnlivé a statisticky méně významné, mírný trend růstu zde taktéž převládal.

### 2.3.1 Projekce RCM pro srážkové extrémy

Množství studií zabývajících se srážkovými extrémy v simulacích RCM vychází z denních dat, nicméně v posledních letech je stále více pozornosti věnováno datům podrobnějšího časového měřítka hodin nebo minut. Takovéto projekce však mohou být vzhledem ke složitosti fyzikálních procesů spojených se srážkovými extrémy v sub-denním měřítku (Stocker et al. 2013) a jejich zjednodušením v rámci parametrizací klimatického modelu zatíženy dalšími nejistotami. Většina v současnosti dostupných simulací RCM je provedena v rozlišení hrubším než 10 km, zatímco konvektivní procesy související s výskytem extrémních srážek probíhají ve znatelně menších měřících (podle Prein et al. 2015 menších než 4 km). RCM musí tedy spoléhat na parametrizační

schematizace konvektivních procesů, která jsou bohužel zdrojem znatelných nejistot a chyb v simulacích (Brockhaus et al. 2008; Hohenegger et al. 2008; Kendon et al. 2012) a zejména pak v simulacích sub-denních srážek (Westra et al. 2014).

Ze souboru simulací RCM řízených reanalýzou ERA40 pro ČR (pro období 1982–2000), Kyselý et al. (2016) zjistili podhodnocení intenzity konvektivních srážek a dále celkové podhodnocení konvektivních a nadhodnocení stratiformních srážkových extrémů, které ovšem vedlo k relativně dobré reprezentaci celkových denních srážkových extrémů. Denní srážkové extrémy byly v simulacích RCM dobře reprezentovány i v dalších evropských zemích (např. Nizozemsko: Hanel et Buishand 2010, nebo Dánsko: Gregersen et al. 2013). Naproti tomu schopnost RCM reprezentovat věrohodně hodinové srážkové extrémy je často zpochybňována (Hanel et Buishand 2010; Gregersen et al. 2013; Kendon et al. 2014).

Studie budoucích změn ve srážkových extrémech pro území ČR (Kyselý et Beranová 2009; Kyselý et al. 2011; Hanel et Buishand 2012) se shodují na nárůstu letních i zimních denních srážkových extrémů pro období do konce 21. století s nárůstem v rozmezí 16–26 % pro 50letý kvantil. Obdobné budoucí změny v denních extrémech podle RCM simulací byly zjištěny také pro další části Evropy (např. Frei et al. 2006; Hanel et Buishand 2011; Madsen et al. 2014).

Studie zabývající se potenciálními změnami v sub-denních srážkových extrémech nejsou tak časté jako analýzy denních dat. Pro Dánsko (Arnbjerg-Nielsen 2012) a Nizozemsko (Hanel et Buishand 2010) byly odhadovány vyšší nárůsty v hodinových extrémech v porovnání s denními a větší nárůst intenzit s kratší dobou trvání a delší dobou opakování. Z pohledu letních extrémních srážkových úhrnů byly zmiňovány nárůsty také v dalších částech Evropy (Lenderink et van Meijgaard 2008; Kendon et al. 2014), avšak objevují se i studie předpokládající pokles, např. pro Německo (Knote et al. 2010) nebo pro západní část Spojených států (Pan et al. 2011).

### ■ 2.3.2 Individuální srážkové události a jejich charakteristiky

Individuální srážkové události a analýza jejich charakteristik přináší alternativní pohled do studia sub-denních srážkových extrémů. Tento přístup založený na sledování charakteristik individuálních intenzivních srážkových událostí je využitelný též z pohledu mnoha hydrologických aplikací. Charakteristiky intenzivních srážkových událostí jako jsou úhrn, doba trvání, průměrná nebo maximální hodinová intenzita mohou poskytovat velmi důležité informace např. z pohledu problematiky městské hydrologie (např. Einfalt et al. 1998; Barbosa et al. 2012; Willems et al. 2012) nebo pro studie posuzující erozi půdy (např. Angulo-Martínez et Beguería 2009; Meusburger et al. 2012; Todisco 2014).

Existuje několik přístupů jak definovat individuální srážkovou událost (viz Peters et Christensen 2006; Ignaccolo et Michele 2010). Jedním z nejpoužívanějších je koncept minimálního času mezi událostmi, tzv. minimum inter-event

time (MIT; Dunkerley 2008), kdy události jsou definovány na základě minimálního časového intervalu mezi dvěma následujícími (ideálně nezávislými) událostmi. Jelikož optimální hodnota MIT se může značně lišit pro různé srážkové řady (jako v našem případě pro různé srážkoměrné stanice a simulace RCM), hodnota MIT je často volena na základě zavedené metodologie, např. 6h dle univerzální rovnice ztráty půdy (USLE; Wischmeier et Smith 1978). Jako minimální hodnota srážkového hodinového intervalu se nabízí 0.1 mm, tedy minimální srážka měřitelná běžnými srážkoměry. Stejná hodnota bývá aplikována také při evaluacích simulací RCM, kdy slouží k odfiltrování častých velmi nízkých hodnot (např. Willems et Vrac 2011; Kendon et al. 2014; Sunyer et al. 2016).

Pro účely studie byly posuzovány následující základní charakteristiky srážkových událostí:

- srážkový úhrn události  $D$  [mm],
- doba trvání události  $T$  [h],
- průměrná intenzita události  $R$  [mm·h<sup>-1</sup>]:

$$R = \frac{D}{T}, \quad (2.19)$$

- maximální 60min intenzita v průběhu události  $I_{60}$  [mm·h<sup>-1</sup>].

Dále byla posuzována dvojice indikátorů potenciálu erozivity srážkových událostí:

- energie srážkové události  $E$  [MJ·ha<sup>-1</sup>], dána podle Brown et Foster (1987) jako:

$$E = \sum_{t=1}^T 0.29d_t[1 - 0.72 \exp(-0.05d_t)], \quad (2.20)$$

kde  $d_t$  je srážkový úhrn během hodiny  $t$  v průběhu doby trvání události  $T$ , a

- index erozivity srážkové události  $EI_{60}$  [MJ·mm·ha<sup>-1</sup>·h<sup>-1</sup>]:

$$EI_{60} = E \cdot I_{60}. \quad (2.21)$$

Maximální 60min intenzita srážkové události ( $I_{60}$ ) a z ní vycházející index erozivity ( $EI_{60}$ ), jsou z důvodu časového rozlišení posuzovaných dat ze simulací RCM brány jako hodinové (ačkoliv metodologie USLE udává časové rozlišení pro tyto charakteristiky poloviční, tedy 30min), z toho důvodu je charakteristika  $EI_{60}$  brána pouze jako indikátor potenciálu erozivity srážkových událostí.

Kromě výše zmíněných charakteristik srážkových událostí byly analyzovány také následující sezónní (květen–září) charakteristiky:

- počet intenzivních srážkových událostí za sezónu  $N_{se}$  [-], a
- sezónní srážkový úhrn přinášený těmito intenzivními srážkovými událostmi  $S_{se}$  [mm].

## Kapitola 3

### Soubor publikací

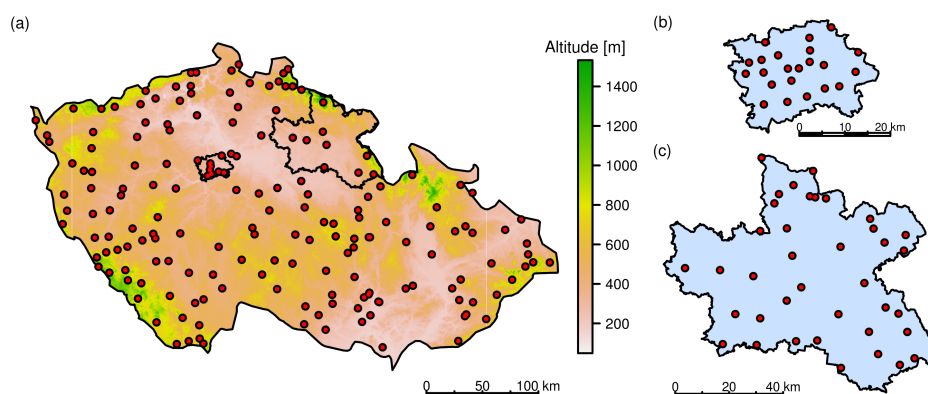
Následující kapitola komentuje soubor představovaných publikací, uvádí řešené území a data na nichž byly publikované výstupy založeny (Kapitola 3.1) a přináší stručný popis prováděných analýz a nejvýznamnějších dosažených poznatků týkající se korelační struktury srážkových dat (Kapitola 3.2), charakteristik srážkových událostí (Kapitola 3.3) a budoucích změn v charakteristikách srážkových událostí (Kapitola 3.4). Metodiky a veškeré výsledky jsou popsány detailně v jednotlivých studiích, které jsou obsahem příloh (viz Seznam příloh str. 63).

#### 3.1 Řešené území a použitá data

Studie byly prováděny na území České republiky. Orografie území je naznačena na Obr. 3.1a, přibližně dvě třetiny území se nacházejí v nadmořské výšce do 500 m, zatímco v horských oblastech v blízkosti hranic nadmořské výšky nezřídka přesahují 1200 m.

Srážky v ČR jsou typické prostorovou a časovou proměnlivostí, která je dána interakcí fyzikálních procesů jejich vzniku, atmosférické cirkulace a fyzikogeografických charakteristik území. V zimní části roku (říjen–březen) jsou srážky vázány hlavně na přechody frontálních systémů a tlakových níží především s vrstevnatou oblačností a jsou charakterizovány zpravidla menší intenzitou a delším trváním. Naopak v měsících letního půlroku (duben–září) jsou srážky nezřídka spojeny s výstupnými konvekčními pohyby vzduchu s tvorbou kupovité až bouřkové oblačnosti. Takovéto srážky mají zpravidla kratší trvání a větší intenzitu. Vlastní množství srážek je ovlivněno charakterem synoptické situace, kdy s ohledem na její postup a dosah se mohou projevat značné prostorové rozdíly. Jde především o situace, které přinášejí do střední Evropy vlhký vzduch z oblasti Atlantského oceánu nebo o typy s přílivem teplého a vlhkého vzduchu z oblasti Středozemního moře. Prostorové rozdíly jsou navíc zvýrazněny orografickými vlivy, k nimž patří zvyšování množství srážek s růstem nadmořské výšky a vlivy expozice, kdy s ohledem na směr proudění mají návětrné svahy vyšší úhrny než svahy závětrné (Tolasz 2007).

Průměrný roční srážkový úhrn měřený na stanicích v ČR za období 1961–2000 se pohybuje zhruba od 420 mm ve středo-západní části republiky až



**Obrázek 3.1:** Srážkoměrné stanice v použitých datasetech: (a) Česká republika, (b) Praha, (c) Královéhradecký kraj.

po hodnoty přesahující 1200 mm v horských oblastech. Republikový průměr je potom kolem 670 mm, přičemž nejvyšší úhrny jsou obvykle zaznamenávány v červnu a v červenci. Téměř dvě třetiny ročních srážkových úhrnů v republikovém průměru pak spadnou v letní polovině roku.

V následujících podkapitolách jsou popsány veškeré srážkové datové řady použité v publikovaných pracích.

### 3.1.1 Pozemní srážkoměrná data

Z pozemních srážkoměrných měření byly využity tři datasety, které jsou popsány níže. Ne každá stanice ovšem poskytovala data v kompletním časovém pokrytí tak jak je udáváno, konkrétní výběry z datasetů jsou pak podrobněji popsány v příslušných kapitolách publikovaných článků.

- Královéhradecký kraj, měsíční data, 1981–2011, 38 stanic (pokrytí 1 stanice na 125 km<sup>2</sup>; Obr. 3.1c), data využita v článku A.

Data byla poskytnuta a kontrolována Českým hydrometeorologickým ústavem, chybějící hodnoty byly doplněny podle procedury jak ji popisuje Štěpánek et al. (2011), tedy pomocí interpolace IDW (s exponentem  $r = 3$ ).

- Česká republika, hodinová data, 1961–2009, 180 stanic (1 stanice na 438 km<sup>2</sup>; Obr. 3.1a), využito v publikacích B, C.

Data poskytl Český hydrometeorologický ústav, původní dataset v 10min rozlišení založený na digitalizovaných a doplněných záznamech ombrografů (viz Květoň et al. 2004) byl ještě kontrolován v práci Hanel et Máca (2014), kteří porovnávali denní data agregovaná z 10min rozlišení se standartními denními záznamy. Hanel et Máca (2014) považovali denní data za nespolehlivá, pokud rozdíl představoval více než 1.5 mm pro dny se srážkovým úhrnem pod 15 mm nebo 10 % pro denní úhrny nad 15 mm. Roky, které obsahovaly takovýchto nepřesných denních záznamů více než 10 %, byly z datasetu vyřazeny. Vzhledem k nespolehlivosti záznamů



v zimním období, bylo navíc využito jen dat z období květen–září. Toto období, charakterizující teplejší část roku pro niž jsou intenzivní krátkodobé srážkové události charakteristické, bylo pro přehlednost označeno jako „sezóna“.

- Praha, hodinová data, 2002–2011, 22 stanic (1 stanice na 23 km<sup>2</sup>; Obr. 3.1b), využito v článku B.

Pražská srážková data poskytla Pražská vodohospodářská společnost a.s., chybějící data v tomto případě nebyla závažným problémem, jelikož byla využita pouze pro stanovení vlivu počtu stanic na efekt prostorového průměrování srážkových dat.

### 3.1.2 Srážkové řady simulované RCM

Přehled simulací RCM z nichž byla analyzována hodinová srážková data na území ČR je obsahem Tabulky 3.1.

Simulace HadRM3, HIRHAM5 a RACMO2 byly provedeny v rámci projektu ENSEMBLES (van der Linden et Mitchell 2009), simulace RCA4 a RACMO2E pak v rámci evropské domény projektu CORDEX (Jacob et al. 2014). Simulace CLM jsou dostupné z databáze World Data Center for Climate přes rozhraní Climate and Environmental Retrieval and Archive (CERA; <http://cera-www.dkrz.de/WDCC/ui/>). Pro účely práce byly využity dva datasety simulací CLM v hodinovém rozlišení (které byly spojeny), konkrétně běh pro 20. století (Lautenschlager et al. 2009a) a simulace pro 21. století dle scénáře SRES A1B (Lautenschlager et al. 2009b).

Ze simulací HadRM3 byly k dispozici také dvě simulace řízeny GCM s přenastavenou fyzikální parametrizací (tzv. „perturbed physics“, více viz Collins et al. 2006). Vedle normálního datasetu simulace se standardně nastavenou parametrizací (HadRM3Q0), je HadRM3Q3 verze s nízkou citlivostí na externí vlivy a verze HadRM3Q16 zahrnující parametrizaci naopak vedoucí k vysoké citlivosti na externí působení. Tyto pozměněné parametrizace jsou aplikovány jak pro řídicí GCM (HadCM3) tak pro samotné RCM (HadRM3).

Výstupy modelů jsou dostupné ve vlastní pravidelné síti čtvercových grid-boxů v souřadnicích s pootočeným pólem (rotated latitude-longitude grid), pouze výstupy z CLM jsou promítnuty do běžných sférických souřadnic (regular non-rotated grid). Ze simulací RCM byly vybrány všechny gridboxy pokrývající nebo alespoň zasahující do území ČR. Rozdíl v hustotě sítě mezi nejpodrobnějším (12.5 km) a nejhrubším rozlišením RCM simulací (50 km) je patrný z Obr. 3.2.

## 3.2 Prostorová korelační struktura v měřených srážkových datech

Na měsíčních srážkových úhrnech v Královéhradeckém kraji za období 1981–2011 byly testovány tři způsoby vyjádření mezistaniční korelace srážkových dat (článek je obsahem Přílohy A). Mezistaniční korelační koeficienty – Pearsonův,

Akronym	Řídicí model	Scénář	Rozlišení	Gridboxy
<b>CLM 2.4.11</b> (Böhm et al. 2006)				
Max Planck Institute for Meteorology (MPI), Germany				
CLM	ECHAM5/MPIOM	SRES A1B	22 km (0.2°)	301
<b>HadRM3.0</b> (Collins et al. 2011)				
Met Office Hadley Centre (MOHC), UK				
HadRM3Q0_HadCM3	HadCM3Q0	SRES A1B	25 km (0.22°)	173
HadRM3Q3_HadCM3	HadCM3Q3	SRES A1B		
HadRM3Q16_HadCM3	HadCM3Q16	SRES A1B		
HadRM3Q0_ERA40	ERA40	reanalýza		
HadRM3Q3_ERA40	ERA40	reanalýza		
HadRM3Q16_ERA40	ERA40	reanalýza		
<b>HIRHAM5</b> (Christensen et al. 2007)				
Danish Meteorological Institute (DMI)				
H5_ARPEGE	ARPEGE	SRES A1B	25 km (0.22°)	173
H5_BCM	BCM	SRES A1B		
H5_ECHAM5	ECHAM5-r3	SRES A1B		
<b>RACMO2.1</b> (van Meijgaard et al. 2008)				
Royal Netherlands Meteorological Institute (KNMI)				
RACMO2_ECHAM5	ECHAM5-r3	SRES A1B	25 km (0.22°)	173
RACMO2_MIROC	MIROC3.2	SRES A1B		
<b>RACMO22E</b> (van Meijgaard et al. 2012)				
Royal Netherlands Meteorological Institute (KNMI)				
RACMO22E	ICHEC-EC-EARTH	RCP4.5, RCP8.5	12.5 km (0.11°)	607
<b>RCA4.0</b> (Kupiainen et al. 2011; Samuelsson et al. 2011)				
Swedish Meteorological and Hydrological Institute (SMHI)				
RCA4_CanESM2	CCCma-CanESM2	RCP4.5, RCP8.5	50 km (0.44°)	52
RCA4_CM5A-MR	IPSL-CM5A-MR	RCP4.5, RCP8.5		
RCA4_CNRM-CM5	CNRM-CM5	RCP4.5, RCP8.5		
RCA4_EC-EARTH	ICHEC-EC-EARTH	RCP2.6, RCP4.5, RCP8.5		
RCA4_ESM2M	NOAA-GFDL-ESM2M	RCP4.5, RCP8.5		
RCA4_ESM-LR	MPI-ESM-LR	RCP4.5, RCP8.5		
RCA4_HadGEM2-ES	MOHC-HadGEM2-ES	RCP4.5, RCP8.5		
RCA4_MIROC5	MIROC5	RCP4.5, RCP8.5		
RCA4_NorESM1-M	NCC-NorESM1-M	RCP4.5, RCP8.5		
RCA4 ERAINT	ERA-INTERIM	reanalýza		


**Tabulka 3.1:** Přehled analyzovaných simulací RCM.

Spearmanův a Kendallův byly vypočítány na základě 38 datových řad a následně proloženy šesticí teoretických korelačních modelů s jedním až třemi parametry (viz Kapitola 2.1.4 a Tabulka 2.1). Přesnost proložení jednotlivými korelačními modely byla porovnávána na základě směrodatné odchylky reziduí:

$$\sigma = \sqrt{\frac{SSE}{n-p}}, \quad (3.1)$$

kde  $SSE$  je reziduální součet čtverců,  $n$  je počet datových záznamů a  $p$  počet odhadovaných parametrů.

Kromě srovnání modelů proložení jednotlivých korelačních koeficientů, posouzení vlivu jednotlivých parametrů a analýzy vzájemných vztahů mezi parametry korelačních modelů, byla u korelačních parametrů následně sledována také jejich časová a prostorová variabilita. Vyhodnocena byla dlouhodobá časová variabilita a vliv sezonality na odhadované parametry. V rámci prostorové variability byly sledovány změny parametrů s ohledem na nadmořskou




**Obrázek 3.2:** Pokrytí České republiky gridboxy (zobrazeny jako středové body gridboxů) pro simulace RCM v prostorovém rozlišení 12.5 km (malé body, 607 gridboxů) a 50 km (velké body, 52 gridboxů).

výšku a jejich prostorové rozložení v rámci studovaného regionu.

U všech tří přístupů výpočtu korelačních koeficientů byla pozorována anizotropie ve směru západ-východ ve větších vzdálenostech než 40 km (nejvýraznější v případě Pearsonova  $r$ , viz Obr. 2.2). Tato anizotropie je ovšem způsobena zejména nedostatečným staničním pokrytím v kombinaci s okrajovým efektem, celkovou prostorovou strukturu jsme tedy považovali za izotropní. Z přímého srovnání hodnot korelačních koeficientů je patrné, že korelační koeficienty počítané metodikou podle Spearmana dosahují podobných hodnot jako v případě Pearsonova korelačního koeficientu (jsou zhruba o 1 % vyšší), zatímco Kendallova metodika poskytuje znatelně nižší absolutní hodnoty korelace (o 22 % ve srovnání s Pearsonem).

Všechny korelační modely s jedním parametrem  $c_0$  (correlation distance) se ukázaly jako nedostatečné pro vyjádření mezistaniční korelace srážkových úhrnů ve vzdálenostech do 100 km vzhledem k neschopnosti zachytit rychlý pokles v malých vzdálenostech (což je nejvíce patrné v případě Kendallova  $\tau$  z Obr. 3.3c). Velmi důležitým je druhý parametr  $s_0$  (shape factor), který v kombinaci s parametrem  $c_0$  právě tyto změny dokáže dobře zachytit (tvar proložené křivky vykazuje strmější pokles v malých vzdálenostech a naopak mírnější ve velkých vzdálenostech, opět viz Obr. 3.3). Třetí parametr  $c_1$  (nugget) v případě dat našeho časového (měsíční úhrny) a prostorového rozlišení (žádné stanice nejsou v bezprostřední blízkosti u sebe) prakticky pozbývá významu. Matérn a Exponenciální model se dvěma parametry tak vykazují nejvhodnější vyjádření poklesu korelace se vzdáleností (parametry obou modelů vykazují silnou vzájemnou lineární závislost). Mírná rozdílnost mezi těmito dvěma modely se projevuje až při vzdálenostech vyšších než 100 km a proto, i vzhledem k náročnosti výpočtu, se jeví pro vyjádření korelace v regionálním měřítku jako optimální volba Exponenciální dvouparametrický korelační model. Nejnižších hodnot směrodatné odchylky residuí  $\sigma$  (při prokládání všemi teoretickými modely) bylo dosahováno při využití korelačních koeficientů podle Spearmana.




**Obrázek 3.3:** Závislost korelačních koeficientů na vzdálenosti včetně proložení korelačními modely pro (a) Pearsonův korelační koeficient  $r$ , (b) Spearmanův koeficient pořadové korelace  $\rho$  a (c) Kendallův koeficient konkordance  $\tau$ .

### 3.2.1 Časová variabilita v parametrech korelačních modelů

Z analyzovaných 31 let srážkových záznamů (v desetiletých pohyblivých výřezech) je z lineárního proložení patrný růst v parametrech vzdálenosti  $c_0$  a to zejména pro víceparametrické korelační modely. Tyto modely vykazují také vyšší výkyvy v hodnotách parametru  $c_0$  v průběhu dekad, zatímco hodnota parametru tvaru  $s_0$  zůstává stabilnější. Výkyvy v hodnotách parametru  $c_0$  jsou ve vztahu s celkovými naměřenými srážkovými úhrny v průběhu dekad (vyšší parametr se vyskytuje v dekadách s vyššími úhrny, přičemž hodnoty parametru celkově rostou stejně jako srážkové úhrny). Vliv sezonality na korelační koeficienty je výrazný, vyšší hodnoty mezistaniční korelace v podzimním a zimním období jsou promítnuty v hodnotách parametru  $c_0$ , který je v těchto obdobích výrazně vyšší než na jaře a v létě (tři až čtyřikrát v závislosti na korelačním modelu).

### 3.2.2 Prostorová variabilita v parametrech korelačních modelů

Stejně jako na průměrné srážkové úhrny, i na prostorovou variabilitu parametrů korelačních modelů má významný vliv nadmořská výška. Zatímco srážkové úhrny s nadmořskou výškou rostou, v korelačních modelech vliv stoupající nadmořské výšky reflektuje zejména parametr tvaru  $s_0$  a to poklesem. V malých vzdálenostech je pokles korelace ve vyšších nadmořských výškách strmější. Hodnoty parametrů byly sledovány v analyzovaném regionu na modelu Voroného polygonace odvozeného na základě vzájemných korelací jednotlivých srážkoměrných stanic jak zobrazuje Obr. 3.4. Na příkladu Pearsonova  $r$  a Exponenciálního tříparametrického modelu je patrná, kromě vlivu nadmořské výšky na parametr  $s_0$  (který je v jižní nížinné části kraje výrazně vyšší), také vzájemná závislost mezi parametry  $c_0$  a  $s_0$ , kdy se nejvyšší hodnoty  $c_0$  vyskytují v oblastech s nejnižšími hodnotami  $s_0$  (stejně vzory jsou charakteristické také pro Spearmanovo a Kendallovo vyjádření korelace). V jižní části regionu (v oblastech vysokých hodnot parametru  $s_0$ ) se u některých stanic projevuje také mírný pokles v nugget parametru  $c_1$ , který jinak celkově v regionu měl zanedbatelný vliv (nejcitlivější na změny tohoto parametru se jeví Kendallovo vyjádření korelace).



**Obrázek 3.4:** Model Voroného polygonace Královéhradeckého kraje s hodnotami korelačních parametrů pro Exponenciální tříparametrický model aplikovaný na Pearsonův korelační koeficient.

## 3.3 Srážkové události v měřených datech a simulacích RCM

Intenzivní srážkové události byly analyzovány na území České republiky, data ze staničních měření byla využita pro validaci simulací RCM pro období 1981–2000 (článek je obsahem Přílohy B).

Srážkové události byly definovány na základě 6h intervalu mezi událostmi (dle konceptu MIT) a minimálního hodinového srážkového intervalu 0.1 mm. Dále analyzovány byly pouze intenzivní události definované na základě metodologie USLE, t.j. bodové srážkové události mající úhrn větší než 12.7 mm



oproti událostem odvozených z bodových dat (o 1.4–2 události v závislosti na prostorovém rozlišení, tedy až o 26 %). Průměrné srážkové úhrny událostí ( $D$ ) v prostorově průměrovaných datech jsou nižší ve srovnání s bodovými daty, avšak díky vyššímu počtu intenzivních událostí jsou celkové sezónní úhrny přinášené těmito událostmi ( $S_{se}$ ) poměrně dobře reprezentovány (v průměru +3 % oproti „bodovým“ událostem).

Všechny charakteristiky individuálních intenzivních událostí v průměru (podle poměru  $rt_m$ ) jsou v prostorově průměrovaných datech nižší než v bodových datech, avšak podle kvantilového poměru  $rt_p$  jsou v některých charakteristikách patrně rozdílnosti s rostoucím kvantilem. Zatímco srážkové úhrny ( $D$ ) „prostorových“ událostí jsou v celém rozsahu o 10–20 % nižší, doby trvání ( $T$ ) krátkých „prostorových“ událostí jsou srovnatelné s „bodovými“

Akronym	$N_{se}$	$S_{se}$	$D$	$T$	$R$	$I_{60}$	$E$	$EI_{60}$
<b>Bodová měření (průměr na stanici)</b>	7.62	194.7	25.0	19.7	2.37	9.38	3.66	48.75
<b>Prostorově průměrovaná měření</b>								
12.5 km	9.41	205.6	21.4	16.2	2.14	7.20	2.92	28.88
25 km	9.00	197.9	21.6	17.1	2.02	6.82	2.89	26.16
50 km	9.66	198.8	20.2	18.1	1.73	5.68	2.56	18.77
<b>Sumarizace simulací RCM</b>								
Průměr z RCM	10.82	223.4	20.0	23.2	1.04	2.93	2.02	7.88
12.5 km RCM	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96
25 km RCM	10.54	215.2	19.8	22.3	1.08	3.12	2.04	9.08
50 km RCM	11.08	235.0	20.5	23.9	1.02	2.60	2.01	5.97
<b>RCM simulace (průměr na gridbox)</b>								
CLM	10.84	208.9	19.2	22.8	1.06	3.91	2.09	13.58
HadRM3Q0_ERA40	11.83	239.2	19.6	20.6	1.19	3.74	2.11	12.28
HadRM3Q3_ERA40	10.05	169.5	16.5	18.8	1.00	2.90	1.70	6.99
HadRM3Q16_ERA40	11.40	226.7	19.1	21.5	1.08	3.21	1.98	9.56
HadRM3Q0_HadCM3	11.33	278.3	23.9	23.2	1.28	4.20	2.62	16.90
HadRM3Q3_HadCM3	10.51	209.0	19.5	21.6	1.04	3.01	2.01	8.56
HadRM3Q16_HadCM3	10.31	231.7	21.6	23.2	1.11	3.48	2.27	11.84
H5_ARPEGE	7.61	132.7	16.9	17.4	1.19	2.83	1.70	5.67
H5_BCM	12.70	246.6	18.5	20.5	1.08	2.51	1.83	5.27
H5_ECHAM5	11.11	224.7	19.0	20.5	1.13	2.91	1.92	6.54
RACMO2_ECHAM5	9.42	191.0	20.2	26.6	0.91	2.81	2.02	7.69
RACMO2_MIROC	9.67	217.8	22.4	31.1	0.85	2.74	2.24	8.63
RACMO22E	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96
RCA4_CanESM2	10.65	221.5	20.0	23.9	1.01	2.63	1.97	6.01
RCA4_CM5A-MR	11.14	219.4	19.2	22.7	1.02	2.53	1.89	5.46
RCA4_CNRM-CM5	12.38	289.2	22.5	25.0	1.07	2.77	2.23	6.94
RCA4_EC-EARTH	11.11	249.7	21.7	26.4	0.95	2.44	2.11	5.86
RCA4_ERAIN	10.20	208.1	19.9	23.0	1.03	2.67	1.97	6.04
RCA4_ESM2M	12.08	275.6	22.2	26.1	0.99	2.53	2.17	6.25
RCA4_ESM-LR	11.45	257.9	21.9	25.0	1.06	2.72	2.17	6.65
RCA4_HadGEM2-ES	9.93	173.3	16.8	21.6	0.93	2.35	1.62	4.35
RCA4_MIROC5	10.11	221.2	21.2	23.0	1.11	2.83	2.11	6.67
RCA4_NorESM1-M	11.76	233.8	19.2	21.9	1.03	2.57	1.89	5.41

**Tabulka 3.2:** Počet intenzivních srážkových událostí za sezónu ( $N_{se}$  [-]), sezónní srážkový úhrn přinášený intenzivními událostmi ( $S_{se}$  [mm]) a průměrné charakteristiky individuálních srážkových událostí ( $D$  [mm],  $T$  [mm],  $R$  [mm·h<sup>-1</sup>],  $I_{60}$  [mm·h<sup>-1</sup>],  $E$  [MJ·ha<sup>-1</sup>] and  $EI_{60}$  [MJ·mm·ha<sup>-1</sup>·h<sup>-1</sup>]) pro kontrolní období 1981–2000 v měřených datech a v simulacích RCM.

pro 12.5 a 25 km rozlišení a vyšší (o  $\approx 20$  %) pro 50 km rozlišení. Doby trvání dlouhých událostí jsou poté pro všechna prostorová rozlišení kratší v porovnání s bodovými daty (o  $\approx 16$  % v průměru). Průměrná intenzita událostí ( $R$ ) je v prostorových datech srovnatelná s bodovými pro malé hodnoty načež výrazně klesá s rostoucími hodnotami. Ostatní „prostorové“ charakteristiky jsou nižší než „bodové“ a dále klesají s rostoucím kvantilem.

Ačkoliv většina „prostorových“ charakteristik klesá s hrubším rozlišením prostorového průměrování (kromě doby trvání, kde je efekt prostorového rozlišení opačný), rozdílnosti mezi charakteristikami v jednotlivých rozlišeních jsou vcelku malé, zvláště pokud vezmeme v úvahu celkové rozdílnosti v charakteristikách napříč řešeným územím. Z tohoto důvodu jsme prostorově průměrovaná data pro posouzení poměru  $rt_p$  dále nerozlišovali podle rozlišení, ale v úvahu brali pouze průměr ze všech tří rozlišení a potenciální rozptyl, daný minimálním 5% a maximálním 95% kvantilem z rozdělení charakteristik všech analyzovaných okolí (viz Obr. 3.5).

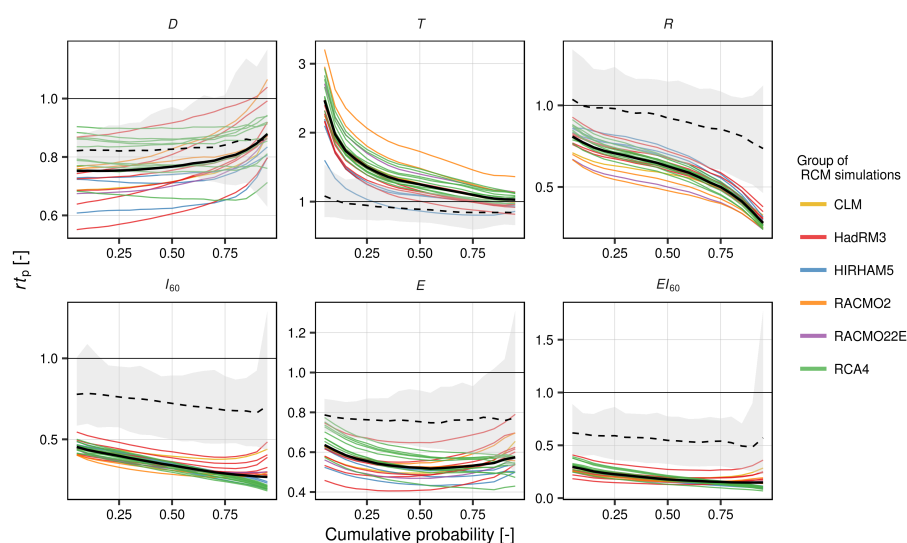
### 3.3.2 Charakteristiky srážkových událostí v simulacích RCM

Simulované charakteristiky intenzivních srážkových událostí byly porovnány s měřeními bodovými daty podle ukazatelů obdobně jak je popsáno v předcházející Kapitole 3.3.1 s tím rozdílem, že „prostorové“ charakteristiky byly v tomto případě vypočteny ze simulovaných hodnot v gridboxech a „bodové“ charakteristiky ze všech stanic splňující požadavky na data (nejméně 10 let záznamu ve validačním období 1981–2000).

Uvažované poměry se v případě posuzování simulací RCM sestávají z kombinace zkusení charakteristik v simulacích RCM a efektu prostorového průměrování měřených dat, proto byly simulované charakteristiky dále posuzovány také vzhledem k charakteristikám srážkových událostí z prostorově průměrovaných měřených dat (jako příklad je uvedeno porovnání kvantilových poměrů  $rt_p$  na Obr. 3.5).

Z porovnání kvantilových poměrů  $rt_p$  pro RCM simulace a prostorově průměrovaná měření posuzovaných charakteristik srážkových událostí (Obr. 3.5) je patrné, že nejlépe jsou reprezentovány srážkové úhrny ( $D$ ) a to zejména pro události s vysokými úhrny (nízké úhrny jsou v průměru všech simulací RCM mírně podhodnoceny). Doby trvání srážkových událostí ( $T$ ) jsou reprezentovány relativně dobře jen pro dlouhé události, oproti tomu trvání nejkratších srážkových událostí je vysoce nadhodnocené (v průměru 2.3krát, t.j. o 4.1 h). Rozdíl mezi simulovanou a měřenou průměrnou intenzitou srážkových událostí ( $R$ ) roste s rostoucím kvantilem. Silnější podhodnocení nejvyšších  $R$  je způsobeno zřetelným nadhodnocením nejkratších dob trvání událostí ( $T$ ). Maximální 60min intenzita v průběhu události ( $I_{60}$ ) je silně podhodnocena (v průměru o 30 %) přičemž silnější podhodnocení se vyskytuje zpravidla opět pro vyšší hodnoty. Indikátory potenciálu erozivity jsou též podhodnocené. Energie srážkové události ( $E$ ) závisí na hodnotách srážkového úhrnu ( $D$ ) a době trvání ( $T$ ), kdy nadhodnocení dob trvání ( $T$ ) pro krátké události částečně kompenzuje podhodnocení nízkých úhrnů ( $D$ ), což vede k 15% pod-





**Obrázek 3.5:** Průměrné kvantilové poměry ( $rt_p$ ) pro charakteristiky srážkových událostí ze všech gridboxů simulací RCM. Plná černá čára zobrazuje průměr ze všech simulací RCM. Šedé oblasti vyznačují obálku pro kvantilové poměry z prostorově průměrovaných dat (vymezenou minimálním 0.05 a maximálním 0.95 kvantilem ze všech okolí) a přerušovaná černá čára udává průměr ze tří posuzovaných prostorových rozlišení.

hodnocení energie ( $E$ ) v simulacích RCM pro nízké kvantily. S rostoucím kvantilem rozdíl mezi simulacemi RCM a měřenými daty roste, avšak díky dobré reprezentaci úhrnů ( $D$ ) vysokých hodnot je podhodnocení  $E$  menší v nejvyšších kvantilech.

Rozdílnosti v histogramech rozdělení četnosti srážkových událostí vyjádřené poměrem  $rt_f$  ukazují v simulacích RCM podhodnocení počtu krátkých událostí s dobou trvání ( $T$ ) do 10 h. Další významný rozdíl je patrný v počtu událostí s malými průměrnými ( $R$ ) a zejména malými maximálními 60min intenzitami ( $I_{60}$ ), jejichž počet je v simulacích RCM nadhodnocen. Důsledkem je pak nedostatek událostí s vyššími intenzitami ( $R > 3 \text{ mm}\cdot\text{h}^{-1}$  a  $I_{60} > 6 \text{ mm}\cdot\text{h}^{-1}$ ), které jsou v prostorově průměrovaných datech výrazně častější.

Počet intenzivních srážkových událostí za sezónu ( $N_{se}$ ) je podle poměru  $rt_m$  v simulacích RCM vyšší ve srovnání s bodovými daty (až o 46 %), nicméně ve srovnání s prostorově průměrovanými daty je rozdíl pouze 16% (tedy 1.5 události na sezónu). Rozdíly mezi simulacemi RCM a měřenými daty v sezónních úhrnech přinášených těmito intenzivními událostmi ( $S_{se}$ ) jsou v rozmezí  $-33$  až  $+48$  %, přičemž v průměru simulace RCM ukazují na sezónu  $+11$  % (23 mm) ve srovnání s prostorově průměrovanými sezónními úhrny.

### 3.3.3 Vliv nadmořské výšky

U charakteristik srážkových událostí simulovaných RCM byl sledován také vliv nadmořské výšky. Lineární regresní model závislosti byl aplikován na vztah mezi  $p$ -tým kvantilem (pro  $p = 0.05, 0.1, \dots, 0.95$ ) rozdělení charakteristik

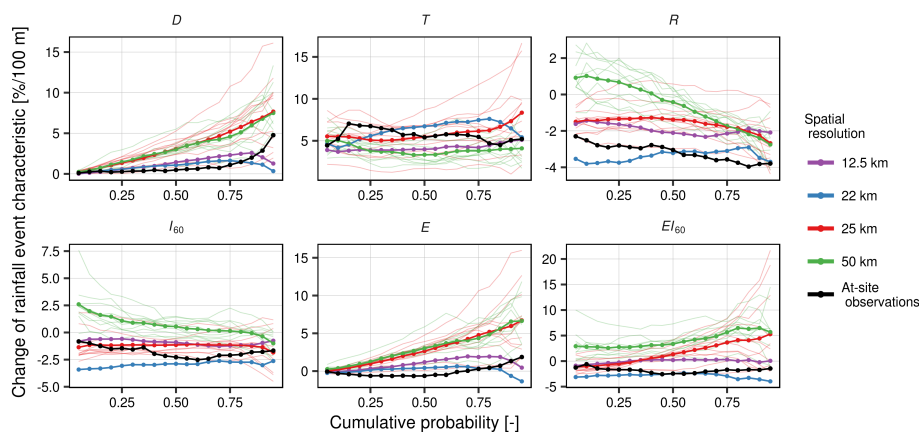
událostí a nadmořskou výškou pro simulace RCM a měřená bodová data. Vliv nadmořské výšky byl následně analyzován jako změna charakteristiky na 100 m nadmořské výšky:

$$y_p = \frac{100\beta + \alpha}{\alpha} \cdot 100 [\%], \quad (3.2)$$

kde  $\beta$  je regresní koeficient (slope) a  $\alpha$  intercept.

Z Obr. 3.6 je pro většinu simulovaných charakteristik patrná relativně dobrá reprezentace závislosti na nadmořské výšce v porovnání s bodově měřenými daty (trendy pro všechny kvantily jsou v rozmezí  $-5$  až  $10$  % na 100 m), přestože několik simulací s rozlišením 25 a 50 km vykazuje silnější závislost na nadmořské výšce pro nejvyšší či nejnižší kvantily charakteristik. Celkově je lineární závislost na nadmořské výšce v RCM simulacích statisticky významná (na hladině významnosti 0.05) pro 68 % všech posuzovaných charakteristik pro všechny kvantily, ačkoliv průměrná ( $R$ ) a maximální 60min intenzita ( $I_{60}$ ) vykazují menší procento statisticky významně závislých hodnot (jen 58 a 51 %, zatímco v pozorovaných datech se jedná o 100 a 95 % všech hodnot).

Počet intenzivních srážkových událostí za sezónu ( $N_{se}$ ) a sezónní úhrny přinášené těmito událostmi ( $S_{se}$ ) jsou v simulacích RCM silně závislé na nadmořské výšce. Z pohledu hodnot regresního koeficientu  $\beta$  je závislost  $N_{se}$  ( $S_{se}$ ) 1.8–7.7krát (1.1–5.9krát) silnější v simulacích RCM než v pozorovaných datech. Výsledkem tedy je, že pro většinu simulací RCM nejsou tyto lineární závislosti v porovnání s bodovými daty příliš realistické a pouze simulace ve vyšším rozlišení (12.5 a 22 km) zachycují závislost adekvátně i ve srovnání s pozorovanými daty (nárůst v pozorovaných datech je 8.4 a 13.4 % na 100 m pro  $N_{se}$  a  $S_{se}$ ).



**Obrázek 3.6:** Závislost mezi charakteristikami intenzivních srážkových událostí a nadmořskou výškou pro simulace RCM a bodová měřená data. Závislost je vyjádřena jako změna charakteristiky v % se 100 m nadmořské výšky pro odpovídající pravděpodobnosti podle distribučních funkcí charakteristik srážkových událostí. Prostorové rozlišení RCM simulací je odlišeno barvou, tučné čáry s body (pro kvantily rozdělení  $p = 0.05, 0.1, \dots, 0.95$ ) zobrazují průměr z RCM simulací podle prostorového rozlišení.

### 3.4 Simulované budoucí změny v charakteristikách srážkových událostí

Změny v charakteristikách srážkových událostí simulovaných RCM pro dvojici scénářových období (SCE1: 2020–2049 a SCE2: 2070–2099) byly posuzovány vzhledem ke kontrolnímu období 1981–2000 (článek je obsahem Přílohy C). Události byly definovány stejně jako v případě validace v kontrolním období a opět byly vybrány pouze intenzivní srážkové události za období květen–září. Obdobně jako pro validaci simulovaných charakteristik byly využity tři ukazatele k vyhodnocení změn mezi scénářovým a kontrolním obdobím a to pro:

1. průměrnou charakteristiku pro každý gridbox náležící do řešeného území (ukazatel změny označen jako  $rts_m$ ; tato změna byla opět analyzována jak v charakteristikách individuálních intenzivních událostí tak v charakteristikách sezónních),
2.  $p$ -tý kvantil distribuční funkce rozdělení charakteristik individuálních srážkových událostí pro každý gridbox pro kumulativní četnosti  $p = 0.05, 0.1, \dots, 0.95$  (označeno jako kvantilová změna  $rts_p$ ),
3. prostorově průměrované roční četnosti výskytů podle histogramů hodnot charakteristik individuálních srážkových událostí (histogramová změna  $rts_f$ ).


Ačkoliv v bližším scénářovém období se počet intenzivních srážkových událostí ( $N_{se}$ ) oproti kontrolnímu období příliš nemění, v období pro závěr 21. století (2070–2099) je již znatelný pokles v počtu intenzivních událostí pro všechny simulace RCM (až o 19 %, tedy dvě události za sezónu). Změny v sezónních úhrnech přinášených těmito událostmi ( $S_{se}$ ) vykazují proměnlivost pro různé simulace RCM, a jsou opět vyšší ve vzdálenějším období (změny dosahují rozptylu od 20% úbytku po 19% nárůstu ve srážkových úhrnech pro různé RCM).

Podle předpokládaných změn v průměrných charakteristikách srážkových událostí ( $rts_m$  pro úhrn  $D$ , dobu trvání  $T$ , maximální 60min intenzitu  $I_{60}$  a energii srážkové události  $E$ ), v průměru na řešené území, byly simulace rozděleny do čtyř základních skupin:

- a) RCM simulace předpokládající pouze malé změny ( $< 10$  %) ve všech charakteristikách srážkových událostí pro obě scénářová období (6 simulací),
- b) RCM simulace předpokládající růst v  $D$ ,  $I_{60}$  a  $E$  a pouze malou změnu ( $< 10$  %) v  $T$  (15 simulací),
- c) RCM simulace předpokládající růst v  $D$ ,  $I_{60}$  a  $E$  s převládajícím nárůstem i v  $T$  (4 simulace),
- d) RCM simulace předpokládající růst v  $I_{60}$  v kombinaci s poklesem  $T$  (přičemž změny v  $D$  a  $E$  jsou převážně malé)(5 simulací).



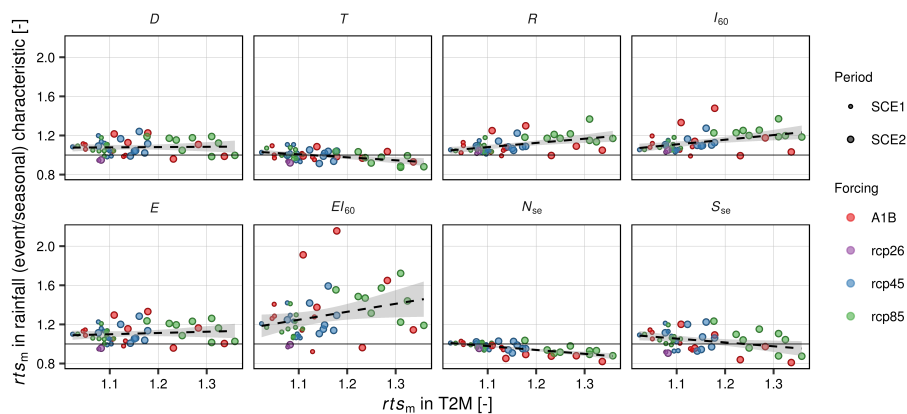
a maximálních 60min intenzitách ( $I_{60}$ ) během srážkových událostí, stejně jako pokles v počtu intenzivních srážkových událostí ( $N_{se}$ ) jsou významně závislé na narůstajících hodnotách radiačního působení a teploty (na hladině významnosti 0.01). Průměr ze souboru simulací RCM ukazuje růst o 6.5 %,



**Obrázek 3.7:** Srovnání kvantilových změn ( $rt_{sp}$ ) pro charakteristiky srážkových událostí simulovaných RCM ve dvou scénářových obdobích: 2020–2049 (SCE1) a 2070–2099 (SCE2). Pro každou simulaci RCM je zobrazen průměr z gridboxů pokrývajících řešené území (simulace jsou rozlišeny barevně podle RCM), průměr z celého souboru RCM simulací je vyznačen černou křivkou.

resp. 9.1 % na 1 °C pro  $RR$  a  $I60$ .

Charakteristiky extrémních událostí (v 95% kvantilu) nevykazují výraznější citlivost na změnu teploty oproti průměrným hodnotám charakteristik, i závislost na změně radiačního působení je silnější pouze minimálně.



**Obrázek 3.8:** Závislost změn charakteristik srážkových událostí na změně teploty. Všechny hodnoty  $rts_m$  jsou zprůměrovány na řešenou oblast. Lineární regresní modely proložení s 95% intervalem spolehlivosti (šedá zóna) jsou přidány jako přerušovaná čára.

## Kapitola 4

### Diskuze a závěr

Vedle analýzy korelační struktury srážkových dat (při níž bylo vyhodnoceno využití tří korelačních koeficientů a několika korelačních modelů s jedním až třemi parametry pro vyjádření mezistaniční korelace), jsou hlavní závěry práce směřovány k srážkovým událostem v České republice. Práce představuje metodiku pro vyhodnocení srážkových charakteristik a jejich potenciálních změn v simulacích RCM z pohledu individuálních srážkových událostí, jejichž význam v současném klimatu nabývá na váze a které jsou důležité z pohledu mnoha hydrologických aplikací.

#### ■ Prostorová korelační struktura v měřených srážkových datech

Z analýzy korelační struktury srážkových dat na příkladu Královéhradeckého kraje můžeme potvrdit, že použití neparametrických odhadů korelace jako je Spearmanův nebo Kendallův korelační koeficient se jeví pro vyjádření korelační struktury srážkových dat vhodnější než využití klasického Pearsonova korelačního koeficientu, na jehož nespolehlivost upozorňují Habib et al. (2001) nebo Krajewski et al. (2003). K co nejpřesnějšímu modelovému vyjádření korelační struktury v regionálním měřítku je pak zásadní využití víceparametrických modelů (často používané jednoparametrické modely korelace nedokáží spolehlivě zachytit změny v malých vzdálenostech).

Vliv sezonality na korelační strukturu je značný, v letních měsících (červen–srpen) mezistaniční korelace klesá se vzdáleností strměji než v zimě, což můžeme vyhodnotit jako důsledek vyššího podílu lokalizovaných srážkových událostí s krátkou dobou trvání a vysokou intenzitou (jak pro letní část roku udává Tolasz 2007). Strmější pokles korelace s rostoucí nadmořskou výškou v malých vzdálenostech signalizuje orografické vlivy na množství srážek a potenciálně také na charakteristiky srážkových událostí.

#### ■ Charakteristiky srážkových událostí

Charakteristiky srážkových událostí pro kontrolní období 1981–2000 byly posuzovány v souboru 23 simulací RCM. Individuální události byly definovány na základě 6h intervalu mezi událostmi (dle konceptu MIT) a minimálního hodinového srážkového intervalu rovnému 0.1 mm. Pozornost byla věnována pouze intenzivním událostem, které byly vybrány na základě kritéria dle

metodologie USLE (události odvozené z bodových měřených dat mající úhrn větší než 12.7 mm, intenzitní kritérium nebylo z důvodu časového rozlišení dat aplikováno), čemuž odpovídá  $\approx 15\%$  událostí s nejvyššími úhrny.

Jako potenciální zdroj části rozdílů v porovnání RCM simulovaných a bodových měřených charakteristik individuálních srážkových událostí byl vyhodnocen efekt prostorového průměrování srážkových dat. Prostorově průměrované charakteristiky z bodových měření byly analyzovány ve třech prostorových rozlišeních (odpovídajících simulacím RCM, tedy 12.5, 25 a 50 km) a charakteristiky simulovaných gridboxových srážkových událostí byly následně vyhodnoceny vzhledem k těmto prostorově průměrovaným charakteristikám. Samotné odhady efektu prostorového průměrování jsou zatíženy řadou nejistot (jejichž přehled uvádí Svensson et Jones 2010), v našem případě se jedná zejména o prostorovou variabilitu v kombinaci s pokrytím řešeného území srážkoměrnými stanicemi. Jelikož pro spolehlivý odhad je nezbytný dostatečný počet srážkoměrných stanic, byl analyzován vliv počtu stanic z kterých mohou být odvozeny prostorově průměrované charakteristiky srážkových událostí na území Prahy (500 km<sup>2</sup>) s hustou sítí 22 srážkoměrných stanic (postup sestával z opakovaného výpočtu poměru  $rt_m$  z dat z náhodných výběrů stanic podle počtu od 2 do 22). Většina prostorově průměrovaných charakteristik srážkových událostí vykazovala závislost na počtu stanic zahrnutých do výpočtu, zejména pokles v charakteristikách intenzity s rostoucím počtem stanic je znatelný. Nejvýraznější změny byly pozorovány mezi prostorovými průměry počítanými z malého počtu stanic, pro 6 a více stanic již rozdíly nejsou tolik výrazné (což je v souladu se studií Allen et DeGaetano 2005, kteří udávají, že počet stanic vyšší než 9 již nemá významný vliv na odhady ARF). Pro území České republiky bylo možné využít v podrobnějších rozlišeních než 50 km pouze omezené množství stanic (v průměru na okolí méně než 3), proto prostorově průměrované charakteristiky pro tyto rozlišení (12.5 a 25 km) mohou být nedostatkem stanic negativně ovlivněny.

Ačkoliv charakteristiky událostí simulovaných RCM vykazují ve vztahu k bodovým měřením obdobné trendy rozdílnosti jako prostorově průměrované charakteristiky (pro většinu charakteristik, kromě dob trvání, pokles oproti bodovým datům), rozdíl mezi charakteristikami událostí simulovaných RCM a charakteristikami událostí odvozených z prostorově průměrovaných měření je v porovnání s bodovými daty pro simulovaná data znatelně větší. Rozdílnost je tedy způsobena především zkreslením charakteristik v RCM simulacích, které je ve srovnání s měřeními bodovými daty zvýrazněno efektem prostorového průměrování.

Přestože v průměru byly počty sezónních intenzivních událostí a jejich celkové úhrny reprezentovány relativně dobře, mezi gridboxy v rámci jednotlivých simulací RCM byly pozorovány velké rozdíly v porovnání s prostorově průměrovanými daty, zejména díky nadmořské výšce. Úhrny extrémních srážkových událostí (v 95% kvantilu, tedy s periodou opakování 20 let) jsou v simulacích RCM reprezentovány velmi dobře. Vzhledem k mírnému podhodnocení úhrnů ostatních intenzivních srážkových událostí a k relativně dlouhé průměrné době trvání událostí ( $> 16$  h), jsou výsledky v souladu se



studii Hanel et Buishand (2010), kteří uvádějí pro území Nizozemska dobrou reprezentaci denních srážkových extrémů, zatímco hodinová maxima mají tendenci být příliš nízká. Pro Českou republiku ze souboru simulací RCM z projektu ENSEMBLES udávají Hanel et Buishand (2012) vyšší podhodnocení denních srážkových extrémů v letním období (až 17 %), nicméně toto zkreslení je v období jara a podzimu výrazně menší, takže květen a září ve srážkových datech může letní podhodnocení kompenzovat a proto je v naší studii podhodnocení úhrnů srážkových událostí menší.

Studie zveřejněné v posledních letech, posuzující simulace RCM podle horizontálního prostorového rozlišení (např. Ban et al. 2014; Chan et al. 2014; Kendon et al. 2014), naznačují lepší reprezentaci srážkových charakteristik v hodinových extrémech pro RCM s podrobnějším rozlišením. Hlavním důvodem lepší reprezentace hodinových extrémů je ovšem především zavedení (alespoň částečného) řešení konvektivních procesů, kdy s rozlišením blízcím se měřítku umožňující konvekce (kolem 4 km podle Prein et al. 2015) je možné velkou část konvektivních parametrizačních schémat odstavit (Fosser et al. 2015). Všechny námi analyzované simulace RCM musí spoléhat na konvektivní parametrizaci a proto rozdíly v simulacích RCM s různým prostorovým rozlišením jsou pouze malé a nejsou systematické. K obdobnému závěru došli též Sunyer et al. (2016), kteří udávají pro srážkové extrémy v simulacích RCM s konvektivní parametrizací rozdíly v důsledku různých prostorových rozlišení menší než v důsledku samotné kombinace RCM a GCM.

Charakteristiky srážkových událostí v simulacích RCM s nejhrubším rozlišením (50 km) vykazují rozdílnosti oproti ostatním simulacím prakticky pouze v nejvyšších maximálních 60min intenzitách, které jsou více podhodnocené (ale také počty událostí s vyššími 60min intenzitami jsou zde výrazně nižší v porovnání s prostorově průměrovanými daty i ostatními simulacemi). Tímto lze potvrdit závěry Sunyer et al. (2016), že simulace RCM v 50km prostorovém rozlišení nejsou schopny spolehlivě reprezentovat hodinové extrémy, zatímco denní hodnoty se zdají být prakticky nezávislé na prostorovém rozlišení simulací RCM.

Simulované hodnoty maximálních 60min intenzit stejně jako počet srážkových událostí s vysokými průměrnými intenzitami jsou ve všech simulacích RCM výrazně nižší než v měřených datech. To může být způsobeno opět konvektivní parametrizací jak upozorňuje Kyselý et al. (2016), protože v letních měsících dochází v simulacích RCM k podhodnocení intenzit v konvektivních srážkách. Podobné vysvětlení nedostatku vysoce intenzivních srážkových událostí s krátkou dobou trvání v simulacích RCM udává také Kendon et al. (2012).

Nadhodnocování dob trvání událostí je následek často zmiňované tendence RCM reprezentovat příliš mnoho vytrvalého mrholení a podhodnocovat počet bezsrážkových dní (Fowler et al. 2007; Boberg et al. 2009; Kendon et al. 2012). Nejvíce patrné je nadhodnocení v případě událostí s krátkou dobou trvání, které jsou i více než dvakrát delší. Vysoké nadhodnocení krátkých dob trvání pak způsobuje vyšší podhodnocení vysokých průměrných intenzit. Problém s příliš dlouhou dobou trvání srážkových událostí se objevuje i v

případech RCM s vysokým rozlišením jak udává např. Fosser et al. (2015) pro simulaci RCM COSMO-CLM s horizontálním rozlišením 2.8 km a vypnutou většinou konvektivních parametrizací. Pokud bychom doby trvání srážkových událostí v simulacích RCM opravili, tzn. proporcionálně zkrátili podle poměru  $rt_p$ , dostali bychom sice hodnoty průměrné intenzity dobře souhlasící s prostorově průměrovanými daty, nicméně nárůst ostatních charakteristik (maximální 60min intenzita, energie a index erozivity srážkové události) by byl nedostatečný a charakteristiky by zůstaly stále podhodnocené.

Závislost charakteristik individuálních srážkových událostí na nadmořské výšce je reprezentována v simulacích RCM podobně jako v bodových měřených datech, přičemž rozdíly v síle závislosti jsou mezi posuzovanými kvantily charakteristik povětšinou malé. Největší rozdílnosti oproti bodovým datům (zejména v charakteristikách souvisejících s intenzitou) jsou patrné pro simulace v hrubším (50 km) rozlišení. Počet individuálních srážkových událostí a jejich sezónní úhrny narůstají s vyšší nadmořskou výškou a tato závislost je lépe zachycena v obou simulacích s nejjemnějším prostorovým rozlišením (12.5 a 22 km) jako očekávaný důsledek lepší reprezentace orografie jak naznačují Rauscher et al. (2010) nebo Prein et al. (2016).

Simulace RCM řízené reanalýzami klimatu (ERA40 a ERA-INTERIM) ve výsledku nevykazují lepší reprezentaci charakteristik srážkových událostí ve srovnání se simulacemi RCM řízenými GCM, což může být odůvodněno stejným argumentem jako udávají Hanel et Buishand (2010), tedy že zkrácení v simulacích RCM je dáno z větší části spíše parametrizacemi srážkových procesů než okrajovými podmínkami klimatického modelu.

#### ■ Změny v charakteristikách srážkových událostí

Předpokládané změny v charakteristikách srážkových událostí byly vyhodnoceny pro dvojici scénářových období (2020–2049 a 2070–2099), v nichž byly srážkové události definovány stejným postupem jako pro kontrolní období. K analýze byl využit soubor čítající celkem 30 simulací RCM.

Relativní změny v charakteristikách srážkových událostí jsou všeobecně výraznější ve vzdálenějším scénářovém období (2070–2099). Počet intenzivních srážkových událostí ve scénářových obdobích klesá (až o 19 %), přičemž změny v sezónních úhrnech intenzivních srážkových událostí v simulacích RCM nejsou jednoznačné a vykazují rozptyl od –20 % do +19 %. Velká část simulací (15 z 30) předpokládá růst (> 10 %) v úhrnech intenzivních srážkových událostí, maximálních 60min intenzitách a energiích srážkových událostí, přičemž doba trvání událostí zůstává prakticky beze změn nebo se v průběhu všech sledovaných období mění jen minimálně. Navíc značná část analyzovaných simulací (více než třetina) vykazuje v maximálních 60min intenzitách a energiích ve vzdálenějším scénářovém období změny vyšší než +20 %. Ostatní simulace vykazují pouze malé změny (< 10 %) v těchto charakteristikách v průběhu obou scénářových období (6 simulací) nebo predikují růst maximálních 60min intenzit v kombinaci se změnami v dobách trvání událostí (4 simulace předpokládají růst dob trvání a 5 simulací naopak pokles).

Udávané změny charakteristik srážkových událostí jsou průměrovány na celou Českou republiku, nicméně ve všech simulacích RCM byla patrná poměrně výrazná prostorová variabilita změn. Pro počty intenzivních událostí (vyšší pokles) a jejich celkové sezónní úhrny (vyšší pokles nebo nižší nárůst) je tato prostorová variabilita změn do značné míry navázána na rostoucí nadmořskou výšku. Na prostorovou variabilitu změn ostatních charakteristik individuálních srážkových událostí nadmořská výška významný vliv nemá.

Ačkoliv Jacob et al. (2014) udávají ze souboru simulací z projektů ENSEMBLES a EURO-CORDEX nárůst v denních intenzivních letních srážkách pro území České republiky až o 25 % pro konec 21. století (a výraznější změny v simulacích dle scénáře RCP8.5), v naší studii (posuzující intenzivní srážkové události za období květen–září z hodinových dat) jsou změny v úhrnech individuálních srážkových událostí i v celkových úhrnech přinášejících intenzivními událostmi obecně menší a bez výraznějších rozdílů mezi scénáři RCP4.5 a RCP8.5. Rozdílná situace je ovšem patrná v průměrných a maximálních 60min intenzitách, kde je již v ve všech simulacích RCM podle RCP8.5 zřetelně vyšší nárůst v porovnání s RCP4.5.

Simulace RCM ukazují mírně vyšší nárůsty pro vyšší (extrémnější) hodnoty charakteristik srážkových událostí (s výjimkou doby trvání), přičemž v intenzitách srážkových událostí jsou nárůsty nejvýznamnější. Doby trvání krátkých událostí se ve vzdálenějším scénářovém období mírně zkracují. Přestože doby trvání srážkových událostí v simulacích RCM se v průměru ve scénářových obdobích příliš neliší od kontrolního období (zvláště v období 2020–2049), ve výsledku změny odpovídají trendům v (erozivních) srážkových událostech jak je z období posledních desetiletí odvodili Hanel et al. (2016), tedy nárůstu v intenzitách a poklesu v dobách trvání událostí. Také další studie pro různé části (západní, severní a střední) Evropy ukazují nárůsty v intenzitách extrémních srážek a to jak v denních (Frei et al. 2006; Kyselý 2009; Kyselý et al. 2011; Hanel et Buishand 2012) tak v sub-denních datech (Arnbjerg-Nielsen 2012; Hanel et Buishand 2010). Jacob et al. (2014) udává z analýzy denních dat ze simulací RCM pro období konce 21. století nárůst středních a vysokých srážkových intenzit, zatímco nízké intenzity klesají. Tomuto přesně odpovídá růst průměrných a maximálních intenzit intenzivních srážkových událostí a také pokles počtu intenzivních událostí s nejnižšími intenzitami jak je uváděno v naší studii. Intenzifikace hodinových srážek byla zjištěna také ze simulací modelu umožňující řešení konvekce pro UK (Kendon et al. 2014), ačkoliv další studie posuzující simulace RCM umožňující konvekce udávají naopak pokles v ročních a letních hodinových srážkových extrémech pro Německo (Knote et al. 2010) a západní část Spojených států (Pan et al. 2011).

Změny charakteristik srážkových událostí v simulacích RCM jsou ovlivněny větším radiačním působením a narůstající teplotou ve scénářových obdobích (Houghton et al. 2001; Moss et al. 2010). Počet intenzivních srážkových událostí s větším radiačním působením a rostoucí teplotou klesá. Zatímco působení na srážkové úhrny (růst s větším radiačním působením) a doby trvání událostí (pokles s rostoucí teplotou) je pouze minimální, charakteristiky související s intenzitou událostí ukazují významný růst s větším radiačním

působením a vyšší teplotou. Odhadovaná změna v průměrných intenzitách srážkových událostí (6.5 % na °C) dobře odpovídá předpokládaným nárůstům srážkových intenzit na základě Clausius-Clapeyronovi rovnice ( $\approx 7$  % na °C; Lenderink et van Meijgaard 2008). Nárůst v maximálních 60min intenzitách v průběhu události je o něco vyšší (9.1 % na °C) a ačkoliv hodnota spadá do rozsahu, který udávají Lenderink et van Meijgaard (2008) pro data simulovaná RCM a podobnou hodnotu udávají také Hanel et Buishand (2010), některé další studie pro simulace klimatických modelů i pozorovaná data uvádějí mnohem vyšší nárůsty na °C v hodinových maximech, a to zejména pro konvektivní srážky (např. Berg et al. 2013; Westra et al. 2014; Molnar et al. 2015). Důvodem proč je v maximálních 60min intenzitách srážkových událostí nárůst „jen“ 9.1 % na °C může být samotný výběr srážkových událostí, které jsou definovány na základě minimálních srážkových úhrnů (do analýz jsou tedy zahrnuty i události s menšími hodnotami maximálních 60min intenzit). Vzhledem k většímu růstu intenzit extrémnějších srážkových událostí (viz Obr. 3.7), se dá očekávat také vyšší procento nárůstu na 1 °C pro vyšší maximální 60min intenzity v průběhu těchto událostí.

#### ■ Závěr

Ačkoliv nebylo možno předpokládat, že současné RCM budou schopny dostatečně přesně simulovat sub-denní variabilitu srážek a tedy i charakteristiky srážkových událostí především s ohledem na jejich horizontální rozlišení a s ním spojené nutné parametrizace (viz Kendon et al. 2014; Westra et al. 2014), identifikace nepřesností a chyb může být užitečná pro budoucí studie využívající simulovaná sub-denní srážková data a také pro vývoj klimatických modelů včetně zpřesňování parametrizací, které je stále aktuální (např. Grell et Freitas 2014) i přes narůstající počet simulací RCM umožňující konvekce. Vzhledem k faktu, že simulace RCM v podrobnějším měřítku umožňující řešení konvekce mohou simulovat změny značně odlišné od simulací RCM s konvektivní parametrizací jak uvádí Kendon et al. (2014), je nezbytné interpretovat změny týkající se srážek a tedy i srážkových událostí podle simulací současných RCM v sub-denních měřítcích se zvýšenou opatrností. Nejnovější studie naznačují, že budoucnost výzkumu by měla být zaměřena právě na klimatické modelování ve vysokém rozlišení, které přináší věrohodnější reprezentaci nejen v sub-denních srážkových extrémech (Prein et al. 2015).



## Literatura

- Abramowitz, M. a I. A. Stegun, eds.  
1972. *Handbook of mathematical functions with formulas, graphs, and mathematical tables*, volume 55 of *National Bureau of Standards Applied Mathematics Series*, 10th edition. Washington, D.C.: U.S. Government Printing Office.
- Alexander, L. V., X. Zhang, T. C. Peterson, J. Caesar, B. Gleason, A. M. G. Klein Tank, M. Haylock, D. Collins, B. Trewin, F. Rahimzadeh, A. Tagipour, K. Rupa Kumar, J. Revadekar, G. Griffiths, L. Vincent, D. B. Stephenson, J. Burn, E. Aguilar, M. Brunet, M. Taylor, M. New, P. Zhai, M. Rusticucci, a J. L. Vazquez-Aguirre  
2006. Global observed changes in daily climate extremes of temperature and precipitation. *Journal of Geophysical Research: Atmospheres*, 111(D5).
- Allen, R. J. a A. T. DeGaetano  
2005. Areal reduction factors for two Eastern United States regions with high rain-gauge density. *Journal of Hydrologic Engineering*, 10(4):327–335.
- Angulo-Martínez, M. a S. Beguería  
2009. Estimating rainfall erosivity from daily precipitation records: a comparison among methods using data from the Ebro Basin (NE Spain). *Journal of Hydrology*, 379(1–2):111–121.
- Arnbjerg-Nielsen, K.  
2012. Quantification of climate change effects on extreme precipitation used for high resolution hydrologic design. *Urban Water Journal*, 9(2):57–65.
- Asquith, W. H. a J. S. Famiglietti  
2000. Precipitation areal-reduction factor estimation using an annual-maxima centered approach. *Journal of Hydrology*, 230(1–2):55–69.
- Ban, N., J. Schmidli, a C. Schär  
2014. Evaluation of the convection-resolving regional climate modeling approach in decade-long simulations. *Journal of Geophysical Research: Atmospheres*, 119(13):7889–7907.
- Barbosa, A., J. Fernandes, a L. David  
2012. Key issues for sustainable urban stormwater management. *Water Research*, 46(20):6787–6798.
- Bartier, P. a C. Keller  
1996. Multivariate interpolation to incorporate thematic surface data using inverse distance weighting (IDW). *Computers & Geosciences*, 22(7):795–799.

- Berg, P. a J. Haerter  
2013. Unexpected increase in precipitation intensity with temperature – a result of mixing of precipitation types? *Atmospheric Research*, 119(0):56–61.
- Berg, P., C. Moseley, a J. Haerter  
2013. Strong increase in convective precipitation in response to higher temperatures. *Nature Geoscience*, 6(3):181–185.
- Boberg, F., P. Berg, P. Thejll, W. Gutowski, a J. Christensen  
2009. Improved confidence in climate change projections of precipitation evaluated using daily statistics from the PRUDENCE ensemble. *Climate Dynamics*, 32(7-8):1097–1106.
- Böhm, U., M. Kücken, W. Ahrens, A. Block, D. Hauffe, K. Keuler, B. Rockel, a A. Will  
2006. CLM - the climate version of LM: brief description and long-term applications. *COSMO Newsletters*, 6:225–235.
- Borga, M. a A. Vizzaccaro  
1997. On the interpolation of hydrologic variables: formal equivalence of multiquadratic surface fitting and kriging. *Journal of Hydrology*, 195(1–4):160–171.
- Bras, R.  
1990. *Hydrology: an introduction to hydrologic science*, Addison-Wesley series in civil engineering. Addison-Wesley.
- Brockhaus, P., D. Lüthi, a C. Schär  
2008. Aspects of the diurnal cycle in a regional climate model. *Meteorologische Zeitschrift*, 17(4):433–443.
- Brown, L. C. a G. R. Foster  
1987. Storm erosivity using idealized intensity distributions. *Transactions of the ASAE - American Society of Agricultural Engineers*, 30(2):379–386.
- Burrough, P. a R. McDonnell  
1998. *Principles of geographical information systems*, 2nd edition, Spatial information systems and geostatistics. Oxford University Press.
- Chan, S. C., E. J. Kendon, H. J. Fowler, S. Blenkinsop, N. M. Roberts, a C. A. T. Ferro  
2014. The value of high-resolution Met Office regional climate models in the simulation of multihourly precipitation extremes. *Journal of Climate*, 27(16):6155–6174.
- ČHMÚ  
2011. Modelování klimatu a jeho změn. Online: [http://portal.chmi.cz/files/portal/docs/meteo/ok/klimazmena/files/cc\\_chap07.pdf](http://portal.chmi.cz/files/portal/docs/meteo/ok/klimazmena/files/cc_chap07.pdf) [cit.: 10.4.2016].
- Christensen, J. H. a O. B. Christensen  
2007. A summary of the PRUDENCE model projections of changes in European climate by the end of this century. *Climatic Change*, 81(1):7–30.
- Christensen, O. B., M. Drews, J. H. Christensen, K. Dethloff, K. Ketelsen, I. Hebestadt, a A. Rinke  
2007. *The HIRHAM regional climate model version 5 (beta)*, Technical Report, no. 06-17. Danish Climate Centre, DMI.

- Chumchean, S., A. Sharma, a A. Seed  
2006. An integrated approach to error correction for real-time radar-rainfall estimation. *Journal of Atmospheric and Oceanic Technology*, 23(1):67–79.
- Ciach, G. J.  
2003. Local random errors in tipping-bucket rain gauge measurements. *Journal of Atmospheric and Oceanic Technology*, 20:752–759.
- Ciach, G. J. a W. F. Krajewski  
2006. Analysis and modeling of spatial correlation structure in small-scale rainfall in Central Oklahoma. *Advances in Water Resources*, 29(10):1450 – 1463.
- Collins, M., B. Booth, B. Bhaskaran, G. Harris, J. Murphy, D. Sexton, a M. Webb  
2011. Climate model errors, feedbacks and forcings: a comparison of perturbed physics and multi-model ensembles. *Climate Dynamics*, 36(9-10):1737–1766.
- Collins, M., B. Booth, G. Harris, J. Murphy, D. Sexton, a M. Webb  
2006. Towards quantifying uncertainty in transient climate change. *Climate Dynamics*, 27(2-3):127–147.
- Şen, Z. a Z. Habib  
2001. Monthly spatial rainfall correlation functions and interpretations for Turkey. *Hydrological Sciences Journal*, 46(4):525–535.
- Dai, A., I. Fung, a A. Del Genio  
1997. Surface observed global land precipitation variations during 1900–1988. *Journal of Climate*, 10:2943–2962.
- Dee, D. P., S. M. Uppala, A. J. Simmons, P. Berrisford, P. Poli, S. Kobayashi, U. Andrae, M. A. Balmaseda, G. Balsamo, P. Bauer, P. Bechtold, A. C. M. Beljaars, L. van de Berg, J. Bidlot, N. Bormann, C. Delsol, R. Dragani, M. Fuentes, A. J. Geer, L. Haimberger, S. B. Healy, H. Hersbach, E. V. Hólm, L. Isaksen, P. Kållberg, M. Köhler, M. Matricardi, A. P. McNally, B. M. Monge-Sanz, J.-J. Morcrette, B.-K. Park, C. Peubey, P. de Rosnay, C. Tavolato, J.-N. Thépaut, a F. Vitart  
2011. The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Quarterly Journal of the Royal Meteorological Society*, 137(656):553–597.
- Delfiner, P. a J. P. Delhomme  
1975. Optimum interpolation by kriging. In *Display and analysis of spatial data*, J. D. Davis a M. J. McCullagh, eds., pp. 96–114. John Wiley and Sons, New York.
- Delhomme, J. P.  
1978. Kriging in the hydrosociences. *Advances in Water Resources*, 1:251–266.
- Dennis, J. E., D. M. Gay, a R. E. Welsch  
1981. An adaptive nonlinear least-squares algorithm. *ACM Transactions on Mathematical Software*, 7(3):348–368.
- Déqué, M.  
2007. Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: model results and statistical correction according to observed values. *Global and Planetary Change*, 57(1-2):16–26.

- Dingman, S.  
2002. *Physical hydrology*. Upper Saddle River, N.J.: Prentice Hall.
- Doviak, R. a D. Zrnić  
1993. *Doppler radar and weather observations*, Dover Books on Engineering Series. Dover Publications.
- Dubrovský, M.  
1997. Creating daily weather series with use of the weather generator. *Environmetrics*, 8(5):409–424.
- Dunkerley, D.  
2008. Rain event properties in nature and in rainfall simulation experiments: a comparative review with recommendations for increasingly systematic study and reporting. *Hydrological Processes*, 22(22):4415–4435.
- Einfalt, T., V. Krejci, a W. Schilling  
1998. Rainfall data in urban hydrology. In *Hydroinformatics tools for planning, design, operation and rehabilitation of sewer systems*, J. Marsalek, C. Maksimovic, E. Zeman, a R. Price, eds., volume 44 of *NATO ASI Series*, pp. 129–168. Springer Netherlands.
- Fosser, G., S. Khodayar, a P. Berg  
2015. Benefit of convection permitting climate model simulations in the representation of convective precipitation. *Climate Dynamics*, 44(1-2):45–60.
- Fowler, H. J., M. Ekström, S. Blenkinsop, a A. P. Smith  
2007. Estimating change in extreme European precipitation using a multimodel ensemble. *Journal of Geophysical Research: Atmospheres*, 112(D18).
- Frei, C., R. Schöll, S. Fukutome, J. Schmidli, a P. L. Vidale  
2006. Future change of precipitation extremes in europe: intercomparison of scenarios from regional climate mode. *Journal of Geophysical Research: Atmospheres*, 111(D6).
- Giorgi, F. a W. J. Gutowski  
2015. Regional dynamical downscaling and the CORDEX initiative. *Annual Review of Environment and Resources*, 40(1):467–490.
- Gregersen, I. B., H. J. D. Sørup, H. Madsen, D. Rosbjerg, P. S. Mikkelsen, a K. Arnbjerg-Nielsen  
2013. Assessing future climatic changes of rainfall extremes at small spatio-temporal scales. *Climatic Change*, 118(3-4):783–797.
- Grell, G. A. a S. R. Freitas  
2014. A scale and aerosol aware stochastic convective parameterization for weather and air quality modeling. *Atmospheric Chemistry and Physics*, 14(10):5233–5250.
- Habib, E., W. F. Krajewski, a G. J. Ciach  
2001. Estimation of rainfall interstation correlation. *Journal of Hydrometeorology*, 2(6):621–629.
- Hand, W. H., N. I. Fox, a C. G. Collier  
2004. A study of twentieth-century extreme rainfall events in the United Kingdom with implications for forecasting. *Meteorological Applications*, 11:15–31.



- Handcock, M. S. a J. R. Wallis  
1994. An approach to statistical spatial-temporal modeling of meteorological fields. *Journal of the American Statistical Association*, 89(426):368–378.
- Hanel, M. a T. A. Buishand  
2010. On the value of hourly precipitation extremes in regional climate model simulations. *Journal of Hydrology*, 393(3–4):265–273.
- Hanel, M. a T. A. Buishand  
2011. Analysis of precipitation extremes in an ensemble of transient regional climate model simulations for the Rhine basin. *Climate Dynamics*, 36(5–6):1135–1153.
- Hanel, M. a T. A. Buishand  
2012. Multi-model analysis of RCM simulated 1-day to 30-day seasonal precipitation extremes in the Czech Republic. *Journal of Hydrology*, 412–413:141–150.
- Hanel, M., L. Kašpárek, M. Mrkvičková, S. Horáček, A. Vizina, O. Novický, a R. Fridrichová  
2011. *Odhad dopadů klimatické změny na hydrologickou bilanci v ČR a možná adaptační opatření*. Výzkumný ústav vodohospodářský T.G. Masaryka, Praha.
- Hanel, M. a P. Máca  
2014. Spatial variability and interdependence of rain event characteristics in the Czech Republic. *Hydrological Processes*, 28(6):2929–2944.
- Hanel, M., A. Pavlásková, a J. Kyselý  
2016. Trends in characteristics of sub-daily heavy precipitation and rainfall erosivity in the Czech Republic. *International Journal of Climatology*, 36(4):1833–1845.
- Harris, G. R., M. Collins, D. M. H. Sexton, J. M. Murphy, a B. B. Booth  
2010. Probabilistic projections for 21st century European climate. *Natural Hazards and Earth System Science*, 10(9):2009–2020.
- Haylock, M. R., N. Hofstra, A. M. G. Klein Tank, E. J. Klok, P. D. Jones, a M. New  
2008. A european daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006. *Journal of Geophysical Research: Atmospheres*, 113(D20).
- Hofstra, N. a M. New  
2009. Spatial variability in correlation decay distance and influence on angular-distance weighting interpolation of daily precipitation over Europe. *International Journal of Climatology*, 29(12):1872–1880.
- Hofstra, N., M. New, a C. McSweeney  
2010. The influence of interpolation and station network density on the distributions and trends of climate variables in gridded daily data. *Climate Dynamics*, 35(5):841–858.
- Hohenegger, C., P. Brockhaus, a C. Schär  
2008. Towards climate simulations at cloud-resolving scales. *Meteorologische Zeitschrift*, 17(4):383–394.
- Horák, J.  
2011. *Prostorové analýzy dat*, 3. vydání, Skripta VŠB-TU. Institut geoinformatiky, Ostrava.

- Houghton, J. T., Y. Ding, D. J. Griggs, M. Noguer, P. J. van der Linden, X. Dai, K. Makell, a C. A. Johnson, eds.  
2001. *Climate change 2001: the scientific basis. Contribution of working group I to the third assessment report of the Intergovernmental Panel on Climate Change*. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press.
- Hutchinson, T. P.  
1997. A comment on correlation in skewed distributions. *The Journal of General Psychology*, 124(2):211–215.
- Huth, R.  
2002. Statistical downscaling of daily temperature in Central Europe. *Journal of Climate*, 15(13):1731–1742.
- Huth, R., L. Metelka, T. Halenka, R. Mládek, Z. Huthová, M. Janoušek, J. Kalvová, S. Kliegrová, J. Kyselý, L. Pokorná, a P. Sedlák  
2003. Regionální klimatické modelování v České republice - projekt ALADIN-climate. *Meteorologické zprávy*, 56(4):97–103.
- Ignaccolo, M. a C. D. Michele  
2010. A point based Eulerian definition of rain event based on statistical properties of inter drop time intervals: an application to Chilbolton data. *Advances in Water Resources*, 33(8):933–941.
- IPCC  
2007. *Climate change 2007: synthesis report. Contribution of working groups I, II and III to the fourth assessment report of the Intergovernmental Panel on Climate Change*. [Core writing team, Pachauri, R.K. and A. Reisinger (eds.)]. IPCC, Geneva, Switzerland.
- IPCC  
2014. *Climate change 2014: synthesis report. Contribution of working groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change*. [Core writing team, Pachauri, R.K. and L.A. Meyer (eds.)]. IPCC, Geneva, Switzerland.
- Jacob, D., J. Petersen, B. Eggert, A. Alias, O. Christensen, L. Bouwer, A. Braun, A. Colette, M. Déqué, G. Georgievski, E. Georgopoulou, A. Gobiet, L. Menut, G. Nikulin, A. Haensler, N. Hempelmann, C. Jones, K. Keuler, S. Kovats, N. Kröner, S. Kotlarski, A. Kriegsmann, E. Martin, E. van Meijgaard, C. Moseley, S. Pfeifer, S. Preuschmann, C. Radermacher, K. Radtke, D. Rechid, M. Rounsevell, P. Samuelsson, S. Somot, J.-F. Soussana, C. Teichmann, R. Valentini, R. Vautard, B. Weber, a P. Yiou  
2014. EURO-CORDEX: new high-resolution climate change projections for European impact research. *Regional Environmental Change*, 14(2):563–578.
- Jones, P., T. J. Osborn, a K. R. Briffa  
1997. Estimating sampling errors in large-scale temperature averages. *Journal of Climate*, 10(10):2548–2568.
- Juřikovská, L.  
2009. Porovnání metod využívajících radarová a srážkoměrná měření. *Symposium GIS Ostrava 2009, GIS ve vodním hospodářství a ochraně ŽP*.

- Kendon, E. J., N. M. Roberts, H. J. Fowler, M. J. Roberts, S. C. Chan, a C. A. Senior  
2014. Heavier summer downpours with climate change revealed by weather forecast resolution model. *Nature Climate Change*, 4(7):570–576.
- Kendon, E. J., N. M. Roberts, C. A. Senior, a M. J. Roberts  
2012. Realism of rainfall in a very high-resolution regional climate model. *Journal of Climate*, 25(17):5791–5806.
- Kiehl, J. T. a K. E. Trenberth  
1997. Earth's annual global mean energy budget. *Bulletin of the American Meteorological Society*, 78(2):197–208.
- Kněžíková, B., R. Brázdil, a P. Štěpánek  
2010. Porovnání měření srážek srážkoměrem Metra 886 a automatickým člunkovým srážkoměrem MR3H ve staniční síti Českého hydrometeorologického ústavu. *Meteorologické zprávy*, 63(5):147–155.
- Knote, C., G. Heinemann, a B. Rockel  
2010. Changes in weather extremes: assessment of return values using high resolution climate simulations at convection-resolving scale. *Meteorologische Zeitschrift*, 19(1):11–23.
- Kráčmar, J.  
2002. Meteorologické radiolokátory. Text pro výukové účely. ČHMÚ, Praha. On-line: <http://portal.chmi.cz/files/portal/docs/meteo/rad/inforadar> [cit.: 21.12.2015].
- Krajewski, W. F., G. J. Ciach, a E. Habib  
2003. An analysis of small-scale rainfall variability in different climatic regimes. *Hydrological Sciences Journal*, 48(2):151–162.
- Kraus, J.  
2007. Geostatistika jako prostorové modelování statistických jevů. *Statistika: Statistics and Economy Journal*, 6:490–502.
- Kundzewicz, Z. W., ed.  
2012. *Changes in flood risk in europe*. IAHS Special Publication 10.
- Kundzewicz, Z. W., U. Ulbrich, T. Brücher, D. Graczyk, A. Krüger, G. C. Leckebusch, L. Menzel, I. Pińskwar, M. Radziejewski, a M. Szwed  
2005. Summer floods in Central Europe – climate change track? *Natural Hazards*, 36(1-2):165–189.
- Kupiainen, M., P. Samuelsson, C. Jones, C. Jansson, U. Willén, U. Hansson, A. Ullerstig, S. Wang, a R. Döscher  
2011. Rossby Centre regional atmospheric model, RCA4. *Rosby Centre Newsletter*, (June 2011).
- Květoň, V., J. Zahradníček, a M. Žák  
2004. Quality control and digitising of pluviographic measurements in the Czech Hydrometeorological Institute. *Metorologické Zprávy*, 57:47–52.
- Kyselý, J.  
2009. Trends in heavy precipitation in the Czech Republic over 1961–2005. *International Journal of Climatology*, 29(12):1745–1758.

- Kyselý, J. a R. Beranová  
2009. Climate-change effects on extreme precipitation in central Europe: uncertainties of scenarios based on regional climate models. *Theoretical and Applied Climatology*, 95(3-4):361–374.
- Kyselý, J., L. Gaál, R. Beranová, a E. Plavcová  
2011. Climate change scenarios of precipitation extremes in Central Europe from ENSEMBLES regional climate models. *Theoretical and Applied Climatology*, 104(3-4):529–542.
- Kyselý, J., Z. Rulfová, A. Farda, a M. Hanel  
2016. Convective and stratiform precipitation characteristics in an ensemble of regional climate model simulations. *Climate Dynamics*, 46(1):227–243.
- Lautenschlager, M., K. Keuler, C. Wunram, E. Keup-Thiel, M. Schubert, A. Will, B. Rockel, a U. Boehm  
2009a. *Climate simulation with CLM, climate of the 20th century run no.2, data stream 3: European region MPI-M/MaD*. World Data Center for Climate (WDCC).
- Lautenschlager, M., K. Keuler, C. Wunram, E. Keup-Thiel, M. Schubert, A. Will, B. Rockel, a U. Boehm  
2009b. *Climate simulation with CLM, scenario A1B run no.2, data stream 3: European region MPI-M/MaD*. World Data Center for Climate (WDCC).
- Lenderink, G., H. Y. Mok, T. C. Lee, a G. J. van Oldenborgh  
2011. Scaling and trends of hourly precipitation extremes in two different climate zones – Hong Kong and the Netherlands. *Hydrology and Earth System Sciences*, 15(9):3033–3041.
- Lenderink, G. a E. van Meijgaard  
2008. Increase in hourly precipitation extremes beyond expectations from temperature changes. *Nature Geoscience*, 1(8):511–514.
- Madsen, H., D. Lawrence, M. Lang, M. Martínková, a T. Kjeldsen  
2014. Review of trend analysis and climate change projections of extreme precipitation and floods in Europe. *Journal of Hydrology*, 519(D):3634–3650.
- Mandapaka, P. V. a X. Qin  
2013. Analysis and characterization of probability distribution and small-scale spatial variability of rainfall in Singapore using a dense gauge network. *Journal of Applied Meteorology and Climatology*, 52(12):2781–2796.
- Maraun, D., F. Wetterhall, A. M. Ireson, R. E. Chandler, E. J. Kendon, M. Widmann, S. Brienen, H. W. Rust, T. Sauter, M. Themeßl, V. K. C. Venema, K. P. Chun, C. M. Goodess, R. G. Jones, C. Onof, M. Vrac, a I. Thiele-Eich  
2010. Precipitation downscaling under climate change: recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, 48(3).
- McGuffie, K. a A. Henderson-Sellers  
2005. *A climate modelling primer*, 3rd edition. John Wiley & Sons.
- Meinshausen, M., S. J. Smith, K. Calvin, J. S. Daniel, M. L. T. Kainuma, J.-F. Lamarque, K. Matsumoto, S. A. Montzka, S. C. B. Raper, K. Riahi, A. Thomson, G. J. M. Velders, a D. P. van Vuuren  
2011. The RCP greenhouse gas concentrations and their extensions from 1765 to 2300. *Climatic Change*, 109(1):213–241.



- Pan, L.-L., S.-H. Chen, D. Cayan, M.-Y. Lin, Q. Hart, M.-H. Zhang, Y. Liu, a J. Wang  
2011. Influences of climate change on California and Nevada regions revealed by a high-resolution dynamical downscaling study. *Climate Dynamics*, 37(9):2005–2020.
- Peters, O. a K. Christensen  
2006. Rain viewed as relaxational events. *Journal of Hydrology*, 328(1–2):46–55.
- Prein, A. F., A. Gobiet, H. Truhetz, K. Keuler, K. Goergen, C. Teichmann, C. Fox Maule, E. van Meijgaard, M. Déqué, G. Nikulin, R. Vautard, A. Colette, E. Kjellström, a D. Jacob  
2016. Precipitation in the EURO-CORDEX 0.11° and 0.44° simulations: high resolution, high benefits? *Climate Dynamics*, 46(1):383–412.
- Prein, A. F., W. Langhans, G. Fosser, A. Ferrone, N. Ban, K. Goergen, M. Keller, M. Tölle, O. Gutjahr, F. Feser, E. Brisson, S. Kollet, J. Schmidli, N. P. M. van Lipzig, a R. Leung  
2015. A review on regional convection-permitting climate modeling: demonstrations, prospects, and challenges. *Reviews of Geophysics*, 53(2):323–361.
- Pretel, J., L. Metelka, O. Novický, J. Daňhelka, J. Rožnovský, a D. Janouš  
2011. *Zpřesnění dosavadních odhadů dopadů klimatické změny v sektorech vodního hospodářství, zemědělství a lesnictví a návrhy adaptačních opatření*, Technické shrnutí výsledků řešení projektu VaV SP/1a6/108/07 v letech 2007–2011. ČHMÚ, Praha.
- Rauscher, S., E. Coppola, C. Piani, a F. Giorgi  
2010. Resolution effects on regional climate model simulations of seasonal precipitation over Europe. *Climate Dynamics*, 35(4):685–711.
- Rogner, H. H., D. Zhou, R. Bradley, P. Crabbé, O. Edenhofer, B. Hare, L. Kuijpers, a M. Yamaguchi  
2007. *Introduction. In Climate change 2007: mitigation. Contribution of working group III to the fourth assessment report of the Intergovernmental Panel on Climate Change*. [Metz, B., O. R. Davidson, P. R. Bosch, R. Dave and L. A. Meyer (eds.)]. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press.
- Rulfová, Z. a J. Kyselý  
2013. Disaggregating convective and stratiform precipitation from station weather data. *Atmospheric Research*, 134:100–115.
- Rulfová, Z. a J. Kyselý  
2014. Trends of convective and stratiform precipitation in the czech republic, 1982-2010. *Advances in Meteorology*, vol. 2014.
- Samuelsson, P., C. G. Jones, U. Willén, A. Ullerstig, S. Gollvik, U. Hansson, C. Jansson, E. Kjellström, G. Nikulin, a K. Wyser  
2011. The Rossby Centre regional climate model RCA3: model description and performance. *Tellus A*, 63(1):4–23.
- Sevruk, B.  
2004. *Niederschlag als wasserkreislaufelement: theorie und praxis der niederschlagsmessung*. Institute für Atmosphäre und Klima ETH.

- Sharon, D.  
1978. Rainfall fields in Israel and Jordan and the effect of cloud seeding on them. *Journal of Applied Meteorology*, 17(1):40–48.
- Sharon, D.  
1979. Correlation analysis of the Jordan Valey rainfall field. *Monthly Weather Review*, 107(8):1042–1047.
- Štěpánek, P., P. Zahradníček, a R. Huth  
2011. Interpolation techniques used for data quality control and calculation of technical series: an example of a Central European daily time series. *Quarterly Journal of the Hungarian Meteorological Service*, 115(1-2):87–98.
- Stocker, T., D. Qin, G.-K. Plattner, M. Tignor, S. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, a P. Midgley, eds.  
2013. *Climate change 2013: the physical science basis. Contribution of working group I to the fifth assessment report of the Intergovernmental Panel on Climate Change*. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press.
- Sunyer, M. A., J. Luchner, C. Onof, H. Madsen, a K. Arnbjerg-Nielsen  
2016. Assessing the importance of spatio-temporal RCM resolution when estimating sub-daily extreme precipitation under current and future climate conditions. *International Journal of Climatology*. In press.
- Svensson, C. a D. Jones  
2010. Review of methods for deriving areal reduction factors. *Journal of Flood Risk Management*, 3(3):232–245.
- Svoboda, V.  
2010. Porovnání srážkových úhrnů předpověděných modelem Aladin s interpolovanými bodovými měřeními pro oblast Jeseníků. Diplomová práce, Česká zemědělská univerzita v Praze, Fakulta životního prostředí, Katedra vodního hospodářství a environmentálního modelování.
- Svoboda, V., M. Hanel, P. Máca, a J. Kyselý  
2016a. Characteristics of rainfall events in RCM simulations for the Czech Republic. *Hydrology and Earth System Sciences Discussion*, in review.
- Svoboda, V., M. Hanel, P. Máca, a J. Kyselý  
2016b. Projected changes of rainfall event characteristics for the Czech Republic. *Journal of Hydrology and Hydromechanics*, 64(4).
- Svoboda, V. a L. Kalecký  
2013. Tvorba a uplatnění (klimatických) scénářů na regionální úrovni. In *Geografický výzkum: společnost a příroda v období krize*, R. Osman, ed., Sborník z workshopu, pp. 190–204. Masarykova univerzita, Brno.
- Svoboda, V., P. Máca, M. Hanel, a P. Pech  
2015. Spatial correlation structure of monthly rainfall at a mesoscale region of north-eastern Bohemia. *Theoretical and Applied Climatology*, 121(1):359–375.
- Tabios, G. Q. a J. D. Salas  
1985. A comparative analysis of techniques for spatial interpolation of precipitation. *Journal of the American Water Resources Association*, 21(3):365–380.

- Taylor, K. E., R. J. Stouffer, a G. A. Meehl  
2012. An overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society*, 93(4):485–498.
- Todisco, F.  
2014. The internal structure of erosive and non-erosive storm events for interpretation of erosive processes and rainfall simulation. *Journal of Hydrology*, 519(Part D):3651–3663.
- Tolasz, R., ed.  
2007. *Atlas podnebí Česka: climate atlas of Czechia*, 1st edition. ČHMÚ, Praha.
- Trenberth, K. E.  
2011. Changes in precipitation with climate change. *Climate Research*, 47(1–2):123–138.
- Uppala, S. M., P. W. KÅllberg, A. J. Simmons, U. Andrae, V. D. C. Bechtold, M. Fiorino, J. K. Gibson, J. Haseler, A. Hernandez, G. A. Kelly, X. Li, K. Onogi, S. Saarinen, N. Sokka, R. P. Allan, E. Andersson, K. Arpe, M. A. Balmaseda, A. C. M. Beljaars, L. V. D. Berg, J. Bidlot, N. Bormann, S. Caires, F. Chevallier, A. Dethof, M. Dragosavac, M. Fisher, M. Fuentes, S. Hagemann, E. Hólm, B. J. Hoskins, L. Isaksen, P. A. E. M. Janssen, R. Jenne, A. P. McNally, J.-F. Mahfouf, J.-J. Morcrette, N. A. Rayner, R. W. Saunders, P. Simon, A. Sterl, K. E. Trenberth, A. Untch, D. Vasiljevic, P. Viterbo, a J. Woollen  
2005. The ERA-40 re-analysis. *Quarterly Journal of the Royal Meteorological Society*, 131(612):2961–3012.
- Utsumi, N., S. Seto, S. Kanae, E. E. Maeda, a T. Oki  
2011. Does higher surface temperature intensify extreme precipitation? *Geophysical Research Letters*, 38(16).
- van der Linden, P. a J. F. B. Mitchell, eds.  
2009. *ENSEMBLES: climate change an its impacts: summary of research and results from the ENSEMBLES project*. Met Office Hadley Centre, Exeter.
- van Meijgaard, E., L. van Ulft, G. Lenderink, S. de Roode, E. Wipfler, R. Boers, a R. Timmermans  
2012. *Refinement and application of a regional atmospheric model for climate scenario calculations of western europe*, KvR 054/12. De Bilt: Programme Office Climate changes Spatial Planning, KNMI.
- van Meijgaard, E., L. H. van Ulft, W. J. van de Berg, F. C. Bosveld, B. van den Hurk, G. Lenderink, a A. P. Siebesma  
2008. *The KNMI regional atmospheric climate model RACMO version 2.1*, Technical Report, TR 302. De Bilt: KNMI.
- Velasco-Forero, C. A., D. Sempere-Torres, E. F. Cassiraga, a J. J. Gómez-Hernández  
2009. A non-parametric automatic blending methodology to estimate rainfall fields from rain gauge and radar data. *Advances in Water Resources*, 32(7):986–1002.
- Villarini, G., P. V. Mandapaka, W. F. Krajewski, a R. J. Moore  
2008. Rainfall and sampling uncertainties: a rain gauge perspective. *Journal of Geophysical Research: Atmospheres*, 113(D11):1–12.



- Weigel, A. P., R. Knutti, M. A. Liniger, a C. Appenzeller  
2010. Risks of model weighting in multimodel climate projections. *Journal of Climate*, 23(15):4175–4191.
- Westra, S., L. V. Alexander, a F. W. Zwiers  
2013. Global increasing trends in annual maximum daily precipitation. *Journal of Climate*, 26(11):3904–3918.
- Westra, S., H. J. Fowler, J. P. Evans, L. V. Alexander, P. Berg, F. Johnson, E. J. Kendon, G. Lenderink, a N. M. Roberts  
2014. Future changes to the intensity and frequency of short-duration extreme rainfall. *Reviews of Geophysics*, 52(3):522–555.
- Willems, P., K. Arnbjerg-Nielsen, J. Olsson, a V. Nguyen  
2012. Climate change impact assessment on urban rainfall extremes and urban drainage: Methods and shortcomings. *Atmospheric Research*, 103:106–118.
- Willems, P. a M. Vrac  
2011. Statistical precipitation downscaling for small-scale hydrological impact investigations of climate change. *Journal of Hydrology*, 402(3–4):193–205.
- Wischmeier, W. H. a D. D. Smith  
1978. *Predicting rainfall erosion losses: a guide to conservation planning*, Agriculture handbook 537. Science and Education Administration, U.S. Department of Agriculture.



## Seznam použitých symbolů a zkratek

<b>ARF</b>	Areal Reduction Factor / prostorový redukční faktor
$c_0$	correlation distance / parametr vzdálenosti v korelačních modelech
$c_1$	nugget / parametr posuvu v korelačních modelech
<b>CDD</b>	Correlation Decay Distance / parametr vzdálenosti v exponenciálních korelačních modelech
$D$	event depth / srážkový úhrn události [mm]
$E$	event rainfall energy / energie srážkové události [ $\text{MJ}\cdot\text{ha}^{-1}$ ]
$EI_{60}$	event rainfall erosivity index / index erozivity srážkové události [ $\text{MJ}\cdot\text{mm}\cdot\text{ha}^{-1}\cdot\text{h}^{-1}$ ]
<b>GCM</b>	Global Climate Model / globální klimatický model
$I_{60}$	maximum 60min rainfall intensity during an event / maximální 60min intenzita v průběhu události [ $\text{mm}\cdot\text{h}^{-1}$ ]
<b>IDW</b>	Inverse Distance Weighting / vážené inverzní vzdálenosti (interpolační metoda)
<b>MIT</b>	Minimum Inter-event Time / minimální čas mezi srážkovými událostmi (koncept pro odlišení individuálních srážkových událostí)
$N_{se}$	number of heavy rainfall events per season / počet intenzivních srážkových událostí za sezónu [-]
<b>OK</b>	Ordinary Kriging / základní kriging
$r$	Pearson's product-moment correlation coefficient / Pearsonův korelační koeficient
$R$	event mean rainfall rate / průměrná intenzita události [ $\text{mm}\cdot\text{h}^{-1}$ ]
$rt_f$	histogram ratio / poměr mezi histogramy prostorových a bodových charakteristik srážkových událostí (viz Kapitola 3.3.2)

$rt_m$	mean ratio / poměr mezi průměrnými hodnotami v prostorových a bodových charakteristikách srážkových událostí (viz Kapitola 3.3.2)
$rt_p$	quantile ratio / poměr mezi kvantily v prostorových a bodových charakteristikách srážkových událostí (viz Kapitola 3.3.2)
$rts_f$	histogram change / změna v histogramech charakteristik srážkových událostí (viz Kapitola 3.4)
$rts_m$	mean change / změna v průměrných charakteristikách srážkových událostí (viz Kapitola 3.4)
$rts_p$	quantile change / změna v kvantilech charakteristik srážkových událostí (viz Kapitola 3.4)
<b>RCM</b>	Regional Climate Model / regionální klimatický model
<b>RCP</b>	Representative Concentration Pathways / reprezentativní směry vývoje koncentrací
<b>RFO</b>	radiative forcing / radiační působení [ $W \cdot m^{-2}$ ]
$s_o$	shape factor / parametr tvaru v korelačních modelech
$S_{se}$	seasonal total due to heavy rainfall events / sezónní srážkový úhrn přinášený intenzivními srážkovými událostmi [mm]
<b>SRES</b>	Special Report on Emissions Scenarios / speciální zpráva o emisních scénářích
$T$	event duration / doba trvání události [h]
$T2M$	daily mean temperature / denní průměrná teplota [ $^{\circ}C$ ]
<b>USLE</b>	Universal Soil Loss Equation / univerzální rovnice ztráty půdy
$\rho$	Spearman's rank-order correlation coefficient / Spearmanův koeficient pořadové korelace
$\sigma$	residual standard error / směrodatná odchylka residuí
$\tau$	Kendall's rank correlation coefficient / Kendallův koeficient konkordance



## Seznam příloh

- **A)** Spatial correlation structure of monthly rainfall at a mesocale region of north-eastern Bohemia (Svoboda et al. 2015) str. 65
- **B)** Characteristics of rainfall events in RCM simulations for the Czech Republic (Svoboda et al. 2016a) str. 85
- **C)** Projected changes of rainfall event characteristics for the Czech Republic (Svoboda et al. 2016b) str. 115





## **Příloha A**

### **Spatial correlation structure of monthly rainfall at a mesocale region of north-eastern Bohemia**

V. Svoboda, P. Máca, M. Hanel, P. Pech  
*Theoretical and Applied Climatology*  
July 2015, volume 121, issue 1, pp. 359–375





# Spatial correlation structure of monthly rainfall at a mesoscale region of north-eastern Bohemia

Vojtěch Svoboda · Petr Máca · Martin Hanel · Pavel Pech

Received: 23 September 2013 / Accepted: 22 July 2014 / Published online: 5 August 2014  
© Springer-Verlag Wien 2014

**Abstract** The spatial correlation structure of monthly rainfall was analysed using data from 38 rain gauges located in north-eastern Bohemia. Three different inter-station correlation measures—Pearson’s correlation coefficient, Spearman’s rank-order correlation coefficient and Kendall’s tau rank correlation coefficient—were estimated using monthly rainfall records from a recent 31-year period. Six different theoretical parametric correlation models were identified using the nonlinear least squares method. The spatial correlation structure was described using the fitted parameters. Comparison of estimated correlation models showed that, as measured by standard error, the best fitted was a two-parameter exponential model. The relationships between parameters of the exponential two-parameter model were further explored and described. The temporal variability of correlation showed trends in the fitted parameters over the studied period. On a seasonal basis, the correlation between the stations was stronger in autumn and winter than in spring and summer. The spatial variability of estimated parameters revealed that parameters of Matérn and two-parameter exponential models were dependent on altitude.

## 1 Introduction

Rainfall spatial correlation structure provides essential information about the distribution of rainfall fields. It plays an important role for many applications in various areas.

For example, description of rainfall distribution and its variability over longer timescales like days or months provides important insights in climate change research, including for monitoring and detecting climate change (New et al. 1999, 2000; Alexander et al. 2006). It is also an essential part of evaluating climate models (Osborn and Hulme 1997; Hofstra et al. 2010) and uncertainties in climate change scenarios (Kyselý and Beranová 2009). Moreover, it is used for calibrating and merging satellite rainfall data (Feidas 2010; Williams et al. 2010).

In order to describe rainfall distribution, the estimation of spatial correlation structure is also studied over finer spatial and temporal resolutions (e.g. spatial scales of 1 km<sup>2</sup> and timescales from a few minutes) using various sources of information, such as data obtained from meteorological radar and dense networks of rain-gauges (Brommundt and Bárdossy 2007; Villarini et al. 2008; Tokay and Öztürk 2012). Knowledge of rainfall spatial correlation structure is also applied when assessing uncertainties associated with the estimation of rainfall distribution (Chumchean et al. 2006; Villarini et al. 2008; Mandapaka et al. 2010).

Tabios and Salas (1985) compared several spatial interpolation techniques for purposes of estimating spatial rainfall distribution, and, together with kriging, those techniques based on knowledge as to the spatial correlation structure (optimal interpolation) provided the best estimates of rainfall fields. Rainfall spatial correlation structure summarizes the relationships between the point records, and it is a commonly used concept for measuring spatial dependence of rainfall fields (Şen and Habib 2001; Ciach and Krajewski 2006). It is mostly expressed using a correlogram, which relates inter-station correlations with inter-site distances.

Estimation of a correlogram is performed in two main steps. The correlation is first described using an appropriate estimator and then the theoretical correlation func-

V. Svoboda (✉) · P. Máca · M. Hanel · P. Pech  
Department of Water Resources and Environmental Modeling,  
Faculty of Environmental Sciences, Czech University of Life  
Sciences Prague, Kamýčká 129, Praha 6–Suchbát, 165 21,  
Czech Republic  
e-mail: vsvoboda@fzpc.czu.cz

tions are identified. The most common correlation estimator is the Pearson product-moment correlation coefficient (e.g. Tabios and Salas 1985; Krajewski et al. 2003; Ciach and Krajewski 2006), which assumes that the data follow a bivariate normal distribution (Serinaldi 2008). For rainfall data distributed non-normally, Pearson's estimator can be biased and inefficient (Habib et al. 2001; Krajewski et al. 2003). To reduce this bias, Habib et al. (2001) proposed logarithmic transformation of rainfall data while assuming bivariate mixed log-normal distribution. In addition, they suggested as possible alternatives such non-parametric rank measures of correlation dependence as Spearman's rank-order correlation coefficient and Kendall's tau rank correlation coefficient.

The theoretical spatial correlation function for rainfall can be represented by several mathematical models. For their study, Tabios and Salas (1985) used three simple one-parameter models—square root, reciprocal and exponential—to describe the correlation function using monthly rainfall data from 30 years. The most widely used theoretical fitted correlation models are two- and three-parameter exponential models (e.g. Habib et al. 2001; Krajewski et al. 2003; Ciach and Krajewski 2006; Villarini et al. 2008; Tokay and Öztürk 2012). Recently, the Matérn model (Minasny and McBratney 2005; Clarke et al. 2011; Kaufman and Shaby 2013) has shown great flexibility for modelling spatial structure of random fields. The Gaussian and exponential correlation models are its special cases. From the conclusions of the aforementioned studies, it can be generalized that using multiple fitted parameters allows more flexible adjustment of the shape of the fitted spatial correlation function.

Krajewski et al. (2003) showed that spatial correlation functions are highly dependent on climatic regimes and temporal scale. They studied high-resolution rainfall data from timescales of 5, 15 and 60 min, and concluded that a one-parameter exponential model can in many situations be inadequate. Working with data from Central Oklahoma, Ciach and Krajewski (2006) presented estimates of spatial correlation functions in small-scale rainfall for distances up to 4 km. Using a sample from 2 years of rainfall data, they estimated spatial correlation using a three-parameter exponential model and demonstrated dependence of the correlation and the fitted parameters on the finer time scale and changes of the parameters on the individual rainfall event and intensity.

While studies dealing with the description of spatial correlation function on daily and monthly temporal basis (at least in the mesoscale regions) rely mainly on the application of exponential type models (Briffa and Jones 1993; Osborn and Hulme 1997; Şen and Habib 2001; Hofstra and New 2009), inter-comparison of spatial correlation functions and their interaction with different correlation estima-

tors may provide important insights into rainfall distribution research.

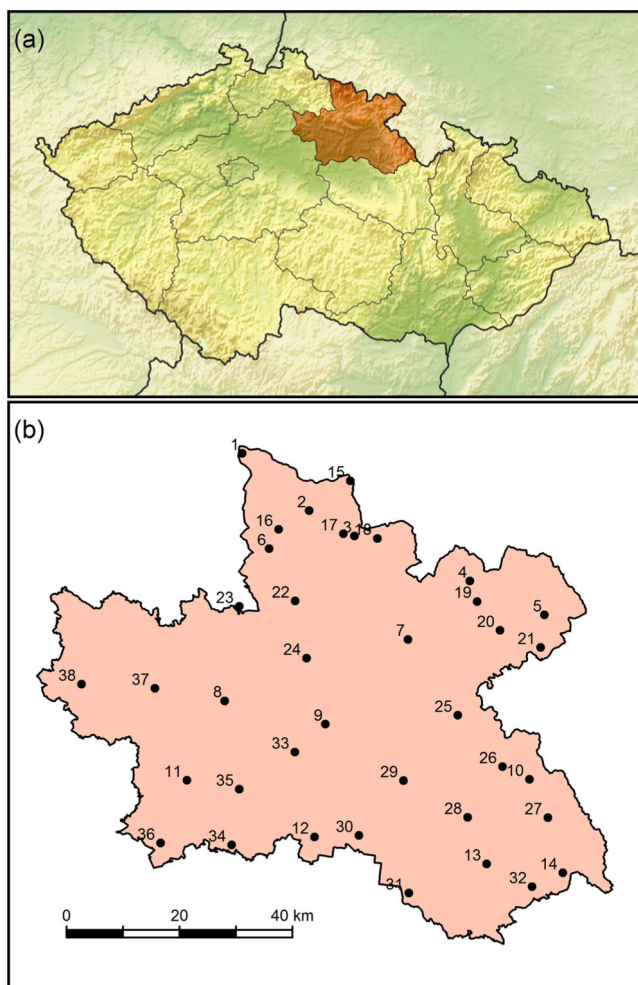
In this paper, we analyse inter-station correlation of rainfall within a mesoscale region in north-eastern Bohemia (Czech Republic). Spatial dependencies of rainfall were studied by examining inter-station correlation based upon 31 years of monthly rainfall data from 38 stations. We used three correlation estimators based on Pearson's sample  $r$ , Spearman's  $\rho$  and Kendall's  $\tau$  correlation coefficients and applied six spatial correlation models. Characteristics of those correlation estimations and the fitted correlation models used were studied and interrelationships between parameters of the multi-parameter models described. Attention was given to analysing temporal variability of the estimated parameters in seasons and decades, and to the dependence of the fitted parameters on elevation using general spatial variability of the parameters within the studied region.

Correlation estimators used for describing the spatial dependence of rainfall (Section 3.1) and theoretical fitted spatial correlation models (Section 3.3) are explained. Location and description of the study area and information about the rainfall data set are in Section 2. Description of the correlation structure of the area is contained in Section 4.1. Results concerning estimation of the spatial correlation functions are presented (Section 4.2), followed by analyses of temporal (Section 4.3) and spatial (Section 4.4) variability of estimated correlation parameters. Discussion and conclusions are stated in Section 5.

## 2 Study area and data description

The Hradec Králové Region, located in the north-eastern part of Bohemia and with total area of 4,759 km<sup>2</sup>, was selected to study the spatial correlation structure of rainfall fields (see Fig. 1a). Geomorphology of the region varies considerably, as mountains in the north and northeast merge into the River Elbe lowlands in the south and southwest. Altitude ranging from 202 to 1,602 m makes the region interesting for the purpose of the study.

Most of the region belongs to the humid climatic region of warm temperate zone (Cfb) according to Köppen's classification. Boreal climate (Dfb and Dfc) occurs in foothills and mountain areas and tundra (ET) at the highest elevations in the north. There is a significant temporal and spatial variability in precipitation. While precipitation in winter half of the year from October to March is characterized by lower intensity and longer duration caused by passing frontal systems and pressure lows, during the summer period from April to September precipitation is usually of shorter duration and greater intensity connected with the upward convective motion of air. Almost two thirds of the



**Fig. 1** Location map of Hradec Králové Region (a) and location of the stations with rain gauges (b)

annual precipitation falls in the summer half of the year. Precipitation conditions in the region are very unevenly, average annual precipitation totals are 550–650 mm in the lowlands whereas up to 1,200–1,600 mm in the mountains (Tolasz 2007).

Monthly rainfall totals collected for the 31 years from January 1981 to December 2011 were used for analysing the spatial correlation structure. Data were acquired from the 38 rain gauges located within the region which are part of the national climatological network administrated by the Czech Hydrometeorological Institute (CHMI). The locations of the stations are shown in Fig. 1b. The inter-gauge distances range from approximately 2 to 94 km. The rain gauge density is 1 rain gauge per 125 km<sup>2</sup>. The rain gauges cover approximately evenly the entire area.

Aggregated monthly measured rainfall totals were quality checked and controlled by CHMI. Missing values were filled, following the procedure explained by Štěpánek et al. (2011), using the inverse distance weighting interpolation


method (IDW). Values were calculated from up to six nearest stations with an allowed maximum difference in altitude of 500 m and the power of weight for IDW method was set to 3.

The distribution of mean annual precipitation totals in the region is shown in Fig. 2. Most of the stations have average annual precipitation between 600 and 800 mm. The greatest precipitation (1,420 mm) was measured at that station (No. 1: Labská bouda) having the highest altitude (1,315 m). The data set shows significant linear dependence of average annual precipitation on elevation (see Fig. 3). The overall linear trend for the Czech Republic for the period 1961–1990 which is indicated in Fig. 3 was provided by the work of Zíková (2009).

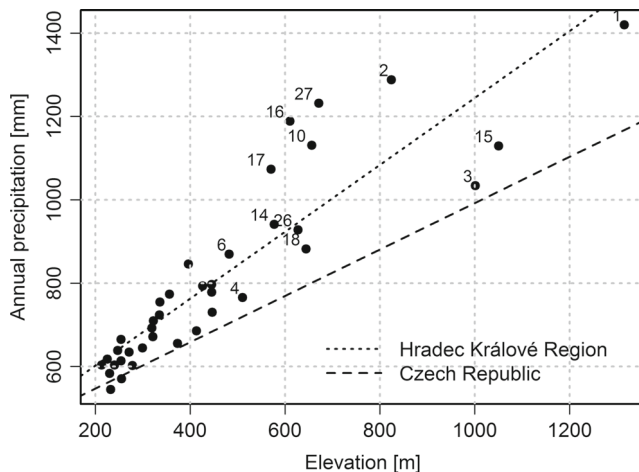
### 3 Methods

The analysis of the spatial rainfall correlation structure consists of the following basic steps:

- a Description of the correlation structure using the estimation of Pearson’s product-moment, Spearman’s rank-order and Kendall’s tau rank correlation coefficients (see Section 3.1).
- b Assessment of isotropy in the correlation structure (see Section 3.2).
- c Application of six theoretical models for description of the correlation structure given by the three metrics from the first step (see Section 3.3).
- d Analysis of the temporal variability of estimated parameters over the whole studied period and on a seasonal basis. The assessment of the effect of temporal resolution on the fitted parameters, and the analysis of the spatial variability over the region and the influence of elevation on the parameters (see Section 3.4).



**Fig. 2** Histogram of mean annual precipitation by number of stations



**Fig. 3** Relationship between annual precipitation and elevation in the studied area during 1981–2011 and in the Czech Republic generally during 1961–1990

### 3.1 Estimation of the inter-station correlation

Pearson's product-moment correlation coefficient is a widely used estimator for describing the spatial dependence of rainfall processes (e.g. Habib et al. 2001; Krajewski et al. 2003; Ciach and Krajewski 2006; Villarini et al. 2008). It indicates and measures the strength of the linear dependence between two variables. The correlation coefficient can be defined as the covariance of the two variables ( $X, Y$ ) divided by the product of their standard deviations:

$$r(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}. \quad (1)$$

While Pearson's sample correlation  $r$  is commonly used as an estimator of the correlation of a general population, for data not normally distributed Pearson's estimator can be inefficient (Habib et al. 2001; Krajewski et al. 2003). Habib et al. (2001) suggested the possibility of using non-parametric rank measures of dependence, such as Spearman's  $\rho$  and Kendall's  $\tau$ , as possible alternatives to avoid the bias of Pearson's correlation coefficient.

Spearman's rank-order correlation coefficient  $\rho$  also as the Kendall's  $\tau$  rank correlation coefficient are measures of how well are the two variables monotonically related in the case that their interrelationship is not linear. Spearman's  $\rho$  is based on Pearson's product-moment correlation in which variables ( $X, Y$ ) are transformed into ranks ( $x_i, y_i$ ). A monotonic relationship is an important underlying assumption for the Spearman's  $\rho$  correlation. The assumption of a monotonic relationship is less restrictive than is that of a linear relationship which must be met by Pearson's  $r$  correlation.

Kendall's  $\tau$  is an alternative measure based on a link among variables known as concordance, which is a measure of the similarity of the orderings of the data when

ranked by each of the quantities. If we consider two observations ( $x_i, y_i$ ), ( $x_j, y_j$ ) from a vector of  $n$  observed rainfall values ( $X, Y$ ), then the pairs ( $x_i, y_i$ ) and ( $x_j, y_j$ ) are said to be concordant if  $(x_i - x_j)(y_i - y_j) > 0$  and discordant if  $(x_i - x_j)(y_i - y_j) < 0$ . Kendall's  $\tau$ , then, is defined as the difference between the probability of concordance and the probability of discordance,

$$\tau(X, Y) = \frac{c_n - d_n}{\frac{1}{2}n(n-1)}, \quad (2)$$

where  $c_n$  is the number of concordant pairs and  $d_n$  number of discordant pairs.

Spearman's rank-order correlation coefficient  $\rho$  and Kendall's  $\tau$  rank correlation coefficient are two closely related and the most commonly used non-parametric measures of association for two random variables. Fredricks and Nelsen (2007) stated that the value of the Spearman's  $\rho$  correlation coefficient is about 50 % larger than the value of the Kendall's  $\tau$  coefficient for the same data sample. Because these measures are invariant under monotone transformations, when we apply them to coherent systems or to order statistics, they are free from distributional assumptions (Navarro and Balakrishnan 2010). In terms of dependence properties Spearman's  $\rho$  is a measure of average quadrant dependence, while Kendall's  $\tau$  is a measure of average likelihood ratio dependence (Nelsen 1992).

For computation of correlation coefficients, we used The R Project for Statistical Computing (R Core Team 2013), specifically *cor()* function (Becker et al. 1988), and compute the correlation coefficients between every pair of stations according to three metrics described above.

### 3.2 Isotropy in the correlation structure

Application of correlation models assumes isotropy in correlation—correlation decreased with increasing distance independently of the direction (e.g. Jones et al. 1997). To determine anisotropy in correlation is used 2-D spatial correlation maps (e.g. Sharon 1978, 1979; Velasco-Forero et al. 2009; Mandapaka and Qin 2013). 2-D spatial correlation map describes a spatial pattern of correlation coefficients which are not dependent on specific points but only on their mutual vectorial differences, thus correlation coefficients become a function only of the distances and directions between the stations. As we take distance and direction of every station versus all the others, the correlation map is symmetric around the zero origin.

To create 2-D spatial correlation maps, we used Ordinary kriging (OK) as widely used method for estimate rainfall fields (described e.g. in Velasco-Forero et al. 2009). The procedure consists of the following steps. After creating an interpolation grid in 1 km resolution covering the study area, we used R library *gstat* (Pebesma 2004) to calculate the

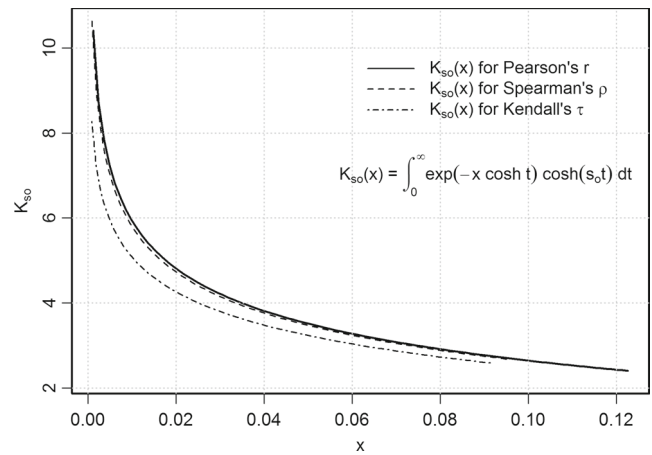
sample variogram for the three correlation estimators and fit variogram model coefficients to sample variogram. This fitted variogram is used to compute the weights used in OK, the result is 2-D spatial correlation map in a 1 km grid from which we can assess the isotropy in the correlation structure.

### 3.3 Theoretical spatial correlation functions

After describing the correlation structure using the estimators explained above, selected theoretical models of spatial correlation are identified using gradient-based nonlinear least squares optimization. We applied *nls()* function with algorithm "port" in R, where nonlinear least squares method is used iteratively to the inter-station correlation coefficients data set to minimize nonlinear sum of squares using analytic jacobian (for technical information related to *nls()* and "port" please see Ritz and Streibig (2008) and Dennis et al. (1981)). Successful fitting depends on setting starting values of parameters that are reasonably close to the solution and constraints on the parameters in required bounds (Fox and Weisberg 2010).

The spatial correlation models are shown in Table 1. Square root, reciprocal and exponential one-parameter (1P) models are models with the single parameter  $c_0$ , termed the correlation distance. The Matérn and exponential two-parameter (2P) and three-parameter (3P) models have a second parameter,  $s_0$ , the shape factor, and the exponential 3P model has a third parameter,  $c_1$ , the nugget parameter. In all equations,  $d$  is the distance between two rain gauges. In the Matérn model equation (Handcock and Wallis 1994),  $\Gamma$  is the gamma function and  $K_{s_0}$  is modified Bessel function of the second kind of order  $s_0$  (Abramowitz and Stegun 1972). Figure 4 provides a description of  $K_{s_0}$  and shows  $K_{s_0}(\sqrt{2s_0} \frac{d}{c_0})$  functions for our fitted monthly rainfall data.

The correlation distance parameter  $c_0$ , also denoted as range or decorrelation scale, characterizes the decay of correlation. For the exponential models, parameter  $c_0$  is defined as the distance at which the fitted correlation curve decays below  $1/e$  and is called the correlation decay distance (CDD) (Hofstra and New 2009). Based on the approach of



**Fig. 4** Bessel functions of the second kind of order  $s_0$  for the Matérn model fitted to the three estimated correlations, where  $x$  is  $\sqrt{2s_0} \frac{d}{c_0}$ , with functions shown for the distances  $d \in [0, 100]$  kilometer

Dai et al. (1997), New et al. (2000) defined CDD as the distance at which zonally averaged inter-station correlation is no longer significant at the 0.05 level ( $\approx 0.368$  for monthly records encompassing 30 years). Many studies have investigated CDD's dependence on latitude and season periods for temperature and rainfall (e.g. Briffa and Jones 1993; Jones et al. 1997; Osborn and Hulme 1997; New et al. 2000; Alexander et al. 2006; Hofstra and New 2009; Mandapaka and Qin 2013). New et al. (2000) found similar CDDs for exponential 1P model as Dai et al. (1997) did for latitudes corresponding to those of Central Europe from monthly precipitation totals. Their CDD values are 400–500 km, depending on the season. A large CDD indicates that more distant stations still retain significant correlation (Briffa and Jones 1993; Osborn and Hulme 1997).

The shape factor  $s_0$  significantly controls the model behaviour in small separation distances (Habib et al. 2001; Ciach and Krajewski 2006). Values less than one indicate rapid decrease of correlation function than the exponential function before the correlation distance  $c_0$  and more slowly decrease at greater distances (Marchand 2012; Mandapaka and Qin 2013). Ciach and Krajewski (2006)

**Table 1** Spatial correlation models with parameters, correlation distance  $c_0$ , shape  $s_0$ , nugget  $c_1$

Model	Fitting function	Parameters
Square root	$r(d) = \frac{1}{\sqrt{1 + \frac{d}{c_0}}}$	$c_0$
Reciprocal	$r(d) = \frac{1}{1 + \frac{d}{c_0}}$	$c_0$
Exponential 1P	$r(d) = \exp\left(-\frac{d}{c_0}\right)$	$c_0$
Exponential 2P	$r(d) = \exp\left[-\left(\frac{d}{c_0}\right)^{s_0}\right]$	$c_0, s_0$
Exponential 3P	$r(d) = c_1 \exp\left[-\left(\frac{d}{c_0}\right)^{s_0}\right]$	$c_0, s_0, c_1$
Matérn	$r(d) = \frac{1}{2^{s_0-1}\Gamma(s_0)} \left(\sqrt{2s_0} \frac{d}{c_0}\right)^{s_0} K_{s_0}\left(\sqrt{2s_0} \frac{d}{c_0}\right)$	$c_0, s_0$

reported that the shape of the correlogram is affected at short time scales while the correlation distance parameter varies more at longer time scales. The value of the shape parameter also determines the interdependence between exponential and Matérn models. If exponential 2P or 3P models have  $s_0 = 1$ , then both models correspond to the exponential 1P model; the same applies to the Matérn model for the case of  $s_0 = 0.5$  (Minasny and McBratney 2005).

The nugget parameter  $c_1$  provides information about the variability of rainfall at very small, near-zero distances and it is also useful in analysing measurement errors. The closer is  $c_1$  to 1 the smaller are the variability and measurement errors (Villarini et al. 2008).

In order to be used as a valid correlation models for simulating spatially correlated random fields and to preserve mathematical stability during the fitting process, we imposed the following constraints on the parameters:  $c_0 > 0$ ,  $s_0 \in [0, 2]$  and  $c_1 \in [0, 1]$ .

The precision of the fitted models is evaluated using residual standard error,

$$\sigma = \sqrt{\frac{SSE}{n - p}}, \quad (3)$$

where  $SSE$  is the sum of squared residuals,  $n$  is the number of original values,  $p$  is the number of fitted parameters and  $n - p$  denotes degrees of freedom.

### 3.4 Analysis of temporal and spatial variability of rainfall correlation from the perspective of fitted parameters

In order to describe the temporal variability of fitted correlation parameters, the long-term temporal variability, seasonality and influence of temporal aggregation on fitted correlation parameters were further explored.

To analyse temporal variability of the fitted parameters during the studied period, we used a 10-year moving window, estimated correlation and fitted the correlation models for each of the 10-year shifts starting from the year 1981 to 1990 and ending in the time window from 2002 to 2011.

For analysing seasonal variability, data for all 31 years were subdivided by months into climatological seasons (MAM, JJA, SON and DJF) and seasonal correlations were computed. The effect of aggregation on the correlation was analysed using the time resolutions of 3, 6, 9 and 12 months. We explored the seasonality and effect of time resolution using the exponential 2P model.

In order to describe the spatial variability of the fitted correlation parameters, the dependence of fitted parameters on elevation and the distribution of parameters over the studied domain were further analysed.

For visual representation of the spatial variability of fitted parameters for the selected models, the region was

divided into Voronoi cells (e.g. Aurenhammer 1991). Thus, the region was divided into 38 subregions approximately centred on each of the stations so that every point in each subregion is closer to its central station than to any other station. Each subregion is characterized by its central station, to which have been fitted correlations for all stations with their distances from the given station.

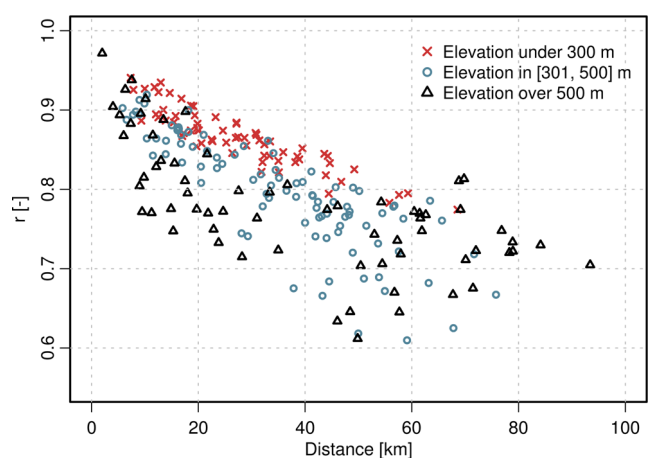
## 4 Results

Results are summarized into the following sections:

- Description of the correlation structure over the studied region for three correlation metrics with assessment of isotropy (see Section 4.1).
- Fitting the theoretical spatial correlation models, assessment of the errors and analysis of the estimated parameters (see Section 4.2).
- Temporal variability of the fitted parameters (see Section 4.3).
- Spatial variability of the fitted parameters (see Section 4.4).

### 4.1 Description of the correlation structure and assessment of isotropy

As correlation decreases as a function of distance, we look at the influence of elevation to the inter-station correlation coefficients. Figure 5 shows example of Pearson's  $r$  (other estimators show the same trend), where are plotted inter-station correlation coefficients only between the stations located at specific altitudes. It is evident that in low altitudes under 300 m is correlation stronger, at high altitudes over 500 m are noticeable two separate mountain areas. As we



**Fig. 5** Pearson's  $r$  between the station pairs located only at specific altitudes under 300 m, in [301, 500] m and over 500 m

had limited amount of stations in thus separate altitudes, we fit and analysed the whole data set.

Inter-station correlation coefficients estimated by Pearson's  $r$ , Spearman's  $\rho$  and Kendall's  $\tau$  are shown in correlograms in Fig. 6. Values of Spearman's correlation coefficients were more similar to Pearson's (Spearman's coefficients were higher by 1 % on average) than those of Kendall's (Kendall's coefficients were lower by 22 % on average).

To assess the isotropy in the correlation, we applied OK and create 2-D spatial correlation maps (Fig. 7). Fitted variograms for three correlation estimators used to compute the weights for OK are shown in Fig. 8. We tested various variogram models and the best variogram fit provides Matérn model with the shape factor  $s_0 \rightarrow \infty$ , which is equivalent of the Gaussian model (Minasny and McBratney 2005). Thus, the corresponding semivariance function can be described as:

$$\gamma(d) = c_1 + c_2 \left[ 1 - \exp\left(-\frac{d^2}{c_0^2}\right) \right], \quad (4)$$

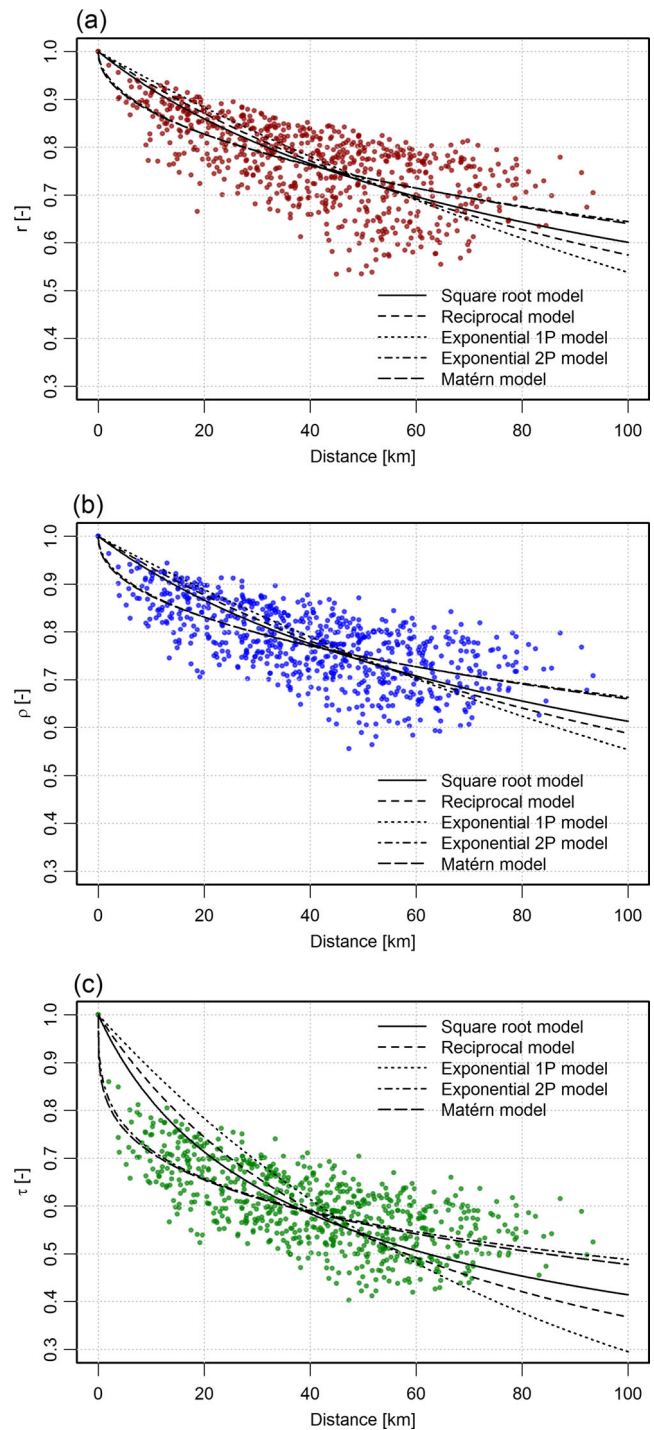
where  $c_0$  is range,  $c_1$  nugget effect and  $c_2$  partial sill (sill variance is  $c_1 + c_2$ ).

Figure 7 shows ordinary kriging predictions in interpolation grid as 2-D spatial correlation maps (Fig. 7a) with corresponding kriging variances (Fig. 7b). Distances are limited up to 40 km, at longer inter-station distances are available correlations too sparse and the edge effect affects results, which is especially apparent in the W–E direction. Although all three models show slight anisotropy in SW–NE direction (the most significant for Pearson's  $r$ ), we consider spatial structure to be isotropic. Prediction error variances (Fig. 7b) increase with increasing distance but still they stay at very low level (around 0.003) for all correlation estimators.

#### 4.2 Fitting the spatial correlation functions

The results of final fitted parameters for spatial correlation functions from all pairs of stations using a data series with 31 years of monthly rainfall including standard errors for all parameters are in Table 2. Figure 6 compares fitted correlation functions as plotted against inter-station distances to show dependence for  $d \in [0, 100]$  km.

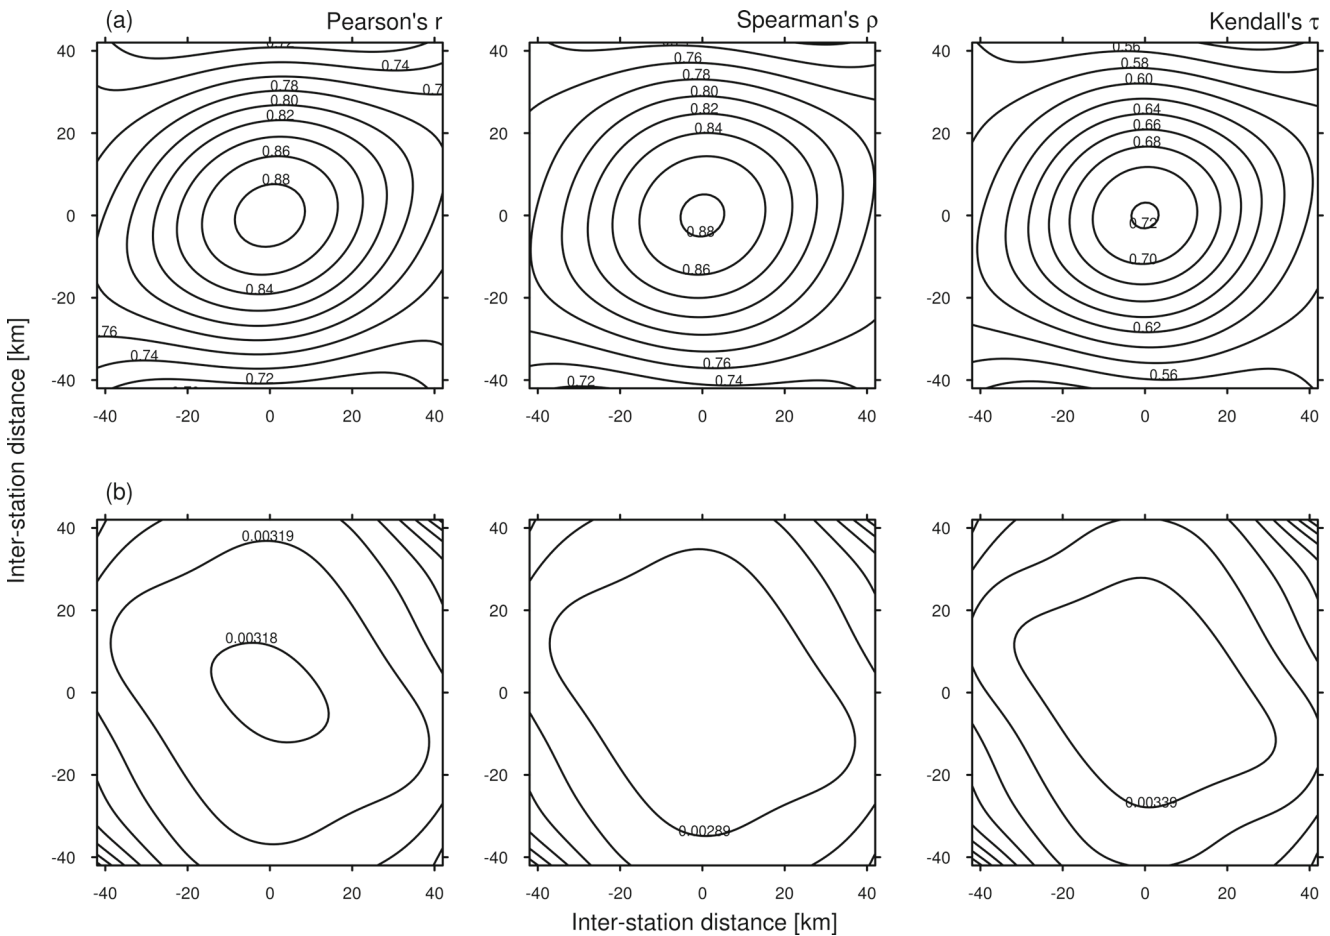
We construct an error curves for each fitting model using the bootstrap procedure. Process consists of performing the 500 simulations on sampled data. Each data sample, consists of 31 years, is generated by year (to eliminate the influence of seasonal variability of correlation) by combination with repetitions. From these 500 simulations are



**Fig. 6** Relationships between Pearson's  $r$  (a), Spearman's  $\rho$  (b), Kendall's  $\tau$  (c) and distances, with models fitted on data

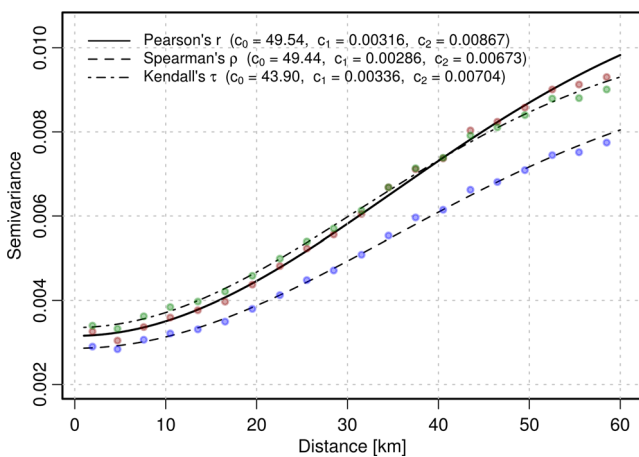
computed 0.1, 0.5 and 0.9 quantiles of correlation coefficients in distances up to 100 km, which represented error curves in Fig. 9.

Differences between 0.1 and 0.9 quantile of correlation coefficients for fitted models depending on the distance are



**Fig. 7** 2-D spatial correlation maps computed from inter-station correlations for Pearson's  $r$ , Spearman's  $\rho$  and Kendall's  $\tau$  (a) with prediction error variances, where *lines* indicate increase of error with increasing distance by  $10^{-5}$  (b)

shown in Fig. 10. The narrowest range at larger separation distances (approximately from 30 km) compared to other estimators have Kendall's  $\tau$ .



**Fig. 8** Sample variograms and fitted Gaussian models for Pearson's  $r$ , Spearman's  $\rho$  and Kendall's  $\tau$  with appropriate model coefficients used to compute the weights for Ordinary kriging to generate 2-D spatial correlation maps

Statistical information for the fitted models is checked by the  $nls()$  function. The residual standard error was lowest for models having more parameters (exponential 2P, 3P and Matérn) while the exponential 1P model had the highest residual standard error. All parameters' values were statistically significant at level  $p < 0.001$ .

In comparing one-parameter models, the exponential model was seen to be closer to a linear trend than the reciprocal and square root models. This corresponds to the higher correlation coefficient at smaller separation distances and lower correlation at longer distances for the exponential model than for the others. The turning point is given by the intersection of the fitting curves. One-parameter models have this area where all fitting curves intersect in a narrow range (52.0–56.2 km for Pearson's, 52.7–56.7 km for Spearman's and 46.9–53.3 km for Kendall's correlation). This behaviour is characterized by the correlation distance parameter  $c_0$ , which increased from a low value in the case of the square root fitting model (56.62 km for Pearson's, 60.25 for Spearman's and 20.13 for Kendall's correlation) to the largest value for the exponential model (161.5 km



**Table 2** Fitted parameters of spatial correlation models, with bold font showing the best model as indicated by the lowest value of  $\sigma$


Correlation estimator	Fitting model	$c_0$	std. dev	$s_0$	std. dev	$c_1$	std. dev	$\sigma$
Pearson's $r$	square root	56.620	(0.6559)	-	-	-	-	0.06648
	reciprocal	135.04	(1.4380)	-	-	-	-	0.06960
	exponential 1P	161.50	(1.5910)	-	-	-	-	0.07413
	exponential 2P	481.16	(40.402)	0.5238	(0.0181)	-	-	<b>0.06289</b>
	exponential 3P	481.16	(43.120)	0.5238	(0.0283)	1	(0.0099)	0.06291
	Matérn	783.95	(72.290)	0.2310	(0.0084)	-	-	0.06299
Spearman's $\rho$	square root	60.253	(0.6677)	-	-	-	-	0.06226
	reciprocal	142.75	(1.4690)	-	-	-	-	0.06551
	exponential 1P	169.51	(1.6300)	-	-	-	-	0.07000
	exponential 2P	604.89	(54.749)	0.4951	(0.0168)	-	-	<b>0.05733</b>
	exponential 3P	604.89	(58.680)	0.4951	(0.0258)	1	(0.0090)	0.05735
	Matérn	982.90	(96.660)	0.2190	(0.0078)	-	-	0.05740
Kendall's $\tau$	square root	20.313	(0.2205)	-	-	-	-	0.07449
	reciprocal	57.225	(0.5866)	-	-	-	-	0.08747
	exponential 1P	80.928	(0.7871)	-	-	-	-	0.10650
	exponential 2P	260.53	(15.050)	0.3345	(0.0093)	-	-	<b>0.05909</b>
	exponential 3P	260.53	(15.650)	0.3345	(0.0120)	1	(0.0095)	0.05911
	Matérn	786.93	(70.930)	0.1294	(0.0040)	-	-	0.05917

for Pearson's, 169.5 for Spearman's and 80.93 for Kendall's correlation).


All fitted multi-parameter models had very similar shapes for distances up to the 100 km. During the parametrization of the exponential 3P models, we excluded correlation values of data series with itself (values at zero distances). The estimated value of the nugget parameter was still practically  $c_1 = 1$ , which is consistent with the report of Villarini et al. (2008) that

nugget parameter asymptotically increases with larger integration times—in their study increasing to 0.96 for just the 5-min scale. For our complex monthly rainfall data series, without near-zero inter-station distances, the exponential 2P and 3P models were practically identical.

The lower value of the shape factor  $s_0$  caused steeper decrease of correlation at small separation distances (lowest value of parameter  $s_0$  is 0.335 for the exponential 2P model



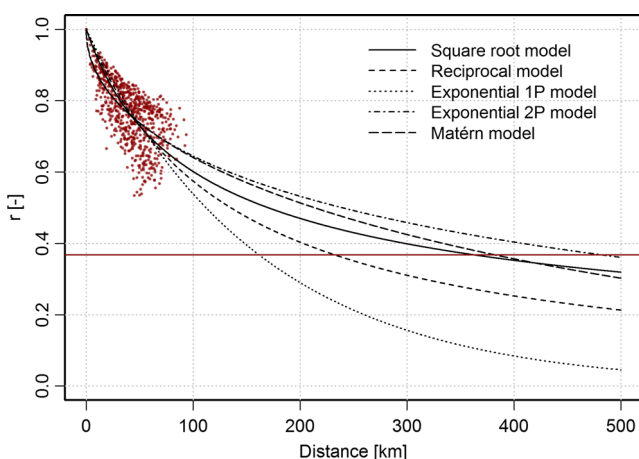
**Fig. 9** Error curves for models fitted on Pearson's  $r$  (left), Spearman's  $\rho$  (middle) and Kendall's  $\tau$  (right), lines represent 0.5 quantile and stripes range between 0.1 and 0.9 quantile of correlation coefficients



**Fig. 10** Range of Pearson's  $r$  (left), Spearman's  $\rho$  (middle) and Kendall's  $\tau$  (right) between error curves of fitted models represented by differences between the 0.1 and 0.9 quantile

and it is 0.129 for the Matérn model fitted to Kendall's correlation). Small separation distances can be indicated as the distances smaller than these where fitting curves of multi-parameter models intersect with fitting curves of one-parameter models (the area where the exponential 2P and Matérn models intersected with the other one-parameter models is given by distances 42.2–48.3 km for Pearson's, 43.0–48.5 km for Spearman's and 37.6–45.6 km for Kendall's correlations, see Fig. 6).

The CDD values (see Fig. 11 for example of Pearson's  $r$  fitted correlation) of exponential models are given by the correlation distance parameter  $c_0$ . For the exponential 1P model CDD equalled 161.50 km and for the exponential 2P model it was 481.16 km. Values of reciprocal (232.04 km), square root (361.75 km) and Matérn (381.44 km) models are shown for comparison (please note that CDD for other than exponential model is not equal to the  $c_0$  parameter). There



**Fig. 11** Comparison of CDD values for exponential models fitted on Pearson's  $r$ ; CDD is given as the point where the fitting curve has correlation of  $1/e$  (displayed as *solid line*), with other models plotted for comparison

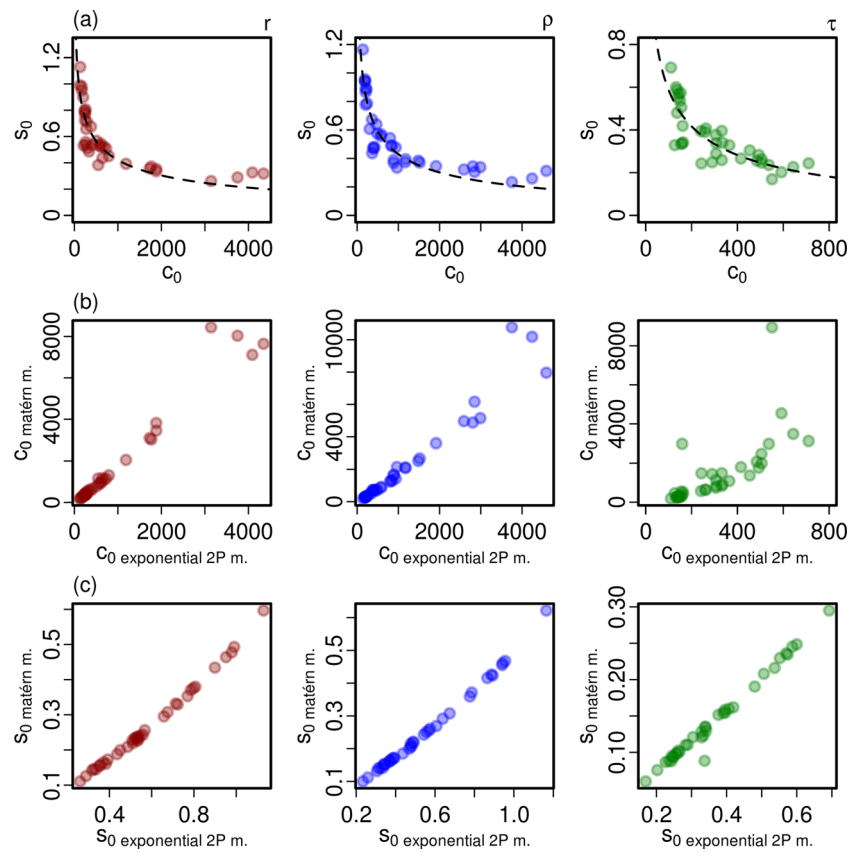
is an evident difference between the Matérn and exponential 2P models for separation distances larger than 100 km, as correlation fitted by the Matérn model decays faster. Fitted models for other correlation estimators showed the same order of CDD values (i.e. the lowest value of CDD was found for the exponential 1P model and highest for the exponential 2P model), as the highest values were in the case of Spearman's fitted correlation and the lowest for Kendall's correlation.

From Fig. 11, it is evident that CDD values are much higher than inter-station distances in the study, thus we can presume that limited inter-station distances affecting the CDD values. The CDD value would be higher for exponential 1P model with involved correlation coefficients in larger separation distances, as one can see in study from Hofstra et al. (2010), but for the exponential 2P model we could expect a decrease of CDD.

The relationship between fitted parameters was examined on the exponential 2P and Matérn models. For each of 38 stations, we estimated the correlation functions with the distances to the other stations using the exponential 2P function, and thus for the each station we obtained a pair of parameters. The relationship between parameters was examined (see Fig. 12). In terms of the variance of parameters' values between stations, the correlation distance  $c_0$  had a relatively wide range with a standard deviation of 1,149 for Pearson's  $r$ , 1,107 for Spearman's  $\rho$  and 170 for Kendall's  $\tau$ , where two  $c_0$  parameters (from Pearson's correlation station no. 15 and from Kendall's correlation station no. 22, for station position [see Fig. 1b]) had very high values (19,602 and 1,251, respectively) compared to the others. These outlier stations have been excluded from parameter analysis.

The shape factor  $s_0$  took on similar values for Pearson's and Spearman's correlations while for Kendall's correlation it had significantly lower values. Having the narrowest

**Fig. 12** Interrelationship between fitted parameters  $c_0$  and  $s_0$  of the exponential 2P fitting function for Pearson's  $r$ , Spearman's  $\rho$  and Kendall's  $\tau$  correlations (a) and comparison of the values of  $c_0$  (b) and  $s_0$  (c) fitted parameters of the Matérn and exponential 2P models



range were parameters for the fitted Kendall's  $\tau$  correlation, at  $c_0 \in [110, 711]$  kilometer with median 290 km and  $s_0 \in [0.1695, 0.6921]$  with median 0.337. From the interdependence among the parameters of the exponential 2P function, a significant interrelationship is visible between the correlation distance  $c_0$  and the shape factor  $s_0$ , wherein a higher value of  $c_0$  implies a lower value of  $s_0$ . This fitted dependence is plotted as a dashed line in Fig. 12a. This relationship between  $c_0$  and  $s_0$  is described by the exponential function, where new parameters are renamed for convenience as

$$s_0(c_0) = n_1 \exp[-(c_0)^{n_0}], \tag{5}$$

where  $n_0$  and  $n_1$  are new parameters. Their fitted values are shown in Table 3. Outlier values have greater influence on the nugget parameter  $n_1$  than on the shape parameter  $n_0$  (e.g.

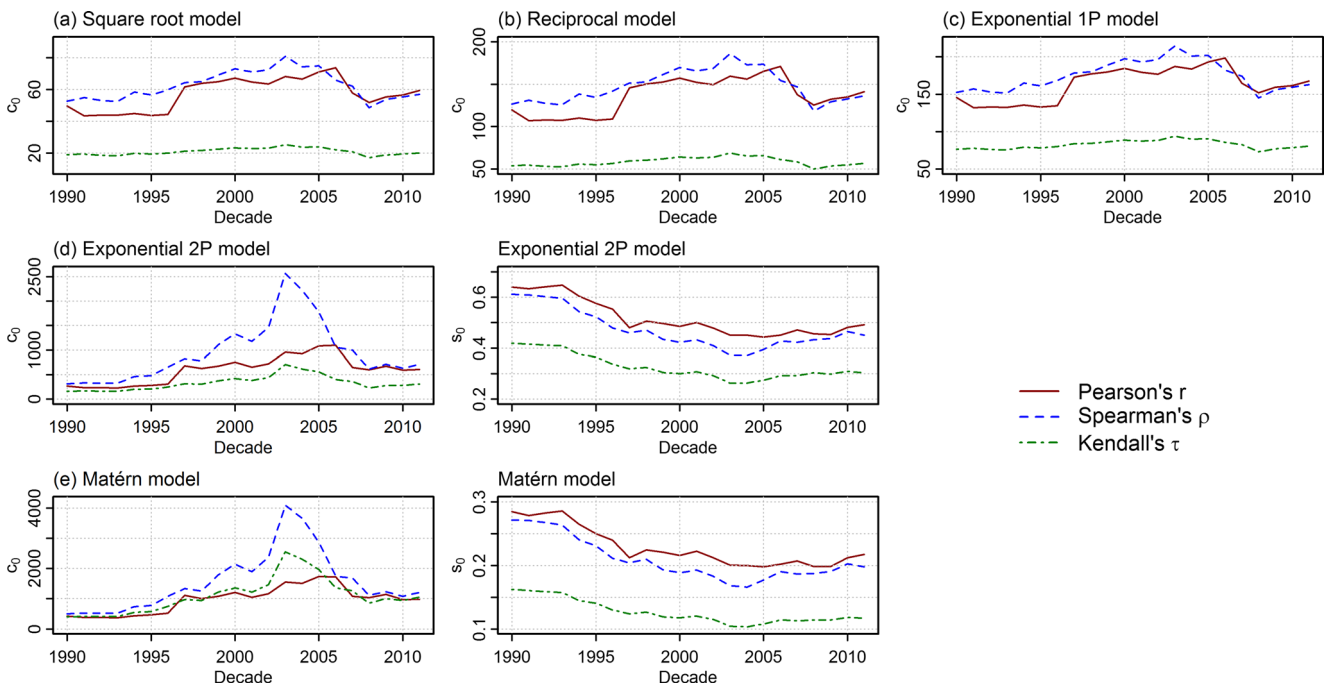
**Table 3** Fitted parameters for the correlation distance and shape factor relationship for the exponential 2P model

Correlation estimator	$n_0$	$n_1$
Pearson's $r$	0.154	7.621
Spearman's $\rho$	0.160	8.785
Kendall's $\tau$	0.191	6.485

for Pearson's correlation with outlier station involved is  $n_1$  lower by 0.22 while  $n_0$  by 0.002).

Inter-comparisons of parameter values computed by the Matérn and exponential 2P models are shown in Figs. 12b and c. There is a strong linear relationship between the two models. Correlation distance parameters  $c_0$  for both models were correlated with correlation coefficients  $r = 0.98$  for fitting Pearson's estimator,  $r = 0.97$  for the Spearman's  $\rho$  and  $r = 0.71$  for the Kendall's  $\tau$ . With involved aforesaid outliers was the relationship much weaker for the Pearson's  $r$ , but slightly stronger for the Kendall's  $\tau$ . If we excluded these stations from the Spearman's  $\rho$ , relationship stays almost the same. The linear relationship between the shape factors is even more evident, there is influence of outliers insignificant.

One-parameter models also had very strong linear relationships of the fitted parameters amongst themselves ( $r > 0.9$ ), with the highest correlation values being between the square root and reciprocal models ( $r > 0.96$  for all fitted estimators). Between the  $c_0$  parameter of the one-parameter models and exponential 2P model, there existed a weak monotonic relationship only for the fitted Pearson's  $r$  (correlation coefficient  $\rho \approx 0.3$ ). No relevant correlation dependence was observed between the  $c_0$  from one-parameter models and the  $s_0$  from multi-parameter models.



**Fig. 13** Changes of fitted parameters of square root (a), reciprocal (b), exponential 1P (c), exponential 2P (d) and Matérn (e) models for Pearson's  $r$  (solid lines), Spearman's  $\rho$  (dashed lines) and Kendall's  $\tau$  (dot-dash lines) correlations during moving decades from 1981–1990 to 2002–2011

#### 4.3 The temporal variability of fitted correlation parameters

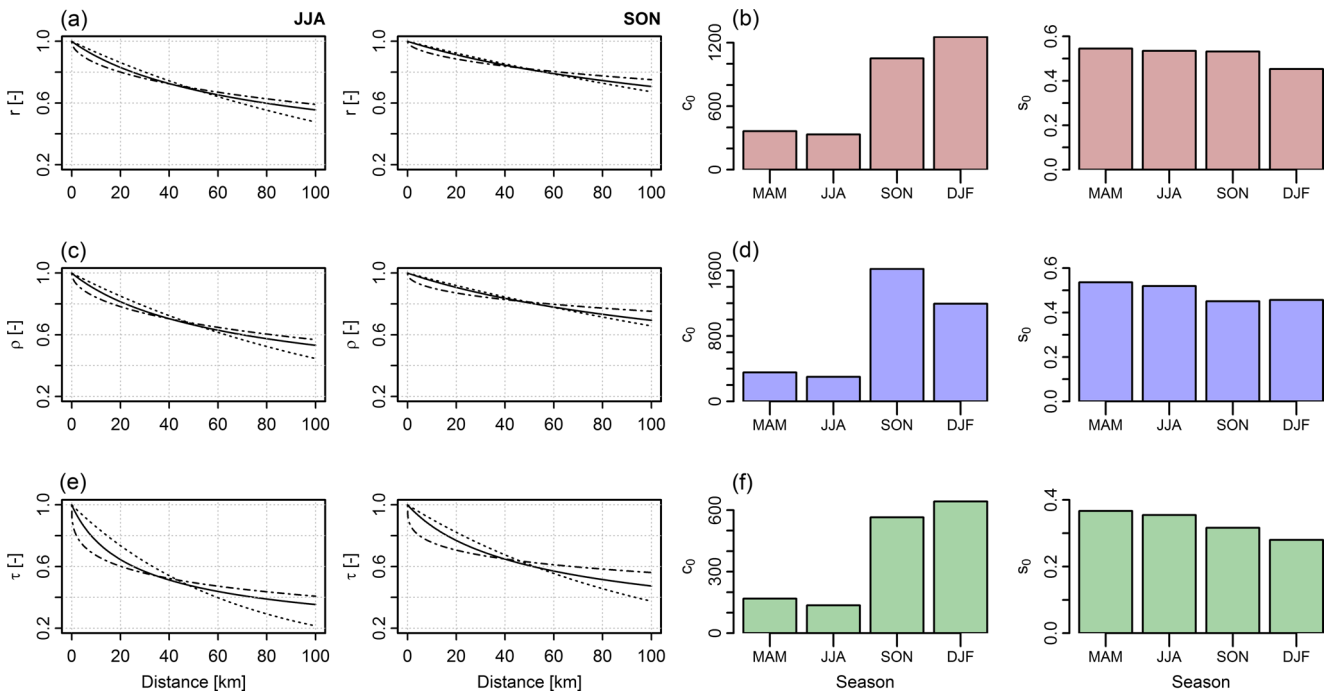
A 10-year moving time window (Fig. 13) shows changes in the five fitted correlation models' parameters during decades from 1981–1990 to 2002–2011, and thus each line represents 21 values.

All one-parameter models had more similar temporal distribution of the  $c_0$  parameter, differing only in the parameter's absolute value, when maximal values were found in the decades from 1991–2000 to 1997–2006. Values of the  $c_0$  parameter are apparently connected with the amount of rainfall totals, because the highest totals were measured in the decades from 1992–2001 to 1995–2004 and lowest totals in the decades from 1982–1991 to 1984–1993. The linear gradient of the  $c_0$  value increased in all cases for one-parameter models. The greatest increase by 10-year period was for the  $c_0$  parameter in the Pearson's correlation fitted by the exponential 1P model (increase by 13.4 per decade), and the lowest was for the Kendall's correlation fitted by square root model (increase by 0.5 per decade). Overall increases of the  $c_0$  parameter over the 31 years in percentage terms were for the Pearson's correlation from 29 to 38 %, for the Spearman's 8.7 to 9.9 % and for the Kendall's 5.9 to 7.1 %, where the lower bound was in all cases given by the exponential 1P model and the upper bound by the square root model.

For the studied period, those models with more parameters showed higher variability of the correlation distance  $c_0$ , whereas the shape factor  $s_0$  remained relatively stable. The maximal values of  $c_0$  and minimal values of  $s_0$  were

again in the decades from 1991–2000 to 1997–2006. The linear gradient of the  $c_0$  value increased more rapidly; the highest increase by 10-year period was for the  $c_0$  parameter in the Spearman's correlation, which increased by 260 per decade if fitted by the exponential 2P model and 448 for the Matérn model. Overall increase in percentage terms was again highest for the Pearson's correlation (by 206 % for the exponential 2P model and 214 % for the Matérn model). The linear gradient of the  $s_0$  value decreased in all cases. The decrease was slighter for the Matérn model, but the percentage changes across the full research period were very similar for all correlations (decreasing by 32 to 34 %).

From the inter-year variability of correlation in climatological seasons, it is clearly evident that there exists stronger correlation of rainfall between the stations in autumn and winter than in spring and summer for all fitted correlations. This is expected since the precipitation is mostly frontal in winter and convective in summer. Figures 14a, c and e shows example of fitted correlations in summer and autumn by square root, exponential 1P and exponential 2P models. Comparison of the exponential 2P fitted correlations (in order of Pearson's, Spearman's and Kendall's correlations) shows in summer lower correlation coefficients on average (by 2.2, 4.1 and 5.7 %) against spring, while these are significantly higher in autumn (by 14.4, 14.5 and 18.1 %) and winter (by 10.7, 11.5 and 15.2 %) than in spring. Values of the fitted parameters computed by exponential 2P model are shown in Figs. 14b, d and f. Noteworthy is that the values of the correlation distance  $c_0$  were much higher in autumn and



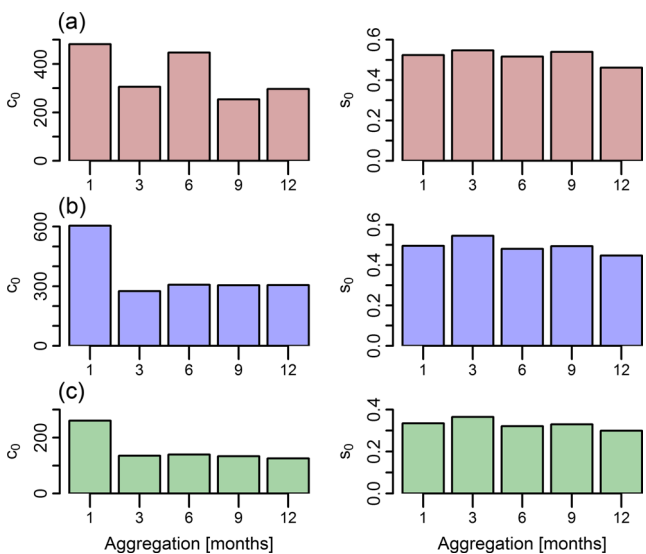
**Fig. 14** Seasonal differences between summer and autumn in fitted Pearson's  $r$  (a), Spearman's  $\rho$  (c) and Kendall's  $\tau$  (e) correlation coefficients, fitted by square root (solid line), exponential 1P (dotted line)

and exponential 2P model (dot-dash line) and values of fitted parameters  $c_0$  and  $s_0$  for  $r$  (b),  $\rho$  (d) and  $\tau$  (f) fitted by exponential 2P model

winter for all correlation measures. Also, the shape factor  $s_0$  decreased significantly in winter.

Effect of temporal resolution, as analysed by aggregation of the rainfall data (See Fig. 15), led to decrease of the correlation distance  $c_0$  for the exponential 2P model, and especially for Spearman's  $\rho$  (range of the values  $c_0$  for 3 to

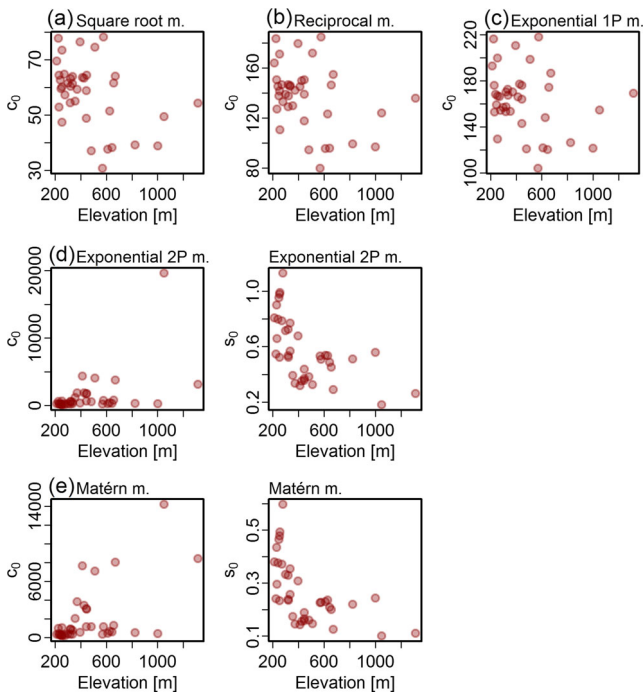
12 months aggregation times was 275.4–307.0 versus 604.9 for monthly data) and Kendall's  $\tau$  correlation (with range of 125.4–139.3 vs. 260.5). With aggregation, Pearson's  $r$  correlation had a wider ranging  $c_0$  with lower decrease against monthly data (253.8–446.6 vs. 481.2). There was no distinct dependence of the  $c_0$  value on the amount of aggregation time between 3 and 12 months. The shape factor  $s_0$  appeared to be almost independent of the aggregation, which was the case for all correlation estimators (values of  $s_0$  from the aggregated data oscillated around the original  $s_0$  value from monthly data with a maximum deviation of 0.05).



**Fig. 15** Effect of temporal resolution (1, 3, 6, 9 and 12 months) on values of the parameters for the exponential 2P model, fitted to the estimated Pearson's  $r$  (a), Spearman's  $\rho$  (b) and Kendall's  $\tau$  (c) correlations

#### 4.4 The spatial variability of fitted correlation parameters

Relationships between the parameters and elevation for all models are plotted in Fig. 16. The estimates using Pearson's  $r$  correlation were fitted. While one-parameter models had fitted values of the correlation distance  $c_0$  in a narrow range even in higher altitudes above 1,000 m, the exponential 2P model had an enormous maximal value and the Matérn model had two maximal values of the  $c_0$  at altitudes above 1,000 m. Elevation had the most significant influence on the shape factor  $s_0$ , which had its lowest values at the highest altitudes and vice versa. Thus, correlation in the small separation distances decays faster at higher altitudes, which could reflect the effect of orography on rainfall processes. The parameters for the other fitted correlation



**Fig. 16** Relationships between fitted parameters and elevation of square root (a), reciprocal (b), exponential 1P (c), exponential 2P (d) and Matérn (e) models, fitted on Pearson's  $r$  correlation for 38 stations

estimators showed similar patterns, with differences only in the parameters' values.

Two models were chosen to illustrate graphically the variability of the fitted parameters (Fig. 17). The one-parameter square root model due to the fact that, in comparison to the other one-parameter models, the latter had the lowest residual standard error and also the lowest values for the correlation distance  $c_0$  and the exponential 3P model, where is clearly visible the interrelationship between the fitted parameters and also the model fitted on stations individually shows decrease of the nugget parameter  $c_1$  for some stations (compared to the exponential 3P model fitted on whole data set with  $c_1$  equal to 1).

Some outliers have been excluded in order to provide the best visibility, wherein the highest parameter values are darkest and lowest values are lightest. Figure 17 illustrates several of the described findings. There are noticeable relationships between the correlation distance  $c_0$  and shape factor  $s_0$  in the exponential 2P and 3P models, whereby the subregions in the southern part with the lowest values  $c_0$  have the highest  $s_0$  values and those subregions with very high  $c_0$  value have low  $s_0$  value. The elevation influence on the shape factor  $s_0$  is also visible, as the highest  $s_0$  values are occurring in the lowlands of the southern subregions. In those subregions with higher values of  $s_0$ , there is visible a slight decrease of the nugget parameter  $c_1$  below the value of 1. The highest sensitivity to the nugget parameter shows Kendall's  $\tau$  correlation.

## 5 Discussion and conclusions

The study presents long-term correlation characteristics of rainfall in a mesoscale region in the north-eastern part of Bohemia, Czech Republic. Analysed was inter-station correlation within distances up to 100 km using 31 years of monthly rainfall data from 38 stations which are part of the climatological network administrated by CHMI.

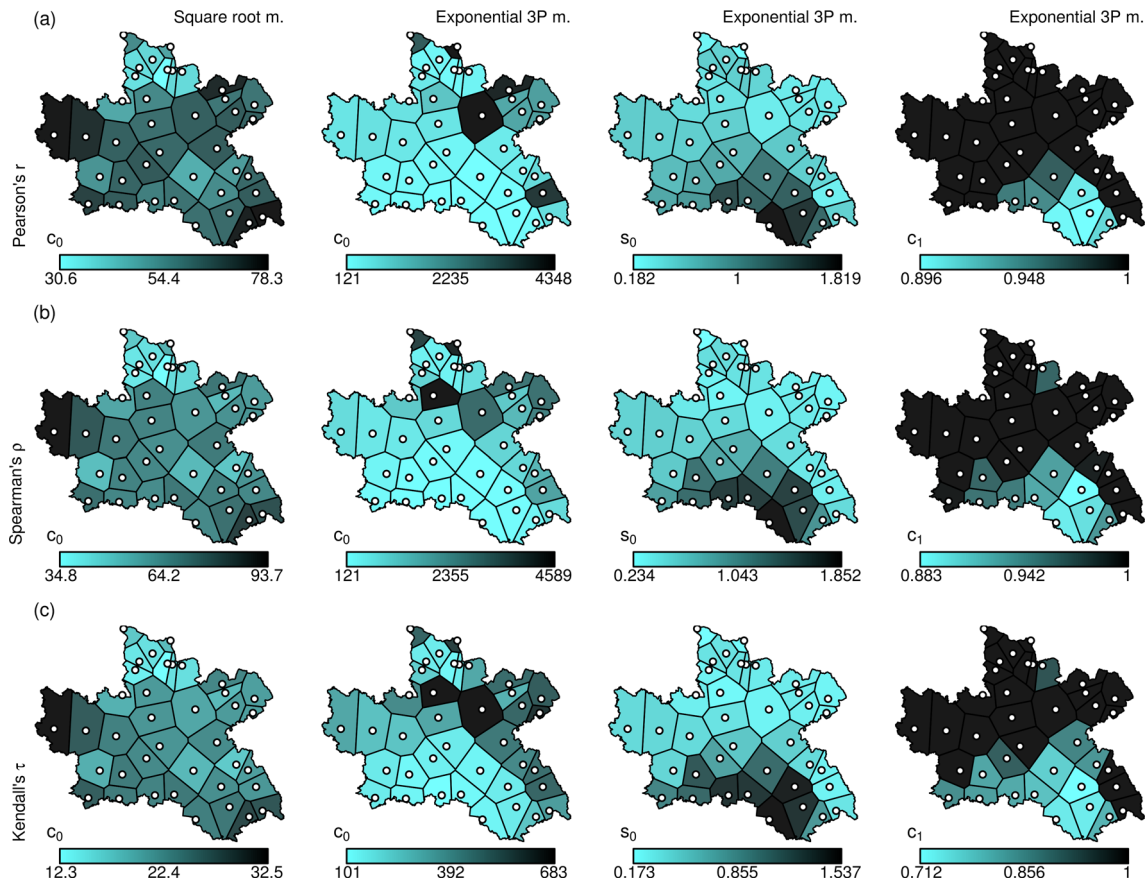
Three correlation estimators were applied (Pearson's product-moment sample correlation coefficient, the non-parametric Spearman's rank-order and Kendall's  $\tau$  rank correlation coefficients) and identified by several models controlled by one (square root, reciprocal and exponential model), two (Matérn and exponential 2P model) or three (exponential 3P model) parameters.

Comparison of spatial correlation estimators from all inter-stations correlations showed Spearman's correlation coefficient values to be almost identical with those of Pearson's correlation (Spearman's correlation values were higher by 1 % on average) while Kendall's correlation gave significantly lower values (by 22 % on average) than did Pearson's correlation.

While from the one-parameter fitted models, the most accurate fit was provided by the square root model, all one-parameter models seemed nevertheless quite inefficient, and especially so in cases where there was more significant decrease of correlation over small distances, as was the case when using Kendall's correlation. The key parameter was the shape factor  $s_0$ , which, in combination with the correlation distance parameter  $c_0$ , provided better results (steeper decrease at shorter distances and flatter degression at longer distances).

The nugget parameter  $c_1$  for our monthly data without near-zero inter-station distances could be taken as 1, and thus there was, as expected, practically no difference between the exponential 2P and 3P models (nevertheless, we applied it on fitting correlations for individual station vs. other stations and some stations correlated with others with determined nugget parameter below the value of 1). The differences between the exponential 2P and Matérn models were significant at separation distances greater than 100 km, and thus, while considering also the complexity of calculation, the most appropriate option for fitting the spatial correlation within distances up to 100 km was proven to be the exponential 2P model. In general, Spearman's correlation function provided the lowest values of the residual standard error during the fitting procedure. When fitting by multi-parameter models, Pearson's correlation function gave rise to the largest standard error.

The correlation of rainfall with the distances to the other stations was computed and fitted for all 38 stations. The significant exponential relationship



**Fig. 17** Voronoi tessellation model of the region according to stations (*dots*) filled with colour gradient set by the fitted parameters of Pearson's  $r$  (a), Spearman's  $\rho$  (b) and Kendall's  $\tau$  (c) inter-station correlation, fitted by the square root and the exponential 3P models

between the correlation distance  $c_0$  and shape factor  $s_0$  was observed from the dependencies between fitted parameters. A higher value of  $c_0$  implied a lower value of  $s_0$ , which was similar for all three spatial correlation estimators and occurred for both exponential and Matérn models. Inter-comparison of fitted parameters by the Matérn and exponential 2P models showed a strong linear relationship between the models.

The overall temporal variability of the correlation coefficients through 31 years demonstrated increase of the correlation distance parameter  $c_0$ , where the linear gradient showed much greater increase for estimations of the multi-parameter models. There were higher amplitudes in the values of the  $c_0$  through the decades in the multi-parameter models, while the shape factor  $s_0$  stayed more stable. Amplitudes and increase of the distance parameter  $c_0$  through the decades are in relationship with rainfall totals, where highest values of the  $c_0$  are in the decades with the highest rainfall totals and rainfall totals are, in general, increasing through 31 years.

Higher correlation in autumn and winter was evident from the seasonal variability of the fitted correlations of

rainfall. This behaviour was related to the values of the correlation distance  $c_0$ , which values were much higher in autumn and winter than in spring and summer (by approximately three to four times depending on the correlation model and season).

Effect of the coarse time resolution, expressed by the simple data aggregation into periods of 3, 6, 9 or 12 months, caused decrease of the correlation distance  $c_0$  (slightly more significantly so for Spearman's and Kendall's correlations) while showing no distinct differences between the various lengths of aggregation period. The effect of the longer time resolution on the shape factor  $s_0$  appeared to be insignificant.

The spatial variability of the 38 inter-stations' correlation of rainfall was affected by the elevation of the stations. Mean precipitation increased with higher elevation. The influence on the fitted parameters was reflected in the shape factor  $s_0$ , whereby at higher altitudes these values were lower and vice versa. This indicated that the correlation in the small separation distances decayed faster at higher altitudes. The highest values of the shape factor  $s_0$  occurred in the south and southwest subregions (i.e. in the lowlands).

**Acknowledgements** The project was supported by the Internal Grant Agency of the Faculty of Environmental Sciences of Czech University of Life Sciences Prague (No. 20124256). The data were provided by the Czech Hydrometeorological Institute (CHMI). We thank to reviewers for their comments which helped us to improve the manuscript.

## References

- Abramowitz M, Stegun IA (eds) (1972) Handbook of mathematical functions with formulas, graphs, and mathematical tables, National Bureau of Standards Applied Mathematics Series, 10th edn, vol 55. U.S. Government Printing Office, Washington, D.C
- Alexander LV, Zhang X, Peterson TC, Caesar J, Gleason B, Klein Tank AMG, Haylock M, Collins D, Trewin B, Rahimzadeh F, Tagipour A, Rupa Kumar K, Revadekar J, Griffiths G, Vincent L, Stephenson DB, Burn J, Aguilar E, Brunet M, Taylor M, New M, Zhai P, Rusticucci M, Vazquez-Aguirre JL (2006) Global observed changes in daily climate extremes of temperature and precipitation. *J Geophys Res-Atmos* 111(D5109):1–22. doi:[10.1029/2005JD006290](https://doi.org/10.1029/2005JD006290)
- Aurenhammer F (1991) Voronoi diagrams—a survey of a fundamental geometric data structure. *Comput Surv* 23(3):345–405
- Becker RA, Chambers JM, Wilks AR (1988) The new S Language: a programming environment for data analysis and graphics. Wadsworth and Brooks/Cole Advanced Books & Software, Monterey
- Briffa K, Jones P (1993) Global surface air temperature variations during the twentieth century: Part 2, implications for large-scale high-frequency palaeoclimatic studies. *Holocene* 3(1):77–88. doi:[10.1177/095968369300300109](https://doi.org/10.1177/095968369300300109)
- Brommundt J, Bárdossy A (2007) Spatial correlation of radar and gauge precipitation data in high temporal resolution. *Adv Geosci* 10:103–109. doi:[10.5194/adgeo-10-103-2007](https://doi.org/10.5194/adgeo-10-103-2007)
- Chumchean S, Sharma A, Seed A (2006) An integrated approach to error correction for real-time radar-rainfall estimation. *J Atmos Ocean Tech* 23(1):67–79. doi:[10.1175/JTECH1832.1](https://doi.org/10.1175/JTECH1832.1)
- Ciach GJ, Krajewski WF (2006) Analysis and modeling of spatial correlation structure in small-scale rainfall in Central Oklahoma. *Adv Water Resour* 29(10):1450–1463. doi:[10.1016/j.advwatres.2005.11.003](https://doi.org/10.1016/j.advwatres.2005.11.003)
- Clarke RT, Buarque DC, Dias de Paiva RC, Collischonn W (2011) Issues of spatial correlation arising from the use of TRMM rainfall estimates in the Brazilian Amazon. *Water Resour Res*:47. doi:[10.1029/2010WR010334](https://doi.org/10.1029/2010WR010334)
- Dai A, Fung I, Del Genio A (1997) Surface observed global land precipitation variations during 1900–1988. *J Climate* 10:2943–2962
- Dennis JE, Gay DM, Welsch RE (1981) An adaptive nonlinear least-squares algorithm. *ACM T Math Software* 7(3):348–368. doi:[10.1145/355958.355965](https://doi.org/10.1145/355958.355965)
- Feidas H (2010) Validation of satellite rainfall products over Greece. *Theor Appl Climatol* 99(1):193–216. doi:[10.1007/s00704-009-0135-8](https://doi.org/10.1007/s00704-009-0135-8)
- Fox J, Weisberg S (2010) Nonlinear regression and nonlinear least squares in R, An appendix to an R Companion to applied regression, 2nd edn
- Fredricks GA, Nelsen RB (2007) On the relationship between Spearman's rho and Kendall's tau for pairs of continuous random variables. *J Stat Plan Infer* 137(7):2143–2150. doi:[10.1016/j.jspi.2006.06.045](https://doi.org/10.1016/j.jspi.2006.06.045)
- Habib E, Krajewski WF, Ciach GJ (2001) Estimation of rainfall interstation correlation. *J Hydrometeorol* 2(6):621–629. doi:[10.1175/1525-7541\(2001\)002<0621:EORIC>2.0.CO;2](https://doi.org/10.1175/1525-7541(2001)002<0621:EORIC>2.0.CO;2)
- Handcock MS, Wallis JR (1994) An approach to statistical spatial-temporal modeling of meteorological fields. *J Am Stat Assoc* 89(426):368–378. doi:[10.1080/01621459.1994.10476754](https://doi.org/10.1080/01621459.1994.10476754)
- Hofstra N, New M (2009) Spatial variability in correlation decay distance and influence on angular-distance weighting interpolation of daily precipitation over Europe. *Int J Climatol* 29(12):1872–1880. doi:[10.1002/joc.1819](https://doi.org/10.1002/joc.1819)
- Hofstra N, New M, McSweeney C (2010) The influence of interpolation and station network density on the distributions and trends of climate variables in gridded daily data. *Climate Dynamics* 35(5):841–858. doi:[10.1007/s00382-009-0698-1](https://doi.org/10.1007/s00382-009-0698-1)
- Jones P, Osborn TJ, Briffa KR (1997) Estimating sampling errors in large-scale temperature averages. *J Climate* 10(10):2548–2568. doi:[10.1175/1520-0442\(1997\)010<2548:ESEILS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1997)010<2548:ESEILS>2.0.CO;2)
- Kaufman CG, Shaby BA (2013) The role of the range parameter for estimation and prediction in geostatistics. *Biometrika* 100(2):473–484. doi:[10.1093/biomet/ass079](https://doi.org/10.1093/biomet/ass079)
- Krajewski WF, Ciach GJ, Habib E (2003) An analysis of small-scale rainfall variability in different climatic regimes. *Hydrolog Sci J* 48(2):151–162. doi:[10.1623/hysj.48.2.151.44694](https://doi.org/10.1623/hysj.48.2.151.44694)
- Kysely J, Beranová R (2009) Climate-change effects on extreme precipitation in central Europe: Uncertainties of scenarios based on regional climate models. *Theor Appl Climatol* 95(3):361–374. doi:[10.1007/s00704-008-0014-8](https://doi.org/10.1007/s00704-008-0014-8)
- Mandapaka PV, Qin X (2013) Analysis and characterization of probability distribution and small-scale spatial variability of rainfall in Singapore using a dense gauge network. *J Appl Meteor Climatol* 52(12):2781–2796. doi:[10.1175/JAMC-D-13-0115.1](https://doi.org/10.1175/JAMC-D-13-0115.1)
- Mandapaka PV, Villarini G, Seo BC, Krajewski WF (2010) Effect of radar-rainfall uncertainties on the spatial characterization of rainfall events. *J Geophys Res Atmos* 115(D17):1–16. doi:[10.1029/2009JD013366](https://doi.org/10.1029/2009JD013366)
- Marchand R (2012) Spatial correlation of hydrometeor occurrence, reflectivity, and rain rate from CloudSat. *J Geophys Res Atmos* 117(D6):1–21. doi:[10.1029/2011JD016678](https://doi.org/10.1029/2011JD016678)
- Minasny B, McBratney AB (2005) The matern function as a general model for soil variograms. *Geoderma* 128(3-4):192–207. doi:[10.1016/j.geoderma.2005.04.003](https://doi.org/10.1016/j.geoderma.2005.04.003)
- Navarro J, Balakrishnan N (2010) Study of some measures of dependence between order statistics and systems. *J Multivar Anal* 101(1):52–67. doi:[10.1016/j.jmva.2009.04.016](https://doi.org/10.1016/j.jmva.2009.04.016)
- Nelsen RB (1992) On measures of association as measures of positive dependence. *Stat Probab Lett* 14(4):269–274. doi:[10.1016/0167-7152\(92\)90056-B](https://doi.org/10.1016/0167-7152(92)90056-B)
- New M, Hulme M, Jones P (1999) Representing twentieth-century space-time climate variability. Part I: Development of a 1961–90 mean monthly terrestrial climatology. *J Climate* 12:829–856
- New M, Hulme M, Jones P (2000) Representing twentieth-century space-time climate variability. Part II: Development of 1901–96 monthly grids of terrestrial surface climate. *J Climate* 13:2217–2238
- Osborn TJ, Hulme M (1997) Development of a relationship between station and grid-box rainday frequencies for climate model evaluation. *J Climate* 10(8):1885–1908. doi:[10.1175/1520-0442\(1997\)010<1885:DOARBS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1997)010<1885:DOARBS>2.0.CO;2)
- Pebesma EJ (2004) Multivariable geostatistics in S: the gstat package. *Comput Geosci* 30:683–691
- R Core Team (2013) R: A language and environment for statistical computing. R foundation for statistical computing, Vienna. <http://www.R-project.org>
- Ritz C, Streibig J (2008) More on nls(). In: Ritz C, Streibig J (eds) *Nonlinear Regression with R, Use R*. Springer, New York, pp 37–54



- Şen Z, Habib Z (2001) Monthly spatial rainfall correlation functions and interpretations for Turkey. *Hydrolog Sci J* 46(4):525–535. doi:[10.1080/02626660109492848](https://doi.org/10.1080/02626660109492848)
- Serinaldi F (2008) Analysis of inter-gauge dependence by Kendall's  $\tau_K$ , upper tail dependence coefficient, and 2-copulas with application to rainfall fields. *Stoch Environ Res Risk Assess* 22(6):671–688. doi:[10.1007/s00477-007-0176-4](https://doi.org/10.1007/s00477-007-0176-4)
- Sharon D (1978) Rainfall fields in Israel and Jordan and the effect of cloud seeding on them. *J Appl Meteor* 17(1):40–48. doi:[10.1175/1520-0450\(1978\)017<0040:RFHIAJ>2.0.CO;2](https://doi.org/10.1175/1520-0450(1978)017<0040:RFHIAJ>2.0.CO;2)
- Sharon D (1979) Correlation analysis of the Jordan Valey rainfall field. *Mon Wea Rev* 107(8):1042–1047. doi:[10.1175/1520-0493\(1979\)107<1042:CAOTJV>2.0.CO;2](https://doi.org/10.1175/1520-0493(1979)107<1042:CAOTJV>2.0.CO;2)
- Štěpánek P, Zahradníček P, Huth R (2011) Interpolation techniques used for data quality control and calculation of technical series: an example of a Central European daily time series. *Q J Hung Meteorol Soc* 115(1-2):87–98
- Tabios GQ, Salas JD (1985) A comparative analysis of techniques for spatial interpolation of precipitation. *J Am Water Resour Assoc* 21(3):365–380. doi:[10.1111/j.1752-1688.1985.tb00147.x](https://doi.org/10.1111/j.1752-1688.1985.tb00147.x)
- Tokay A, Öztürk K (2012) An experimental study of the small-scale variability of rainfall. *J Hydrometeorol* 13(1):351–365. doi:[10.1175/JHM-D-11-014.1](https://doi.org/10.1175/JHM-D-11-014.1)
- Tolasz R (ed) (2007) Atlas podnebí Česka: Climate atlas of Czechia, 1st edn. Český hydrometeorologický ústav, Praha
- Velasco-Forero CA, Sempere-Torres D, Cassiraga EF, Gmez-Hernández JJ (2009) A non-parametric automatic blending methodology to estimate rainfall fields from rain gauge and radar data. *Adv Water Resour* 32(7):986–1002. doi:[10.1016/j.advwatres.2008.10.004](https://doi.org/10.1016/j.advwatres.2008.10.004)
- Villarini G, Mandapaka PV, Krajewski WF, Moore RJ (2008) Rainfall and sampling uncertainties: a rain gauge perspective. *J Geophys Res* 113(D11):1–12. doi:[10.1029/2007JD009214](https://doi.org/10.1029/2007JD009214)
- Williams CJR, Kniveton DR, Layberry R (2010) Assessment of a climate model to reproduce rainfall variability and extremes over Southern Africa. *Theor Appl Climatol* 99(1–2):9–27
- Zíková N (2009) Spatial variability of precipitation annual cycles. Master's thesis, Charles University in Prague, Faculty of Mathematics and Physics, Department of Meteorology and Environment Protection





## **Příloha B**

# **Characteristics of rainfall events in RCM simulations for the Czech Republic**

V. Svoboda, M. Hanel, P. Máca, J. Kyselý  
*Hydrology and Earth System Sciences*  
June 2016, in review





# Characteristics of rainfall events in RCM simulations for the Czech Republic

Vojtěch Svoboda<sup>1</sup>, Martin Hanel<sup>1,2</sup>, Petr Máca<sup>1</sup>, and Jan Kyselý<sup>1,3</sup>

<sup>1</sup>Faculty of Environmental Sciences, Czech University of Life Sciences Prague, Kamýcká 129, Praha 6 – Suchbátka, 165 21, Czech Republic

<sup>2</sup>T. G. Masaryk Water Research Institute, Podbabská 2582/30, Praha 6 – Dejvice, 160 00, Czech Republic

<sup>3</sup>Institute of Atmospheric Physics, Czech Academy of Sciences, Boční II 1401, Praha 4 – Spořilov, 141 31, Czech Republic

*Correspondence to:* Vojtěch Svoboda (vsvoboda@fzp.czu.cz)

**Abstract.** Characteristics of rainfall events in an ensemble of 23 regional climate model (RCM) simulations are evaluated against observed data in the Czech Republic for the period 1981–2000. Individual rainfall events are identified using the concept of minimum inter-event time (MIT) and only heavy events during the warm season (May–September) are considered. Inasmuch as an RCM grid box represents a spatial average rather than a point measurement, the effects from areal averaging of rainfall data on characteristics of events are investigated using the observed data. Rainfall events from the RCM simulations are then compared to those from the at-site and area-average observations. Simulated number of heavy events and seasonal total precipitation due to heavy events are on average represented relatively well despite the higher spatial variation compared to observations. RCM-simulated event depths are comparable to the area-average observations, while event durations are overestimated and other characteristics related to rainfall intensity are significantly underestimated. Most of the rainfall event characteristics in the majority of the RCM simulations show a similar altitude-dependence pattern as in the observed data. The number of heavy events and seasonal total precipitation due to heavy events increase with altitude, and this dependence is captured better by the RCM simulations with higher spatial resolution.

## 1 Introduction

Not only are such characteristics of heavy rainfall events as event depth, duration, or intensity relevant for urban hydrology (e.g. Einfalt et al., 1998; Barbosa et al., 2012; Willems et al., 2012) or soil erosion assessment studies (e.g. Angulo-Martínez and Beguería, 2009; Meusburger et al., 2012; Todisco, 2014), they also influence such hydrological processes involving vegetation as interception, throughfall, and stemflow (e.g. Staelens et al., 2008; Siegert and Levia, 2014; Lozano-Parra et al., 2015). Moreover, potential changes in characteristics of precipitation events due to climate change may have significant societal impacts, especially when daily extreme rainfall intensity increases (e.g. Alexander et al., 2006; Trenberth, 2011; Westra et al., 2014). Short-duration extreme events in particular might intensify more in future climate due to dynamical feedbacks (Lenderink and van Meijgaard, 2008; Berg and Haerter, 2013; Millán, 2014). Despite their importance, however, only a few studies have dealt with the characteristics of individual rainfall events derived from observed rainfall data (Fiener et al., 2013; Hanel et al., 2016). A comparative review of the published rainfall event characteristics has been provided by Dunkerley (2008a).



Many studies of precipitation extremes across Europe examine daily data from regional climate model (RCM) simulations (e.g. Jacob et al., 2007; Fowler and Ekström, 2009; Herrera et al., 2010; Hanel and Buishand, 2011, 2012). Although in recent years growing attention has been given to studies at sub-daily time scales (Hanel and Buishand, 2010; Arnbjerg-Nielsen, 2012; Kendon et al., 2012; Gregersen et al., 2013; Chan et al., 2014a; Kendon et al., 2014; Sunyer et al., 2015), the complexity of physical processes related to sub-daily extremes (Stocker et al., 2013; Siler and Roe, 2014) and their simplification within climate model parameterizations might discourage researchers from verification of sub-daily simulated precipitation. The lack of long and high-quality observed rainfall data series at hourly or sub-hourly time scales presents another barrier to verification (Westra et al., 2014).

Even as the majority of RCM simulations available are conducted in resolution coarser than 10 km, the convective processes associated with extreme rainfall actually develop at much finer scales ( $< 4$  km; Prein et al., 2015). RCMs usually rely, therefore, on convection parameterization schemes, even though these are known sources of significant uncertainties and errors (Brockhaus et al., 2008; Hohenegger et al., 2008; Kendon et al., 2012). That is especially the case for the simulated sub-daily precipitation (Westra et al., 2014).

For the Czech Republic and an ensemble of RCMs, Kyselý et al. (2016) reported that underestimation of convective and overestimation of stratiform precipitation extremes result in a relatively good representation of total daily precipitation extremes. This had been noted also for other regions, including the the Netherlands (Hanel and Buishand, 2010) and Denmark (Gregersen et al., 2013). Moreover, the intensity of convective precipitation and total depths in summer were underestimated (more so in lowlands; Kyselý et al., 2016). Underestimation of summer precipitation totals was reported also by, for example, Hanel and Buishand (2012) (for the Czech Republic) and Rauscher et al. (2010) (for the region Eastern Europe). Kjellström et al. (2010) indicated that agreement between RCMs and observations at daily time scales was best for moderate rainfall intensities and that bias was increasing for heavier rainfall events. The ability of RCMs to represent hourly rainfall extremes properly has been questioned in several studies (e.g. Hanel and Buishand, 2010; Gregersen et al., 2013; Kendon et al., 2014). For instance, Hanel and Buishand (2010) found that 1 h maxima were underestimated (compared to those from radar data) in most of those RCM simulations which they analysed for the Netherlands.

Characteristics of individual heavy rainfall events (such as event depth, duration, and intensity) in RCM simulations have not been studied to date. Therefore, the purpose of this study is to assess rainfall event characteristics in an ensemble of RCM simulations using hourly data conducted within the ENSEMBLES (van der Linden and Mitchell, 2009) and EURO-CORDEX (Jacob et al., 2014) projects. The simulated rainfall events are compared to area-average observations in the Czech Republic for the validation period 1981–2000.

The paper is organized as follows: Section 2 describes the study area, as well as the observed and RCM-simulated data. Section 3 presents the definition of rainfall events, the event characteristics considered, and the approaches for assessing areal-averaging effects and biases in the RCM simulations. Results concerning the effects from areal averaging of rainfall data on events and evaluation of RCM-simulated rainfall event characteristics are presented in Sect. 4 and discussed in Sect. 5. Key findings are summarized in Sect. 6.



## 2 Study area and data

### 2.1 Study area

Rainfall event characteristics are analysed for the Czech Republic (78,800 km<sup>2</sup>), located in Central Europe (Fig. 1a). Orography of the country varies considerably. As can be seen in Fig. 1b, approximately two-thirds of the area is situated at altitudes below  
5 500 m a.s.l., even as several mountain ranges exceed 1200 m a.s.l.

Average annual precipitation totals for the 1961–2000 period vary from about 420 mm in the central-western part of the country to more than 1200 mm in the mountains. Mean annual precipitation for the Czech Republic is about 670 mm, with a single maximum occurring at most stations in June and July (Tolasz, 2007). If averaged across the Czech Republic, almost two-thirds of the annual precipitation falls in the warm half of the year. Rainfall events during the warm period (April–September)  
10 are usually of shorter duration and greater intensity. Rainfall or snowfall events during the cold half of the year (October–March), meanwhile, are mainly characterized by lower intensities and longer durations, and these are associated with passing frontal systems and pressure lows (Tolasz, 2007).

### 2.2 Observed precipitation data

In the present study, we used hourly precipitation data provided by the Czech Hydrometeorological Institute. The original data  
15 in 10 min resolution are based on digitized pluviograph records (from float-type self-recording pluviographs with interception area of 250 cm<sup>2</sup>) and were quality checked by Květoň et al. (2004), who identified and reconstructed damaged or missing pluviograph records while considering many sources of rainfall information. Hanel and Máca (2014) had further assessed the quality of the reconstructed data set by comparing daily precipitation depths aggregated from 10 min data with daily precipitation depths from standard ombrometers. They had considered data for a day unreliable when the difference exceeded  
20 1.5 mm for daily precipitation totals below 15 mm or 10 % for daily precipitation totals above 15 mm. The years with the fraction of unreliable records larger than 10 % were excluded from the data set. These same criteria were applied in the present study.

Given the unreliability of the pluviograph records in the winter period (Květoň et al., 2004), only records from May to September have been considered. This period is hereinafter referred to as the “season”. Only stations with at least 10 years  
25 of reliable data were used for the comparison of RCM-simulated and observed rainfall event characteristics in the validation period 1981–2000. The validation period was set to just 20 years in order to maximize overlap of the available RCM simulations (Sect. 2.3) and observed data. In total, 154 stations (with density of 1 station per 512 km<sup>2</sup>) fulfilled this condition. (Meanwhile, more than 15 years of reliable data were available for 60 stations.)

In order to increase the number of stations available for spatial averaging, a longer period (1961–2009) was considered  
30 for analysing the areal-averaging effects. This resulted in making 26 additional stations available (each of which has records shorter than 10 years or ending before 1981). Figure 1b shows all 180 stations from the data set, the density of which came to approximately 1 station per 438 km<sup>2</sup>.



Moreover, we examined the influence of the number of stations considered in the areal averaging using a dense rain gauge network for Prague (22 stations within 500 km<sup>2</sup>). Hourly precipitation data for the period 2002–2011 were provided by Pražská vodohospodářská společnost a.s., administrator of the Prague water management property.

### 2.3 RCM simulations

5 An ensemble of 23 RCM simulations was examined (see Table 1 for an overview). Six RCMs were driven by 14 global climate models (GCMs) to produce 19 simulations in total. Two RCMs (with a total of four runs) were also driven by ERA40 (Uppala et al., 2005) or ERA-INTERIM (Dee et al., 2011) reanalysis.

The RCMs' outputs are available on a rotated latitude–longitude grid with horizontal resolutions ranging from 12.5 to 50 km (Table 1). Only the CLM simulation is on a regular grid. From each RCM simulation only grid boxes covering the area of  
10 the Czech Republic (i.e. 52–607 grid boxes for different resolutions and RCMs) were selected.

The HIRHAM5, HadRM3, and RACMO2 simulations were conducted within the ENSEMBLES project (van der Linden and Mitchell, 2009), while the RCA4 and RACMO2E simulations were within the EURO-CORDEX project (Jacob et al., 2014). Two of the HadRM3 simulations were driven by the GCM version with perturbed physics parameterizations (Collins et al., 2006). HadCM3Q0 is an unperturbed model run, HadCM3Q3 is a version with a low sensitivity to external forcing, and  
15 HadCM3Q16 includes perturbations resulting in high sensitivity to external forcing. The perturbations in the HadRM3 RCM correspond to those in the HadCM3 GCM.

## 3 Methods

This section defines rainfall events in the observed and RCM-simulated data (Sect. 3.1) and describes those event characteristics considered (Sect. 3.2). Inasmuch as the RCM data represent areal averages rather than point values, the methods for assessing  
20 the effect on event characteristics from areal averaging of rainfall data are further described in Sect. 3.3. Finally, approaches taken in evaluating simulated rainfall events are presented in Sect. 3.4.

### 3.1 Rainfall event definition

Several methods exist for defining individual rainfall events (e.g. Peters and Christensen, 2006; Ignaccolo and Michele, 2010; Gaál et al., 2014). One approach frequently used involves the concept of minimum inter-event time (MIT), which defines events  
25 on the basis of a minimum time interval – reached or exceeded – between two individual events (Dunkerley, 2008b; Ignaccolo and Michele, 2010). The value of MIT should be selected so that the rainfall events are independent. Nevertheless, MIT is often set on an ad hoc basis, for instance by following another well-established method such as the universal soil loss equation (USLE; Wischmeier and Smith, 1978).

Although the estimated optimal MIT would generally vary between the RCM simulations and across the area, and because  
30 the value of MIT influences the values of rainfall events characteristics, a constant MIT is required in order to provide comparable characteristics (e.g. Dunkerley, 2008b; Hanel and Máca, 2014). Therefore, a 6 h MIT was used for deriving rainfall events





within this study for all RCM simulations as well as for the observed data. It should be noted that although this value is lower than the optimal MITs estimated for the Czech Republic by Hanel and Máca (2014), it is one of the values most frequently used (Dunkerley, 2008b). Similarly as in the USLE methodology, we considered further only the heavy rainfall events, i.e. at-site events with total depth greater than 12.7 mm (Wischmeier and Smith, 1978).

5 For the observed data, the minimum wet-hour depth is related to rain gauge precision (0.1 mm). The same wet-hour threshold as used here had been applied also for RCM simulations in previous studies (e.g. Willems and Vrac, 2011; Kendon et al., 2014; Sunyer et al., 2016). Although the same minimum event depth could be taken for RCM simulations as for observations (12.7 mm), it is well known that the RCM-simulated precipitation totals are often biased. As a consequence, the number of selected events might be influenced by the bias in mean precipitation. Alternatively, the minimum event depth of a heavy rainfall event  
 10 is chosen such that the number of heavy events is on average the same as for observations ( $\approx 15\%$ ). This approach is similar to the quantile mapping method used frequently for bias correction.

To summarize, the areal heavy rainfall events (in RCM simulations and area-average observations) are here defined while considering a 6 h MIT, fixed wet-hour threshold of 0.1 mm, and minimum event depth corresponding to the 0.85 quantile of the distribution of event depths.

### 15 3.2 Rainfall event characteristics

We focused on the following basic characteristics of rainfall events:

- event depth  $D$  [mm],
- event duration  $T$  [h],
- event mean rainfall rate  $R$  [ $\text{mm h}^{-1}$ ]:

$$20 \quad R = \frac{D}{T}, \text{ and} \quad (1)$$

- maximum 60 min rainfall intensity during the event  $I_{60}$  [ $\text{mm h}^{-1}$ ].

As our definition of a rainfall event is in general consistent with the USLE methodology, we consider also indicators of rainfall event erosivity:

- event rainfall energy  $E$  [ $\text{MJ ha}^{-1}$ ] (Brown and Foster, 1987):

$$25 \quad E = \sum_{t=1}^T 0.29d_t[1 - 0.72 \exp(-0.05d_t)], \quad (2)$$

where  $d_t$  is rainfall volume during hour  $t$ , and

- event rainfall erosivity index  $EI_{60}$  [ $\text{MJ mm ha}^{-1} \text{h}^{-1}$ ]:

$$EI_{60} = E \cdot I_{60}. \quad (3)$$



Note that in the USLE methodology, maximum 30 min rainfall intensity is considered. Due to the temporal resolution of RCM-simulated data used in this study, we instead consider maximum 60 min rainfall intensity during an event ( $I_{60}$ ). The  $E$  and  $EI_{60}$  indices are considered here not in order to quantify soil loss but rather as indicators as to the erosive potential of a rainfall event.

5 In addition to the aforementioned rainfall event characteristics, we analysed also the following seasonal (May–September) characteristics:

- number of heavy rainfall events per season  $N_{se}$  [–], and
- seasonal total precipitation due to heavy rainfall events  $S_{se}$  [mm].

### 3.3 Areal averaging of rainfall data

10 Areal averaging of rainfall data can significantly affect such characteristics of the events as depths (Svensson and Jones, 2010) or intensity (Eggert et al., 2015). Because an RCM grid box represents a spatial average, RCM simulations cannot be compared directly to at-site observations. Therefore, various gridded data sets are used for validation of RCM data (e.g. the E-OBS data set for Europe; Haylock et al., 2008). The gridded data sets available are limited to daily or longer temporal resolution. Therefore, analogously to the well-established areal reduction factors describing the decrease in rainfall/runoff maxima with increasing  
15 averaging area, we quantified the effect that the areal averaging of rainfall data has on the rainfall event characteristics.

To assess this effect on the (event and seasonal) characteristics, we compared characteristics of events in area-average and at-site observed data as follows:

1. Square neighbourhoods with area corresponding to the considered resolutions (12.5, 25, and 50 km) were defined around each station. Neighbourhoods with only one station were excluded. This resulted in 36 neighbourhoods for the 12.5  
20 km resolution, 118 for the 25 km, and 180 for the 50 km resolution. Average numbers of stations included in the neighbourhoods were 2.25 for the 12.5 km, 2.9 for the 25 km, and 6.04 for the 50 km resolution.
  2. Areal average rainfall was calculated for each neighbourhood. Rainfall events were determined for this areal average as well as at-site for the central station. Characteristics of rainfall events were then calculated (hereafter referred to as “area-average” and “at-site” characteristics, respectively).
  - 25 3. We evaluated the following indices:
    - (a) Ratio of areal mean (event and seasonal) characteristics for each neighbourhood to the mean at-site (event and seasonal) characteristics, averaged over all neighbourhoods in the Czech Republic. This ratio is further denoted  $rt_m$ .
    - (b) Ratio of the  $p^{\text{th}}$  quantiles of event characteristics for each neighbourhood to the  $p^{\text{th}}$  quantiles of at-site event characteristics, averaged across all neighbourhoods in the Czech Republic for  $p = 0.05, 0.1, \dots, 0.95$ . This ratio is referred to as quantile ratio  $rt_p$ .
- 30



- (c) Ratio of seasonal frequencies (averaged across the Czech Republic) for corresponding bins of the histograms of areal and at-site event characteristics, further denoted as histogram ratio  $rt_f$ .

### 3.4 Evaluation of RCM-simulated characteristics of rainfall events

The RCM-simulated event characteristics (i.e. their areal averages) were compared to the observed at-site characteristics in a manner similar to that described in point 3 of the procedure specified in Sect. 3.3 by replacing the observed areal average (event and seasonal) characteristics for the neighbourhoods with the values for individual grid boxes.

We note that the ratios between the RCM simulations and observed at-site rainfall combine the bias in the RCM simulation with the effect of areal averaging of rainfall data. Therefore, ratios for RCM-simulated characteristics were further compared to those for area-average observations.

10 Finally, we also examined the dependence of the RCM-simulated (event and seasonal) characteristics on altitude. A linear regression model of the dependence of the  $p^{\text{th}}$  quantile (for  $p$  from 0.05 to 0.95) of the distribution of event characteristics on altitude was fitted while considering the RCMs and at-site data. Altitude dependence of rainfall event characteristics was then examined as the change of a characteristic per 100 m change in elevation ( $y_p$ ) given by:

$$y_p = \frac{100\beta + \alpha}{\alpha} \cdot 100 [\%], \quad (4)$$

15 where  $\beta$  is the slope coefficient and  $\alpha$  is the intercept. Moreover, the values of the estimated slope coefficient ( $\beta$ ) were analysed for the seasonal characteristics.

## 4 Results

This section presents findings related to areal averaging of rainfall data (Sect. 4.1). Further, the RCM-simulated rainfall event characteristics are evaluated with respect to the observed data for the validation period (1981–2000) using ratios of mean characteristics ( $rt_m$ ; Sect. 4.2), quantile ratios ( $rt_p$ ; Sect. 4.3), and histogram ratios ( $rt_f$ ; Sect. 4.4). Altitude-dependence of event characteristics considering the RCM simulations and at-site observations is assessed in Sect. 4.5.

### 4.1 Effects of areal averaging in the observed data

The number of rainfall events in area-average observations is higher than that for the at-site data. The same holds true for the number of area-average heavy rainfall events ( $N_{se}$ ) for the three spatial resolutions considered (Table 2, top four rows), which is on average approximately 1.4–2 events per season higher (i.e. by as much as 26 %) than the number of at-site events. Minimum event depth (based on the 85<sup>th</sup> quantile of event depths) for area-average observations is lower than 12.7 mm (the value for the at-site data), and that results in smaller average event depths ( $D$ ) compared to these for the at-site observations. Smaller  $D$  are compensated, however, by a higher number of events ( $N_{se}$ ), and that leads to a good representation of seasonal totals due to heavy rainfall events ( $S_{se}$ ; +3 % for area-average observations on average).



Mean characteristics of rainfall events considered for the at-site and area-average observations are shown in the right part of Table 2. Observed area-average characteristics are in general lower than at-site characteristics:  $D$  by 14–19 %,  $T$  by 8–18 %,  $R$  by 10–27 %, and  $I_{60}$  by 23–39 %.

The quantile ratios  $rt_p$  are shown in Fig. 2. Because in general the spread of the quantile ratios is similar for the spatial resolutions considered (not shown), only the envelope of  $rt_p$  for all neighbourhoods representing the maximum range between the 5<sup>th</sup> and 95<sup>th</sup> quantiles for the three spatial resolutions is indicated by grey areas in Fig. 2.

Area-average event depths ( $D$ ) are  $\approx$  10–20 % smaller than at-site  $D$  for the whole range of event depths. The area-average duration ( $T$ ) of short events is comparable to the at-site  $T$  for the 12.5 and 25 km resolutions and larger (by  $\approx$  20 %) for the 50 km resolution. For long events, the area-average  $T$  is about 16 % shorter compared to the at-site observations. The area-average rainfall rate ( $R$ ) is similar to the at-site observations for low values and then significantly diminishes with increasing rainfall rate. The remaining area-average characteristics' values are lower than those of the at-site observations, and the differences are larger for higher quantiles.

To demonstrate how spatial resolution influences the area-average characteristics, boxplots of  $rt_m$  for the area-average observations are presented as a part of Fig. 3 (grey boxplots in the right part of each panel). Most of the area-average characteristics decrease with increasing area. The exception is event duration ( $T$ ), which increases with area. The differences in mean event characteristics between the considered spatial resolutions are generally small (less than 10 %), with the exceptions of  $R$ ,  $I_{60}$  and  $EI_{60}$  (at 17, 16, and 21 %, respectively). These differences are considerably smaller, however, than are the differences between the event characteristics over the study area.

## 4.2 Simulated mean (event and seasonal) characteristics

Figure 3 presents boxplots of  $rt_m$  ratios between the RCM-simulated and observed at-site rainfall event characteristics for the validation period (1981–2000) as derived for grid boxes over the study area.

In the RCM simulations, the event depths ( $D$ ) correspond generally well with the area-average observations (20 % smaller on average compared to at-site observations). Event duration ( $T$ ) is longer for most of the RCM simulations than for at-site observations (on average by 18 %). That is in contrast with the area-average observations, for which the event duration ( $T$ ) is shorter than for at-site observations (by 13 % on average). Because event depths ( $D$ ) for the RCM simulations are smaller than for at-site observations and event durations ( $T$ ) are longer in general, event mean rainfall rates ( $R$ ) are significantly lower compared to the at-site characteristics (by 56 % on average) while  $R$  for area-average observations are lower only by 17 % on average. Other characteristics' values, too, are significantly lower for RCM simulations compared to both the area-average and the at-site characteristics. For example, maximum 60 min rainfall intensities during an event ( $I_{60}$ ) are lower by 30 % with respect to the area-average observations and by 69 % on average with respect to the at-site data.

The number of heavy events per season ( $N_{se}$ ) is in general higher in the RCM simulations compared to the at-site observations (by 42 % on average, i.e. 3.2 events per season). That difference is only 16 % (less than 1.5 events per season), however, when compared to the area-average observations. The differences in  $S_{se}$  between the RCM simulations and both at-site and area-average observations range from –33 to +48 % (+11 % on average, i.e. 23 mm per season compared to the area-average



observations). For the two HIRHAM5 simulations (H5\_BCM and H5\_ECHAM5), large outliers are present at the grid boxes with the highest altitude (in the northern part of the Czech Republic). There, the number of simulated heavy events ( $N_{se}$ ) reaches to approximately 44 per season and the seasonal total precipitation due to heavy events ( $S_{se}$ ) to approximately 1700 mm. For observations (both at-site and area-average), maximum values are given by stations at highest altitudes, as well, but the maximum  $N_{se}$  is 16 and that for  $S_{se}$  is  $\approx 500$  mm. Moreover, several other outliers with higher values for the characteristics are present in the RCM simulations (especially for event depths and energies; not shown in Fig. 3). These outliers, too, are generally linked to grid boxes with the highest altitudes.

The coefficient of variation (CV; not shown) of  $rt_m$  for the RCM grid boxes (indicator of spatial variability) corresponds relatively well with that of the area-average observations for event depth ( $D$ ; CV about 9 % on average), duration ( $T$ ; about 12 %), and kinetic energy ( $E$ ; about 10 %). The RCM-simulated spatial variability is somewhat lower compared to the area-average observations for the other characteristics (CV is 9 % for  $R$ , 8 % for  $I_{60}$ , and 18 % for  $EI_{60}$  for the RCM simulations whereas these are 12 %, 12 %, and 29 %, respectively, for the area-average observations). CV for the number of heavy events per season ( $N_{se}$ ) and seasonal totals due to heavy events ( $S_{se}$ ) is significantly higher in most of the RCM simulations (by almost as much as three times for  $N_{se}$  in several RCA4 simulations). Only for RACMO2 and RACMO22E simulations do CVs for  $N_{se}$  and  $S_{se}$  correspond well with the area-average observations (CV of about 25 and 30 % for  $N_{se}$  and  $S_{se}$ , respectively).

### 4.3 Quantile ratios ( $rt_p$ )

Figure 4 gives the quantile ratios ( $rt_p$ ) for the RCM simulations and the area-average observations. For the latter, only the average value (from the 12.5, 25, and 50 km neighbourhoods) and envelope representing the maximum 5<sup>th</sup>–95<sup>th</sup> quantile range for all neighbourhoods is shown (for details, see Sect. 4.1 and Fig. 2).

The correspondence between simulated and area-average event depths ( $D$ ) is best for events with large  $D$ . Some of the RCM simulations underestimate depths ( $D$ ) for events with low  $D$  (which results in 7 % underestimation on average of  $D$  for the 0.05 quantile in the RCM simulations). For most of the RCA4 runs, the quantile ratio  $rt_p$  does not depend on event depth ( $D$ ). That is also the case for area-average observations.

For the longest events, the RCM-simulated event duration ( $T$ ) corresponds relatively well with the area-average and at-site observations. However, shortest durations ( $T$ ) are greatly overestimated (by 1.5 to 3.1 times; i.e. 2.3 times in the RCM simulations on average compared to the area-average characteristics). Only the event duration ( $T$ ) in the H5\_ARPEGE matches that of the area-average observations for the whole range of event durations.

The difference between areal (RCM simulations as well as area-average observations) and at-site rainfall rate ( $R$ ) grows with increasing quantile. Stronger underestimation of largest rainfall rates ( $R$ ) is related to significant overestimation of shortest durations ( $T$ ). Moreover, underestimation of the maximum 60 min intensities ( $I_{60}$ ) is greater for larger values.

Event rainfall energy ( $E$ ) is related to the values for event depth ( $D$ ) and duration ( $T$ ). The overestimation of duration ( $T$ ) for short events partly compensates for the underestimation of small depths ( $D$ ), and that results in 15 % underestimation of the rainfall energy ( $E$ ) in the RCM simulations for low quantiles. As quantile increases the differences increase as well. Due



to good correspondence between simulated and observed area-average largest event depths ( $D$ ), however, the underestimation of  $E$  is smaller for the highest quantiles.

#### 4.4 Histogram ratios ( $rt_f$ )

Differences in distribution of rainfall event characteristics' values between the RCM simulations and the at-site observations are described by histogram ratio  $rt_f$  (Fig. 5).

Considerably higher numbers of events with smaller depths ( $D$ ) in the RCM simulations compared to the at-site observations are expected, partly due to the definition of a rainfall event (minimum values of  $D$  in the RCM simulations are between 7 and 11.5 mm). Approximately 2.5 % of all considered events for at-site observations have depths ( $D$ ) smaller than 13 mm, while for area-average observations and the three spatial resolutions considered the proportion of such events is 22–29 %. For the ensemble of RCM simulations, this range takes in 15–54 % of events. Extreme heavy events (with depths exceeding 250 mm), which rarely occur at some stations, are not present in most of the RCM simulations (exceptions being for all HIRHAM5 runs, HadRM3Q16 driven by ERA40, and HadRM3 driven by HadCM3).

Simulated numbers of events with short duration ( $T$ ) are underestimated. Only 0.3–7.5 % (1.6 % on average) of events considered for the RCM simulations are shorter than 6 h, while for the area-average observations it is 9–13 % of events (15 % for the at-site observations).

Events with the smallest rainfall rates ( $R < 0.5 \text{ mm h}^{-1}$ ) are more frequent in the RCM simulations (8–28 % of considered events) than in the area-average (5–8 %) and at-site observations (7 %). On the other hand, high rainfall rates ( $R > 3 \text{ mm h}^{-1}$ ) are very rare for the RCM simulations (0.3–4 % of considered events), while for the area-average observations these represent from 8 to 15 % (and for at-site observations almost 19 %) of considered events.

Most of the simulated events (84–99 %) have maximum 60 min intensity ( $I_{60}$ ) less than  $6 \text{ mm h}^{-1}$ . Among area-average and at-site observations, meanwhile, just 60–72 % and 40 % of events, respectively, have  $I_{60} < 6 \text{ mm h}^{-1}$ . RCA4 simulations (50 km resolution) have absolute maximum values of  $I_{60}$  significantly lower compared to those of other RCM simulations (only around  $11 \text{ mm h}^{-1}$ ).

Only 24 % of the observed at-site events considered have rainfall energy ( $E$ ) below  $2 \text{ MJ ha}^{-1}$ , whereas for the area-average observations this figure is 51–58 % and for the RCM simulations it is 38–62 % (with mean 54 %) of events. The RCM simulations also have more events with low rainfall erosivity index ( $EI_{60}$ ). For the RCM simulations, 68–92 % (with mean of 83 %) of events have  $EI_{60} < 10 \text{ MJ mm ha}^{-1} \text{ h}^{-1}$ , and for the area-average observations that range is 50–60 %. For the at-site observations, this low erosivity index occurs for only 26 % of events.

#### 4.5 Altitude-dependence

Figure 6 shows the altitude-dependence of event characteristics for the RCM simulations and at-site observations (note that for the area-average observations the altitude-dependence has not been investigated due to an uneven spatial distribution and different numbers of stations in neighbourhoods). The altitude-dependence is expressed as the change in characteristics values



per 100 m in elevation as estimated by a linear regression between altitude and the values of the rainfall event characteristics for a specific quantile.

Although the RCM simulations generally show a similar pattern of altitude-dependence as that for the at-site observations regarding most characteristics (with trends between  $-5$  and  $10$  %/100 m for all quantiles), several RCM simulations at 25 and 50 km resolutions show stronger altitude-dependence compared to at-site observations for high (event depth, duration, rainfall energy, and rainfall erosivity index) or low (rainfall rate and maximum 60 min intensity) quantiles of rainfall event characteristics. Two simulations with the highest horizontal resolution (RACMO22E and CLM) show different behaviour for greatest event depths ( $D$ ) compared to those of other RCM simulations and at-site observations inasmuch as large  $D$  does not increase with altitude. These differences are nevertheless less than 5 %.

The linear regression is significant (with  $p < 0.05$ ) for 78 % of all assessed quantiles for all characteristics and the at-site observations and for 68 % of those quantiles in the case of the RCM simulations. For RCM-simulated rainfall rates ( $R$ ) and maximum 60 min intensities ( $I_{60}$ ), however, the altitude-dependence is found to be significant much less frequently (58 and 51 % of cases) than for at-site observations (100 and 95 %, respectively). The number of significant regressions was also considerably smaller for the RCA4 runs with 50 km resolution.

Number of heavy events per season ( $N_{se}$ ) and seasonal totals due to heavy events ( $S_{se}$ ) strongly depend on altitude in the RCM simulations (not shown). Simulated  $N_{se}$  increase with altitude, with a slope coefficient  $\beta$  1.8–7.7 times greater than those for at-site observations. A similar situation is found for  $S_{se}$ , with  $\beta$  1.1–5.9 times greater. These steeper slope coefficients  $\beta$  make altitude-dependence of seasonal characteristics unrealistic compared to at-site observations for a large part of the RCM simulations. Only two RCM simulations with the higher spatial resolution (CLM with 11.7 and 13.9 %/100 m, and RACMO22E with 15 and 21 %/100 m) represent the altitude-dependence of  $N_{se}$  and  $S_{se}$  for the Czech Republic adequately (trends for at-site observations are 8.4 and 13.4 %/100 m, respectively).

## 5 Discussion

### 5.1 Definition and characteristics of rainfall events

Heavy rainfall event characteristics were assessed in an ensemble of 23 RCM simulations. Events were identified while considering 6 h minimum inter-event time (MIT), 0.1 mm fixed wet-hour threshold, and minimum total event depth derived for each RCM simulation as event depth with the same exceedance probability as for the 12.7 mm depth in the observed at-site rainfall events. Setting the minimum event depth to the fixed value of 12.7 mm led to results generally similar to those presented in Sect. 4. On the other hand, setting the wet-hour threshold using quantile matching (i.e. in general to lower than 0.1 mm) resulted in excessive prolongation of rainfall events in some RCM simulations and distortion in the distributions of other event characteristics.

While the 6 h MIT was used here for the sake of consistency with the definition in other studies (e.g. Agnese et al., 2006; Murakami, 2006; Fiener et al., 2013; Hanel et al., 2016) and given by the USLE, the optimal MIT estimated by Hanel and Máca (2014) for the Czech Republic was considerably larger (426–2055 min, 763 min on average). Larger values of optimal



MIT had been reported also by Dunkerley (2008b). To explore the optimal MIT for the RCM simulations, we used the same procedure as considered by Hanel and Máca (2014) and which is based on the coefficient of variation (CV) of the inter-event times (Restrepo-Posada and Eagleson, 1982). Optimal MIT averaged across grid boxes for the RCM simulations varied from 7 h (RCA4\_NorESM1-M) to 27 h (HadRM3Q3\_HadCM3), with an average value of  $\approx 13$  h. Differences in the optimal MIT  
5 between grid boxes for the individual RCM simulations were large, ranging from 4 h for RCA4\_CM5A-MR (optimal MIT in the range of 8–11 h) to more than 24 h for H5\_ARPEGE (14–41 h). The spatial variability was greatest for the three RCM simulations with the highest optimal MIT: HadRM3Q3\_HadCM3, HadRM3Q3\_ERA40, and H5\_ARPEGE. Because MIT value strongly influences the values of event characteristics (e.g. higher MIT leads to a smaller number of events, consequently with larger duration and event depths; Hanel and Máca, 2014), the evaluation of event characteristics would not be feasible  
10 using estimated, highly variable MITs.

## 5.2 Effect of areal averaging

The areal-averaging effect was considered when comparing at-site observed and RCM-simulated event characteristics. Observed area-average rainfall event characteristics were analysed for an extended period (1961–2009) in three spatial resolutions (12.5, 25, and 50 km) corresponding to the resolutions of the RCMs.

15 Estimates as to the effect of areal averaging are influenced by several sources of uncertainties (Svensson and Jones, 2010), in particular by spatial variability and coverage of rain gauges. Because it is obvious that a sufficient number of stations must be available in order to provide a reliable estimate of the areal-averaging effect, we assessed the effect of the number of stations considered in the areal averaging on the estimated  $rt_m$  ratio using a dense rain gauge network for Prague (22 stations, 500 km<sup>2</sup>). The assessment was based on repetitive estimation of  $rt_m$  from resampled data with the number of stations used for  
20 areal averaging ranging from 2 to 22.

The number of stations included into the calculation of the areal average influenced the estimated event characteristics. Mean event depths ( $D$ ) were least affected by the number of stations compared to other characteristics (with  $rt_m$  decreasing with the number of stations from  $-12$  to  $-15$  % of the at-site value). Event duration ( $T$ ) was slightly increasing with the number of stations involved (from  $-5.6$  to  $4.3$  %). Behaviour of  $D$  and  $T$  was reflected in the event mean rainfall rate ( $R$ ), which was  
25 continually decreasing with the rising number of stations from  $-17$  to  $-39$  %. As a consequence, the ratios for maximum 60 min intensity ( $I_{60}$ ;  $-17$  to  $-33$  %), event rainfall energy ( $E$ ;  $-18$  to  $-26$  %), and event rainfall erosivity index ( $EI_{60}$ ;  $-36$  to  $-59$  %) were decreasing with the number of stations as well. The largest differences in ratios were observed between areal averages estimated from a small number of stations (typically fewer than 6). This finding is in agreement with Allen and DeGaetano (2005), who reported that areal reduction factors are not substantially influenced by the number of stations  
30 involved when derived from 10 or more stations. Observed area-average rainfall event characteristics for the study area (the Czech Republic) can therefore be affected by insufficient number of stations for resolution finer than 50 km (below 3 stations per neighbourhood).

Several conclusions can be drawn from the comparison of area-average and at-site characteristics in general:





- More heavy rainfall events are identified in area-average observations while the area-average seasonal total precipitation due to heavy events corresponds well with that from the at-site observations.
- Area-average event characteristic values are on average lower than are those for at-site observed characteristics, except that area-average event duration is longer for the shortest events and rainfall rate is comparable for events with low rates.
- 5 • For most of the characteristics, the difference between the area-average and at-site observations grows with increasing non-exceedance probability (the exception being event depth, for which the difference is comparable across the whole distribution). Many other studies point out larger differences between area-average and at-site rainfall for more extreme rainfall events (e.g. Skaugen, 1997; Asquith and Famiglietti, 2000; Allen and DeGaetano, 2005).
- Considerably fewer events with high maximum 60 min rainfall intensity ( $I_{60}$ ) and more events with low  $I_{60}$  occur in  
10 area-average observations than in at-site observations.
- The effect of areal averaging (lower values of characteristics with larger area, except for event duration) is generally in agreement with the review published by Svensson and Jones (2010) and the analysis of Eggert et al. (2015), who have shown more pronounced decrease for more extreme convective precipitation intensity with coarser spatial and larger  
15 temporal resolution derived from radar data. However, the estimated areal-averaging effect was not much different for the considered area sizes, and especially with respect to its great spatial variability. This might be a consequence of a small number of stations being available for estimation at finer spatial scales.

### 5.3 RCM-simulated rainfall event characteristics

Differences between the RCM-simulated and at-site observed characteristics are in general considerably larger than are those between the at-site and area-average observations, i.e. these differences are dominated by the RCMs' bias rather than the  
20 areal-averaging effect.

The ensemble-average number of heavy rainfall events is larger by 1.5 events (16 %) per season than for area-average observations, and the ensemble average of seasonal total precipitation due to heavy events is larger by 23 mm (11 %). Although the RCM-simulated number of heavy events and seasonal total precipitation due to heavy events averaged across the Czech Republic correspond relatively well with the area-average observations, large differences between individual grid boxes may  
25 be found (especially due to elevation). Generally good simulation of extremes (mean annual maxima, 20-year return values) in total precipitation amounts (from both convective and stratiform daily precipitation data together) were also reported for the Czech Republic by Kyselý et al. (2016).

Simulated event depths ( $D$ ) are comparable with the area-average observations, with depths of extreme heavy rainfall events (with non-exceedance probability  $p = 0.95$ ) corresponding best with the area-average observations. Because mean simulated  
30 (and area-average) event durations ( $T$ ) are relatively long ( $> 16$  h), the results are in general consistent with those of Hanel and Buishand (2010), who reported good representation of daily precipitation extremes for the area of the Netherlands even as hourly maxima tended to be too low. For the Czech Republic, Hanel and Buishand (2012) found larger negative bias in daily



precipitation extremes for an ensemble of RCM simulations from the ENSEMBLES project in summer (by as much as 17 %), while the bias was significantly lower in spring and autumn. Hence, including May and September into rainfall data might reduce the bias, which is smaller in our study.

Recent studies considering different spatial resolutions of RCM simulations suggest that hourly precipitation characteristics of extreme events are represented better in RCMs with higher spatial resolution (e.g. Ban et al., 2014; Chan et al., 2014b; Kendon et al., 2014). The better representation of hourly extremes is mainly due to the convection-resolving approach, however, because by increasing spatial resolution to approach the convection-permitting scale (about 4 km; Prein et al., 2015) it is possible to switch off most of the convection parameterizations (Fosser et al., 2015). All RCM simulations analysed in this paper rely on convection parameterization schemes, and the differences between RCM simulations conducted at different spatial resolutions are small and not systematic. Also, Sunyer et al. (2016) suggest that differences between RCM simulations with convective parameterization due to spatial resolution are smaller than differences due to RCM–GCM combinations for precipitation extremes. Therefore, characteristics of rainfall events for the RCM simulations with 50 km resolution (RCA4) also are not much different from these for other RCM simulations. Exceptions are the highest maximum 60 min rainfall intensities during an event ( $I_{60}$ ), which are underestimated more in RCA4 simulations compared to these from other RCMs. These results are in accordance with those of Sunyer et al. (2016), who concluded that the 50 km spatial resolution is not sufficient to reproduce hourly extreme precipitation even though the performance of the RCMs considering daily extremes seems not to depend on the spatial resolution.

The RCM-simulated maximum 60 min rainfall intensities ( $I_{60}$ ) as well as the number of events with large rainfall rate ( $R$ ) are significantly lower than for the observed data. This is in accord with Kyselý et al. (2016), who concluded that intensity of RCM-simulated convective precipitation in summer is underestimated and that this underestimation is related to convective parameterization. Similar explanation for the underrepresentation of short-duration, high-intensity events in RCM simulations was given also by Kendon et al. (2012).

Overestimation of event duration ( $T$ ) is a consequence of the well-known tendency of RCMs to produce too much persistent light rain and underestimate the number of dry days (e.g. Fowler et al., 2007; Boberg et al., 2009; Kendon et al., 2012). This strongly impacts especially events with the shortest durations ( $T$ ), which are severely overestimated in the RCM simulations. Large overestimation of short durations ( $T$ ) then causes pronounced underestimation of larger rainfall rates ( $R$ ). Fosser et al. (2015) reported the same issue of too-long events also for an RCM with higher resolution and most of the convective parameterizations turned off (COSMO-CLM, 2.8 km resolution).

It should be noted that when event duration ( $T$ ) is corrected (i.e. the events are proportionally shortened according to quantile ratio  $rt_p$  of event durations), mean rainfall rate ( $R$ ) increases to values that are well comparable with the area-average observations. For instance, correcting the event durations ( $T$ ) in the RACMO2\_ECHAM5 simulation (corresponding best with the area-average event depths) results in an 80 % increase of mean  $R$  (mean characteristics are shown in Table 2). Shortening an event also increases the maximum 60 min intensity during an event ( $I_{60}$ ; by about 50 %), event rainfall energy ( $E$ ; by 10 %), and erosivity index ( $EI_{60}$ ; by 65 %), even though these values are still slightly below the area-average observations (ratios  $rt_m$  in Fig. 3 for corrected mean  $I_{60}$ ,  $E$ , and  $EI_{60}$  would then be 0.46, 0.61, and 0.26, respectively).



Most analysed characteristics in most of the RCM simulations show a pattern of altitude-dependence similar to that for the at-site observations, and the differences in strength of the altitude-dependence for different quantiles of rainfall event characteristics are in general small (largest differences compared to at-site observations appear for simulations with the coarse 50 km resolution). The number of heavy events per season and seasonal total precipitation due to heavy events increase with altitude, and this dependence is captured better by RCM simulations with the higher spatial resolution. This could be expected due to better representation of orography as indicated by Rauscher et al. (2010) or Prein et al. (2016).

RCM simulations driven by the ERA reanalyses do not in general show better results compared to those from the GCM-driven RCMs. That is in agreement with Hanel and Buishand (2010), who indicated that bias is largely due to the precipitation parameterization rather than the driving boundary conditions. Although HadRM3 runs driven by the ERA40 reanalysis have event durations ( $T$ ) considerably shorter than these for the GCM-driven simulations (i.e. they show greater similarity with observations), values for event depths ( $D$ ) as well as other characteristics are generally lower in the ERA40-driven simulations. As a result, the distribution functions of the other event characteristics appear similar for the simulations driven by ERA40 as for those driven by GCMs, with larger differences occurring mostly between the perturbed and unperturbed runs. RCA4 driven by ERA-INTERIM reanalysis remains approximately in the middle of the range of all RCA4 runs for all characteristics and all assessed ratios. That is in line with the inter-comparison of RCA4 simulations according to monthly precipitation amounts as reported by Strandberg et al. (2014).

## 6 Conclusions

This study presents a methodology for analysis of precipitation characteristics in RCM simulations from an event-based perspective. Individual rainfall events are important with respect to many hydrological applications. Although it is generally not expected that the current RCMs would simulate sub-daily variability and rainfall event characteristics properly (e.g. Kendon et al., 2014; Westra et al., 2014), characterization of the biases can be useful for studies using simulated sub-daily rainfall data and also for the development of climate models, including research concerning their parameterizations, which is still very pertinent (e.g. Grell and Freitas, 2014) despite the increasing availability of convection-permitting RCM simulations (Prein et al., 2015).

The results suggest that representation of individual rainfall events in the RCM simulations suffers from several deficiencies which have been only partly discussed in previous studies dealing with precipitation characteristics and extremes. The most important findings are summarized as follows:

- Differences between RCM-simulated and at-site observed rainfall event characteristics are dominated by the bias of the climate models rather than the areal-averaging effect.
- The RCMs on average represent the number of heavy rainfall events and seasonal total precipitation due to heavy events relatively well, except that grid boxes at the highest altitudes produce large overestimation for some RCM simulations



(in general, slightly higher numbers of events for most of the RCM simulations; as well as a good representation of seasonal total precipitation for an ensemble of RCMs, despite larger differences for different RCM simulations).

- Simulated event depths correspond relatively well with the area-average observations, while event durations are over-estimated. Other characteristics (event mean rainfall rate, maximum 60 min rainfall intensity, and indicators of rainfall event erosivity) are significantly underestimated.
- The underestimation is larger for larger rainfall rates and maximum 60 min rainfall intensities during an event. These characteristics are underestimated most for extreme heavy events.
- The largest deficiencies are found for events with short duration, which are longer in the RCM simulations compared to the area-average observations. Therefore, the numbers of events with shortest duration (below 10 h) also are much lower in the RCM data. Overestimation of event durations then causes underestimation of rainfall rates and partly also of other characteristics.

The limitations in RCM-simulated rainfall event characteristics should be taken into consideration when applying their outputs in hydrological studies and climate change assessments.

*Acknowledgements.* The research was supported by the Czech Science Foundation (project number 14-18675S) and the Ministry of the Interior of the Czech Republic (project number VG20122015092). We thank E. Buonomo (MOHC), O. B. Christensen (DMI), E. van Meijgaard (KNMI), and G. Nikulin (SMHI) for providing the sub-daily RCM data. We acknowledge the ENSEMBLES project, funded by the European Commission's sixth Framework Programme through contract GOCE-CT-2003-505539, and the World Climate Research Programme's Working Group on Regional Climate, and the Working Group on Coupled Modelling, former coordinating body of CORDEX and responsible panel for CMIP5. We also thank the climate modelling groups and institutions (listed in Table 1 of this paper) for producing and making available their model output. We thank the Czech Hydrometeorological Institute and Pražská vodohospodářská společnost a.s. for providing observed at-site data.



## References

- Agnese, C., Bagarello, V., Corrao, C., D'Agostino, L., and D'Asaro, F.: Influence of the rainfall measurement interval on the erosivity determinations in the Mediterranean area, *J. Hydrol.*, 329, 39–48, doi:10.1016/j.jhydrol.2006.02.002, 2006.
- Alexander, L. V., Zhang, X., Peterson, T. C., Caesar, J., Gleason, B., Klein Tank, A. M. G., Haylock, M., Collins, D., Trewin, B., Rahimzadeh, F., Tagipour, A., Rupa Kumar, K., Revadekar, J., Griffiths, G., Vincent, L., Stephenson, D. B., Burn, J., Aguilar, E., Brunet, M., Taylor, M., New, M., Zhai, P., Rusticucci, M., and Vazquez-Aguirre, J. L.: Global observed changes in daily climate extremes of temperature and precipitation, *J. Geophys. Res.-Atmos.*, 111, doi:10.1029/2005JD006290, 2006.
- Allen, R. J. and DeGaetano, A. T.: Areal reduction factors for two eastern United States regions with high rain-gauge density, *J. Hydrol. Eng.*, 10, 327–335, doi:10.1061/(ASCE)1084-0699(2005)10:4(327), 2005.
- 10 Angulo-Martínez, M. and Beguería, S.: Estimating rainfall erosivity from daily precipitation records: a comparison among methods using data from the Ebro Basin (NE Spain), *J. Hydrol.*, 379, 111–121, doi:10.1016/j.jhydrol.2009.09.051, 2009.
- Arnbjerg-Nielsen, K.: Quantification of climate change effects on extreme precipitation used for high resolution hydrologic design, *Urban Water J.*, 9, 57–65, doi:10.1080/1573062X.2011.630091, 2012.
- Asquith, W. and Famiglietti, J.: Precipitation areal-reduction factor estimation using an annual-maxima centered approach, *J. Hydrol.*, 230, 55–69, doi:10.1016/S0022-1694(00)00170-0, 2000.
- 15 Ban, N., Schmidli, J., and Schär, C.: Evaluation of the convection-resolving regional climate modeling approach in decade-long simulations, *J. Geophys. Res.-Atmos.*, 119, 7889–7907, doi:10.1002/2014JD021478, 2014.
- Barbosa, A., Fernandes, J., and David, L.: Key issues for sustainable urban stormwater management, *Water Res.*, 46, 6787–6798, doi:10.1016/j.watres.2012.05.029, special Issue on Stormwater in urban areas, 2012.
- 20 Berg, P. and Haerter, J.: Unexpected increase in precipitation intensity with temperature – a result of mixing of precipitation types?, *Atmos. Res.*, 119, 56–61, doi:10.1016/j.atmosres.2011.05.012, 2013.
- Boberg, F., Berg, P., Thejll, P., Gutowski, W., and Christensen, J.: Improved confidence in climate change projections of precipitation evaluated using daily statistics from the PRUDENCE ensemble, *Clim. Dynam.*, 32, 1097–1106, doi:10.1007/s00382-008-0446-y, 2009.
- Böhm, U., Kücken, M., Ahrens, W., Block, A., Hauffe, D., Keuler, K., Rockel, B., and Will, A.: CLM – the climate version of LM: brief description and long-term applications, *COSMO Newsletter*, 6, 225–235, 2006.
- 25 Brockhaus, P., Lüthi, D., and Schär, C.: Aspects of the diurnal cycle in a regional climate model, *Meteorol. Z.*, 17, 433–443, doi:10.1127/0941-2948/2008/0316, 2008.
- Brown, L. C. and Foster, G. R.: Storm erosivity using idealized intensity distributions, *T. ASAE*, 30, 379–386, 1987.
- Chan, S. C., Kendon, E. J., Fowler, H. J., Blenkinsop, S., and Roberts, N. M.: Projected increases in summer and winter UK sub-daily precipitation extremes from high-resolution regional climate models, *Environ. Res. Lett.*, 9, 2014a.
- 30 Chan, S. C., Kendon, E. J., Fowler, H. J., Blenkinsop, S., Roberts, N. M., and Ferro, C. A. T.: The value of high-resolution Met Office regional climate models in the simulation of multihourly precipitation extremes, *J. Climate*, 27, 6155–6174, doi:10.1175/JCLI-D-13-00723.1, 2014b.
- Christensen, O. B., Drews, M., Christensen, J. H., Dethloff, K., Ketelsen, K., Hebestadt, I., and Rinke, A.: The HIRHAM regional climate model version 5 (beta), Technical Report, no. 06-17, Danish Climate Centre, Danish Meteorological Institute, 2007.
- Collins, M., Booth, B., Harris, G., Murphy, J., Sexton, D., and Webb, M.: Towards quantifying uncertainty in transient climate change, *Clim. Dynam.*, 27, 127–147, doi:10.1007/s00382-006-0121-0, 2006.



- Collins, M., Booth, B., Bhaskaran, B., Harris, G., Murphy, J., Sexton, D., and Webb, M.: Climate model errors, feedbacks and forcings: a comparison of perturbed physics and multi-model ensembles, *Clim. Dynam.*, 36, 1737–1766, doi:10.1007/s00382-010-0808-0, 2011.
- Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M. A., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A. C. M., van de Berg, L., Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A. J., Haimberger, L., Healy, S. B., Hersbach, H., Hólm, E. V., Isaksen, I., Kållberg, P., Köhler, M., Matricardi, M., McNally, A. P., Monge-Sanz, B. M., Morcrette, J.-J., Park, B.-K., Peubey, C., de Rosnay, P., Tavolato, C., Thépaut, J.-N., and Vitart, F.: The ERA-Interim reanalysis: configuration and performance of the data assimilation system, *Q. J. Roy. Meteor. Soc.*, 137, 553–597, doi:10.1002/qj.828, 2011.
- Dunkerley, D.: Rain event properties in nature and in rainfall simulation experiments: a comparative review with recommendations for increasingly systematic study and reporting, *Hydrol. Process.*, 22, 4415–4435, doi:10.1002/hyp.7045, 2008a.
- Dunkerley, D.: Identifying individual rain events from pluviograph records: a review with analysis of data from an Australian dryland site, *Hydrol. Process.*, 22, 5024–5036, doi:10.1002/hyp.7122, 2008b.
- Eggert, B., Berg, P., Haerter, J. O., Jacob, D., and Moseley, C.: Temporal and spatial scaling impacts on extreme precipitation, *Atmos. Chem. Phys.*, 15, 5957–5971, doi:10.5194/acp-15-5957-2015, 2015.
- Einfalt, T., Krejci, V., and Schilling, W.: Rainfall data in urban hydrology, in: *Hydroinformatics tools for planning, design, operation and rehabilitation of sewer systems*, edited by Marsalek, J., Maksimovic, C., Zeman, E., and Price, R., vol. 44 of *NATO ASI Ser.*, pp. 129–168, Springer Netherlands, 1998.
- Fiener, P., Neuhaus, P., and Botschek, J.: Long-term trends in rainfall erosivity – analysis of high resolution precipitation time series (1937–2007) from Western Germany, *Agr. Forest Meteorol.*, 171–172, 115–123, doi:10.1016/j.agrformet.2012.11.011, 2013.
- Fosser, G., Khodayar, S., and Berg, P.: Benefit of convection permitting climate model simulations in the representation of convective precipitation, *Clim. Dynam.*, 44, 45–60, doi:10.1007/s00382-014-2242-1, 2015.
- Fowler, H. J. and Ekström, M.: Multi-model ensemble estimates of climate change impacts on UK seasonal precipitation extremes, *Int. J. Climatol.*, 29, 385–416, doi:10.1002/joc.1827, 2009.
- Fowler, H. J., Ekström, M., Blenkinsop, S., and Smith, A. P.: Estimating change in extreme European precipitation using a multimodel ensemble, *J. Geophys. Res.-Atmos.*, 112, doi:10.1029/2007JD008619, 2007.
- Gaal, L., Molnar, P., and Szolgay, J.: Selection of intense rainfall events based on intensity thresholds and lightning data in Switzerland, *Hydrol. Earth Syst. Sc.*, 18, 1561–1573, doi:10.5194/hess-18-1561-2014, 2014.
- Gregersen, I. B., Sørup, H. J. D., Madsen, H., Rosbjerg, D., Mikkelsen, P. S., and Arnbjerg-Nielsen, K.: Assessing future climatic changes of rainfall extremes at small spatio-temporal scales, *Climatic change*, 118, 783–797, doi:10.1007/s10584-012-0669-0, 2013.
- Grell, G. A. and Freitas, S. R.: A scale and aerosol aware stochastic convective parameterization for weather and air quality modeling, *Atmos. Chem. Phys.*, 14, 5233–5250, doi:10.5194/acp-14-5233-2014, 2014.
- Hanel, M. and Buishand, T. A.: On the value of hourly precipitation extremes in regional climate model simulations, *J. Hydrol.*, 393, 265–273, doi:10.1016/j.jhydrol.2010.08.024, 2010.
- Hanel, M. and Buishand, T. A.: Analysis of precipitation extremes in an ensemble of transient regional climate model simulations for the Rhine basin, *Clim. Dynam.*, 36, 1135–1153, doi:10.1007/s00382-010-0822-2, 2011.
- Hanel, M. and Buishand, T. A.: Multi-model analysis of RCM simulated 1-day to 30-day seasonal precipitation extremes in the Czech Republic, *J. Hydrol.*, 412–413, 141–150, doi:10.1016/j.jhydrol.2011.02.007, 2012.
- Hanel, M. and Máca, P.: Spatial variability and interdependence of rain event characteristics in the Czech Republic, *Hydrol. Process.*, 28, 2929–2944, doi:10.1002/hyp.9845, 2014.



- Hanel, M., Pavlásková, A., and Kyselý, J.: Trends in characteristics of sub-daily heavy precipitation and rainfall erosivity in the Czech Republic, *Int. J. Climatol.*, 36, 1833–1845, doi:10.1002/joc.4463, 2016.
- Haylock, M. R., Hofstra, N., Klein Tank, A. M. G., Klok, E. J., Jones, P. D., and New, M.: A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006, *J. Geophys. Res.-Atmos.*, 113, doi:10.1029/2008JD010201, 2008.
- 5 Herrera, S., Fita, L., Fernández, J., and Gutiérrez, J. M.: Evaluation of the mean and extreme precipitation regimes from the ENSEMBLES regional climate multimodel simulations over Spain, *J. Geophys. Res.-Atmos.*, 115, doi:10.1029/2010JD013936, 2010.
- Hohenegger, C., Brockhaus, P., and Schär, C.: Towards climate simulations at cloud-resolving scales, *Meteorol. Z.*, 17, 383–394, doi:10.1127/0941-2948/2008/0303, 2008.
- Ignaccolo, M. and Michele, C. D.: A point based Eulerian definition of rain event based on statistical properties of inter drop time intervals: an application to Chilbolton data, *Adv. Water Resour.*, 33, 933–941, doi:10.1016/j.advwatres.2010.04.002, 2010.
- 10 Jacob, D., Bärring, L., Christensen, O., Christensen, J., de Castro, M., Déqué, M., Giorgi, F., Hagemann, S., Hirschi, M., Jones, R., Kjellström, E., Lenderink, G., Rockel, B., Sánchez, E., Schär, C., Seneviratne, S., Somot, S., van Ulden, A., and van den Hurk, B.: An inter-comparison of regional climate models for Europe: model performance in present-day climate, *Climatic change*, 81, 31–52, doi:10.1007/s10584-006-9213-4, 2007.
- 15 Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O., Bouwer, L., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsmann, A., Martin, E., van Meijgaard, E., Moseley, C., Pfeifer, S., Preuschmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.-F., Teichmann, C., Valentini, R., Vautard, R., Weber, B., and Yiou, P.: EURO-CORDEX: new high-resolution climate change projections for European impact research, *Reg. Environ. Change*, 14, 563–578, doi:10.1007/s10113-013-0499-2, 2014.
- 20 Kendon, E. J., Roberts, N. M., Senior, C. A., and Roberts, M. J.: Realism of rainfall in a very high-resolution regional climate model, *J. Climate*, 25, 5791–5806, doi:10.1175/JCLI-D-11-00562.1, 2012.
- Kendon, E. J., Roberts, N. M., Fowler, H. J., Roberts, M. J., Chan, S. C., and Senior, C. A.: Heavier summer downpours with climate change revealed by weather forecast resolution model, *Nat. Clim. Change*, 4, 570–576, doi:10.1038/nclimate2258, 2014.
- 25 Kjellström, E., Boberg, F., Castro, M., Christensen, H. J., Nikulin, G., and Sánchez, E.: Daily and monthly temperature and precipitation statistics as performance indicators for regional climate models, *Clim. Res.*, 44, 135–150, doi:10.3354/cr00932, 2010.
- Kupiainen, M., Samuelsson, P., Jones, C., Jansson, C., Willén, U., Hansson, U., Ullerstig, A., Wang, S., and Döschner, R.: Rossby Centre regional atmospheric model, RCA4, Rossby Centre Newsletter, 2011.
- Květoň, V., Zahradníček, J., and Žák, M.: Quality control and digitising of pluviographic measurements in the Czech Hydrometeorological Institute, *Meteorologické zprávy*, 57, 47–52, 2004.
- 30 Kyselý, J., Rulfová, Z., Farda, A., and Hanel, M.: Convective and stratiform precipitation characteristics in an ensemble of regional climate model simulations, *Clim. Dynam.*, 46, 227–243, doi:10.1007/s00382-015-2580-7, 2016.
- Lautenschlager, M., Keuler, K., Wunram, C., Keup-Thiel, E., Schubert, M., Will, A., Rockel, B., and Boehm, U.: Climate simulation with CLM, climate of the 20th century run no.2, data stream 3: European region MPI-M/MaD, World Data Center for Climate (WDCC), doi:10.1594/WDCC/CLM\_C20\_2\_D3, 2009.
- 35 Lenderink, G. and van Meijgaard, E.: Increase in hourly precipitation extremes beyond expectations from temperature changes, *Nat. Geosci.*, 1, 511–514, doi:10.1038/ngeo262, 2008.



- Lozano-Parra, J., Schnabel, S., and Ceballos-Barbancho, A.: The role of vegetation covers on soil wetting processes at rainfall event scale in scattered tree woodland of Mediterranean climate, *J. Hydrol.*, 529, Part 3, 951–961, doi:10.1016/j.jhydrol.2015.09.018, 2015.
- Meusburger, K., Steel, A., Panagos, P., Montanarella, L., and Alewell, C.: Spatial and temporal variability of rainfall erosivity factor for Switzerland, *Hydrol. Earth Syst. Sc.*, 16, 167–177, doi:10.5194/hess-16-167-2012, 2012.
- 5 Millán, M. M.: Extreme hydrometeorological events and climate change predictions in Europe, *J. Hydrol.*, 518, Part B, 206–224, doi:10.1016/j.jhydrol.2013.12.041, 2014.
- Murakami, S.: A proposal for a new forest canopy interception mechanism: splash droplet evaporation, *J. Hydrol.*, 319, 72–82, doi:10.1016/j.jhydrol.2005.07.002, 2006.
- Peters, O. and Christensen, K.: Rain viewed as relaxational events, *J. Hydrol.*, 328, 46–55, doi:10.1016/j.jhydrol.2005.11.045, 2006.
- 10 Prein, A. F., Langhans, W., Fosser, G., Ferrone, A., Ban, N., Goergen, K., Keller, M., Tölle, M., Gutjahr, O., Feser, F., Brisson, E., Kollet, S., Schmidli, J., van Lipzig, N. P. M., and Leung, R.: A review on regional convection-permitting climate modeling: demonstrations, prospects, and challenges, *Rev. Geophys.*, 53, 323–361, doi:10.1002/2014RG000475, 2015.
- Prein, A. F., Gobiet, A., Truhetz, H., Keuler, K., Goergen, K., Teichmann, C., Fox Maule, C., van Meijgaard, E., Déqué, M., Nikulin, G., Vautard, R., Colette, A., Kjellström, E., and Jacob, D.: Precipitation in the EURO-CORDEX 0.11° and 0.44° simulations: high resolution, high benefits?, *Clim. Dynam.*, 46, 383–412, doi:10.1007/s00382-015-2589-y, 2016.
- 15 Rauscher, S. A., Coppola, E., Piani, C., and Giorgi, F.: Resolution effects on regional climate model simulations of seasonal precipitation over Europe, *Clim. Dynam.*, 35, 685–711, doi:10.1007/s00382-009-0607-7, 2010.
- Restrepo-Posada, P. and Eagleson, P.: Identification of independent rainstorms, *J. Hydrol.*, 55, 303–319, doi:10.1016/0022-1694(82)90136-6, 1982.
- 20 Samuelsson, P., Jones, C. G., Willén, U., Ullerstig, A., Gollvik, S., Hansson, U., Jansson, C., Kjellström, E., Nikulin, G., and Wyser, K.: The Rossby Centre regional climate model RCA3: model description and performance, *Tellus A*, 63, 4–23, doi:10.1111/j.1600-0870.2010.00478.x, 2011.
- Siegert, C. and Levia, D.: Seasonal and meteorological effects on differential stemflow funneling ratios for two deciduous tree species, *J. Hydrol.*, 519, Part A, 446–454, doi:10.1016/j.jhydrol.2014.07.038, 2014.
- 25 Siler, N. and Roe, G.: How will orographic precipitation respond to surface warming? An idealized thermodynamic perspective, *Geophys. Res. Lett.*, 41, 2606–2613, doi:10.1002/2013GL059095, 2014.
- Skaugen, T.: Classification of rainfall into small and large-scale events by statistical pattern recognition, *J. Hydrol.*, 200, 40–57, doi:10.1016/S0022-1694(97)00003-6, 1997.
- Staelens, J., De Schrijver, A., Verheyen, K., and Verhoest, N. E. C.: Rainfall partitioning into throughfall, stemflow, and interception within a single beech (*Fagus sylvatica* L.) canopy: influence of foliation, rain event characteristics, and meteorology, *Hydrol. Process.*, 22, 33–45, doi:10.1002/hyp.6610, 2008.
- 30 Stocker, T., Qin, D., Plattner, G.-K., Tignor, M., Allen, S., Boschung, J., Nauels, A., Xia, Y., Bex, V., and Midgley, P., eds.: Climate change 2013: the physical science basis. Contribution of working group I to the fifth assessment report of the Intergovernmental panel on climate change, Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, doi:10.1017/CBO9781107415324, 2013.
- 35 Strandberg, G., Bärring, L., Hansson, U., Jansson, C., Jones, C., Kjellström, E., Kolax, M., Kupiainen, M., Nikulin, G., Samuelsson, P., Ullerstig, A., and Wang, S.: CORDEX scenarios for Europe from the Rossby Centre regional climate model RCA4, Report Meteorology and Climatology no. 116, Swedish Meteorological and Hydrological Institute, SE 601 76 Norrköping, Sweden, 2014.





- Sunyer, M. A., Gregersen, I. B., Rosbjerg, D., Madsen, H., Luchner, J., and Arnbjerg-Nielsen, K.: Comparison of different statistical down-scaling methods to estimate changes in hourly extreme precipitation using RCM projections from ENSEMBLES, *Int. J. Climatol.*, 35, 2528–2539, doi:10.1002/joc.4138, 2015.
- Sunyer, M. A., Luchner, J., Onof, C., Madsen, H., and Arnbjerg-Nielsen, K.: Assessing the importance of spatio-temporal RCM resolution when estimating sub-daily extreme precipitation under current and future climate conditions, *Int. J. Climatol.*, doi:10.1002/joc.4733, in press, 2016.
- Svensson, C. and Jones, D.: Review of methods for deriving areal reduction factors, *J. Flood Risk Manage.*, 3, 232–245, doi:10.1111/j.1753-318X.2010.01075.x, 2010.
- Todisco, F.: The internal structure of erosive and non-erosive storm events for interpretation of erosive processes and rainfall simulation, *J. Hydrol.*, 519, Part D, 3651–3663, doi:10.1016/j.jhydrol.2014.11.002, 2014.
- Tolasz, R., ed.: *Atlas podnebí Česka (Climate atlas of Czechia)*, Český hydrometeorologický ústav, Praha, 1. edn., 2007.
- Trenberth, K. E.: Changes in precipitation with climate change, *Clim. Res.*, 47, 123–138, doi:10.3354/cr00953, 2011.
- Uppala, S. M., Kållberg, P. W., Simmons, A. J., Andrae, U., Bechtold, V. D. C., Fiorino, M., Gibson, J. K., Haseler, J., Hernandez, A., Kelly, G. A., Li, X., Onogi, K., Saarinen, S., Sokka, N., Allan, R. P., Andersson, E., Arpe, K., Balmaseda, M. A., Beljaars, A. C. M., Berg, L. V. D., Bidlot, J., Bormann, N., Caires, S., Chevallier, F., Dethof, A., Dragosavac, M., Fisher, M., Fuentes, M., Hagemann, S., Hólm, E., Hoskins, B. J., Isaksen, L., Janssen, P. A. E. M., Jenne, R., McNally, A. P., Mahfouf, J.-F., Morcrette, J.-J., Rayner, N. A., Saunders, R. W., Simon, P., Sterl, A., Trenberth, K. E., Untch, A., Vasiljevic, D., Viterbo, P., and Woollen, J.: The ERA-40 re-analysis, *Q. J. Roy. Meteor. Soc.*, 131, 2961–3012, doi:10.1256/qj.04.176, 2005.
- van der Linden, P. and Mitchell, J. F. B., eds.: *ENSEMBLES: climate change and its impacts: summary of research and results from the ENSEMBLES project*, Met Office Hadley Centre, Exeter, 2009.
- van Meijgaard, E., van Ulft, L. H., van de Berg, W. J., Bosveld, F. C., van den Hurk, B., Lenderink, G., and Siebesma, A. P.: The KNMI regional atmospheric climate model RACMO version 2.1, Technical Report, TR 302, KNMI, De Bilt, 2008.
- van Meijgaard, E., van Ulft, L., Lenderink, G., de Roode, S., Wipfler, E., Boers, R., and Timmermans, R.: Refinement and application of a regional atmospheric model for climate scenario calculations of Western Europe, Kvr 054/12, Programme Office Climate changes Spatial Planning, KNMI, De Bilt, 2012.
- Westra, S., Fowler, H. J., Evans, J. P., Alexander, L. V., Berg, P., Johnson, F., Kendon, E. J., Lenderink, G., and Roberts, N. M.: Future changes to the intensity and frequency of short-duration extreme rainfall, *Rev. Geophys.*, 52, 522–555, doi:10.1002/2014RG000464, 2014.
- Willems, P. and Vrac, M.: Statistical precipitation downscaling for small-scale hydrological impact investigations of climate change, *J. Hydrol.*, 402, 193–205, doi:10.1016/j.jhydrol.2011.02.030, 2011.
- Willems, P., Arnbjerg-Nielsen, K., Olsson, J., and Nguyen, V.: Climate change impact assessment on urban rainfall extremes and urban drainage: methods and shortcomings, *Atmos. Res.*, 103, 106–118, doi:10.1016/j.atmosres.2011.04.003, 2012.
- Wischmeier, W. H. and Smith, D. D.: *Predicting rainfall erosion losses: a guide to conservation planning*, Agriculture handbook 537, Science and Education Administration, U.S. Department of Agriculture, 1978.



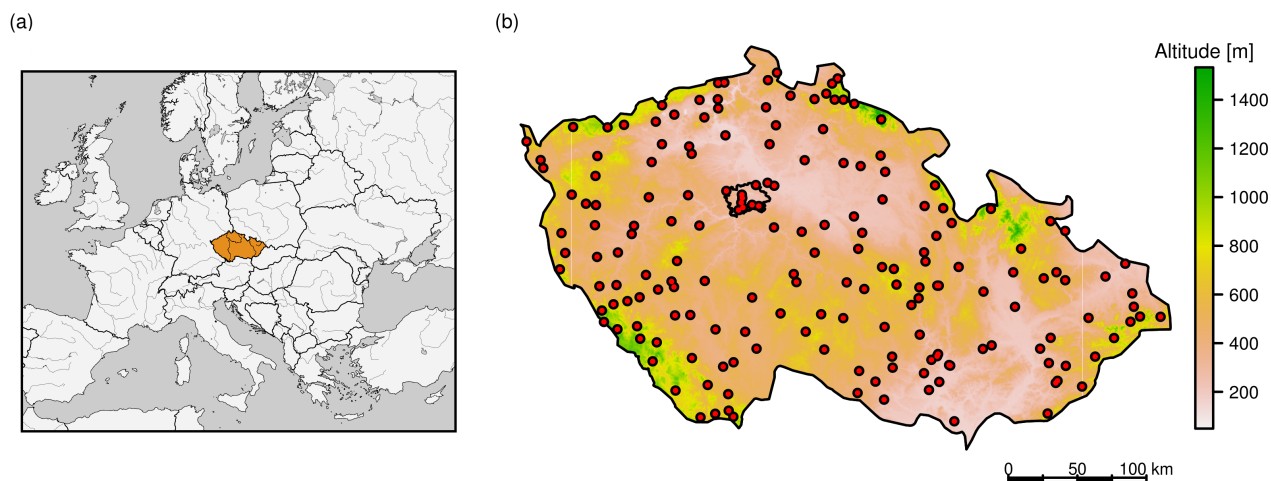
**Table 1.** RCM simulations analysed.

<b>RCM (reference) – Institution producing the model output</b>			
Acronym	Driven by	Horizontal resolution	Number of gridboxes
<b>CLM 2.4.11</b> (Böhm et al., 2006; Lautenschlager et al., 2009) – Max Planck Institute for Meteorology (MPI), Germany			
CLM	ECHAM5/MPIOM	22 km (0.2°)	301
<b>HadRM3.0</b> (Collins et al., 2011) – Met Office Hadley Centre (MOHC), UK			
HadRM3Q0_ERA40	ERA40	25 km (0.22°)	173
HadRM3Q3_ERA40	ERA40		
HadRM3Q16_ERA40	ERA40		
HadRM3Q0_HadCM3	HadCM3Q0		
HadRM3Q3_HadCM3	HadCM3Q3		
HadRM3Q16_HadCM3	HadCM3Q16		
<b>HIRHAM5</b> (Christensen et al., 2007) – Danish Meteorological Institute (DMI)			
H5_ARPEGE	ARPEGE	25 km (0.22°)	173
H5_BCM	BCM		
H5_ECHAM5	ECHAM5-r3		
<b>RACMO2.1</b> (van Meijgaard et al., 2008) – Royal Netherlands Meteorological Institute (KNMI)			
RACMO2_ECHAM5	ECHAM5-r3	25 km (0.22°)	173
RACMO2_MIROC	MIROC3.2		
<b>RACMO22E</b> (van Meijgaard et al., 2012) – Royal Netherlands Meteorological Institute (KNMI)			
RACMO22E	ICHEC-EC-EARTH	12.5 km (0.11°)	607
<b>RCA4.0</b> (Kupiainen et al., 2011; Samuelsson et al., 2011) – Swedish Meteorological and Hydrological Institute (SMHI)			
RCA4_ERAINTE	ERA-INTERIM	50 km (0.44°)	52
RCA4_CanESM2	CCCma-CanESM2		
RCA4_CM5A-MR	IPSL-CM5A-MR		
RCA4_CNRM-CM5	CNRM-CM5		
RCA4_EC-EARTH	ICHEC-EC-EARTH		
RCA4_ESM2M	NOAA-GFDL-ESM2M		
RCA4_ESM-LR	MPI-ESM-LR		
RCA4_HadGEM2-ES	MOHC-HadGEM2-ES		
RCA4_MIROC5	MIROC5		
RCA4_NorESM1-M	NCC-NorESM1-M		

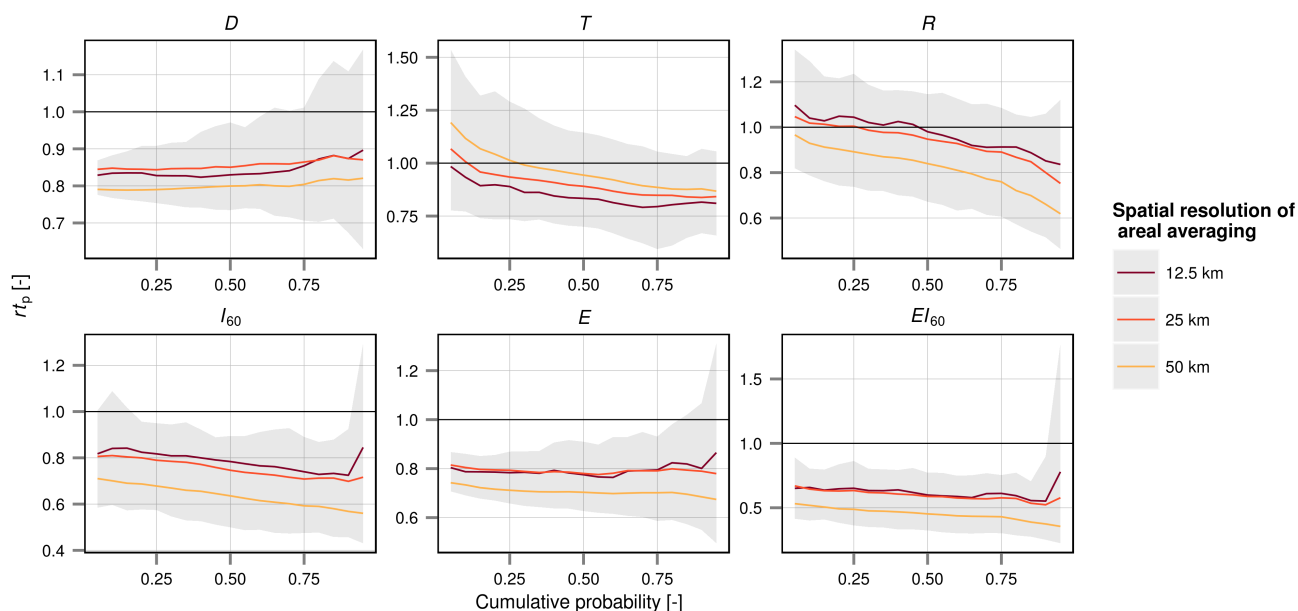


**Table 2.** Seasonal number of heavy rainfall events ( $N_{se}$  [–]), seasonal total precipitation due to heavy events ( $S_{se}$  [mm]), and mean rainfall event characteristics ( $D$  [mm],  $T$  [mm],  $R$  [mm h<sup>-1</sup>],  $I_{60}$  [mm h<sup>-1</sup>],  $E$  [MJ ha<sup>-1</sup>], and  $EI_{60}$  [MJ mm ha<sup>-1</sup> h<sup>-1</sup>]) for the 1981–2000 period in the observed data (top 4 rows) and the RCM simulations.

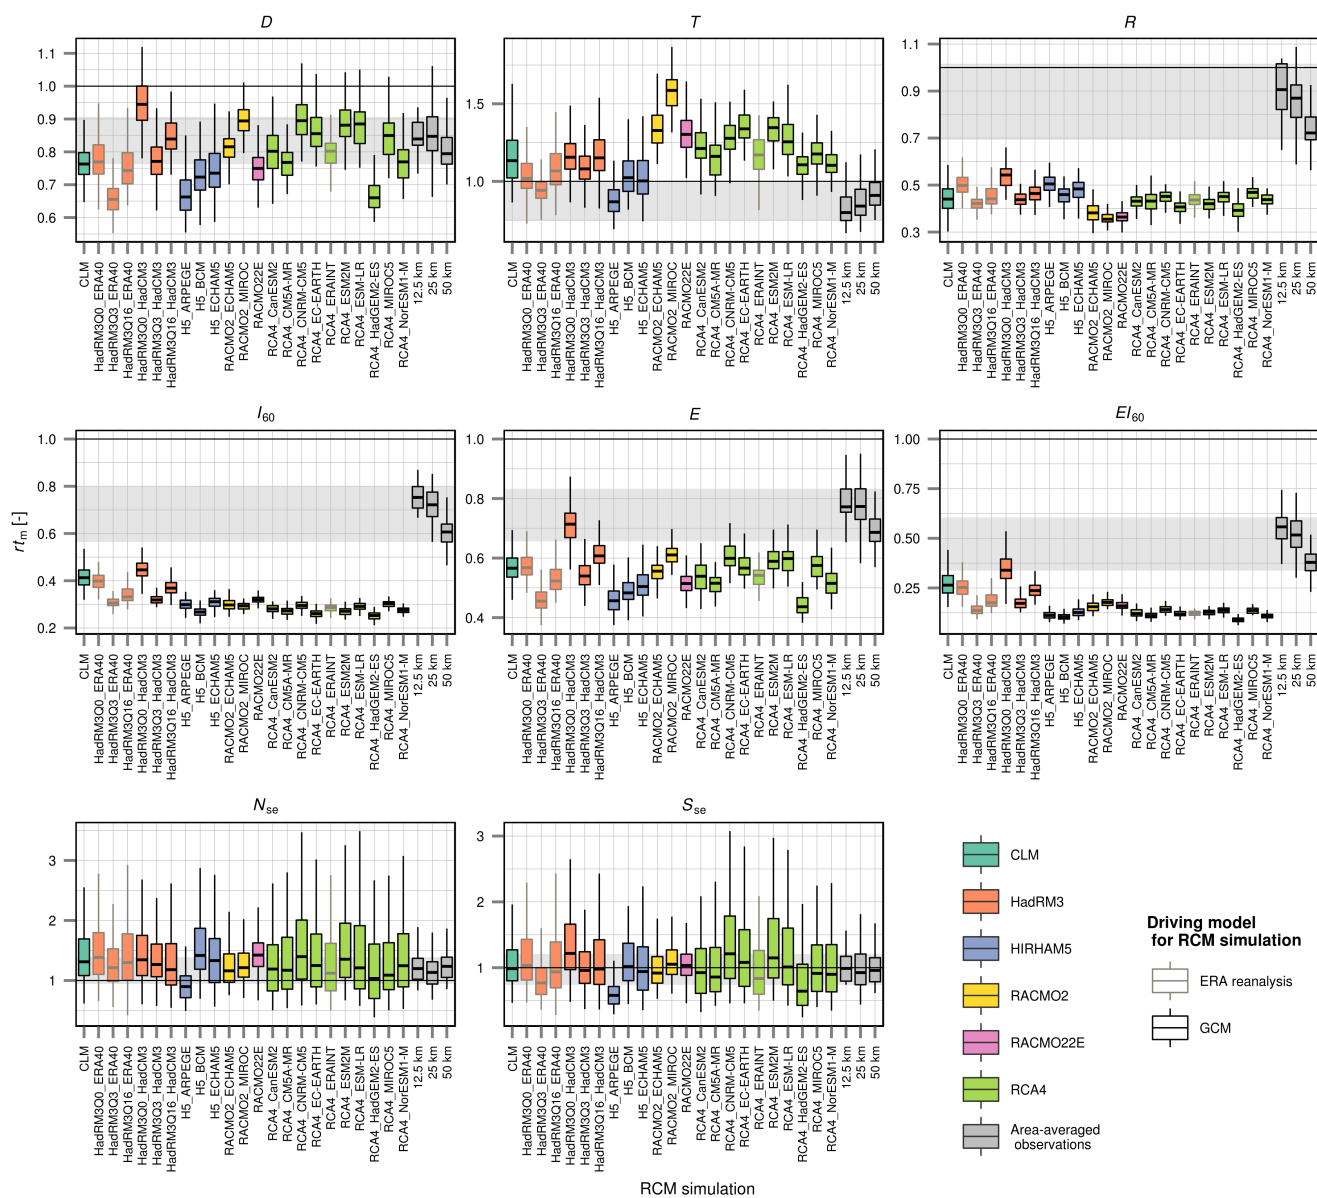
Acronym	$N_{se}$	$S_{se}$	$D$	$T$	$R$	$I_{60}$	$E$	$EI_{60}$
<b>At-site observations average</b>	7.62	194.7	25.0	19.7	2.37	9.38	3.66	48.75
<b>Area-average observations</b>								
12.5 km	9.41	205.6	21.4	16.2	2.14	7.20	2.92	28.88
25 km	9.00	197.9	21.6	17.1	2.02	6.82	2.89	26.16
50 km	9.66	198.8	20.2	18.1	1.73	5.68	2.56	18.77
<b>Summary of RCM simulations</b>								
RCMs average	10.82	223.4	20.0	23.2	1.04	2.93	2.02	7.88
12.5 km res. RCM	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96
25 km res. RCMs	10.54	215.2	19.8	22.3	1.08	3.12	2.04	9.08
50 km res. RCMs	11.08	235.0	20.5	23.9	1.02	2.60	2.01	5.97
<b>RCM simulations</b>								
CLM	10.84	208.9	19.2	22.8	1.06	3.91	2.09	13.58
HadRM3Q0_ERA40	11.83	239.2	19.6	20.6	1.19	3.74	2.11	12.28
HadRM3Q3_ERA40	10.05	169.5	16.5	18.8	1.00	2.90	1.70	6.99
HadRM3Q16_ERA40	11.40	226.7	19.1	21.5	1.08	3.21	1.98	9.56
HadRM3Q0_HadCM3	11.33	278.3	23.9	23.2	1.28	4.20	2.62	16.90
HadRM3Q3_HadCM3	10.51	209.0	19.5	21.6	1.04	3.01	2.01	8.56
HadRM3Q16_HadCM3	10.31	231.7	21.6	23.2	1.11	3.48	2.27	11.84
H5_ARPEGE	7.61	132.7	16.9	17.4	1.19	2.83	1.70	5.67
H5_BCM	12.70	246.6	18.5	20.5	1.08	2.51	1.83	5.27
H5_ECHAM5	11.11	224.7	19.0	20.5	1.13	2.91	1.92	6.54
RACMO2_ECHAM5	9.42	191.0	20.2	26.6	0.91	2.81	2.02	7.69
RACMO2_MIROC	9.67	217.8	22.4	31.1	0.85	2.74	2.24	8.63
RACMO22E	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96
RCA4_CanESM2	10.65	221.5	20.0	23.9	1.01	2.63	1.97	6.01
RCA4_CM5A-MR	11.14	219.4	19.2	22.7	1.02	2.53	1.89	5.46
RCA4_CNRM-CM5	12.38	289.2	22.5	25.0	1.07	2.77	2.23	6.94
RCA4_EC-EARTH	11.11	249.7	21.7	26.4	0.95	2.44	2.11	5.86
RCA4 ERAINT	10.20	208.1	19.9	23.0	1.03	2.67	1.97	6.04
RCA4_ESM2M	12.08	275.6	22.2	26.1	0.99	2.53	2.17	6.25
RCA4_ESM-LR	11.45	257.9	21.9	25.0	1.06	2.72	2.17	6.65
RCA4_HadGEM2-ES	9.93	173.3	16.8	21.6	0.93	2.35	1.62	4.35
RCA4_MIROC5	10.11	221.2	21.2	23.0	1.11	2.83	2.11	6.67
RCA4_NorESM1-M	11.76	233.8	19.2	21.9	1.03	2.57	1.89	5.41



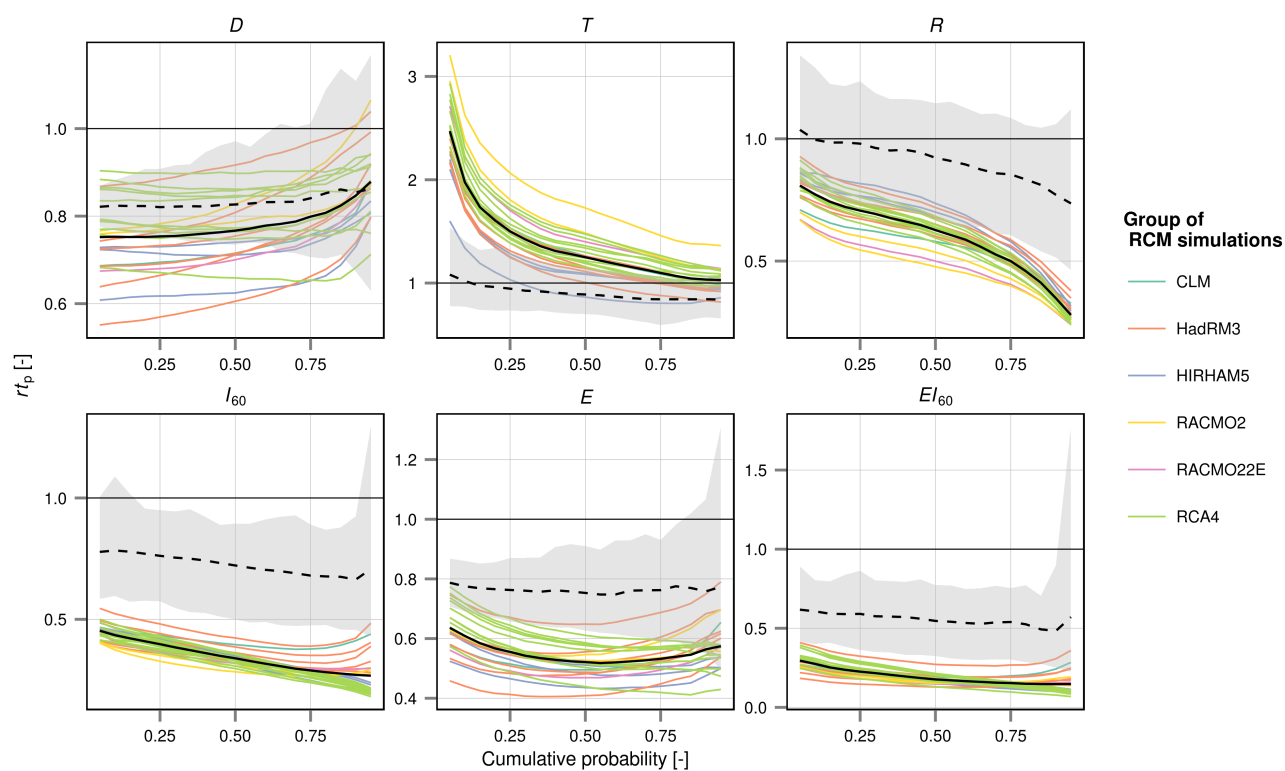
**Figure 1.** (a) Location of the Czech Republic in Central Europe. (b) Stations (dots) used for assessing the areal-averaging effect and evaluating the RCM simulations. Altitude is indicated by colour.



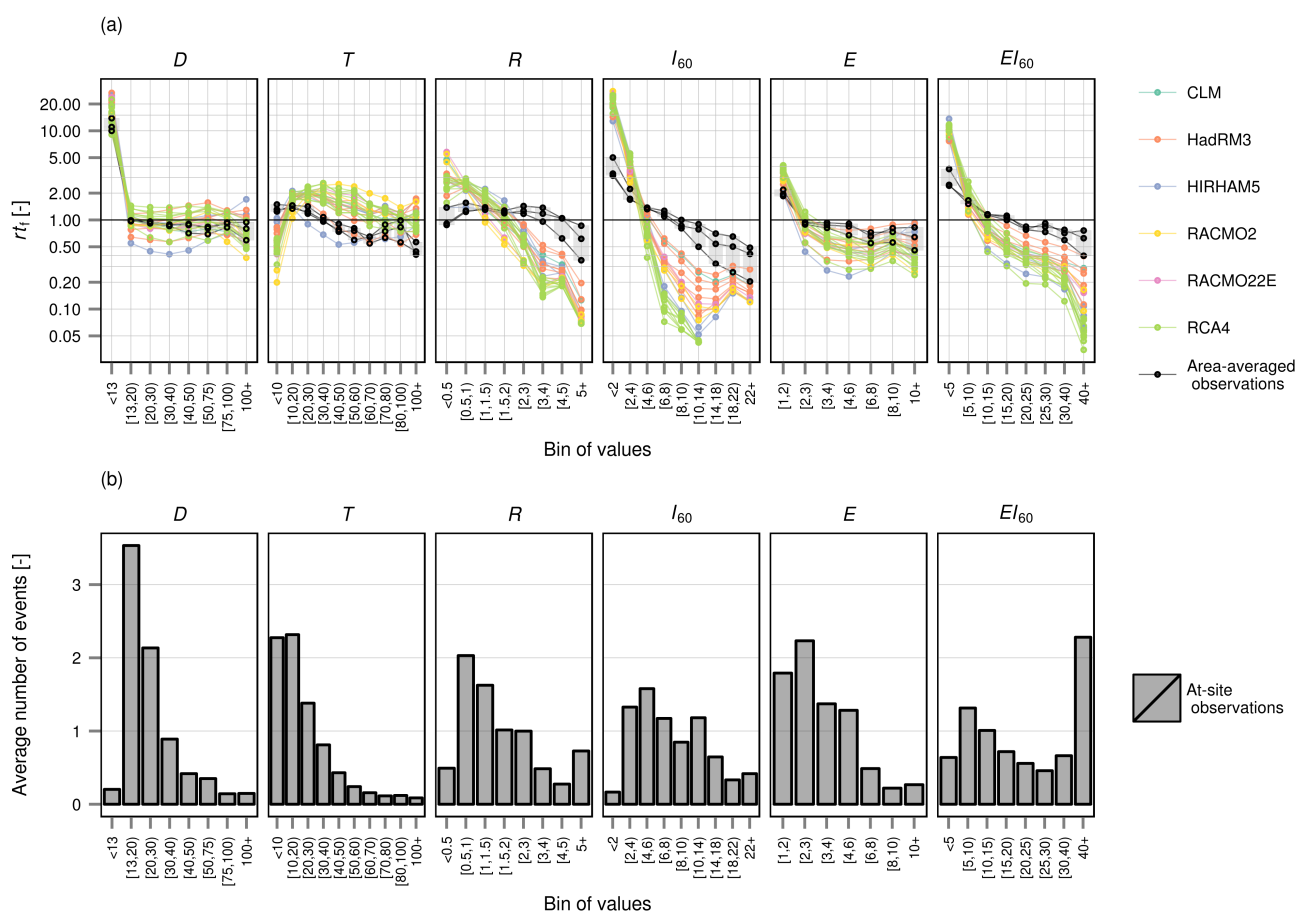
**Figure 2.** Quantile ratios  $rt_p$  for the distribution of the area-average and at-site rainfall event characteristics ( $D$ ,  $T$ ,  $R$ ,  $I_{60}$ ,  $E$ ,  $EI_{60}$ ). For each spatial resolution (12.5, 25, 50 km), the average from all neighbourhoods is indicated by solid line. Envelopes of  $rt_p$  for all neighbourhoods (grey areas) represent the maximum range between the 5<sup>th</sup> and 95<sup>th</sup> quantiles for the three considered spatial resolutions.



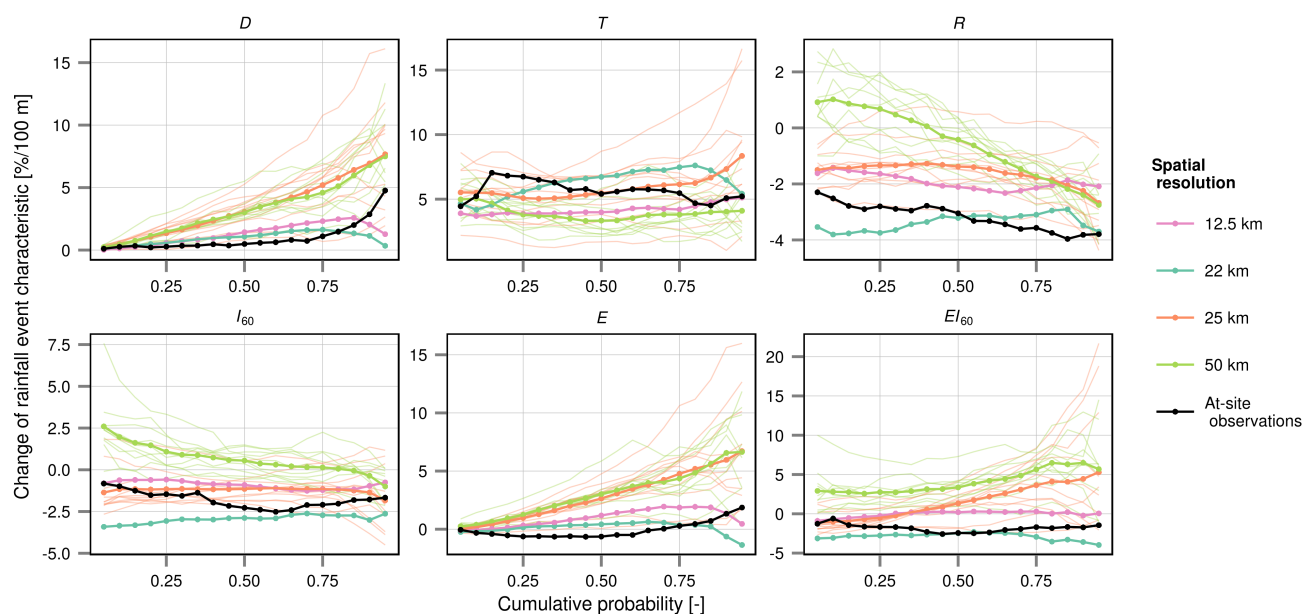
**Figure 3.** Ratios  $r_{tm}$  between areal (grid box or neighbourhood) and station average of mean (event and seasonal) characteristics for each RCM simulation and area-average observations (grey boxplots in the right part of each panel). Each boxplot corresponds to values for all grid boxes (neighbourhoods) over the Czech Republic. Grey areas indicate the range between the minimum 25<sup>th</sup> and maximum 75<sup>th</sup> quantiles of  $r_{tm}$  for observed data from all neighbourhoods.



**Figure 4.** Area-average quantile ratios  $r_{t_p}$  for the event characteristics derived from RCM simulations. Bold black line shows average from all RCM simulations. Grey area corresponds to the 90 % envelope of the quantile ratios for the area-average observations, and broken line indicates the areal average.



**Figure 5.** (a) Histogram ratios  $rt_f$  between areal and station average of frequencies of corresponding bins of the histograms of rainfall event characteristics. Frequencies of bins are averaged per individual season and grid box for the RCM simulations (or neighbourhoods for area-average observations). Grey bars highlight ranges between the 12.5, 25, and 50 km area-average observations (black dots). (b) Histograms of the number of at-site events averaged per individual season and individual station. Units of characteristics defining bins of values are: mm ( $D$ ), h ( $T$ ),  $\text{mm h}^{-1}$  ( $R$ ,  $I_{60}$ ),  $\text{MJ ha}^{-1}$  ( $E$ ), and  $\text{MJ mm ha}^{-1} \text{h}^{-1}$  ( $EI_{60}$ ).



**Figure 6.** Dependence between rainfall event characteristics and altitude. Dependence is expressed by the change of characteristic per 100 m in elevation for the corresponding probability from the empirical distribution function of the event characteristics. Spatial resolution of the RCM simulations is indicated by colour (lines with points show RCM simulations average).





## Příloha C

### Projected changes of rainfall event characteristics for the Czech Republic

V. Svoboda, M. Hanel, P. Máca, J. Kyselý  
*Journal of Hydrology and Hydromechanics*  
May 2016, volume 64, no. 4, early view



# Projected changes of rainfall event characteristics for the Czech Republic

Vojtěch Svoboda<sup>1</sup>, Martin Hanel<sup>1, 2\*</sup>, Petr Máca<sup>1</sup>, Jan Kyselý<sup>1, 3</sup>

<sup>1</sup> Faculty of Environmental Sciences, Czech University of Life Sciences Prague, Kamýcká 129, 165 21 Prague 6–Suchbát, Czech Republic.

<sup>2</sup> Technical University of Liberec, Studentská 1402/2, 461 17 Liberec 1, Czech Republic.

<sup>3</sup> Institute of Atmospheric Physics, Czech Academy of Sciences, Boční II 1401, 141 31 Prague 4–Spořilov, Czech Republic.

\* Corresponding author. Tel.: +420 22438 3834. E-mail: hanel@fzp.czu.cz

**Abstract:** Projected changes of warm season (May–September) rainfall events in an ensemble of 30 regional climate model (RCM) simulations are assessed for the Czech Republic. Individual rainfall events are identified using the concept of minimum inter-event time and only heavy events are considered. The changes of rainfall event characteristics are evaluated between the control (1981–2000) and two scenario (2020–2049 and 2070–2099) periods. Despite a consistent decrease in the number of heavy rainfall events, there is a large uncertainty in projected changes in seasonal precipitation total due to heavy events. Most considered characteristics (rainfall event depth, mean rainfall rate, maximum 60-min rainfall intensity and indicators of rainfall event erosivity) are projected to increase and larger increases appear for more extreme values. Only rainfall event duration slightly decreases in the more distant scenario period according to the RCM simulations. As a consequence, the number of less extreme heavy rainfall events as well as the number of long events decreases in majority of the RCM simulations. Changes in most event characteristics (and especially in characteristics related to the rainfall intensity) depend on changes in radiative forcing and temperature for the future periods. Only changes in the number of events and seasonal total due to heavy events depend significantly on altitude.

**Keywords:** Rainfall event; Hourly rainfall; Regional climate model; Climate change.

## INTRODUCTION

Potential changes in characteristics of precipitation events such as event depth, duration or intensity due to climate change are of significant societal concern, especially after evidence of increasing daily extreme rainfall intensity has strengthened (Alexander et al., 2006; Trenberth, 2011; Westra et al., 2014). Central Europe has been affected by several major flood events in the recent decades (e.g. Kundzewicz et al., 2005; Kundzewicz, 2012). These floods resulted either from heavy multi-day rainfall events affecting large areas (e.g. Blöschl et al., 2013) or from localized extreme sub-daily events (e.g. Marchi et al., 2010). Especially short duration extreme events might intensify more in future climate due to dynamical feedbacks (Berg and Haerter, 2013; Lenderink and van Meijgaard, 2008; Millán, 2014).

A comprehensive overview of the assessment studies on trends in precipitation extremes and floods across Europe is given by Madsen et al. (2014). Over the Czech Republic, Kyselý (2009) evaluated seasonal trends in heavy precipitation on daily basis for 1961–2005. In winter, spatially coherent increases were reported mainly in the western part of the country. The trends were spatially less uniform in summer, but increasing tendency in heavy precipitation prevailed. Decreases were observed in spring, while the least spatially coherent and insignificant trends were found in autumn.

Only a limited number of studies analysed sub-daily rainfall extremes (e.g. Beck et al., 2015; Jakob et al., 2011; Lenderink et al., 2011). For the Czech Republic, Hanel et al. (2016) analysed trends in characteristics of sub-daily heavy precipitation (at various aggregation levels from 30-min to 1-day) considering 17 stations and 51 years (May–September periods for 1961–2011). Observed trends in indices of heavy precipitation (seasonal maxima; rain intensity index; fractions of precipitation due to very wet days) were significant and positive for many of the stations (an average increase of 2–9% per decade for all examined characteristics).

Recently, Rulfová and Kyselý (2014) analysed characteristics of convective and stratiform precipitation separately at 11 stations for 1982–2010. They found that spatially averaged trends in convective precipitation were positive for rainfall totals and the number of wet days in spring, summer and autumn, and tended to be more pronounced at lowland stations. The trends in extreme convective precipitation (maximum seasonal 6-hour and 1-day totals) were spatially more variable and often insignificant, but slight increase prevailed as well. The observed increase in total precipitation in spring and summer was mainly due to an increase in convective precipitation (Rulfová and Kyselý, 2014).

Events with high rainfall depths and durations of a few hours are most often associated with convective storms (Hand et al., 2004; Westra et al., 2014). Rulfová and Kyselý (2013) reported that the convective precipitation represents about 50% of the total precipitation in summer for the Czech Republic, and heavy rainfall events contribute significantly to precipitation in warm season.

Despite the relevance to urban hydrology or soil erosion assessment, only a few studies dealt with characteristics of individual rainfall events derived from observed rainfall data. Fiener et al. (2013), for instance, found significant trends in annual rainfall erosivity in a long record (1937–2007) of 5-min precipitation data for 10 stations in Germany. Hanel et al. (2016) assessed erosive rainfall events for the 1961–2011 period in the Czech Republic and found significant increasing trends in event rainfall rate and significant decreasing trends in event duration.

To obtain estimates of possible future changes in precipitation at a regional or local scale, regional climate models (RCMs) are widely used. Studies on precipitation extremes in ensembles of RCM simulations over the area of the Czech Republic (Hanel and Buishand, 2012; Kyselý and Beranová, 2009; Kyselý et al., 2011) reported increases in summer and winter 1-day precipitation extremes for the late 21<sup>st</sup> century (increases in the 50-year quantile ~ 16–26%). Comparable

future changes in daily summer precipitation extremes were indicated also for many other locations in Europe (e.g. Frei et al., 2006; Hanel and Buishand, 2011; Madsen et al., 2014).

While the simulated changes in precipitation extremes at daily and multi-day time scales are explored relatively well, only few studies considered changes at sub-daily time scales. For instance, based on RCM simulations and climate analogues, Arnbjerg-Nielsen (2012) estimated an increase in design sub-daily precipitation intensities in Denmark (up to 50% for hourly precipitation maxima and 100-year return period within the next 100 years). The projected increase in intensities tended to be larger with shorter durations and higher return periods. Hanel and Buishand (2010) analysed changes in hourly and daily summer precipitation extremes over the Netherlands using a statistical model. The estimated changes in annual daily maxima were relatively small ( $\approx 20\%$  for return periods larger than 5 years). A similar value was found also for hourly extremes, when the statistical model was constrained to allow for changes only in the first two moments of the distribution; however, an unconstrained model revealed  $\approx 45\text{--}60\%$  increase in 50 to 200-year precipitation maxima indicating large uncertainty in projected changes of high quantiles. Large increases in simulated heavy summer precipitation were also mentioned by Lenderink and van Meijgaard (2008) for the Netherlands and Kendon et al. (2014) for the UK, while Knote et al. (2010) and Pan et al. (2011) reported decreases for Germany and Western U.S., respectively.

The majority of available RCM simulations (having spatial resolution coarser than 10 km) relies on convection parameterization schemes, which are sources of significant uncertainties and errors (Brockhaus et al., 2008; Hohenegger et al., 2008; Kendon et al., 2012) especially for sub-daily precipitation (Westra et al., 2014). The deficiencies in simulating convective precipitation may significantly affect the estimated changes in rainfall extremes (Kendon et al., 2014).

The purpose of this paper is to analyse changes of heavy rainfall event characteristics between the control (1981–2010) and two scenario periods (2020–2049 and 2070–2099) as projected by an ensemble of RCM simulations with hourly data conducted within the ENSEMBLES (van der Linden and Mitchell, 2009) and EURO-CORDEX (Jacob et al., 2014) projects.

The paper is organized as follows. The study area and RCM data are described in following section. Section Methods provides definition of heavy rainfall events, considered event characteristics and approaches for the assessment of changes in RCM-simulated rainfall events. The changes in RCM-simulated

heavy rainfall events are given in the Results section. The paper is closed by Discussion and Summary.

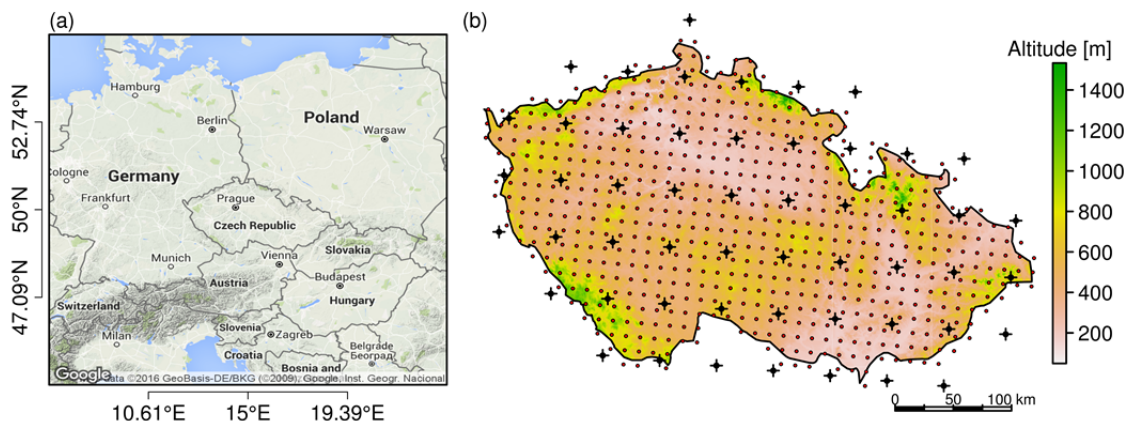
## STUDY AREA AND THE RCM SIMULATIONS

Projected changes in RCM-simulated rainfall event characteristics are analysed for the Czech Republic (78800 km<sup>2</sup>) located in Central Europe (Fig. 1a). Approximately two-thirds of the area are situated in altitudes below 500 m, while several mountain ranges on the borders exceed 1200 m in elevation (maximum is about 1600 m in the north; Fig. 1b). Average annual precipitation totals for the 1961–2000 period vary from about 420 mm in the central-western part of the country up to more than 1200 mm in the mountains. Mean annual precipitation for the Czech Republic is about 670 mm and the wettest months at most stations are June and July (Tolasz, 2007). Almost two-thirds of the annual precipitation falls in the summer half of the year. During the summer half-year (April–September) the rainfall events usually have shorter durations and larger intensities, while during the winter half-year (October–March) the rainfall events are mainly characterized by lower intensities and longer durations, and are connected to low pressure and frontal systems (Tolasz, 2007).

The examined ensemble of 30 RCM simulations is described in Table 1. Six RCMs are driven by 14 global climate models (GCMs) forced by scenarios SRES A1B (Nakicenovic and Swart, 2000), RCP2.6, RCP4.5 or RCP8.5 (van Vuuren et al., 2011). The RCMs outputs are available on a rotated latitude-longitude grid with a horizontal resolution ranging from 12.5 to 50 km. Only the CLM simulation is on a regular grid. From each RCM simulation only grid boxes covering the area of the Czech Republic (i.e. 52–607 grid boxes for different RCMs) were selected (see Fig. 1b).

The HIRHAM5, HadRM3 and RACMO2 simulations were conducted within the ENSEMBLES project (van der Linden and Mitchell, 2009), while the RCA4 and RACMO22E simulations within the EURO-CORDEX project (Jacob et al., 2014). Two of the HadRM3 simulations are driven by the GCM version with perturbed physics parameterization (Collins et al., 2006). HadRM3Q0 is an unperturbed model run, HadRM3Q3 is a version with low sensitivity to external forcing, and HadRM3Q16 includes perturbations resulting in high sensitivity to external forcing. The perturbations in the HadRM3 RCM correspond to those in the HadCM3 GCM.

Projected changes were analysed between the control period (1981–2000) and two scenario periods (2020–2049 and 2070–2099).



**Fig. 1.** (a) Location of the Czech Republic in Central Europe. (b) Centres of grid boxes covering the Czech Republic for RCM simulations with 50 km (black dots, 52 grid boxes) and 12.5 km spatial resolution (small red dots, 607 grid boxes).

**Table 1.** Overview of the RCM simulations.

RCM Acronym	Driven by GCM	Forcing	Horizontal resolution	Grid boxes
<b>CLM 2.4.11</b> (Böhm et al. 2006; Lautenschlager et al. 2009a, b) – Max Planck Institute for Meteorology (MPI), Germany				
CLM	ECHAM5/MPIOM	SRES A1B	22 km (0.2°)	301
<b>HadRM3.0</b> (Collins et al. 2011) – Met Office Hadley Centre (MOHC), UK				
HadRM3Q0_HadCM3	HadCM3Q0	SRES A1B	25 km (0.22°)	173
HadRM3Q3_HadCM3	HadCM3Q3			
HadRM3Q16_HadCM3	HadCM3Q16			
<b>HIRHAM5</b> (Christensen et al. 2007) – Danish Meteorological Institute (DMI)				
H5_ARPEGE	ARPEGE	SRES A1B	25 km (0.22°)	173
H5_BCM	BCM			
H5_ECHAM5	ECHAM5-r3			
<b>RACMO2.1</b> (van Meijgaard et al. 2008) – Royal Netherlands Meteorological Institute (KNMI)				
RACMO2_ECHAM5	ECHAM5-r3	SRES A1B	25 km (0.22°)	173
RACMO2_MIROC	MIROC3.2			
<b>RACMO22E</b> (van Meijgaard et al. 2012) – Royal Netherlands Meteorological Institute (KNMI)				
RACMO22E	ICHEC-EC-EARTH	RCP4.5, RCP8.5	12.5 km (0.11°)	607
<b>RCA4.0</b> (Kupiainen et al. 2011; Samuelsson et al. 2011) – Swedish Meteorological and Hydrological Institute (SMHI)				
RCA4_CanESM2	CCCma-CanESM2	RCP4.5, RCP8.5	50 km (0.44°)	52
RCA4_CM5A-MR	IPSL-CM5A-MR	RCP4.5, RCP8.5		
RCA4_CNRM-CM5	CNRM-CM5	RCP4.5, RCP8.5		
RCA4_EC-EARTH	ICHEC-EC-EARTH	RCP2.6, RCP4.5, RCP8.5		
RCA4_ESM2M	NOAA-GFDL-ESM2M	RCP4.5, RCP8.5		
RCA4_ESM-LR	MPI-ESM-LR	RCP4.5, RCP8.5		
RCA4_HadGEM2-ES	MOHC-HadGEM2-ES	RCP4.5, RCP8.5		
RCA4_MIROC5	MIROC5	RCP4.5, RCP8.5		
RCA4_NorESM1-M	NCC-NorESM1-M	RCP4.5, RCP8.5		

## METHODS

This section provides the definition of rainfall events and considered event characteristics. Methods for the analysis of changes in rainfall events are presented at the end of the section.

### Rainfall event definition

Rainfall events were defined using the minimum inter-event time (MIT) approach (e.g. Dunkerley, 2008). Six hour MIT was used for the derivation of rainfall events in all RCM simulations. This value is used most frequently for the identification of individual events in observed data (Dunkerley, 2008) and is typical also in rainfall erosion studies (e.g. Wischmeier and Smith, 1978). Please note, however, that the estimated optimal MIT for observed data over the Czech Republic is longer (Hanel and Máca, 2014). This holds true also for most of the RCM simulations for the Czech Republic in 1981–2000 (not shown).

In addition to 6-hour MIT a wet-hour threshold of 0.1 mm was considered in order to account for drizzling effect in the evaluation of RCM simulations (Kjellström et al., 2010). The same value was used also in previous studies (e.g. Kendon et al., 2014; Willems and Vrac, 2011). We further focused on 15% of rainfall events with the largest event depth during the warm season (May–September), which are referred to as heavy rainfall events in the rest of the paper. Note that for observed data this means that the threshold defining heavy rainfall events roughly corresponds to 12.7 mm, which is the minimum event

depth of a rainfall event to be considered erosive according to the Universal Soil Loss Equation methodology (Wischmeier and Smith, 1978).

### Rainfall event characteristics

We focused on projected future changes of the following rainfall event characteristics:

- rainfall event depth  $D$  [mm],
- rainfall event duration  $T$  [h],
- event mean rainfall rate  $RR$  [ $\text{mm}\cdot\text{h}^{-1}$ ]:

$$RR = \frac{D}{T} \quad (1)$$

- maximum 60-min rainfall intensity during an event  $I60$  [ $\text{mm}\cdot\text{h}^{-1}$ ].

In addition, the following indicators of erosive potential of a rainfall event were considered as well:

- event rainfall energy  $E$  [ $\text{MJ}\cdot\text{ha}^{-1}$ ]; Brown and Foster (1987):

$$E = \sum_{t=1}^T 0.29d_t[1 - 0.72\exp(-0.05d_t)] \quad (2)$$

where  $d_t$  is a rainfall volume during hour  $t$ .

- event rainfall erosivity index  $EI60$  [ $\text{MJ}\cdot\text{mm}\cdot\text{ha}^{-1}\cdot\text{h}^{-1}$ ]:

$$EI60 = E \cdot I60 \quad (3)$$

Finally, we analysed also projected changes in seasonal (May–September) characteristics:

- the number of heavy rainfall events per season  $Ne$  [–] and
- seasonal total due to heavy rainfall events  $TOT$  [mm].

### Assessment of projected changes of rainfall event characteristics

The changes of rainfall (event/seasonal) characteristics over two scenario periods: 2020–2049 (SCE1) and 2070–2099 (SCE2) with respect to the control period 1981–2000 were assessed in the RCM simulations for the Czech Republic as follows:

1) Rainfall events were determined for each grid box across the study area and all periods. Characteristics of rainfall events were calculated.

2) We evaluated changes in the RCM simulations between the scenario and control periods for:

- a) mean rainfall (event/seasonal) characteristics for each grid box over the study area (further denoted  $rts_m$ );
- b)  $p^{\text{th}}$  quantiles of the distribution of rainfall event characteristics for each grid box for cumulative probabilities  $p = 0.05, 0.1, \dots, 0.95$  (further referred to as quantile changes  $rts_p$ );
- c) areal average annual frequencies for corresponding bins of the histograms of rainfall event characteristics (further denoted as histogram changes  $rts_f$ ).

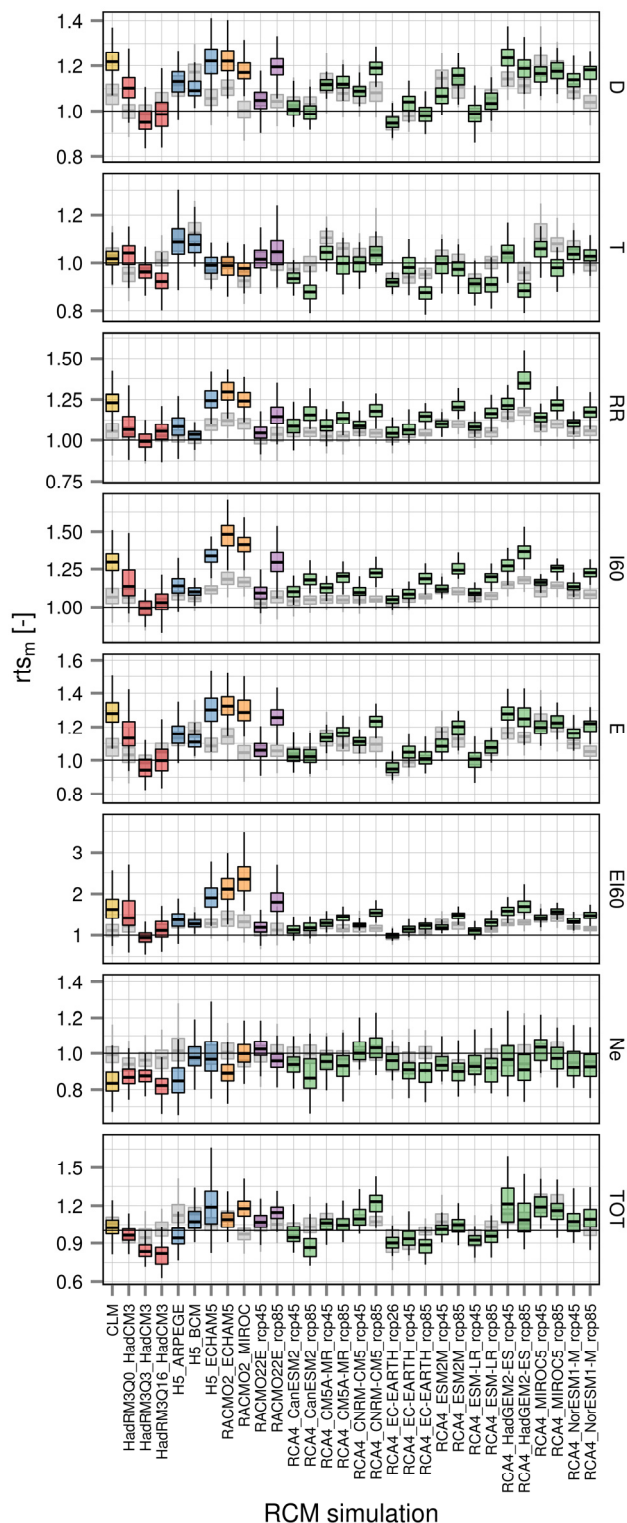
3) Because atmospheric temperature may influence the intensity of rainfall extremes (e.g. Utsumi et al., 2011; Westra et al., 2013), we analysed also relations of simulated rainfall event characteristics to changes in daily mean temperature ( $T2M$  [°C]) and radiative forcing ( $RFO$  [ $W \cdot m^{-2}$ ]). Radiative forcing as given by Houghton et al. (2001) for the SRES A1B emission scenario and Meinshausen et al. (2011) for the RCP scenarios was considered. Changes of radiative forcing and daily temperature for the scenario periods were calculated in the same way as  $rts_m$  for other (event/seasonal) characteristics. Then all  $rts_m$  were averaged over the study area (i.e. one  $rts_m$  value for each characteristic for an RCM simulation and a scenario period) and a linear regression model for the dependence of changes ( $rts_m$ ) in rainfall (event/seasonal) characteristics on changes in  $RFO$  ( $T2M$ ) was fitted considering the whole RCM ensemble.

### PROJECTED CHANGES OF RAINFALL EVENT CHARACTERISTICS

Results related to changes in RCM-simulated rainfall (event/seasonal) mean characteristics, quantiles and histograms are described in this section. Relations between radiative forcing, temperature and rainfall event characteristics are summarized in at the end of this section.

#### Changes of mean rainfall (event/seasonal) characteristics

Mean characteristics of RCM-simulated heavy rainfall events for the control period (1981–2000) averaged over the study area are shown in the left part of Table 2. Relative changes of mean characteristics ( $rts_m$ ) for the RCM-simulated rainfall events between the control and the scenario periods for all grid boxes across the study area are shown as boxplots in Fig. 2.



**Fig. 2.** Comparison of relative changes ( $rts_m$ ) in the RCM-simulated rainfall event characteristics for two scenario periods: 2020–2049 (SCE1, grey boxplots) and 2070–2099 (SCE2, coloured boxplots). Boxplots show relative changes in mean characteristics between the scenario periods and the control period for all grid boxes over the study area.

For the closer scenario period SCE1 the number of heavy events per season ( $Ne$ ) is approximately the same as for the control period for most RCM simulations.  $Ne$  is in general lower (by a maximum of two events per season) in the more distant scenario period SCE2. The changes in the seasonal total

**Table 2.** Mean heavy rainfall event characteristics (abbreviations are explained in section Methods) averaged over grid boxes in the Czech Republic in the control period (1981–2000) and their future changes in two scenario periods SCE1 (2020–2049) and SCE2 (2070–2099). Changes are evaluated as: insignificant changes below 5% (0); small changes between 5 and 10% (+); significant changes exceeding 10% (++); the largest significant changes exceeding 20% (+++); negative changes are denoted in the same way with sign (-).

Acronym	Control period										Changes in SCE1/SCE2 period										Group				
	Ne	TOT	D	T	RR	I60	E	E/60	Ne	TOT	D	T	RR	I60	E	E/60									
HadRM3Q3_HadCM3	10.51	209.0	19.5	21.6	1.04	3.01	2.01	8.56	0	/--	0	/--	0	/0	0	/0	0	/0	-	/0	(a)				
HadRM3Q16_HadCM3	10.31	231.7	21.6	23.2	1.11	3.48	2.27	11.8	0	/--	0	/--	0	/0	0	/0	0	/0	0	/0		++	/++		
RACM022E_rcp45	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96	0	/0	0	/+	+	/0	0	/0	0	/0	0	/+		++	/++		
RCA4_EC-EARTH_rcp26	11.11	249.7	21.7	26.4	0.95	2.44	2.11	5.86	0	/0	-	/-	-	/-	0	/+	0	/+	0	/+		-	/0	0	/0
RCA4_EC-EARTH_rcp45	11.11	249.7	21.7	26.4	0.95	2.44	2.11	5.86	-	/-	-	/-	-	/0	0	/0	-	/0	0	/+		0	/+	+	/++
RCA4_ESM1LR_rcp45	11.45	257.9	21.9	25.0	1.06	2.72	2.17	6.65	-	/-	0	/0	-	/0	0	/+	0	/+	0	/+		0	/+	0	/+
CLM	10.84	208.9	19.2	22.8	1.06	3.91	2.09	13.6	0	/-	-	/-	-	/0	+	/+++	0	/0	+	/+++		+	/+++	++	/+++
HadRM3Q0_HadCM3	11.33	278.3	23.9	23.2	1.28	4.20	2.62	16.9	-	/--	-	/0	-	/+	0	/+	0	/0	0	/+		+	/+	+	/+++
H5_ECHAM5	11.11	224.7	19.0	20.5	1.13	2.91	1.92	6.54	0	/0	+	/+++	+	/+++	+	/+++	++	/+++	++	/+++		++	/+++	++	/+++
RACM02_ECHAM5	9.42	191.0	20.2	26.6	0.91	2.81	2.02	7.69	0	/-	++	/+	++	/+++	0	/0	++	/+++	++	/+++		++	/+++	++	/+++
RACM02_MIROC	9.67	217.8	22.4	31.1	0.85	2.74	2.24	8.63	0	/0	0	/+	0	/+	-	/0	++	/+++	++	/+++	++	/+++	++	/+++	
RACM022E_rcp85	11.20	212.5	18.8	25.9	0.86	3.00	1.90	7.96	0	/0	+	/++	0	/++	0	/0	0	/++	0	/0	+	/++	+	/+++	
RCA4_CNRM5A-MIR_rcp85	11.14	219.4	19.2	22.7	1.02	2.53	1.89	5.46	0	/-	0	/0	+	/++	+	/++	0	/0	0	/++	+	/++	+	/+++	
RCA4_CNRM5A-MIR_rcp45	12.38	289.2	22.5	25.0	1.07	2.77	2.23	6.94	0	/0	+	/++	+	/+	0	/0	+	/+	0	/+	+	/+	+	/+++	
RCA4_CNRM5A-CM5_rcp45	12.38	289.2	22.5	25.0	1.07	2.77	2.23	6.94	0	/0	+	/++	+	/++	+	/++	+	/++	+	/++	+	/++	+	/+++	
RCA4_ESM2M_rcp45	12.08	275.6	22.2	26.1	0.99	2.53	2.17	6.25	0	/-	+	/0	++	/++	0	/0	++	/+++	++	/+++	++	/+++	++	/+++	
RCA4_ESM2M_rcp85	12.08	275.6	22.2	26.1	0.99	2.53	2.17	6.25	-	/-	0	/0	++	/++	0	/0	++	/+++	++	/+++	++	/+++	++	/+++	
RCA4_HadGEM2-ES_rcp45	9.93	173.3	16.8	21.6	0.93	2.35	1.62	4.35	0	/0	++	/+++	++	/+++	0	/0	++	/+++	++	/+++	++	/+++	++	/+++	
RCA4_HadGEM2-ES_rcp85	10.11	221.2	21.2	23.0	1.11	2.83	2.11	6.67	0	/0	++	/++	++	/++	+	/0	++	/+++	++	/+++	++	/+++	++	/+++	
RCA4_MIROC5_rcp45	11.76	233.8	19.2	21.9	1.03	2.57	1.89	5.41	0	/0	0	/+	+	/++	+	/0	0	/+	0	/+	+	/++	+	/+++	
RCA4_NoESM1-M_rcp45	11.76	233.8	19.2	21.9	1.03	2.57	1.89	5.41	0	/-	0	/+	0	/++	0	/0	+	/+	0	/+	+	/++	+	/+++	
RCA4_NoESM1-M_rcp85	7.61	132.7	16.9	17.4	1.19	2.83	1.70	5.67	0	/--	0	/0	+	/++	+	/+	0	/+	0	/+	+	/++	+	/+++	
H5_ARPEGE	7.61	132.7	16.9	17.4	1.19	2.83	1.70	5.67	0	/--	0	/0	+	/++	+	/+	0	/+	0	/+	+	/++	+	/+++	
H5_BCM	12.70	246.6	18.5	20.5	1.08	2.51	1.83	5.27	0	/0	++	/+	++	/++	+	/+	0	/0	+	/+	+	/++	+	/+++	
RCA4_CNRM5A-MIR_rcp45	11.14	219.4	19.2	22.7	1.02	2.53	1.89	5.46	0	/0	+	/+	++	/++	+	/++	0	/0	0	/+	+	/++	+	/+++	
RCA4_MIROC5_rcp45	10.11	221.2	21.2	23.0	1.11	2.83	2.11	6.67	0	/0	+++	/+++	++	/+++	++	/++	++	/+++	++	/+++	++	/+++	++	/+++	
RCA4_MIROC5_rcp85	10.65	221.5	20.0	23.9	1.01	2.63	1.97	6.01	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	
RCA4_CanESM2_rcp45	10.65	221.5	20.0	23.9	1.01	2.63	1.97	6.01	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	
RCA4_CanESM2_rcp85	10.65	221.5	20.0	23.9	1.01	2.63	1.97	6.01	0	/--	+	/--	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	
RCA4_EC-EARTH_rcp85	11.11	249.7	21.7	26.4	0.95	2.44	2.11	5.86	0	/--	0	/--	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	
RCA4_ESM1LR_rcp85	11.45	257.9	21.9	25.0	1.06	2.72	2.17	6.65	0	/-	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	0	/0	
RCA4_HadGEM2-ES_rcp85	9.93	173.3	16.8	21.6	0.93	2.35	1.62	4.35	0	/-	+	/++	++	/+++	++	/+++	++	/+++	++	/+++	++	/+++	++	/+++	

due to heavy events ( $TOT$ ) are much more variable across the RCM simulations. While the simulated changes in  $TOT$  are larger than  $\pm 10\%$  only for 6 RCM simulations in the SCE1 period, in the SCE2 period the changes vary from a 20% decrease to a 19% increase (corresponding to a change ranging from  $-40$  to  $+54$  mm).

Four groups can be identified according to changes in grid box average rainfall event depth ( $D$ ), duration ( $T$ ), maximum 60-min intensity ( $I60$ ) and event rainfall energy ( $E$ ) as follows:

- RCM simulations with only small changes (below 10%) in all characteristics and scenario periods;
- RCM simulations with increasing  $D$ ,  $I60$ ,  $E$  and only small change (below 10%) in  $T$ ;
- RCM simulations with increasing  $D$ ,  $I60$ ,  $E$  and prevailing increase also in event duration ( $T$ );
- RCM simulations with increasing  $I60$  combined with decreasing  $T$ . The changes in  $D$  and  $E$  are small for most of these RCM simulations, except for RCA4\_HadGEM2-ES\_rcp85 with a significant increase in  $D$  and  $E$ .

A complete overview of changes of the considered event characteristics in the RCM simulations is given in Table 2.

### Quantile changes

Projected quantile changes ( $rt_{sp}$ ) between the control and two scenario periods are shown in Fig. 3. The changes are in general small ( $<10\%$ ) for most of the RCM simulations and quantiles in the SCE1 period, while there is a slight increase for the SCE2 period for all event characteristics except the event duration ( $T$ ), which is getting shorter.

In general, the increase is larger for larger values of  $D$ ,  $RR$ ,  $I60$ ,  $E$  and  $EI60$ , while the event duration ( $T$ ) remains on average the same for long events and decreases for the shortest heavy rainfall events.


### Histogram changes

Histogram changes ( $rt_{sp}$ ) between the control and scenario periods are similar for both scenario periods. In the SCE2 period (Fig. 4) the changes are slightly higher only for some characteristics. In general the number of heavy rainfall events with low  $D$ ,  $RR$ ,  $I60$ ,  $E$ ,  $EI60$  and high  $T$  is projected to decrease in most of the RCM simulations. The number of events with lowest depths ( $D < 13$  mm) and energies ( $E < 1$  MJ·ha $^{-1}$ ) clearly decreases, with the projected number of events in SCE2 being over 5 times smaller than that for the control period in several RCM simulations. Notable is also an increase in the number of rainfall events with moderate  $RR$  (2–4 mm·h $^{-1}$ ) and  $I60$  (4–10 mm·h $^{-1}$ ).

### Dependence on radiative forcing and projected temperature changes

For all emission (SRES A1B) and concentration (RCP) scenarios considered in this paper the estimated radiative forcing ( $RFO$ ) increases in the scenario periods. The increases are generally larger in the more distant (SCE2) period (exception is only the RCP2.6 scenario). The largest increases in the radiative forcing are estimated for the A1B and RCP8.5 scenarios in the SCE2 period as shown in Fig. 5. All RCM simulations indicate also increasing temperature ( $T2M$ ) with larger increases in the SCE2 period (on average  $\approx 3.2$  °C).

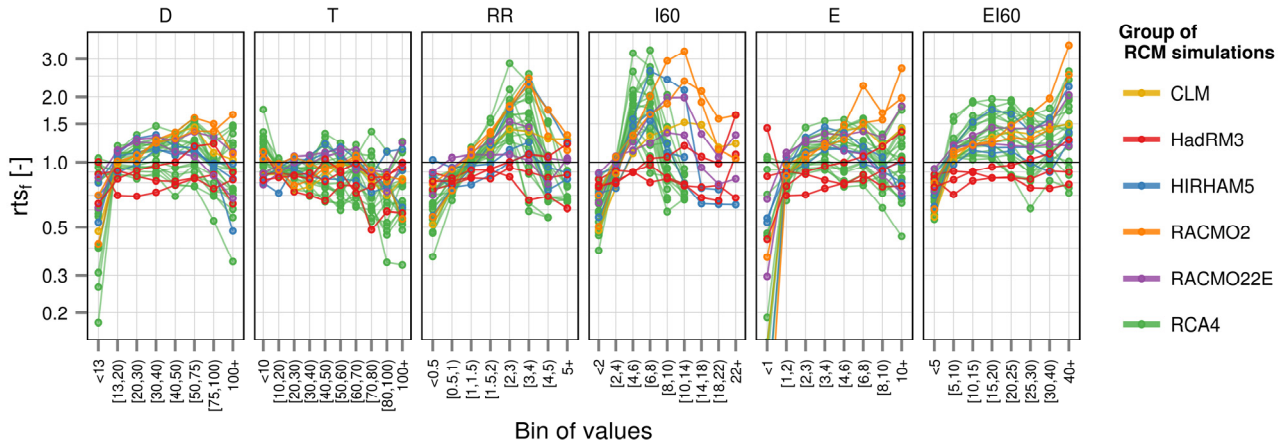
Most of the rainfall event characteristics in the ensemble of the RCM simulations depend on radiative forcing ( $RFO$ ) and temperature ( $T2M$ ) in a relatively similar way as demonstrated



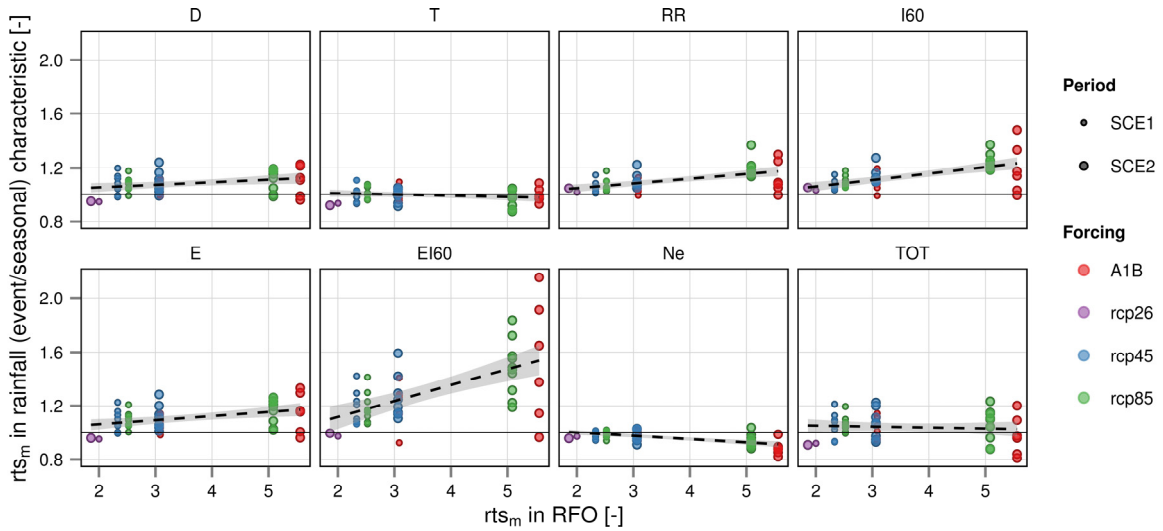
**Fig. 3.** Comparison of quantile changes ( $rt_{sp}$ ) in the RCM-simulated rainfall event characteristics for two scenario periods: 2020–2049 (SCE1) and 2070–2099 (SCE2). Thin lines represent the average from all grid boxes over the study area for each RCM simulation, bold black lines show ensemble average.

in Figs. 5 and 6. Slight differences occur for event depths ( $D$ ), which do not show any significant dependence on  $T2M$ , but slightly increase with  $RFO$  (statistically significant with  $p$ -value  $< 0.05$ ). On the other hand, event duration ( $T$ ) appears to be independent on  $RFO$ , but a decrease of  $T$  with increasing  $T2M$  is statistically significant ( $p$ -value  $< 0.01$ ). An increase in mean rainfall rate ( $RR$ ) and maximum 60-min rainfall intensity during

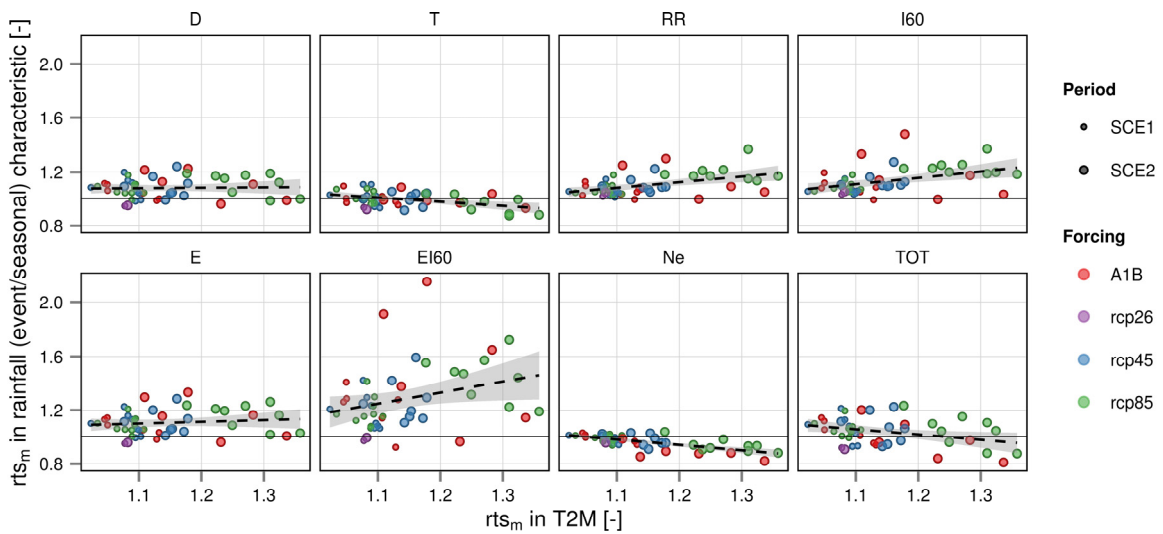




**Fig. 4.** Histogram changes ( $rts_f$ ) in the RCM-simulated rainfall event characteristics between the control period and scenario period SCE2 (2070–2099). Frequencies of bins in RCM simulations are averaged per one year and grid box over the study area.



**Fig. 5.** Dependence of changes ( $rts_m$ ) in rainfall (event/seasonal) characteristics on changes ( $rts_m$ ) in radiative forcing ( $RFO$ ). All  $rts_m$  are averaged over the study area. The linear regression models fitted to the data (dashed lines) with the 95% confidence intervals (grey strips) are shown.



**Fig. 6.** Dependence of changes ( $rts_m$ ) in rainfall (event/seasonal) characteristics on changes ( $rts_m$ ) in temperature ( $T2M$ ). All  $rts_m$  are averaged over the study area. The linear regression models fitted to the data (dashed lines) with the 95% confidence intervals (grey strips) are shown.

an event ( $I60$ ) as well as a decrease in the number of heavy rainfall events per season ( $Ne$ ) are significant with increasing  $RFO$  and  $T2M$  ( $p$ -value  $< 0.01$ ). Ensemble averaged  $RR$  and  $I60$  increase at a rate of 6.5% and 9.1% per 1 °C, respectively.

Characteristics of extreme rainfall events (with non-exceedance probability  $p = 0.95$ ) in general show the same dependence on  $RFO$  and  $T2M$  as mean characteristics. Only  $RFO$  influence is slightly stronger compared to mean characteristics (slope coefficient  $\beta$  is only slightly larger; not shown).

## DISCUSSION

Projected changes in characteristics of heavy rainfall events in an ensemble of 30 RCM simulations were assessed for two scenario periods (2020–2049 and 2070–2099) against the control period (1981–2000). The RCM-simulated heavy rainfall events were identified considering 6-hour minimum inter-event time (MIT), 0.1 mm wet-hour threshold and top 15% rainfall events with the largest event depth for each RCM simulation.

Relative changes of the characteristics for RCM-simulated rainfall events are larger for the more distant scenario period (SCE2: 2070–2099). The number of heavy rainfall events is in general lower in the scenario periods (by a maximum of two events per season, i.e. 19%). Changes in the seasonal total due to heavy events vary from –20% to +19%.

According to the changes in mean characteristics of rainfall events for the scenario periods we identified 4 groups of RCM simulations. Large part of the RCM simulations (15 out of 30) were identified as simulations with increasing rainfall event depths ( $D$ ), maximum 60-min rainfall intensities ( $I60$ ), event rainfall energies ( $E$ ) and with relatively unchanged rainfall event durations ( $T$ ) through control and scenario periods. Considerable part of these RCM simulations shows larger than 20% increases in  $I60$  and  $E$  and at least 10% increase in event depths ( $D$ ) in the SCE2 period. As a consequence mean rainfall rate ( $RR$ ) and rainfall erosivity index ( $EI60$ ) increase as well. Six RCM simulations have only small changes in the considered characteristics (below 10%) and the 9 remaining RCM simulations project varied changes in event durations ( $T$ ) combined with increases in  $I60$  (4 with increasing  $T$  and 5 with decreasing  $T$ ). For comparison, Jacob et al. (2014) found statistically significant increases in total precipitation in large parts of Central Europe for the late 21<sup>st</sup> century from an ensemble of RCM simulations evaluated at the daily time scale (from the EURO-CORDEX and ENSEMBLES projects). For the Czech Republic, an increase in heavy summer precipitation up to 25% was reported. This increase was in general more pronounced in RCM simulations forced by RCP8.5 compared to SRES A1B and RCP4.5 scenarios (Jacob et al., 2014). From our analysis (which differs by considering the sub-daily time scale and individual rainfall events), changes in event depths ( $D$ ) as well as seasonal totals due to heavy rainfall events are smaller and in general not significantly different between the simulations forced by RCP8.5 and RCP4.5. However, the simulation with the highest spatial resolution RACMO22E (12.5 km) shows clearly larger increases in  $D$  for RCP8.5 when compared to RCP4.5. The situation is different for mean rainfall rates ( $RR$ ) and maximum 60-min rainfall intensities ( $I60$ ), since all RCM simulations forced by RCP8.5 yield larger increases compared to the RCP4.5 forced simulations.

The RCM simulations show slightly larger increases for larger (more extreme) values of rainfall event characteristics except for event duration ( $T$ ). The increases are most significant for the largest rainfall rates ( $RR$ ) and event rainfall erosivity

indices ( $EI60$ ). Shortest event durations ( $T$ ) slightly decrease in the SCE2 period. Although  $T$  is rather unchanged in the RCM simulations on average (and especially in the SCE1 period: 2020–2049), our findings are in general consistent with trends in erosive rainfall events found by Hanel et al. (2016) for the recent decades (increasing trends in rainfall rate and decreasing trends in event duration). Many other studies for western, northern and central Europe show increases in extreme precipitation intensities at daily (Frei et al., 2006; Hanel and Buishand, 2012; Hlavčová et al., 2015; Kyselý and Beranová, 2009; Kyselý et al., 2011) and sub-daily time scales (Arnbjerg-Nielsen, 2012; Hanel and Buishand, 2010). Jacob et al. (2014) concluded that at the daily scale, RCM simulations reduce weak precipitation intensities and project increases in moderate and high intensities for 2071–2100. This is consistent with an increase in  $RR$  and  $I60$  and a decrease in the number of heavy rainfall events with low  $RR$  and  $I60$  reported in our study. The intensification of hourly rainfall was also reported by Kendon et al. (2014) for the UK considering a convection-permitting model. On the other hand, the assessment of simulations at convection-permitting resolutions for Germany (Knote et al., 2010) and Western U.S. (Pan et al., 2011) revealed decrease in annual and summer hourly precipitation extremes, respectively.

Larger radiative forcing ( $RFO$ ) and increasing temperature ( $T2M$ ) in scenario periods (Houghton et al., 2001; Moss et al., 2010) are linked to characteristics of heavy rainfall events in the RCM simulations. The number of heavy rainfall events slightly decreases with larger  $RFO$  and  $T2M$ . While the effect is in general small for event depth ( $D$ ; increase with larger radiative forcing) and duration ( $T$ ; decrease with higher temperature), characteristics related to rainfall intensity show large significant increases with  $RFO$  and higher  $T2M$ . The estimated change in rainfall rate ( $RR$ ), i.e. 6.5% per °C corresponds well with the expectation from the Clausius-Clapeyron relation ( $\approx 7\%$ , see e.g. Lenderink and van Meijgaard, 2008). Although the increase in  $I60$  estimated in our study (9.1% per °C) is almost the same as that mentioned by Hanel and Buishand (2010) and also lies within the range reported by Lenderink and van Meijgaard (2008) for RCM-simulated data, much larger increases per °C were already reported for climate model simulations as well as for observed data, especially for convective rainfall events (e.g. Berg et al., 2013; Westra et al., 2014; Molnar et al., 2015). Note that in contrast to standard studies on precipitation-temperature scaling, where a fraction of largest (hourly) precipitation intensities is considered, here we analyse maximum hourly intensities within events selected on the basis of total event depth. This may lead to a situation when also less extreme  $I60$  are considered, which can partly explain relatively small increase in  $I60$  with temperature. In addition, given the dependence of the increase in  $I60$  on the exceedance probability (see Fig. 3) the scaling rate would be larger for more extreme  $I60$  than for the average  $I60$ . Finally, the increase may also be at least partly limited by available water vapour content.

Kendon et al. (2014) have shown that the changes derived from models allowing for convection might be considerably different than those from coarser resolution RCMs. Several other studies have also demonstrated a better skill of convection-permitting models in reproducing sub-daily precipitation characteristics, including the diurnal cycle and extremes (which are both closely linked to convection). Therefore, the projected changes in precipitation at short temporal scales from current RCMs have to be interpreted with caution.

The reported changes are averaged over the studied area. However, considerable spatial variability of changes can be

observed for each RCM simulation and characteristics. This spatial variability may be partly explained by altitude for changes in the number of heavy rainfall events (the decrease in the number of events is in general larger at high altitudes) and seasonal total due to heavy events (the decrease is larger or the increase is smaller at high altitudes).

## SUMMARY

The paper presents a contribution towards the currently limited knowledge on possible future changes in sub-daily precipitation extremes that are of great importance also for hydrological modelling and other applications. We analysed a large ensemble of 21<sup>st</sup> century RCM projections with a focus on heavy rainfall event characteristics. The main findings can be summarized as follows:

- For most of the RCM simulations the event depths (*D*), maximum 60-min rainfall intensities (*I60*) and event rainfall energies (*E*) are projected to increase, while the event durations (*T*) remain in general constant. More than one-third of all RCM simulations show increases exceeding 20% in *I60* and *E* and at least 10% in *D*.
- The changes are in general larger for larger values of rainfall event characteristics.
- Changes of rainfall event characteristics can to some extent be related to the changes in mean temperature and radiative forcing. Only changes in the number of heavy rainfall events and seasonal total due to heavy events depend significantly on altitude.
- The changes of calculated gradients of event rainfall rates (*RR*) per °C are generally consistent with the value expected from the Clausius-Clapeyron relation, except *I60* for which they are slightly larger.

The size of the analysed ensemble together with the focus on a wide range of event characteristics make our study rather unique in the context of climate change studies of sub-daily precipitation characteristics. Due to deficiencies in the convection parameterizations used in the current RCMs, however, the projected changes have to be interpreted with caution.

*Acknowledgements.* The research was supported by the Czech Science Foundation (project number 14-18675S) and the Ministry of the Interior of the Czech Republic (project number VG20122015092). We thank E. Buonomo (MOHC), O. B. Christensen (DMI), E. van Meijgaard (KNMI) and G. Nikulin (SMHI) for providing the sub-daily RCM data. We acknowledge the ENSEMBLES project, funded by the European Commission's 6th Framework Programme through contract GOCE-CT-2003-505539, and the World Climate Research Programme's Working Group on Regional Climate, and the Working Group on Coupled Modelling, former coordinating body of CORDEX and responsible panel for CMIP5. We also thank the climate modelling groups and institutions (listed in Table 1 of this paper) for producing and making available their model outputs.

## REFERENCES

- Alexander, L.V., Zhang, X., Peterson, T.C., Caesar, J., Gleason, B., Klein Tank, A.M.G., Haylock, M., Collins, D., Trewin, B., Rahimzadeh, F., Tagipour, A., Rupa Kumar, K., Revadekar, J., Griffiths, G., Vincent, L., Stephenson, D.B., Burn, J., Aguilar, E., Brunet, M., Taylor, M., New, M., Zhai, P., Rusticucci, M., Vazquez-Aguirre, J.L., 2006. Global observed changes in daily climate extremes of temperature and precipitation. *J. Geophys. Res. Atmos.*, 111, D5, doi: 10.1029/2005JD006290
- Arnbjerg-Nielsen, K., 2012. Quantification of climate change effects on extreme precipitation used for high resolution hydrologic design. *Urban Water J.*, 9, 2, 57–65, doi: 10.1080/1573062X.2011.630091.
- Beck, F., Bárdossy, A., Seidel, J., Müller, T., Sanchis, E.F., Hauser, A., 2015. Statistical analysis of sub-daily precipitation extremes in Singapore. *J. Hydrol.: Regional Studies*, 3, 337–358, doi: 10.1016/j.ejrh.2015.02.001.
- Berg, P., Haerter, J. O., 2013. Unexpected increase in precipitation intensity with temperature – a result of mixing of precipitation types? *Atmos. Res.*, 119, 56–61, doi: 10.1016/j.atmosres.2011.05.012.
- Berg, P., Moseley, C., Haerter, J. O., 2013. Strong increase in convective precipitation in response to higher temperatures. *Nat. Geosci.*, 6, 181–185, doi: 10.1038/NCEO1731.
- Blöschl, G., Nester, T., Komma, J., Parajka, J., Perdigão, R.A.P., 2013. The June 2013 flood in the Upper Danube Basin, and comparisons with the 2002, 1954 and 1899 floods. *Hydrol. Earth Syst. Sc.*, 17, 12, 5197–5212, doi: 10.5194/hess-17-5197-2013.
- Böhm, U., Kücken, M., Ahrens, W., Block, A., Hauffe, D., Keuler, K., Rockel, B., Will, A., 2006. CLM – the climate version of LM: brief description and long-term applications. *COSMO Newsl.*, 6, 225–235.
- Brockhaus, P., Lüthi, D., Schär, C., 2008. Aspects of the diurnal cycle in a regional climate model. *Meteorol. Z.*, 17, 4, 433–443, doi: 10.1127/0941-2948/2008/0316.
- Brown, L.C., Foster, G.R., 1987. Storm erosivity using idealized intensity distributions. *Trans. ASAE – Am. Soc. Agric. Eng.*, 30, 2, 379–386.
- Christensen, O.B., Drews, M., Christensen, J.H., Dethloff, K., Ketelsen, K., Hebestadt, I., Rinke, A., 2007. The HIRHAM regional climate model version 5 (beta). Technical Report, No. 06-17, Danish Climate Centre, Danish Meteorological Institute, Copenhagen, 22 p.
- Collins, M., Booth, B., Harris, G., Murphy, J., Sexton, D., Webb, M., 2006. Towards quantifying uncertainty in transient climate change. *Clim. Dynam.*, 27, 2–3, 127–147, doi: 10.1007/s00382-006-0121-0.
- Collins, M., Booth, B., Bhaskaran, B., Harris, G., Murphy, J., Sexton, D., Webb, M., 2011. Climate model errors, feedbacks and forcings: a comparison of perturbed physics and multi-model ensembles. *Clim. Dynam.*, 36, 9–10, 1737–1766, doi: 10.1007/s00382-010-0808-0.
- Dunkerley, D., 2008. Identifying individual rain events from pluviograph records: a review with analysis of data from an Australian dryland site. *Hydrol. Process.*, 22, 26, 5024–5036, doi: 10.1002/hyp.7122.
- Fiener, P., Neuhaus, P., Botschek, J., 2013. Long-term trends in rainfall erosivity – analysis of high resolution precipitation time series (1937–2007) from Western Germany. *Agr. Forest Meteorol.*, 171–172, 115–123, doi: 10.1016/j.agrformet.2012.11.011.
- Frei, C., Schöll, R., Fukutome, S., Schmidli, J., Vidale, P.L., 2006. Future change of precipitation extremes in Europe: intercomparison of scenarios from regional climate models. *J. Geophys. Res.*, 111, D6, doi: 10.1029/2005JD005965.
- Hand, W.H., Fox, N.I., Collier, C.G., 2004. A study of twentieth-century extreme rainfall events in the United Kingdom with implications for forecasting. *Meteorol. Appl.*, 11, 15–31, doi: 10.1017/S1350482703001117.
- Hanel, M., Buishand, T.A., 2010. On the value of hourly pre-

- precipitation extremes in regional climate model simulations. *J. Hydrol.*, 393, 3–4, 265–273, doi: 10.1016/j.jhydrol.2010.08.024.
- Hanel, M., Buishand, T.A., 2011. Analysis of precipitation extremes in an ensemble of transient regional climate model simulations for the Rhine basin. *Clim. Dynam.*, 36, 5–6, 1135–1153, doi: 10.1007/s00382-010-0822-2.
- Hanel, M., Buishand, T.A., 2012. Multi-model analysis of RCM simulated 1-day to 30-day seasonal precipitation extremes in the Czech Republic. *J. Hydrol.*, 412–413, 141–150, doi: 10.1016/j.jhydrol.2011.02.007.
- Hanel, M., Máca, P., 2014. Spatial variability and interdependence of rain event characteristics in the Czech Republic. *Hydrol. Process.*, 28, 6, 2929–2944, doi: 10.1002/hyp.9845.
- Hanel, M., Pavlásková, A., Kyselý, J., 2016. Trends in characteristics of sub-daily heavy precipitation and rainfall erosivity in the Czech Republic. *Int. J. Climatol.*, 36, 4, 1833–1845, doi: 10.1002/joc.4463.
- Hlavčová, K., Lapin, M., Valent, P., Szolgay, J., Kohnová, S., Rončák, P., 2015. Estimation of the impact of climate change-induced extreme precipitation events on floods. *Contributions to Geophysics and Geodesy*, 45, 3, 173–192, doi: 10.1515/congeo-2015-0019.
- Hohenegger, C., Brockhaus, P., Schär, C., 2008. Towards climate simulations at cloud-resolving scales. *Meteorol. Z.*, 17, 4, 383–394, doi: 10.1127/0941-2948/2008/0303.
- Houghton, J.T., Ding, Y., Griggs, D.J., Noguer, M., van der Linden, P.J., Dai, X., Makell, K., Johnson, C.A. (Eds.), 2001. *Climate change 2001: the scientific basis. Contribution of working group I to the third assessment report of the intergovernmental panel on climate change.* Cambridge University Press, Cambridge, UK and New York, USA, 94 p.
- Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O. B., Bouwer, L.M., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsman, A., Martin, E., van Meijgaard, E., Moseley, C., Pfeifer, S., Preussmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.F., Teichmann, C., Valentini, R., Vautard, R., Weber, B., Yiou, P., 2014. EURO-CORDEX: new high-resolution climate change projections for European impact research. *Reg. Environ. Change*, 14, 2, 563–578, doi: 10.1007/s10113-013-0499-2.
- Jakob, D., Karoly, D.J., Seed, A., 2011. Non-stationarity in daily and sub-daily intense rainfall – part 1: Sydney, Australia. *Nat. Hazard. Earth Syst.*, 11, 8, 2263–2271, doi: 10.5194/nhess-11-2263-2011.
- Kendon, E.J., Roberts, N.M., Senior, C.A., Roberts, M.J., 2012. Realism of rainfall in a very high-resolution regional climate model. *J. Clim.*, 25, 17, 5791–5806, doi: 10.1175/JCLI-D-11-00562.1.
- Kendon, E.J., Roberts, N.M., Fowler, H.J., Roberts, M.J., Chan, S.C., Senior, C.A., 2014. Heavier summer downpours with climate change revealed by weather forecast resolution model. *Nat. Clim. Change*, 4, 7, 570–576, doi: 10.1038/nclimate2258.
- Kjellström, E., Boberg, F., Castro, M., Christensen, H.J., Nikulin, G., Sánchez, E., 2010. Daily and monthly temperature and precipitation statistics as performance indicators for regional climate models. *Clim. Res.*, 44, 2–3, 135–150, doi: 10.3354/cr00932.
- Knote, C., Heinemann, G., Rockel, B., 2010. Changes in weather extremes: assessment of return values using high resolution climate simulations at convection-resolving scale. *Meteorol. Z.*, 19, 1, 11–23, doi: 10.1127/0941-2948/2010/0424.
- Kundzewicz, Z.W. (Ed.), 2012. *Changes in Flood Risk in Europe.* IAHS Special Publication 10, CRC Press, Wallingford, UK, 544 p.
- Kundzewicz, Z.W., Ulbrich, U., Brücher, T., Graczyk, D., Krüger, A., Leckebusch, G.C., Menzel, L., Pińskwar, I., Radziejewski, M., Szwed, M., 2005. Summer floods in Central Europe – climate change track? *Nat. Hazards*, 36, 1–2, 165–189, doi: 10.1007/s11069-004-4547-6.
- Kupiainen, M., Samuelsson, P., Jones, C., Jansson, C., Willén, U., Hansson, U., Ullerstig, A., Wang, S., Döscher, R., 2011. Rossby Centre regional atmospheric model, RCA4. Rossby Centre Newsletter (June), SHMI, Norrköping, Sweden.
- Kyselý, J., 2009. Trends in heavy precipitation in the Czech Republic over 1961–2005. *Int. J. Climatol.*, 29, 12, 1745–1758, doi: 10.1002/joc.1784.
- Kyselý, J., Beranová, R., 2009. Climate-change effects on extreme precipitation in Central Europe: uncertainties of scenarios based on regional climate models. *Theor. Appl. Climatol.*, 95, 3–4, 361–374, doi: 10.1007/s00704-008-0014-8.
- Kyselý, J., Gaál, L., Beranová, R., Plavcová, E., 2011. Climate change scenarios of precipitation extremes in Central Europe from ENSEMBLES regional climate models. *Theor. Appl. Climatol.*, 104, 3–4, 529–542, doi: 10.1007/s00704-010-0362-z.
- Lautenschlager, M., Keuler, K., Wunram, C., Keup-Thiel, E., Schubert, M., Will, A., Rockel, B., Boehm, U., 2009a. Climate simulation with CLM, climate of the 20th century run no.2, data stream 3: European region MPI-M/MaD. World Data Center for Climate (WDCC), Max Planck Institute for Meteorology, Hamburg, Germany, doi: 10.1594/WDCC/CLM\_C20\_2\_D3.
- Lautenschlager, M., Keuler, K., Wunram, C., Keup-Thiel, E., Schubert, M., Will, A., Rockel, B., Boehm, U., 2009b. Climate simulation with CLM, scenario A1B run no.2, data stream 3: European region MPI-M/MaD. World Data Center for Climate (WDCC), Max Planck Institute for Meteorology, Hamburg, Germany, doi: 10.1594/WDCC/CLM\_A1B\_2\_D3.
- Lenderink, G., van Meijgaard, E., 2008. Increase in hourly precipitation extremes beyond expectations from temperature changes. *Nat. Geosci.*, 1, 8, 511–514, doi: 10.1038/ngeo262, 10.1038/ngeo262.
- Lenderink, G., Mok, H.Y., Lee, T.C., van Oldenborgh, G.J., 2011. Scaling and trends of hourly precipitation extremes in two different climate zones – Hong Kong and the Netherlands. *Hydrol. Earth Syst. Sci.*, 15, 9, 3033–3041, doi: 10.5194/hess-15-3033-2011.
- Madsen, H., Lawrence, D., Lang, M., Martinková, M., Kjeldsen, T., 2014. Review of trend analysis and climate change projections of extreme precipitation and floods in Europe. *J. Hydrol.*, 519, D, 3634–3650, doi: 10.1016/j.jhydrol.2014.11.003.
- Marchi, L., Borga, M., Preciso, E., Gaume, E., 2010. Characterisation of selected extreme flash floods in Europe and implications for flood risk management. Flash floods: observations and analysis of hydrometeorological controls, *J. Hydrol.*, 394, 1–2, 118–133, doi: 10.1016/j.jhydrol.2010.07.017.
- Meinshausen, M., Smith S.J., Calvin, K., Daniel, J.S., Kainuma, M.L., Lamarque, J.F., Matsumoto, K., Montzka, S.A., Raper, S.C., Riahi, K., Thomson, A., Velders, G.J., van

- Vuuren, D.P., 2011. The RCP greenhouse gas concentrations and their extensions from 1765 to 2300. *Clim. Change*, 109, 1–2, 213–241, doi: 10.1007/s10584-011-0156-z.
- Millán, M.M., 2014. Extreme hydrometeorological events and climate change predictions in Europe. *J. Hydrol.*, 518, Part B, 206–224, doi: 10.1016/j.jhydrol.2013.12.041.
- Molnar, P., Fatichi, S., Gaál, L., Szolgay, J., Burlando, P., 2015. Storm type effects on super Clausius–Clapeyron scaling of intense rainstorm properties with air temperature. *Hydrol. Earth Syst. Sci.*, 19, 1753–1766, doi: 10.5194/hess-19-1753-2015.
- Moss, R.H., Edmonds, J.A., Hibbard, K.A., Manning, M.R., Rose, S.K., van Vuuren, D.P., Carter, T.R., Emori, S., Kainuma, M., Kram, T., Meehl, G.A., Mitchell, J.F.B., Nakicenovic, N., Riahi, K., Smith, S.J., Stouffer, R.J., Thomson, A.M., Weyant, J.P., Wilbanks, T.J., 2010. The next generation of scenarios for climate change research and assessment. *Nature*, 463, 7282, 747–756, doi: 10.1038/nature08823.
- Nakicenovic, N., Swart, R. (Eds.), 2000. Special report on emissions scenarios: a special report of working group III of the Intergovernmental panel on climate change. Cambridge University Press, Cambridge, UK, 612 p.
- Pan, L.L., Chen, S.H., Cayan, D., Lin, M.Y., Hart, Q., Zhang, M.H., Liu, Y., Wang, J., 2011. Influences of climate change on California and Nevada regions revealed by a high-resolution dynamical downscaling study, *Clim. Dyn.*, 37, 9, 2005–2020, doi: 10.1007/s00382-010-0961-5.
- Rulfová, Z., Kyselý, J., 2013. Disaggregating convective and stratiform precipitation from station weather data. *Atmos. Res.*, 134, 100–115, doi: 10.1016/j.atmosres.2013.07.015.
- Rulfová, Z., Kyselý, J., 2014. Trends of convective and stratiform precipitation in the Czech Republic, 1982–2010. *Adv. Meteorol.*, Vol. 2014, doi: 10.1155/2014/647938.
- Samuelsson, P., Jones, C.G., Willén, U., Ullerstig, A., Gollvik, S., Hansson, U., Jansson, C., Kjellström, E., Nikulin, G., Wyser, K., 2011. The Rossby Centre regional climate model RCA3: model description and performance. *Tellus A*, 63, 1, 4–23, doi: 10.1111/j.1600-0870.2010.00478.x.
- Tolasz, R. (Ed.), 2007. Atlas podnebí Česka. [Climate atlas of Czechia]. 1st edn. Český hydrometeorologický ústav, Prague, Czech Republic, 255 p. (In Czech.)
- Trenberth, K.E., 2011. Changes in precipitation with climate change. *Clim. Res.*, 47, 1–2, 123–138, doi: 10.3354/cr00953.
- Utsumi, N., Seto, S., Kanae, S., Maeda, E.E., Oki, T., 2011. Does higher surface temperature intensify extreme precipitation? *Geophys. Res. Lett.*, 38, 16, doi: 10.1029/2011GL048426.
- van der Linden, P., Mitchell, J.F.B. (Eds.), 2009. ENSEMBLES: climate change and its impacts: summary of research and results from the ENSEMBLES project. Met. Office Hadley Centre, Exeter, UK, 160 p.
- van Meijgaard, E., van Ulft, L.H., van de Berg, W.J., Bosveld, F.C., van den Hurk, B., Lenderink, G., Siebesma, A.P., 2008. The KNMI regional atmospheric climate model RACMO version 2.1. Technical Report, TR 302, KNMI, De Bilt, Netherlands.
- van Meijgaard, E., van Ulft, L., Lenderink, G., de Roode, S., Wipfler, E., Boers, R., Timmermans, R., 2012. Refinement and Application of a Regional Atmospheric Model for Climate Scenario Calculations of Western Europe. KvR 054/12, Programme Office Climate changes Spatial Planning, KNMI, De Bilt, Netherlands, 47 p.
- van Vuuren, D., Edmonds, J., Kainuma, M., Riahi, K., Thomson, A., Hibbard, K., Hurtt, G., Kram, T., Krey, V., Lamarque, J.F., Masui, T., Meinshausen, M., Nakicenovic, N., Smith, S., Rose, S., 2011. The representative concentration pathways: an overview. *Clim. Change*, 109, 1–2, 5–31, doi: 10.1007/s10584-011-0148-z.
- Willems, P., Vrac, M., 2011. Statistical precipitation downscaling for small-scale hydrological impact investigations of climate change. *J. Hydrol.*, 402, 193–205, doi: 10.1016/j.jhydrol.2011.02.030.
- Wischmeier, W.H., Smith, D.D., 1978. Predicting rainfall erosion losses: a guide to conservation planning. *Agric. Handb.*, 537, Science and Education Administration, U.S. Department of Agriculture, Washington, D.C.
- Westra, S., Alexander, L.V., Zwiers, F.W., 2013. Global increasing trends in annual maximum daily precipitation. *J. Clim.*, 26, 11, 3904–3918, doi: 10.1175/JCLI-D-12-00502.1.
- Westra, S., Fowler, H.J., Evans, J.P., Alexander, L.V., Berg, P., Johnson, F., Kendon, E.J., Lenderink, G., Roberts, N.M., 2014. Future changes to the intensity and frequency of short-duration extreme rainfall. *Rev. Geophys.*, 52, 3, 522–555, doi: 10.1002/2014RG000464.

Received 21 December 2015

Accepted 25 May 2016