

Université du Québec
Institut national de la recherche scientifique
Centre Eau Terre Environnement

**POST-TRAITEMENT STOCHASTIQUE DES PRÉCIPITATIONS
JOURNALIÈRES ISSUES DE RÉANALYSES: APPLICATION À LA
RÉANALYSE CFSR AU CANADA**

Par

Dikra Khedhaouiria

Thèse présentée pour l'obtention du grade de
PhilosophiæDoctor, Ph.D.
en sciences de l'eau

Jury d'évaluation

Examinateur externe

Mélissa Gervais
Pennsylvania State University

Examinateur externe

Martin Leduc
Ouranos

Examinateur interne

Erwan Gloaguen
INRS, Centre Eau Terre Environnement

Co-directrice de recherche

Anne-Catherine Favre
Institut national polytechnique de Grenoble
(GINP)/Ecole nationale supérieure Énergie,
Eau et Environnement (ENSE3)

Directeur de recherche

Alain Mailhot
INRS, Centre Eau Terre Environnement

REMERCIEMENTS

Cette thèse a été un long chemin que j'ai partagé avec des gens formidables.

Tout d'abord, Alain, mon directeur de recherche, tu as été LA personne qui m'a accompagné des balbutiements jusqu'à l'ultime fin. Je te remercie pour tout, tu auras été un professeur sur qui l'on peut compter tant sur le plan scientifique qu'humain. À tes côtés, j'ai appris à travailler, à être indépendante et critique vis-à-vis des travaux que je menais. Tu pousses toujours tes étudiants à faire mieux alors je te remercie pour cette rigueur indispensable à la recherche et que tu as réussi à me transmettre. Merci pour ta disponibilité, ta bienveillance et ta capacité d'écoute, avec toi on peut parler dans un climat de confiance! Tu auras définitivement été plus qu'un professeur pour moi!

Je remercie également ma super codirectrice Anne-Catherine. On aurait pu croire qu'avec un océan entre nous et un décalage horaire de 6h, il aurait été difficile de communiquer. Que nenni, tu t'es toujours arrangée pour te rendre disponible, alors merci. Merci aussi pour les échanges scientifiques et ta bonne humeur contagieuse, tu tires les gens vers le haut et c'est toujours apprécié.

Merci à toutes les personnes de l'équipe, les permanents comme toi Guillaume pour ton aide indéfectible à fournir les données et sans lesquelles il aurait été difficile de réaliser ce projet, mais aussi toi Samuel, nous avons moins travaillé ensemble, mais c'est toujours agréable d'échanger avec toi. Les personnes de "passage" ont aussi apporté leur pierre à l'édifice. Je pense à toi, Géremy notre post-doctorant préféré, tu n'es resté qu'un an avec nous, mais tu as été un modèle. Avec toi, aucune question n'est bête et tu sais toujours expliquer les choses avec beaucoup de pédagogie! Alors merci à toi! Je remercie également une petite bestiole, une petite Italienne, une petite statisticienne, une petite colocataire de bureau (le qualificatif petite est ici utilisé à des fins affectueuses, car on fait presque la même taille), et surtout une amie, la seule et l'unique Silvia. Tu as influencé cette thèse à travers les discussions scientifiques que l'on a eues, mais aussi la personne que je suis devenue lors de ces cinq dernières années. Merci d'être toi, tu es sans doute l'une des personnes les plus généreuses qu'il m'ait été donné de rencontrer. Même sous tes airs de personne désorganisée, je sais que je peux compter sur toi. Et c'est ça qui compte au final, non?

Merci à mes amis rencontrés à l'INRS, vous avez fait en sorte que cette thèse se passe de façon tellement plus agréable. Yohann, premier contact avec le monde des doctorants, avec toi tout se passe bien et sans stress, ton côté tahitien sans doute. Merci d'avoir été là. Merci à toi Lau, on se côtoie toujours, tu es une des personnes avec qui l'on peut parler de vraiment tous les sujets et cela fait

toujours du bien d'avoir ce genre d'oreille dans notre entourage. Merci à Pierre, l'optimiste de la gang, le seul a encore apprécier la neige au mois de mai Géraldine, on s'est rencontré vers la fin de la thèse, le sport nous a beaucoup rapprochés et continue toujours de le faire. Tu es une personne généreuse, positive, motivée et motivante merci à toi! Otta, Ottina, notre princesse Carlotta, merci! Que dire de toi, tu es belle au sens français et italien! Nos pauses café auront marqué mon doctorat! Merci à Etienne, Véronique, Cheick et tous les autres amis que je ne cite pas, mais que je n'oublie pas, vous avez tous été importants durant ce voyage.

Un merci spécial à mes anciennes colocataires et amies françaises, Marie et Chloé, vous avez été là de façon ponctuelle durant cette thèse, pas facile avec cette distance, mais vous occupez et occuperez toujours une place spéciale dans mon coeur. Que dire des amis rencontrés à la course à pieds, vous m'avez aidé durant cette thèse à me dépasser physiquement pour mieux me dépasser dans ma thèse, et surtout à décompresser. Alors merci Martin, coach de feu, merci à Wonder (tu te reconnaîtras), merci à notre philosophe runner, vous êtes tout simplement inspirants! Enfin, mes super amies rencontrées grâce aux sorties canines hebdomadaires, Gwen et Alice. Merci Gwen pour ton optimisme à toute épreuve, pour tes blagues pas toujours drôles, mais qui finissent par l'être. Que dire de toi Alice, une personne passionnée par la vie, on oublie la chance qu'on a des fois et tu es là pour nous le rappeler. Merci !! Vous êtes toutes les deux rafraîchissantes.

Merci à ma famille, la distance n'est pas facile, mais vous êtes toujours présents, et en particulier, un gros merci à toi Cha pour tout simplement exister.

Mes derniers remerciements vont à toi François, ma personne à moi! Merci d'être toujours là, peu importe les circonstances avec une attitude on ne peut plus positive! Tu fais de moi une meilleure personne.

RÉSUMÉ

Il est communément admis que la disponibilité de séries journalières de précipitations observées est indispensable pour plusieurs applications. Au Canada, comme pour beaucoup d'autres pays, la densité des stations de mesure est faible et les historiques sont courts. Le développement des modèles numériques de temps performants au cours de ces dernières décennies offre la possibilité de se tourner vers de nouveaux jeux de données. Les réanalyses, en particulier, présentent l'avantage d'assimiler tout au long d'une période donnée divers types d'observations, offrant ainsi un contrôle continu de la dynamique de l'atmosphère et donc une bonne représentation de la météorologie. Ces dernières, disponibles sur des grilles couvrant l'ensemble du globe avec une résolution spatio-temporelle donnée, peuvent présenter des erreurs de diverses natures (p.ex., biais, erreur de représentativité). Il est alors difficile d'utiliser directement ces données comme *proxy* pour des applications nécessitant des données locales. Dans ce contexte, le présent projet s'intéresse à post-traiter les données de précipitations journalières issues d'une réanalyse nommée *Climate Forecast System Reanalysis* (CFSR), afin de proposer des séries non biaisées, ayant des caractéristiques locales (par opposition au point de grille) et ce notamment aux endroits dépourvus d'observations.

Le projet s'articule autour de trois axes principaux: i) analyser un modèle probabiliste basé sur des approches de régression afin de post-traiter les précipitations journalières de la réanalyse CFSR en se basant sur des stations d'observation; ii) intégrer la structure spatio-temporelle du processus de précipitations dans ces mêmes modèles pour améliorer l'estimation des séries post-traitées; iii) et proposer des champs journaliers de précipitations en combinant les modèles du second axe à des modèles spatiaux.

Le post-traitement développé donne des résultats très encourageants quant à la correction systématique du biais des sorties de réanalyses, mais aussi concernant la représentation de plusieurs caractéristiques locales des précipitations. Cette étude ouvre, par ailleurs, des perspectives très intéressantes à la fois méthodologique (p.ex: implémentation pour les précipitations extrêmes), mais aussi en termes de champs d'utilisation avec l'application de ces approches aux scénarios de modèles climatiques pour l'analyse de l'évolution des précipitations locales sous un climat changeant.

Mots-clés Réanalyses ; descente d'échelle statistique ; modèle spatio-temporel ; modèle régional ; simulation aléatoire des précipitations.

ABSTRACT

It is widely recognized that the availability of observed daily precipitation series is essential for several applications. The most important challenge that many countries face, including Canada, is to characterize historical precipitation considering the low station density in many of their regions and the short sample size. Reanalysis, generated by Numerical Weather Prediction methods assimilating past observations, is an attractive alternative as they provide coherent, spatially and temporally continuous meteorological fields for a specific period and domain. However, reanalysis, available on grids covering the whole globe, present errors of various natures (e.g., bias, representativeness error) that prevent from their direct use as a proxy for applications that require local data. In this context, the present project is interested in post-processing the daily precipitation data from one reanalysis, Climate Forecast System Reanalysis (CFSR), in order to propose unbiased series, with local characteristics (as opposed to grid points), even at places without observations.

The project conducted here was organized around three major axes: i) to analyze a probabilistic model based on regression approaches in order to post-treat the daily CFSR precipitation at sites with observations; ii) to consider the spatio-temporal structure of the precipitation process into these same models to improve the estimation of post-processed series at the daily scale; and (iii) to propose daily precipitation fields by combining the second-axis models with spatial models so that to propose post-treated daily series at each grid point of the domain.

The developed stochastically based post-treatment bring very encouraging results by systematically correcting CFSR biases but also by providing good representation of several local characteristics of the precipitation process. This study also opens very interesting perspectives, as regards the improvement of the methodology (e.g., explicit implementation of the extreme precipitation) but also concerning the enlargement of the application fields. For example, the current approach could be applied to climate model scenarios to provide analysis of the evolution of local precipitation in a changing climate.

Keywords Reanalyses; statistical downscaling; spatio-temporal model; regional model; random simulation of precipitation

TABLE DES MATIÈRES

Remerciements	iii
Résumé	v
Abstract	vii
Table des matières	ix
Liste des figures	xi
Liste des tableaux	xiii
Liste des abréviations	xvii
1 Introduction et Objectifs de la thèse	1
1 Introduction	1
2 Problématiques	3
3 Objectifs de la thèse	5
4 Plan de la thèse	7
2 Revue de la littérature	9
1 Introduction	9
2 Descente d'échelle dynamique: les modèles régionaux	11
3 Descente d'échelle statistique	13
4 Modélisation des précipitations	16
3 Données et méthode	19
1 Territoire à l'étude et régions climatiques	19
2 Les précipitations journalières: données disponibles	21
3 Cadre méthodologique de l'approche de post-traitement	28
4 Post-traitement stochastique des précipitations journalières de CFSR au Canada	47
1 Introduction	47

2	Article: Stochastic post-processing of CFSR daily precipitation across Canada	49
5	Modélisation des champs de précipitations journalières en utilisant CFSR	81
1	Introduction	81
2	Article: Daily precipitation fields modeling across the Great Lakes region (Canada) by using the CFSR reanalysis	83
6	Précipitations journalières aux sites non instrumentés	117
1	Introduction	117
2	Article: Regional modeling of daily precipitation fields across the Great Lakes region (Canada) using the CFSR reanalysis	119
7	Conclusions et perspectives	155
1	Principaux résultats	158
2	Perspectives	159
A	Estimation des coefficients des GLM et VGLM par maximum de vraisemblance	181
1	Occurrence	181
2	Intensité	183
B	Supplementary Material	185
1	Article 1	186
2	Article 2	190
3	Article 3	194

LISTE DES FIGURES

2.1	Grille du MRC (rouge) encastrée dans la grille du MCG (noir). Les mailles du MRC sont seize fois plus petites que celle du MCG.	11
3.1	Domaine d'étude limité par la ligne en pointillé et les dix régions climatiques de Plummer <i>et al.</i> (2006)	20
3.2	Stations de mesure des précipitations journalières. Les points rouges correspondent aux stations de l'APC2.	22
3.3	Stations valides et homogènes réparties selon les dix régions de (Plummer <i>et al.</i> , 2006) .	26
3.4	Carte des tuiles où les séries des précipitations annuelles sont homogènes (en gris) et non homogènes (en bleu) selon l'approche de Wijngaard <i>et al.</i> (2003)	27
3.5	Schématisation des différentes étapes du post-traitement stochastique pour l'article 1 et 2. Les abréviations A1 et A2 associées à certaines étapes font référence à la méthodologie spécifique à l'article 1 et 2 respectivement. Les étapes qui en sont dépourvues signifient qu'elles sont communes aux articles 1 et 2.	40
3.6	Schématisation de l'estimation de la distribution mixte journalière aux sites s^* sans observation selon le krigage (Méthode 1) et avec les modèles VGAM régionaux (Méthode 2). Les étapes pour l'estimation des champs météo-gaussiens latents et la génération aléatoire des précipitations sont les mêmes que celle de la Figure 3.5 (Étapes 3.A2 et 4.A2, respectivement)	46

LISTE DES TABLEAUX

2.1 Principaux modèles de régression utilisés dans les SDMs de type <i>Perfect-Prognosis</i>	14
3.1 Caractéristiques physiographiques et climatiques des régions de Plummer <i>et al.</i> (2006)	21
3.2 Impact du traitement de qualité sur le nombre de stations de l'ensemble du domaine et à pour chaque région.	24
4.1 Indices climatiques de précipitations de la liste de l'ETCCDI calculés aux échelles annuelles et saisonnières (adapté de Zhang <i>et al.</i> (2011))	51

LISTE DES ABRÉVIATIONS

ADKS	(Tests de) Anderson-Darling et de Kolomogorov-Smirnov test
AIC	<i>Akaike Information Criterion</i>
APC2	<i>second generation Adjusted Precipitation for Canada</i>
BIC	<i>Bayesian Information Criterion</i>
B(S)S	<i>Brier (Skill) Score</i>
CASE	<i>Comprehensive And Systematic Evaluation</i>
CFSR	<i>Climate Forecast System Reanalysis</i>
CPC	<i>Climate Prediction Center</i>
CRP(S)S	<i>Continous Ranked Probability (Skill) Score</i>
ECC	Environnement et Changement climatique Canada
EGPD (Loi)	<i>Extended Generalized Pareto Distribution</i>
ETCCDI	<i>Expert Team on Climate Change Detection and Indices</i>
GAM	<i>Generalized Additive Model</i>
GEV	<i>Generalized Extreme Value</i>
GLM	<i>Generalized Linear Model</i>
i.i.d.	(variables) indépendantes et identiquement distribuées
KG	<i>Kriging (approaches)</i>
MCG	Modèle Climatique Global
MLE	<i>Maximum Likelihood Estimation</i>
MOS	<i>Model Output Statistics</i>
MRC	Modèle Regional du Climat
NCEP	<i>National Centers for Environmental Prediction</i>
PP	<i>Perfect Prognosis</i>
RMSE	<i>Root Mean Squared Error</i>
SDM	<i>Statistical Downscaling Model</i>
SMOS	<i>Stochastic Model Output Statistics</i>
TIC	Takeuchi Information Criterion
VGAM	<i>Vector Generalized Additive Model</i>
VGLM	<i>Vector Generalized Linear Model</i>
WG	<i>Weather Generator</i>
WT	<i>Weather-Type</i>

INTRODUCTION ET OBJECTIFS DE LA THÈSE

Sommaire

1	Introduction	1
2	Problématiques	3
3	Objectifs de la thèse	5
4	Plan de la thèse	7

1 Introduction

L'étude des précipitations revêt un intérêt majeur à la fois pour des raisons socio-économiques et environnementales. Les séries temporelles de précipitations observées permettent, par exemple, de concevoir des infrastructures urbaines, des ouvrages hydrauliques de protection de crues, mais sont également nécessaires à la prévision hydrologique pour la production d'hydroélectricité (Devine & Mekis, 2008). D'autres champs d'applications comme la dynamique de transport des pesticides (Nolan *et al.*, 2008), la vulnérabilité à la désertification (Bathurst & Bovolo, 2004) ou encore la gestion des ressources en eau (Fowler *et al.*, 2005) constituent aussi des disciplines pour lesquelles la connaissance des précipitations s'avère cruciale. Les précipitations sont, par ailleurs, une donnée source car elles permettent de dériver, par le biais de modélisation physique par exemple, d'autres variables qui, elles, sont beaucoup plus difficiles à mesurer (p. ex., le ruissellement, les débits hydrauliques en cours d'eau). Toutes ces applications demeurent toutefois dépendantes de la disponibilité des informations fournies au droit des stations de mesure. La densité des réseaux et la couverture temporelle assurée par ces stations constituent alors la pierre angulaire pour obtenir une information de base de qualité pour ces applications.

Au Canada, les premières mesures remontent aux années 1870 (Metcalfe *et al.*, 1997). Le nombre de stations semble, certes, plus important aujourd'hui et les technologies se sont améliorées, mais la densité du réseau demeure faible et hétérogène à travers ce vaste pays. Il n'est en effet pas rare que des stations présentent soit des périodes de mesure relativement courtes, soit des données manquantes plus ou moins conséquentes dans les séries mesurées. Les régions comme le Nord, les Plaines, mais aussi les Rocheuses, soumises à un climat rigoureux combiné à une faible densité de population, sont peu propices à la mesure des précipitations et constituent les régions canadiennes les plus concernées par le manque de données. Par ailleurs, plus la fréquence d'archivage des précipitations est élevée (p. ex., horaire versus journalier) plus les historiques de mesures se font rares et courts. Cependant, les besoins pour ces données sont bien présents et il devient alors nécessaire de se tourner vers d'autres types de jeu de données que les mesures lorsque l'on souhaite obtenir une information de base pour diverses applications (p. ex., conception d'ouvrages) en ces endroits.

Il existe un très grand nombre d'approches développées dans le but de proposer des séries de précipitations ayant une couverture spatio-temporelle continue. Bien souvent, les résultats produits se présentent sous forme de grille ayant une résolution spatio-temporelle et un domaine intrinsèque. On peut citer, par exemple, les précipitations issues de l'interpolation statistique. Ces méthodes d'interpolation peuvent présenter un degré de complexité plus ou moins fort (p. ex., *splines*, approches bayésiennes ; Newlands *et al.*, 2011) et se basent sur des outils statistiques appliqués aux sites observés. Cependant, même si elles peuvent se révéler utiles pour des applications spécifiques, elles présentent des limites concernant la sous-estimation systématique des précipitations, largement documentée dans la littérature (Daly, 2006; Gervais *et al.*, 2014b), surtout pour les extrêmes. De plus, l'interpolation étant basée sur l'information apportée par les plus proches voisins, ces grilles sont délicates à utiliser à certains endroits au Canada connaissant la faible densité du réseau de mesures, et *a fortiori* pour la précipitation, grandeur météorologique qui présente une très forte variabilité spatio-temporelle. Il est possible d'utiliser, par ailleurs, des jeux de données satellitaires combinées aux observations (Huffman *et al.*, 2007; Lin & Wang, 2011), qui ont aussi été développés dans le but de proposer une couverture quasi mondiale des précipitations. Cependant, ces données présentent également certaines limitations (p. ex., une mauvaise représentation des événements de précipitations courts, Huffman *et al.*, 2007), empêchant leur application dans plusieurs contextes. D'autres jeux de données s'appuyant sur des observations existent également, mais sont soumis à d'autres problèmes. Les radars météorologiques, par exemple, couvrent des domaines souvent peu étendus et sont peu fiables à la fois en milieu urbain et montagneux (Pellarin *et al.*, 2002).

Les données sur grilles issues de modélisations numériques telles que les modèles climatiques, les modèles météorologiques, ou encore les réanalyses offrent une nouvelle alternative au manque de données mesurées. Les précipitations issues des réanalyses présentent un intérêt supérieur par rapport aux autres jeux de données. En effet, la puissance de la réanalyse réside dans la prise en compte de la dynamique de l'atmosphère (modèle numérique) combinée à l'assimilation d'un nombre important et très varié d'observations passées pour reconstruire l'historique de plusieurs variables atmosphériques (Bengtsson & Shukla, 1988). Les grilles de réanalyses possèdent l'avantage d'assurer une cohérence temporelle et spatiale de toutes les variables physiques sur plusieurs décennies tout en couvrant, dans la plupart des cas, l'ensemble du globe (Bosilovich *et al.*, 2008).

Les travaux de recherche entrepris dans le cadre de cette thèse se sont basés essentiellement sur les précipitations journalières de réanalyses au Canada. Le but de la prochaine section est de présenter les problématiques liées à l'utilisation des données de réanalyses dans une optique où ces dernières pourraient être utilisées en complément des observations. Les différents objectifs de cette thèse pour répondre à ces problématiques sont présentés dans la Section 3.

2 Problématiques

Les précipitations issues de réanalyses ne peuvent pas être utilisées directement comme *proxy* de la précipitation locale. Comme elles sont issues de modèles numériques, elles sont une représentation imparfaite de la réalité. En effet, certains processus de petites échelles, notamment pour les précipitations convectives, sont paramétrés et donc approchés à l'échelle du point de grille (Betts *et al.*, 2006). De plus, contrairement à d'autres variables, comme la température ou les vents, qui sont directement assimilées dans les réanalyses (Janowiak *et al.*, 1998), les produits de précipitations ne le sont pas. Les sorties de ces modèles peuvent aussi être entachées d'erreurs systématiques, facilement corrigibles, ou d'erreurs plus « subtiles » à détecter comme l'existence de non stationnarités n'ayant pas une origine climatique et qui se caractérisent par des ruptures artificielles de certaines séries de données. Eum *et al.* (2014) a, par exemple, mis en évidence l'existence de ruptures dans la *North American Regional Reanalysis* (NARR) attribuables à la variation dans le temps de la quantité de données assimilées. Enfin, les données de réanalyses, comme tout autre jeu de données sous forme de grilles, sont sujettes aux erreurs dites de représentativité, définies par Tustison *et al.* (2001) comme étant « *les erreurs dans la représentation des données à une échelle différente de leurs échelles inhérentes* ».

Cette thèse s'intéresse au post-traitement des réanalyses afin de tirer le meilleur parti de ces jeux de données et ainsi pouvoir les appliquer en des sites non instrumentés. Il est important de rappeler que les réanalyses sont issues de modélisations numériques assimilant, de façon presque continue sur la période étudiée, diverses variables observées, ce qui justifie la volonté d'utiliser ces données. En effet, contrairement à d'autres jeux de données sur grilles, les réanalyses pour les régions ayant un réseau de stations de précipitations faiblement dense, bénéficient de la disponibilité d'autres variables météorologiques plus faciles à mesurer (p. ex., hauteur géopotentielle, température, pression au niveau de la mer; Asong *et al.*, 2015), qui, elles-mêmes, pourront expliquer, à travers les lois de la dynamique de l'atmosphère, les précipitations à différentes échelles spatio-temporelles.

On retrouve une littérature abondante sur les approches permettant de transformer des variables synoptiques (de grande échelle spatiale), généralement disponibles sur des grilles de résolution de plusieurs dizaines voire de centaines de kilomètres, pour obtenir des estimations locales des caractéristiques des séries temporelles de précipitations (Fowler *et al.*, 2007; Maraun *et al.*, 2010). Elles sont plus communément appelées méthodes de descente d'échelle, ou encore de *downscaling* (von Storch, 1999), et regroupent un nombre très important d'approches. Ces dernières font l'objet d'une revue de littérature plus substantielle au Chapitre 2. Les modèles de descente d'échelle développés dans le cadre de cette thèse sont de même nature que celles retrouvées dans la littérature, mais nous préférons utiliser dans le manuscrit le terme de "post-traitement". En effet, il s'agit de corriger les précipitations simulées par les réanalyses afin d'éliminer de possibles biais et d'obtenir des estimations adéquates à l'échelle locale.

3 Objectifs de la thèse

L'objectif global de la thèse consiste à développer une approche permettant de corriger (ou post-traiter) les séries journalières de précipitation issues de réanalyses afin d'estimer différents indices climatiques en des sites non jaugés. Pour ce faire, trois grandes étapes énoncées ci-dessous permettront d'atteindre cet objectif.

La première étape de la thèse consiste à appliquer une méthode stochastique de post-traitement à une réanalyse à l'échelle pancanadienne. Les objectifs spécifiques à cette étape concernent :

- l'estimation du pouvoir prédictif d'une méthode de post-traitement appliquée aux couples station-tuile de la réanalyse par rapport à la climatologie observée. Il s'agira ici d'évaluer la performance d'un système de prédiction probabiliste (post-traitement stochastique) par rapport à une référence: les observations. Les distributions des précipitations seront analysées selon des "skill scores" ;
- l'évaluation de la performance de la méthode de post-traitement des réanalyses appliquées aux séries de précipitations journalières à reproduire certains indices climatiques spécifiques. L'approche de post-traitement retenue permettant de générer des séries probables de précipitations journalières, le but consistera à tester si certains attributs du processus de précipitation sont reproduits dans ces séries.

Cette première étape permettra d'appréhender les forces et les faiblesses de l'approche de post-traitement proposée par rapport à la réanalyse brute et mettra en évidence les aspects à améliorer afin de reproduire telle ou telle autre caractéristique des précipitations journalières.

La seconde étape consiste à améliorer l'approche de post-traitement, en se basant sur les résultats obtenus à la précédente étape, afin d'assurer une cohérence spatiale et une persistance temporelle des séries post-traitées. L'application sera développée sur la région des Grands Lacs et les sous-objectifs à atteindre comprennent:

- l'évaluation de l'approche de post-traitement à reproduire les caractéristiques statistiques de base des séries de précipitations journalières, et certains indices climatiques, le tout à l'échelle des sites et à l'échelle du domaine ;
- l'évaluation de la performance de ces approches à reproduire la structure spatio-temporelle des séries de précipitations journalières observées.

Cette seconde étape visera à quantifier l'avantage d'utiliser un post-traitement par rapport à la réanalyse brute, relativement aux observations, en intégrant à ce stade l'aspect spatio-temporel.

La troisième étape permet de généraliser la méthode pour pouvoir générer des séries de précipitations journalières aux endroits non instrumentés, mais renseignés par la réanalyse choisie. Ceci implique de pouvoir estimer les paramètres de l'approche de post-traitement aux sites non jaugés (régionalisation des paramètres). Deux approches de modélisation spatiale de complexité différente seront appliquées sur la même région des Grands Lacs pour répondre à cet objectif.

Les résultats de la modélisation spatiale seront évalués de la même façon qu'à l'étape précédente, mais en considérant des sous-domaines à la fois en calibration et en validation.

Ce dernier travail permettra de constater si, en utilisant l'information aux sites jaugés, il est possible d'utiliser la réanalyse post-traitée sur l'ensemble d'une région et de quantifier le gain du post-traitement par rapport à la réanalyse brute.

4 Plan de la thèse

Le post-traitement statistique des précipitations issues de la réanalyse CFSR sur l'ensemble du Canada et ses régions constituera le fil conducteur de ce document.

Une revue de littérature, exposée au Chapitre 2, permettra de présenter la variété des approches de descente d'échelle spatiale et de modélisation des précipitations. Le domaine étudié ainsi que les sources de données de précipitations seront par la suite présentés au Chapitre 3. Les Chapitres 4 à 6 répondent respectivement aux objectifs 1 à 3 (voir Section 3 de ce Chapitre). Finalement, le Chapitre 7 résume l'ensemble des résultats obtenus et aborde les perspectives futures de recherche.

REVUE DE LITTÉRATURE

Sommaire

1	Introduction	9
2	Descente d'échelle dynamique: les modèles régionaux	11
3	Descente d'échelle statistique	13
3.1	<i>Perfect Prognosis</i>	13
3.2	Correction de biais	15
3.3	Générateurs stochastiques de séquences météorologiques	15
4	Modélisation des précipitations	16

1 Introduction

Contrairement à d'autres variables comme la température, la résolution horizontale des grilles de données impacte assurément les séries de précipitations et ce d'autant plus les événements extrêmes (Volosciuk *et al.*, 2015). L'intensité sur une maille de la grille correspond en effet à une moyenne spatiale (Chen & Knutson, 2008). Or, la forte variabilité spatio-temporelle des précipitations fait en sorte que les données sur grille sont mal adaptées pour plusieurs utilisateurs qui exigent une information locale (p. ex., modélisation du ruissellement, Vischel & Lebel, 2007). Au vu du potentiel des données sur grilles issues de réanalyses ou de modèles du climat, la littérature s'est beaucoup développée autour de méthodes de *downscaling* permettant, pour une ou plusieurs variables, de passer d'échelle spatiale relativement grossière à une autre échelle beaucoup plus fine (Ailliot *et al.*, 2015; Maraun, 2016; Maraun *et al.*, 2010). Il existe, en effet, un besoin de disposer d'une donnée locale, car plus pertinente pour plusieurs

applications, notamment comme donnée de base dans la conception des ouvrages hydrauliques. Par ailleurs, ce besoin ne peut être comblé par la mesure directe en raison du manque de données à certains endroits et/ou sur une certaine période pour de nombreuses régions dans le monde. Enfin, et *a contrario*, la disponibilité des produits sur grilles ne cesse de croître (Beck *et al.*, 2017). Les sorties de modèles climatiques globaux ou régionaux ou encore de réanalyses en font partie et possèdent l'avantage de couvrir de façon continue l'espace et le temps. Toutefois, ils présentent des biais et des erreurs. En effet, certains processus ne sont, d'une part, toujours pas correctement simulés (p. ex., évapotranspiration, humidité, Volosciuk *et al.*, 2015). D'autre part, la propagation des incertitudes des observations dans les réanalyses (Lorente-Plazas & Hacker, 2017) et des modèles globaux dans les modèles régionaux (Hall, 2014) peut avoir un impact sur certaines variables simulées. Il est donc difficile d'utiliser directement ces données sachant ces limitations, d'autant plus marquées lorsqu'une donnée locale est nécessaire (p. ex., vent, précipitations). Les approches permettant de transformer les variables de grande échelle spatiale (issues de modèles) vers une échelle plus locale et en corrigeant les erreurs, par des approches soit dynamique (Section 2), soit statistique (Section 3), se sont donc beaucoup développées durant ces 20 dernières années (Langousis *et al.*, 2016). Même si usuellement la descente d'échelle est un terme réservé aux sorties de modèles du climat, la problématique pour les sorties temporelles issues de réanalyses, qui fait l'objet de cette thèse, est très similaire. Pour ces raisons, une revue de la littérature à ce sujet est exposée dans les prochaines sections. Il ne s'agira pas de proposer un exposé exhaustif des diverses approches de descentes d'échelles, mais de présenter plutôt une vision d'ensemble de ces méthodes afin de préparer le lecteur au cadre méthodologique retenu pour cette thèse. Le lecteur intéressé pourra consulter Hewitson & Crane (1996), Maraun *et al.* (2010), ou encore Ailliot *et al.* (2015) pour des revues exhaustives et approfondies de ces méthodes.

Dans un autre registre que celui de la descente d'échelle spatiale, les réanalyses ont également été beaucoup utilisées dans le contexte de la modélisation stochastique des précipitations. Ce dernier domaine s'intéresse à générer, à l'aide d'approches stochastiques, des séries de précipitation ayant les mêmes caractéristiques statistiques que les observations en se basant sur des variables prédictives autres que les précipitations. Contrairement à la descente d'échelle, où les modèles sont calibrés sur une période de référence passée pour être appliqués sur une période future, la modélisation des précipitations n'est réalisée que dans un contexte de simulation. Les réanalyses ont joué un rôle crucial dans ce champ d'études durant ces dernières années (Wilks, 1998), car elles mettent à disposition un grand nombre de variables synoptiques de grande échelle qui peuvent constituer de bons prédicteurs pour les précipitations

(p. ex., humidité spécifique, pression au niveau de la mer). La modélisation des précipitations se base sur des modèles statistiques très similaires à certaines approches de descente d'échelle (générateur stochastique de séquences météorologiques ou encore *weather generator*, Section 3.3). Une revue de littérature spécifique à l'utilisation des réanalyses pour la modélisation des précipitations est exposée à la Section 4.

2 Descente d'échelle dynamique: les modèles régionaux

Les méthodes de descente d'échelle dynamique sont nées avec le développement et l'application croissante des scénarios de modèles climatiques globaux (MCG). Les MCG simulent l'ensemble du système climatique terrestre et découpent le domaine de simulation selon des grilles dont les résolutions spatiales sont comprises entre 100 et 200 km (Rummukainen, 2016). Ils sont conçus pour représenter les patrons globaux de circulation atmosphérique et océanique (Rummukainen, 2010). Cependant, à ces échelles, plusieurs processus en jeu à des échelles spatiales inférieures à la résolution de la grille ne sont pas pris en compte et ne peuvent être adéquatement représentés. Une solution possible consisterait à augmenter la résolution des MCG, mais les temps de calcul sur les machines actuelles rend cette solution peu adaptée (Rummukainen, 2010). L'idée de procéder à une descente d'échelle dynamique à partir des MCG s'est donc développée et a donné naissance aux modèles régionaux du climat (MRC; illustrés par la grille rouge de la Figure 2.1) (Laprise *et al.*, 2008).

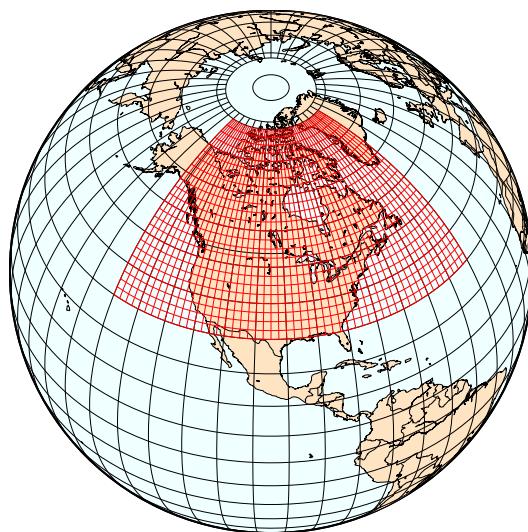


Figure 2.1 – Grille du MRC (rouge) encastrée dans la grille du MCG (noir). Les mailles du MRC sont seize fois plus petites que celle du MCG.

Les MRC reposent sur les mêmes loi physiques que les MCG. Les plus récentes versions produisent des simulations avec une résolution horizontale en deçà de 10 km (Rummukainen, 2016), mais sont déployées sur un domaine plus limité. Les simulations des MRC sont connectées au climat global grâce aux conditions aux frontières imposées soit par un MCG soit par une réanalyse; on dit que le MRC est piloté par le MGC ou la réanalyse (Figure 2.1). Malgré ce contrôle aux limites, le MRC développe sa propre variabilité climatique et ce d'autant plus lorsqu'on s'éloigne des frontières du domaine du MRC. Les avantages de ces modèles régionaux sont multiples: ils assurent, entre autres, une cohérence entre les variables météorologiques; plusieurs processus physiques sont résolus. De plus, la topographie et l'occupation du sol sont plus finement représentées que dans les MCG et assurent donc une « meilleure » représentativité du climat régional (Frei *et al.*, 2006; Giorgi & Marinucci, 1996). Dans la littérature, beaucoup de MRC ont été développés et plusieurs projets d'intercomparaison de modèles, tels qu'ENSEMBLES en Europe (Hewitt, 2004) et CORDEX (*Coordinated Regional climate Downscaling Experiment*, Giorgi *et al.*, 2009) à l'échelle internationale, ont vu le jour. L'objectif visait de partager des MRC différents pour développer une expertise sur les changements climatiques, mais aussi de mieux comprendre et éventuellement améliorer ces modèles.

Les MRC restent soumis à des coûts de calculs très importants avec des grilles toujours plus fines nécessitant l'intégration de nouvelles données et la résolution de nouveaux processus. Les domaines et les périodes couvertes par les simulations sont alors réduits pour diminuer ces coûts (Lucas-Picher *et al.*, 2017; Vaittinada Ayar *et al.*, 2015). Plusieurs choix conditionnent également la qualité des simulations. Par exemple, la délimitation des domaines de simulations et l'intégration des conditions aux limites entre MCG et MRC (p. ex.,variables aux 6 h pour les MCG et aux heures pour les MRC) (Rummukainen, 2010; Xue *et al.*, 2014) posent des défis de taille. Enfin, la précipitation, variable centrale de ce travail de thèse, demeure difficile à représenter dans les MCG et MRC. La résolution finie de ces modèles nécessite que tous les processus ayant lieu à une échelle sous-maille soient approchés, on parle alors de paramétrisation (Rummukainen, 2010). Par exemple, les précipitations extrêmes de courte durée souvent issues de processus convectifs, avec une ascension rapide de l'air chaud avant saturation suivie de précipitations localisées et intenses, sont paramétrées lorsque les résolutions sont supérieures à 4 km (Lindstedt *et al.*, 2015; Rummukainen, 2016). De ce fait, la modélisation des extrêmes est potentiellement moins bien représentée. Les MRC restent tout de même un outil indispensable pour évaluer la climatologie et réaliser des études d'impact de certaines variables sous un climat en évolution. Ces limitations ne permettent pas de se servir des sorties de MRC/MCG afin d'analyser les précipitations aux échelles

locales. Les modèles de descente d'échelle statistique sont alors utilisés. (Fowler *et al.*, 2007; Langousis & Kaleris, 2014).

3 Descente d'échelle statistique

Les modèles de descente d'échelle statistique (*Statistical Downscaling Models*, SDM) établissent un lien statistique entre une ou plusieurs variables de grande échelle appelées X (covariable ou prédicteur) et une variable locale notée Y (prédictand). Contrairement aux modèles physiques présentés à la Section 2 de ce chapitre, les SDM se concentrent sur une seule variable de sortie (p. ex. les précipitations), mais présentent l'avantage d'être beaucoup plus accessibles et moins coûteux en termes de temps de calcul.

Dans le cadre de ce travail de recherche, les SDM ont été retenues pour post-traiter les précipitations journalières de la réanalyse CFSR. Il existe dans la littérature une très grande variété de SDM qu'il convient ici de présenter avant de spécifier à la Section 3 dans quel cadre ce projet s'inscrit. Bien que les diverses approches de SDM se recoupent en plusieurs points, la classification suivante selon trois familles est retenue pour la suite (Maraun *et al.*, 2010; Wilby & Wigley, 1997) à savoir les approches : 1) de la prévision parfaite (*Perfect Prognosis*, PP); 2) de correction de biais (*Model Output Statistics*, MOS); et 3) les générateurs stochastiques de séquences météorologiques (*Weather Generator*, WG).

3.1 *Perfect Prognosis*

L'approche *Perfect Prognosis* (PP) construit un lien statistique entre des observations de variables synoptiques, généralement des *proxys* d'observations issus par exemple de réanalyses (Maraun *et al.*, 2010), et les observations locales (Klein *et al.*, 1959). Une synchronicité temporelle entre les deux jeux de données est une condition nécessaire à la calibration de ces modèles. Les approches de type régression, résumées au Tableau 2.1 suivant, s'apparentent à la famille des PP. La sélection des variables explicatives constitue un point majeur de ces modèles, car ces dernières ne doivent pas être trop nombreuses pour éviter les problèmes de sur-ajustement (*overfitting*), mais juste assez conséquentes afin d'en extraire l'information physique pertinente (Maraun *et al.*, 2010). Les outils statistiques fondés sur la fonction de vraisemblance, tels que le *Akaike Information Criterion* (AIC, Akaike, 1974) et le *Bayesian Information Criterion* (BIC, Schwarz, 1978), sont utilisés pour sélectionner ces covariables.

Tableau 2.1 – Principaux modèles de régression utilisés dans les SDMs de type *Perfect-Prognosis*

		Modèle	Type de prédictand	Référence
1.	Régression linéaire	$\mu = \beta_0 + \beta_1 X_1 + \cdots + \beta_p X_p$ Avec μ moyenne conditionnelle de Y et $\beta = (\beta_0, \dots, \beta_p)$ coefficients à estimer	Variable gaussienne	Neter <i>et al.</i> (1996)
2.	Generalized Linear Model (GLM)	$g(\mu) = \beta_0 + \beta_1 X_1 + \cdots + \beta_p X_p$ Avec g fonction lien à choisir (p. ex., logit)	Variable à distribution asymétrique (p. ex., les précipitations)	Dobson (2010)
3.	Vector Generalized Linear Model (VGLM)	$g_i(p_i) = \beta_{0,i} + \beta_{1,i} X_1 + \cdots + \beta_{p,i} X_p$ Avec $p = (p_1, \dots, p_k)$, k paramètres de la distribution choisie (p. ex., distribution Gamma)	Variable à distribution asymétrique et modélisation des extrêmes	Yee (2015)

Dans la famille des PP, certaines méthodes autorisent la modélisation de relations non linéaires entre les covariables et les prédictands. Par exemple Jha *et al.* (2015) ont utilisé des méthodes géostatistiques non linéaires, pour la descente d'échelle, appliquées aux précipitations et températures sur une région en Australie. Olsson *et al.* (2001) ont appliqué les réseaux de neurones artificiels (*Artificial Neural Network*, ANN) pour la réduction d'échelle des précipitations journalières au Japon.

Enfin, la méthode des analogues (*Weather-Type*, WT) est également classée dans la famille des PP. Initialement développée pour la prévision à court terme en météorologie (Lorenz, 1969), la méthode des analogues s'est largement développée dans les études de SDMs (Boé *et al.*, 2006; Raynaud *et al.*, 2017; Yiou *et al.*, 2013). Elle repose sur des analogies, quantifiées par des mesures de distances, entre des champs de circulations atmosphériques et la variable d'intérêt locale. L'hypothèse sous-jacente est que des états atmosphériques similaires donnent lieu des situations météorologiques locales similaires (Chardon, 2014). La philosophie de cette approche réside sur la création d'un catalogue historique, sur un domaine donné, associant la réalisation de la variable locale d'intérêt et le champ de circulation atmosphérique associé. Ainsi, en climat futur, connaissant les champs de circulations donnés par les MRC et en cherchant dans le catalogue des champs ceux présentant la plus grande similarité, il est possible de reconstituer la variable d'intérêt. L'un des problèmes souvent soulevés est l'impossibilité de sortir des bornes de ce qui a été observé dans le passé, facteur ainsi limitant les analyses en climat futur (Vaittinada Ayar *et al.*, 2015).

3.2 Correction de biais

Les méthodes décrites précédemment se révèlent inapplicables pour des sorties de MRC qui ne sont pas pilotées par des réanalyses, car l'hypothèse de synchronicité temporelle n'est plus vérifiée. Les variables issues des modèles régionaux du climat apportent tout de même une information pertinente, mais nécessitent une réduction d'échelle préalable pour être utilisables, par exemple pour des études d'impacts (Maraun *et al.*, 2010). Les méthodes de corrections de biais (MOS), s'intéressent à établir des relations entre les statistiques de sorties de modèles climatiques (*model outputs*) et celles observées (Vaittinada Ayar *et al.*, 2015). Les MOS peuvent corriger les moyennes (Mailhot *et al.*, 2011), les moyennes et les variances (Leander & Buishand, 2007) ou encore les fonctions de répartition des variables d'intérêt (Piani *et al.*, 2010). Les observations peuvent correspondre à des mesures locales ou des estimations sur grilles, elles-mêmes basées sur des observations (p. ex., grilles issues d'une méthode d'interpolation). Les fonctions mathématiques définissant les MOS sont calibrées sur une période dite de référence et sont ensuite appliquées sur une période future, l'hypothèse sous-jacente étant la stationnarité du biais.

3.3 Générateurs stochastiques de séquences météorologiques

Les générateurs stochastiques de séquences météorologiques, ou en anglais *Weather Generators*, sont des modèles stochastiques paramétriques permettant de générer aléatoirement des séries temporelles de variables possédant des caractéristiques statistiques similaires aux variables observées (Olson & Kleiber, 2017; Richardson, 1981). Pour tenir compte de la nature intermittente des précipitations, les générateurs stochastiques modélisent séparément l'occurrence et l'intensité des précipitations. L'occurrence des précipitations (état binaire: 1 pluie ou 0 sec) est simulée à partir d'une chaîne de Markov du premier ordre et l'intensité des jours pluvieux (variable continue) à partir d'une distribution choisie (p. ex., loi EGPD - *Extended Generalized Pareto Distribution*, Naveau *et al.*, 2016).

Dans un contexte de réduction d'échelle, les séries temporelles sont simulées à partir de la densité de probabilité de la variable d'intérêt locale (Y) conditionnelle aux variables de plus grandes échelles (X) (Wilks, 2010). Une fois que la distribution théorique censée reproduire le processus physique (p. ex., loi normale pour les températures) a été choisie, la deuxième étape consiste à relier les paramètres (p. ex., paramètre de position de la distribution) de ces distributions aux variables synoptiques, à l'aide par exemple d'un GLM (cf. Tableau 2.1). On retrouve aussi cette approche sous la dénomination de

Stochastic Model Output Statistics (SMOS) dans les travaux de Wong *et al.* (2014). Tout l'art de la méthode réside dans de la densité de probabilité ainsi que des covariables composant le modèle. Par ailleurs, contrairement à l'approche MOS, la non-stationnarité éventuelle des variables d'intérêt est indirectement introduite par l'intermédiaire des prédicteurs, le tout en gardant un lien stationnaire entre prédictant et prédicteur.

Les générateurs stochastiques de séquences météorologiques peuvent s'appliquer de façon indépendante en chacun des sites d'un domaine d'étude (Wong *et al.*, 2014) ou en adoptant une approche multi-sites (Wilks, 1998; Yang *et al.*, 2005). Le premier cas est le plus simple, car les paramètres des modèles WG sont estimés localement sans tenir compte du voisinage et de possibles corrélations entre ces paramètres. La corrélation spatiale des covariables permet tout de même d'assurer une cohérence spatiale des caractéristiques climatiques (p. ex., moyenne) des séries temporelles générées, mais pas forcément à des échelles plus fines (p. ex., journalière). L'approche multi-sites est plus complexe, car son but consiste à modéliser la distribution multivariée en intégrant la dépendance entre tous les sites. Elle permet de prendre en compte l'information apportée par les voisins et de la structure spatiale de la variable étudiée dans la simulation locale des séries temporelles aux sites existants. Dans le contexte des précipitations, le cadre multivarié s'annonce plus délicat à mettre en place du fait de la distribution fortement asymétrique des pluies (Olson & Kleiber, 2017) et de la masse de probabilité importante en zéro. Souvent, les auteurs tentent de rendre gaussienne cette variable afin d'utiliser la loi normale multivariée, plus facile à implémenter. L'approche multi-sites ne permet cependant pas d'estimer les paramètres en dehors des sites avec station d'observation, contrairement aux WG spatiaux, qui font l'objet de la Section 3.2.3. Pour une revue de littérature plus détaillée des WG, le lecteur se référera à Ailliot *et al.* (2015).

4 Modélisation des précipitations

L'un des objectifs de ce travail de recherche consistant à proposer des séquences probables de précipitations journalières locales, on ne peut ignorer tout le pan de littérature traitant des approches de modélisation statistique des précipitations. Haberlandt *et al.* (2011) proposent une classification de ces diverses méthodes en cinq catégories :

1. Les modèles de renouvellement alternatif (*alternating renewal models*, Pegram & Clothier, 2001) se définissent par l'analyse des événements secs et humides.

2. Les processus ponctuels (*point processes*) qui se basent sur la structure physique du processus de précipitations afin de décrire la probabilité qu'un événement pluvieux ait lieu à l'échelle infra-journalière (Onof *et al.*, 2000).
3. Les modèles de désagrégation (*disaggregation models*) qui reposent sur les relations d'échelle spatiale et temporelle des précipitations pour désagréger les précipitations (Lombardo *et al.*, 2017).
4. Les techniques de ré-échantillonnage (*resampling techniques*) qui ne nécessitent pas d'hypothèses sur les distributions des précipitations et s'appuient essentiellement sur l'échantillonnage des valeurs observées (Buishand & Brandsma, 2001).
5. Les modèles de type séries temporelles (*Time Series Models*) comprennent les chaînes de Markov, les GLM décrits plus haut, les modèles *Autoregressive-moving-average model* (ARMA, Hipel & McLeod, 1994) et permettent de générer de longues séries de variables hydrologiques en utilisant des variables exogènes (Wilks, 1998).

L'objectif de la thèse étant de générer des séries temporelles de précipitation locales en utilisant les précipitations issues d'une réanalyse, seules les approches de la 5^{eme} catégorie sont utilisables dans ce contexte. On ne s'attardera ci-après seulement à ces modèles. Les méthodes statistiques sont exactement celles présentées à la Section 3.3, *i.e.* avec l'utilisation des WG, mais se distinguent par le nombre (généralement plus conséquent) et surtout par le type de covariables, qui est par définition exogène à la précipitation. Ainsi, Serinaldi & Kilsby (2014) utilisent la pression au niveau de la mer issue de la réanalyse du *National Center for Atmospheric Research* (NCEP, Kalnay *et al.*, 1996) comme covariable pour générer des champs de précipitations journaliers sur le bassin du Danube. Le but des auteurs ne consistait pas de proposer des séries locales, car les champs obtenus sont sous forme de grille ayant une résolution de 25 km. Asong *et al.* (2016a), basés sur les travaux de Chandler & Wheater (2002), ont eu recours à 21 covariables atmosphériques de grande échelle provenant également du NCEP. Ces auteurs ont employé un GLM multi-sites sur les provinces canadiennes des Prairies pour générer des précipitations journalières à l'échelle locale. D'autres études se sont également basées sur les mêmes approches avec des variantes permettant de mieux simuler les extrêmes de précipitation (Baxevani & Lennartsson, 2015). En général, les auteurs s'accordent sur la pertinence de ces approches pour représenter les caractéristiques principales des précipitations observées, dont la variabilité à diverses échelles temporelles .

Le présent projet de doctorat montre des points communs avec la descente d'échelle, car les précipitations sur grilles issues de modèles numériques de temps (*numerical weather prediction models*) sont

transformées en précipitations locales. Il comporte également des similitudes avec la modélisation statistique des précipitations, car des variables issues de réanalyses sont utilisées pour générer des précipitations sur une période passée. Pour éviter les confusions possibles dues à des terminologies consacrées à tel ou tel autre jeu de données, on parlera dans la suite du manuscrit de post-traitement des précipitations issues de réanalyses.

DONNÉES ET MÉTHODE

Sommaire

1	Territoire à l'étude et régions climatiques	19
2	Les précipitations journalières: données disponibles	21
2.1	Réseau pluviométrique	21
2.2	La réanalyse CFSR	23
2.3	Contrôle de qualité des données disponibles	23
3	Cadre méthodologique de l'approche de post-traitement	28
3.1	Introduction	28
3.2	Considérations théoriques générales	30
3.3	Modèles stochastiques de post-traitement de l'occurrence et de l'intensité: méthode de l'article 1	37
3.4	Modélisation des champs météo-gaussiens spatio-temporels latents : méthode de l'article 2	41
3.5	Estimation des distributions mixtes des précipitations journalières aux sites sans observations: méthode de l'article 3	44

1 Territoire à l'étude et régions climatiques

Le territoire étudié couvre l'ensemble du Canada terrestre et présente une grande diversité climatique. En effet, on observe notamment une topographie très marquée à l'ouest, la présence de grandes masses d'eau à l'est (Grands Lacs) et l'aridité des régions nordiques, autant de facteurs ayant une influence majeure sur les régimes de précipitations (Phillips, 1990). Pour faciliter les analyses, les résultats obtenus

à l'échelle de la station sont regroupés selon dix régions proposées par Plummer *et al.* (2006) et illustrées à la Figure 3.1. Les régions ont été construites à la fois à partir de caractéristiques physiographiques et climatiques. Ces dernières sont détaillées dans le Tableau 3.1. Elles ont l'avantage de présenter une bonne homogénéité tout en n'étant pas trop nombreuses. Certaines de ces régions initialement définies sur un domaine plus grand ont été modifiées pour les besoins de ce projet de recherche, afin de ne couvrir que le territoire canadien (voir la ligne en pointillé de la Figure 3.1).

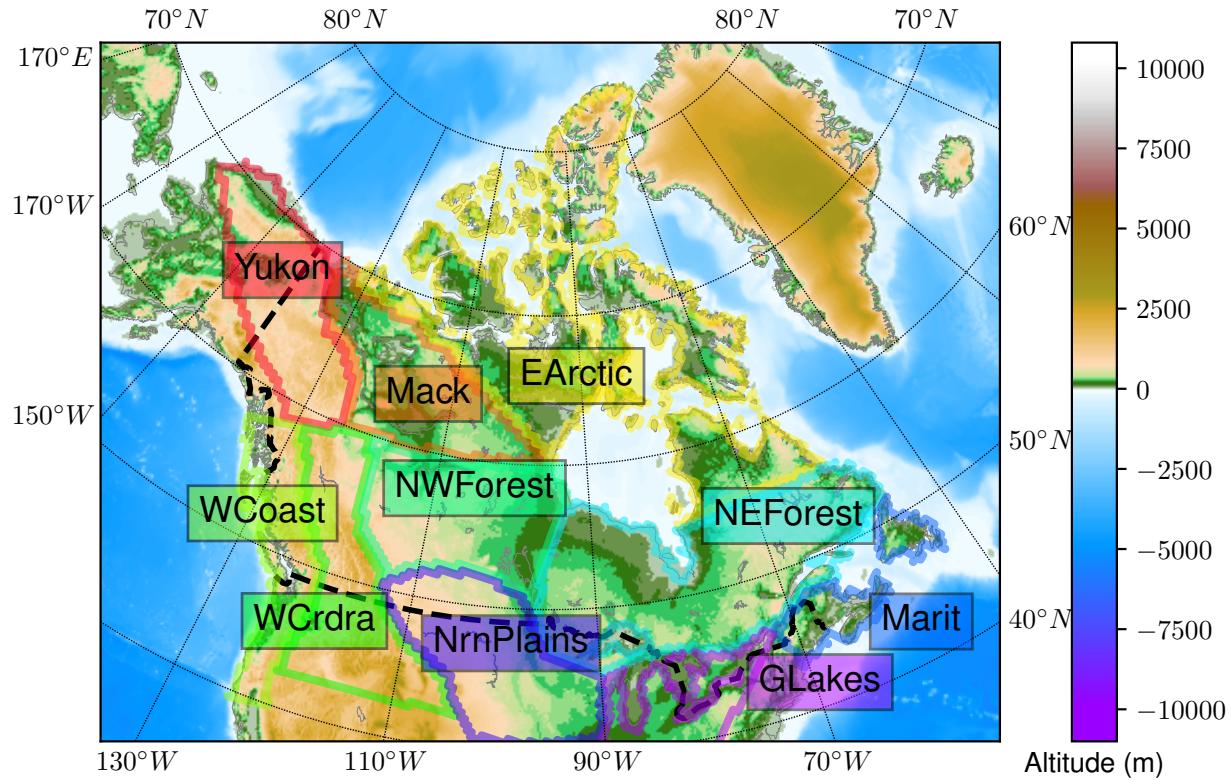


Figure 3.1 – Domaine d'étude limité par la ligne en pointillé et les dix régions climatiques de Plummer *et al.* (2006)

Tableau 3.1 – Caractéristiques physiographiques et climatiques des régions de Plummer *et al.* (2006)

	Nom	Abréviation	Caractérisation
Régions Nordiques	Yukon Territory	Yukon	Région montagneuse (Cordillère américaine) de climat polaire et subarctique
	Mackenzie Valley	Mack	Bassin du fleuve Mackenzie de climat subarctique
	East Arctic	EArctic	Archipel de climat arctique avec des montagnes et des plaines
Régions de l'ouest	West Coast	WCoast	Région côtière de l'ouest soumise un climat océanique
	Western Cordillera	WCrdra	Région de hauts reliefs et plateaux avec un climat continental
Régions centrales	North West Forest	NWForest	Région forestière avec au sud une forêt mixte et au nord une forêt boréale de conifères soumise à un climat subarctique
	Northern Plains	NrnPlains	Sud des plaines intérieures de climat continental sec
Régions de l'est	North East Forest	NEForest	Région forestière boréale de l'est
	Great Lakes	GLakes	Région de climat continental très fortement influencée par les Grands Lacs
	Canadian Maritimes	Marit	Région côtière de l'est de climat continental humide

2 Les précipitations journalières: données disponibles

2.1 Réseau pluviométrique

La pluie est un processus dont la mesure est incertaine du fait de son intermittence et de sa grande variabilité spatiale et temporelle. Les appareils possèdent, en effet, une résolution fine (p. ex., 0.2 mm) et un pas d'archivage (p. ex., horaire) qui ne permettent pas de rendre compte complètement de la variabilité temporelle. L'effet de cet échantillonnage peut avoir plus ou moins de conséquences selon le but visé par les applications finales de ces données. Par exemple, l'intensité maximale d'un événement pluvieux est sous-estimée lorsque la fréquence d'archivage est trop faible. Les stations de mesure peuvent également être soumises à des modifications qui affectent l'analyse du processus de précipitation. Le déplacement géographique de la station, ou encore la modification du type d'appareil sont des exemples parmi d'autres affectant la fiabilité des séries mesurées (Canadian Standards Association, 2012) ainsi que leur homogénéité. Le réseau pluviométrique canadien est, par ailleurs, peu dense et non homogène spatialement. Les pluviomètres sont pour la plupart concentrés au sud du pays, régions au climat plus doux avec une forte densité de population. Il est de ce fait difficile d'établir la climatologie des précipitations

pour une grande partie du territoire. Cependant, malgré ces limitations, les mesures issues du réseau canadien de pluviomètres demeurent la plus fiable et la plus directe source d'information concernant les précipitations et sont utilisées comme données de référence. Les considérations à propos des incertitudes de ces mesures permettent de prendre en considération le fait que les données observées de précipitations ne sont pas une vérité absolue et qu'une grande vigilance dans le traitement de qualité de ces dernières est requise (cf. Section 2.3).

Le jeu initial de stations mesurant des précipitations journalières compte un total de 4 881 stations réparties à travers le Canada. Leur position géographique est indiquée à la Figure 3.2. Parmi ces stations, un nombre de 463, majoritairement situées dans le sud du pays, ont été homogénéisées et corrigées pour tenir compte, entre autres, de la sous-captation causée par le vent, de l'évaporation et des pertes par mouillage au niveau des contenants des pluviomètres (Mekis & Hogg, 1999; Mekis & Vincent, 2011). Ce sous-ensemble de stations est désigné comme l'ensemble de deuxième génération de précipitations ajustées (*Second Generation Adjusted Precipitation for Canada, APC2*) (Environment and Climate Change Canada, 2013). Les données aux autres stations n'ont fait l'objet d'aucune correction et ont également été fournies par Environnement et Changement climatique Canada (ECC). De même, le Ministère du Développement Durable, de l'Environnement et de la Lutte contre les Changements Climatiques (MDDELCC) a également mis à disposition certaines données pour le Québec.

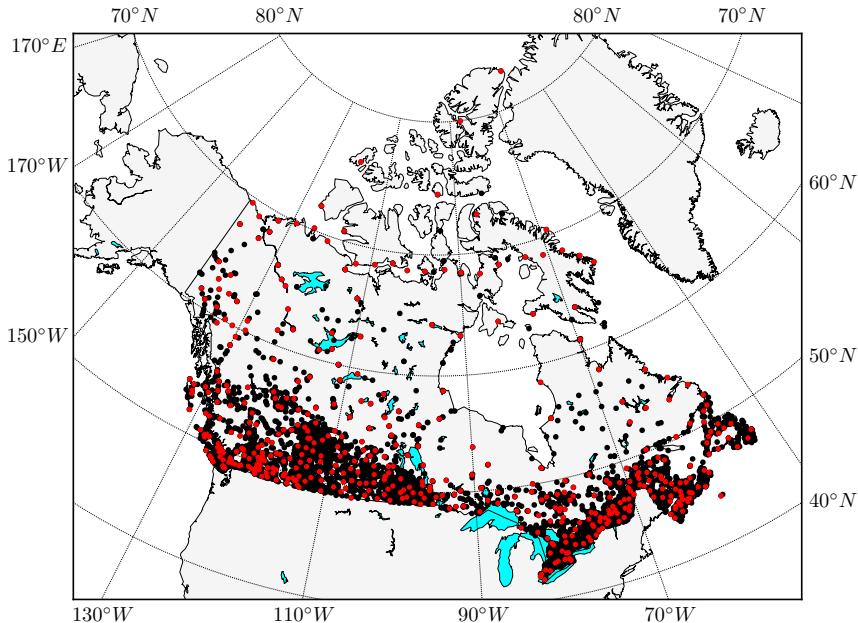


Figure 3.2 – Stations de mesure des précipitations journalières. Les points rouges correspondent aux stations de l'APC2.

2.2 La réanalyse CFSR

CFSR est la réanalyse utilisée dans la suite du manuscrit. Elle est produite par le NCEP et couvre l'ensemble du globe sur la période 1979-2009 (Saha *et al.*, 2010, 2006). CFSR est générée par un modèle couplé (*Coupled Forecast system model*, CFS) qui simule l'état passé de l'océan et de l'atmosphère avec une résolution horizontale de $0.312^\circ \times 0.312^\circ$ (~ 38 km à 45°N). CFSR présente plusieurs avantages par rapport à d'autres réanalyses dont : 1) le couplage des modèles d'atmosphère, d'océan, de terre, et de glace (Bromwich *et al.*, 2011) ; 2) l'assimilation des radiances satellitaires sur l'ensemble de la période et 3) la prise en compte des séries temporelles de concentration en CO₂ (Mesinger *et al.*, 2006). Un autre point fort de la réanalyse CFSR concerne l'intégration de deux produits de précipitations dans les modèles de surfaces : 1) la grille des moyennes sur cinq jours issue du *Climate Prediction Center Merged Analysis of Precipitation* (Xie & Arkin, 1997, CMAP,) construite à partir d'observations aux pluviomètres et par télédétection radar et ayant une résolution de $2.5^\circ \times 2.5^\circ$ et 2) la grille des cumuls journaliers issue du *Climate Prediction Center* (CPC) construite à partir d'observations aux pluviomètres dont la qualité des enregistrements est contrôlée et disponible avec une résolution $0.5^\circ \times 0.5^\circ$.

Pour les besoins de ce projet de recherche, les précipitations horaires de la réanalyse CFSR ont été agrégées au pas de temps journalier sur le créneau 6h- 6h UTC. Selon l'article de Hutchinson *et al.* (2009), les mesures journalières aux stations se font généralement aux fenêtres temporelles suivantes: 6h-6h, 7h-7h, ou 8h-8h UTC, selon les sites. Cette dernière information n'étant pas disponible et la fenêtre 6h - 6h UTC semblant être la plus répandue, elle est par conséquent considérée dans ce travail.

2.3 Contrôle de qualité des données disponibles

2.3.1 Gestion des données manquantes

La présence de données manquantes dans les séries de précipitations est une réalité indéniable dont il faut tenir compte pour retenir une série plutôt qu'une autre. La question ne se pose pas pour la réanalyse, car les données sont continues dans l'espace et le temps. La réalité est par contre toute autre pour les données aux stations pluviométriques. De ce fait, pour assurer des séries observées contenant suffisamment d'information, tout en ne perdant pas un nombre trop conséquent de stations, surtout dans le nord du pays, les critères de sélection suivants ont été appliqués au jeu initial de 4 881 stations :

1. chaque année doit contenir un minimum de 90% d'observations (une année respectant ce critère est qualifiée d'année valide);
2. chaque série couvre un minimum de 10 années valides incluses dans la période 1979-2009 (conditionnée par la période disponible pour CFSR) dont au moins cinq années consécutives.

Vingt-deux stations dans le sud de la province du Saskatchewan présentent des séries avec une année manquante sur deux autour des années 80. Ces stations ont donc été écartées du jeu de données. Deux mille soixante-douze (2 072) stations répondent aux critères décrits plus hauts. Le Tableau 3.2 résume l'impact des traitements de qualité sur le jeu initial de données observées. Tout d'abord, on peut y constater la faible densité du réseau de mesure dans les régions nordiques qui représente seulement 5% des stations du domaine étudié. Par ailleurs, on peut remarquer le fort impact du traitement de qualité avec plus de 50% des sites qui ne satisfont pas les critères de qualité.

Tableau 3.2 – Impact du traitement de qualité sur le nombre de stations de l'ensemble du domaine et à pour chaque région.

	Canada	Yukon	Mack	EArctic	WCoast	WCrdra	NWForest	NrnPlains	NEForest	Marit	GLakes
Nombre initial de stations	4879	72	58	97	641	552	564	608	722	695	870
Nombre de stations avec traitement de qualité	2072	38	25	49	253	223	224	267	320	335	338

Une analyse préliminaire des séries de précipitations de CFSR a montré l'existence de précipitations horaires négatives, de l'ordre du millième de mm. L'impact de ces valeurs en termes de fréquence (p. ex., la proportion de pas de temps avec des précipitations négatives sur la période étudiée) et de cumuls (p. ex., la contribution de ces précipitations aux cumuls annuels) s'est révélé négligeable. Les précipitations horaires négatives ont donc été ramenées à 0 mm avant de procéder à l'agrégation à un pas de temps journalier.

2.3.2 Seuil journalier des précipitations

Un seuil journalier de 1 mm a été appliqué à la fois aux précipitations journalières observées et à CFSR. En deçà de ce seuil, les précipitations sont considérées comme nulles et la journée correspondante est dite "sèche". Ce seuil permet de s'affranchir des valeurs résiduelles propres aux modèles numériques (*drizzle effect*; Sun *et al.*, 2006). Les modèles ont, en effet, tendance à générer de nombreux pas de temps avec de très faibles hauteurs de précipitations. Ce seuil de 1 mm est généralement considéré pour des

séries de précipitations journalières que ce soit pour les données observées ou simulées afin de distinguer les journées dites “sèches” des journées “humides” (Vaittinada Ayar *et al.*, 2015; Wong *et al.*, 2014).

2.3.3 Homogénéité statistique des séries de précipitations

L'homogénéité, au sens statistique, des séries des cumuls annuels observés et celles de CFSR a également été vérifiée. Plusieurs facteurs peuvent contribuer à rendre inhomogènes les séries enregistrées aux stations. Parmi ces facteurs on peut mentionner un changement d'instrumentation, d'observateur, un déplacement de l'instrument ou encore une modification des conditions locales (p. ex., la végétation, Mekis & Vincent, 2011). Pour les réanalyses, une variation du volume de données assimilées peut rendre les séries inhomogènes (p. ex., à travers l'apparition de ruptures dans les séries de précipitations) et ainsi affecter certaines analyses (Beaulieu *et al.*, 2007; Eum *et al.*, 2014). L'utilisation des tests d'homogénéité permettant de détecter ces éventuelles inhomogénéités apparaît donc tout à fait pertinente, à la fois aux stations, car une grande partie d'entre elles ne provient pas de l'APC2, et aux tuiles de la réanalyse CFSR (Eum *et al.*, 2014). En général, l'analyse de l'homogénéité est réalisée à partir des métadonnées (ensemble des informations précisant le type d'instrumentation en place, la localisation de la station, etc.) en utilisant les séries aux stations voisines (Beaulieu, 2009). Dans le cas présent, le fait de ne pas disposer des métadonnées aux stations a conduit à appliquer des tests statistiques d'homogénéité. L'intermittence et la forte asymétrie des distributions des précipitations journalières empêchent d'utiliser les tests classiques à cette échelle temporelle. En effet, bien souvent les caractéristiques de ces séries ne respectent pas les hypothèses de base des tests (p. ex., normalité, indépendance). Conséquemment, ces tests ont été appliqués aux séries temporelles des cumuls annuels.

Plusieurs tests et approches existent pour évaluer l'homogénéité (Lubes-Niel *et al.*, 1998), et la méthodologie proposée par Wijngaard *et al.* (2003) a été retenue. Cette approche possède l'avantage de combiner quatre tests avec un niveau de confiance fixé à 99% :

1. *Standard Normal Homogeneity Test* (SNHT, Alexandersson, 1986) ;
2. Buishand (Buishand, 1982) ;
3. Pettit (Pettitt, 1979) ;
4. Ratio de Von Neumann (von Neumann, 1941).

Le caractère indépendant et identiquement distribué (i.i.d.) de la variable d'intérêt, ici les cumuls annuels des précipitations, constitue l'hypothèse nulle (\mathcal{H}_0) pour les quatre tests. Les tests SNHT, Buishand et de Pettitt sont des tests de rupture, ils considèrent dans l'hypothèse alternative (\mathcal{H}_1) l'existence d'un pas de temps durant lequel une rupture est observée (changement des paramètres de la distribution au cours du temps, par exemple la moyenne pour le SNHT). Le ratio de Von Neumann prend lui comme hypothèse \mathcal{H}_1 , le caractère non aléatoire de la série étudiée, et contrairement aux précédents tests, il est également sensible à des inhomogénéités qui seraient d'autres natures qu'une rupture dans la série (p. ex., variation trop rapide de la valeur moyenne Wijngaard *et al.*, 2003). Le développement mathématique de ces tests est présenté dans l'article de Wijngaard *et al.* (2003).

Selon les résultats de ces quatre tests, Wijngaard *et al.* (2003) classifie les séries en trois groupes : 1) "utile" lorsque \mathcal{H}_0 n'est pas rejetée par au moins trois tests ; 2) "incertaine" lorsque \mathcal{H}_0 est rejetée par deux tests ; et 3) "suspecte" lorsque \mathcal{H}_0 est rejetée par au moins trois tests. Dans le présent projet, seules les séries observées classées dans la catégorie "utile" ont été conservées pour fin d'analyse. Les résultats des tests ont montré que les séries annuelles aux stations valides (Tableau 3.2) sont pour la grande majorité homogènes (niveau de confiance à 99%). Le nombre et la répartition des stations valides et homogènes sont résumés à la Figure 3.3.

	Nombre de stations homogènes
Canada	1884
Yukon	36
Mack	22
EArctic	45
WCoast	245
WCrdra	219
NWForest	200
NrnPlains	181
NEForest	290
Marit	314
GLakes	332

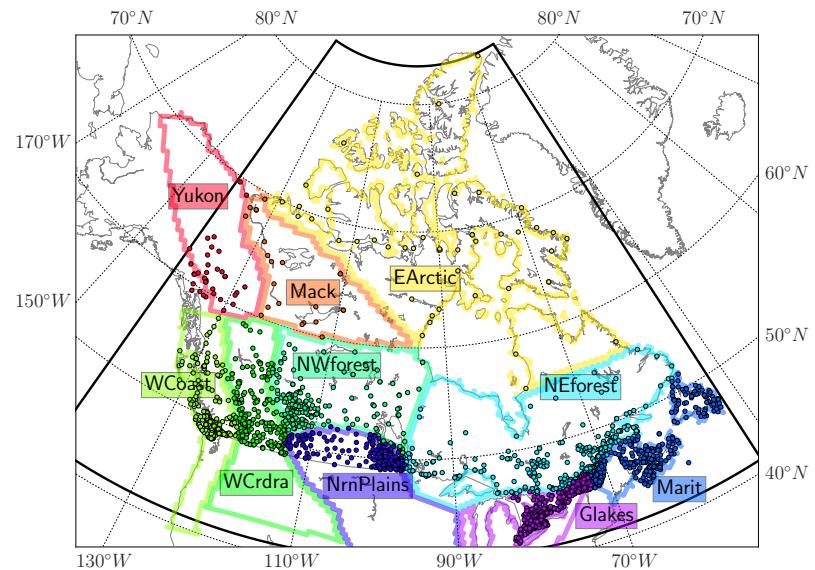


Figure 3.3 – Stations valides et homogènes réparties selon les dix régions de (Plummer *et al.*, 2006)

Les cumuls annuels de CFSR non homogènes appartenant à la catégorie "incertaine" ou "suspecte" selon Wijngaard *et al.* (2003), représentent seulement 4% des tuiles du domaine (Figure 3.4) dont la majeure partie correspond à des tuiles maritimes. Par ailleurs, contrairement par exemple à la réanalyse *North American Regional Reanalysis* (NARR) où l'on observait une rupture systématique à la frontière entre le Canada et les États-Unis (Guillaume Talbot, communication personnelle), la répartition spatiale des tuiles non homogènes est apparemment aléatoire. Une inspection visuelle des séries annuelles de précipitations à certaines de ces tuiles n'a pas permis de constater de ruptures majeures dans les séries, contrairement aux séries observées classées non homogènes. Par conséquent, ces tuiles ont tout de même été retenues pour fin d'analyse.

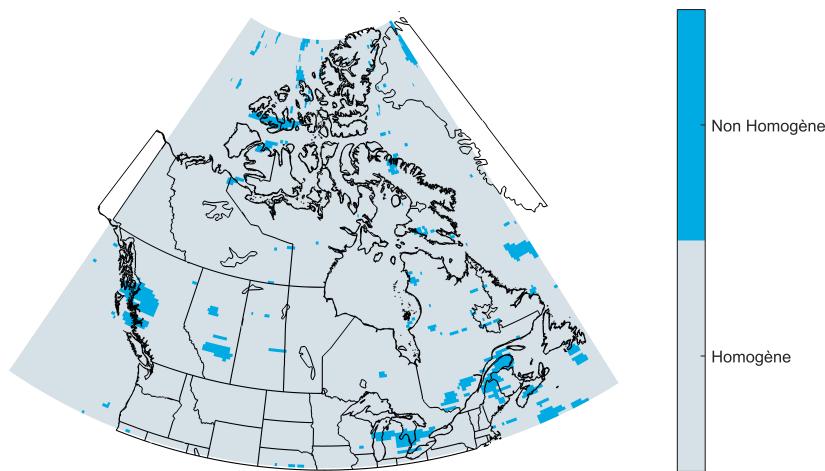


Figure 3.4 – Carte des tuiles où les séries des précipitations annuelles sont homogènes (en gris) et non homogènes (en bleu) selon l'approche de Wijngaard *et al.* (2003)

3 Cadre méthodologique de l'approche de post-traitement

3.1 Introduction

Les SMOS combinés aux précipitations journalières issues de CFSR sont développés et appliqués pour fournir des séries temporelles de précipitations présentant des caractéristiques locales semblables à celles observées. Deux points principaux ont motivé l'utilisation de cette approche. Tout d'abord, le cadre méthodologique des SMOS offre la possibilité de générer en chacun des sites un grand nombre de séries temporelles aléatoires de précipitations journalières. Ces séries générées présentent des caractéristiques statistiques similaires à celles des séries observées. Par ailleurs, la cohérence et la continuité spatio-temporelle de l'ensemble des variables simulées par la réanalyse constituent des atouts supplémentaires dont il est intéressant de tirer avantage.

L'une des difficultés de modéliser les précipitations à l'échelle journalière dans le cadre d'une approche SMOS réside dans le caractère mixte des distributions de précipitations journalières. En effet, cette distribution comporte une composante discrète à savoir l'occurrence ou non de jours secs (précipitations nulles ou en deçà d'un seuil préalablement défini) et une composante continue à savoir l'intensité durant les jours humides (précipitations strictement positives) (Neykov *et al.*, 2014). L'occurrence et l'intensité des précipitations journalières sont communément traitées séparément (Wilks, 1998). En général, l'occurrence est modélisée à l'aide d'une chaîne de Markov (Wilks, 1998) ou d'un processus de type logit/probit (Verdin *et al.*, 2015). L'intensité peut, quant à elle, être modélisée à l'aide d'une distribution Gamma (Wong *et al.*, 2014), d'une loi de Pareto généralisée (Serinaldi & Kilsby, 2014), d'une distribution mixte exponentielle (Wan *et al.*, 2005), ou encore d'une distribution mixte Gamma-Pareto (Vrac & Naveau, 2007). Dans le présent post-traitement, cette modélisation en deux parties de la distribution mixte des précipitations journalières est également adoptée et passe par la mise en place d'un modèle linéaire généralisé pour l'occurrence (GLM; Section 3.2.1) et d'un *Vector Linear Generalized Model* (VGLM; Section 3.2.1) pour l'intensité. Les SMOS, appliqués indépendamment en chacun des sites à l'échelle pan-canadienne sont considérés pour répondre au premier objectif de la thèse (Section 3 du Chapitre 1). Les résultats associés sont présentés dans un article exposé au Chapitre 4. Les SMOS sont essentiellement basés sur des méthodes de régression plus ou moins complexes, dont un rappel est présenté à la Section 3.2.1. Les développements plus spécifiques au présent projet y sont également exposés.

La généralisation du modèle de post-traitement SMOS tenant compte à la fois des aspects spatiaux et temporels constitue une suite naturelle aux modèles SMOS locaux. En effet, les SMOS sont caractérisés par des paramètres en chacun des sites, qui vont par la suite définir pour chaque jour la distribution mixte des précipitations locales en ces mêmes sites. Les générations aléatoires issues de ces distributions ne présentent donc pas forcément la cohérence spatiale ni une corrélation temporelle suffisante (*persistence*) à l'échelle journalière. La modélisation des champs de précipitations, domaine pour lequel la littérature inclut un nombre conséquent d'études, peut alors être considérée pour pallier ce problème. On peut citer les méthodes bayésiennes qui intègrent dans un seul modèle SMOS, sur un domaine spécifié, la structure spatiale des précipitations (Olson & Kleiber, 2017). Plus couramment, on retrouve l'utilisation de champs gaussiens spatiaux latents, appliqués également dans le cadre de ce projet de recherche, pour définir la structure spatiale des précipitations journalières combinées aux SMOS (Baxevani & Lennartsson, 2015; Serinaldi & Kilsby, 2014). Une brève introduction aux processus spatiaux suivie du cadre méthodologique propre à cette partie de la thèse sont développés à la Section 3.2.3. Les résultats associés font l'objet d'un second article présenté au Chapitre 5.

Les champs gaussiens latents permettent d'assurer des champs de précipitations dont la structure spatio-temporelle est similaire à celle des champs observés, mais dont les caractéristiques locales (p. ex., moyennes des intensités) sont définies par le biais des SMOS. L'étape suivante consiste à profiter de la couverture spatiale offerte par la réanalyse pour proposer des séries de précipitations aux sites dépourvus d'observations. La modélisation des champs gaussiens ne dépend pas de la présence ou non d'observations et ne nécessite pas de traitement supplémentaire (Section 3.2.3). Par contre, afin d'être en mesure de générer les séries de précipitations aux sites non observés, il est nécessaire de disposer de la distribution mixte des précipitations en ces sites et donc des paramètres décrivant ces distributions. Constatant une certaine cohérence spatiale des paramètres SMOS aux sites observés, ces derniers ont été estimés aux points de grille où CFSR comprend des séries de précipitations journalières selon deux méthodes. Les distributions mixtes des précipitations journalières locales sont alors complètement définies en ces endroits. Les modèles d'interpolation et l'approche retenue sont présentés à la Section 3.5. L'application de ces derniers fait l'objet du Chapitre 6.

La Section 3.2 expose le cadre théorique général relatif aux modèles de régression utilisés dans les SMOS et les différents modèles spatiaux, à la fois pour la simulation des champs de précipitations et l'interpolation des paramètres SMOS. La Section 3.3 s'intéresse à l'application de ces modèles et aux spécificités propres au domaine et données utilisées dans ce projet.

3.2 Considérations théoriques générales

3.2.1 Les modèles de régression

Modèles linéaires généralisés - GLM

Les modèles linéaires généralisés (*Generalized Linear Model*; GLM) font référence à une plus grande classe de modèles que les outils de régression linéaires multiples (Nelder & Wedderburn, 1972) et sont composés des trois éléments :

1. Une composante aléatoire qui consiste à associer une loi de probabilité à la variable réponse \mathbf{Y} . Pour les GLM, cette distribution doit être issue de la famille exponentielle (Normale, Bernoulli, Poisson, Gamma);
2. Un prédicteur linéaire, $\boldsymbol{\eta}$, la composante déterministe du GLM, qui est associé au vecteur de paramètre $\boldsymbol{\beta}$ de dimension p de la façon suivante :

$$\boldsymbol{\eta} = \mathbf{X}\boldsymbol{\beta}$$

3. Enfin, le troisième élément correspond à la fonction lien $g(\cdot)$. Supposée monotone différentiable, elle exprime la relation entre la composante aléatoire et le prédicteur linéaire. En notant μ_i , l'espérance de $Y_i, i = 1, \dots, n$, on obtient :

$$\begin{aligned} \eta_i &= g(\mu_i) \quad i = 1, \dots, n \\ g(\mu_i) &= x_i^t \boldsymbol{\beta} \end{aligned} \tag{3.1}$$

Les paramètres $\boldsymbol{\beta}$ sont estimés soit par la méthode du maximum de vraisemblance résolue numériquement, par exemple, à l'aide de l'algorithme de Newton-Raphson ou par la méthode des moindres carré récursifs (*Iteratively Reweighted Least Square*; IRLS).

Les GLM offrent la possibilité de décrire l'espérance d'un grand nombre de distributions conditionnelles à des covariables choisies. Or, on peut avoir besoin d'intégrer l'effet d'une covariable sur un autre paramètre, d'une distribution donnée, que celui définissant l'espérance (Maraun *et al.*, 2010). Par exemple, les paramètres de forme et de position de la loi Gamma, utilisée pour représenter les précipita-

tions journalières, peuvent être fonction des saisons (les processus générant les précipitations hivernales et estivales étant très différents). Au lieu de développer un modèle par saison, augmentant ainsi drastiquement le nombre de paramètres, il est intéressant d'appliquer un seul modèle intégrant directement cette information. Les VGLM offrent cette flexibilité et sont le sujet de la prochaine section.

Vector Generalized Linear Model (VGLM) et Vector Generalized Additive Model (VGAM)

Les VGLM forment une classe de modèles englobant les GLM dont la distribution conditionnelle de \mathbf{Y} s'exprime en fonction de la variable explicative \mathbf{x} sous la forme (Yee, 2016a) :

$$f(\mathbf{y}, \mathbf{x}, \mathbf{B}) = f(\mathbf{y}, \eta_1, \dots, \eta_M) \quad (3.2)$$

$$\begin{aligned} \eta_j &= \beta_{(j)}^T \mathbf{x} \\ &= \sum_{k=1}^p \beta_{(j),k} x_k, \quad j = 1, \dots, M \end{aligned} \quad (3.3)$$

où $f(\cdot)$ est une fonction de densité de probabilité choisie (première composante), \mathbf{B} la matrice $p \times M$ des coefficients $\beta_{(j),k}$; et η_j est le $j^{\text{ème}}$ prédicteur linéaire au regard des coefficients β_j (deuxième composante introduite à la Section 3.2.1) avec $\mathbf{x} = (x_1, \dots, x_p)^t$ et $x_1 = 1$ lorsqu'une ordonnée à l'origine est considérée. Comme pour les GLM, une fonction lien est choisie et constitue également la troisième composante (Section 3.2.1) des modèles VGLM. L'estimation des paramètres s'effectue toujours par la méthode du maximum de vraisemblance et de façon numérique à l'aide des IRLS. Les modèles VGLM constituent un outil puissant et très flexible. Ils permettent de considérer plus d'un prédicteur (p. ex., les paramètres de position et d'échelle d'une loi GEV - *Generalized Extreme Value*) et ne sont plus limités aux distributions de la famille exponentielle. Ils offrent la possibilité d'appliquer des contraintes différentes sur les paramètres de la distribution (p.ex, impact des saisons sur le paramètre de forme et de position, mais pas sur le paramètre d'échelle de la distribution GEV).

Les VGAM constituent une généralisation des VGLM, l'équation 3.3 s'écrivant comme une somme de fonctions lisses des différentes covariables (Hastie & Tibshirani, 1990; Yee, 2016b) :

$$\begin{aligned}\eta_j(\boldsymbol{x}) &= \beta_{(j),1} + \sum_{k=2}^p f_{(j),k}(x_k), \quad j = 1, \dots, M \\ \boldsymbol{\eta}(\boldsymbol{x}) &= \boldsymbol{\beta}_{(1)} + \sum_{k=2}^p \boldsymbol{f}_k(x_k)\end{aligned}\tag{3.4}$$

avec $\boldsymbol{f}_k = (f_{(1),k}(x_k), \dots, f_{(M),k}(x_k))^T$ l'ensemble des fonctions à estimer. Ces fonctions peuvent être linéaires, auquel cas on retrouve le VGLM, ou des fonctions lisses de classe \mathcal{C}_n (n étant l'ordre de continuité) telles que les splines et les p-splines. Les mêmes contraintes s'appliquant aux VGLM le sont aussi pour les VGAM. L'intérêt des VGAM repose sur la possibilité de modéliser les effets de certaines covariables de façon différente avec, par exemple, une fonction spline pour une covariable spatiale et fonction linéaire pour les autres covariables. Un meilleur ajustement aux données est dès lors possible dans certains cas.

3.2.2 Qualité des ajustements et sélection des modèles GLM, VGLM et VGAM

La somme des carrés des résidus et le coefficient de détermination constituent des outils classiques permettant d'évaluer l'ajustement des modèles de régression simple ou multiple. Cependant ces critères ne peuvent être mis en oeuvre pour les GLM, les VGLM et les VGAM. Une généralisation de ces outils est la déviance D qui compare la vraisemblance du modèle saturé (l_{sat}), *i.e.* ayant autant de paramètres que d'observations, à celle du modèle estimé (l) de la façon suivante (Lee & Nelder, 1998):

$$D = -2(l - l_{sat})$$

En théorie, on montre qu'asymptotiquement D suit une loi de χ^2 avec $(n - p)$ degrés de liberté. D peut alors être jugée significative ou non, et donc le modèle en question accepté ou non, selon un niveau de confiance, à l'aide de tests statistiques.

Le critère d'Akaike, noté AIC, utilisé dans cette thèse, permet d'identifier parmi des modèles celui qui respecte le principe de parcimonie selon lequel « les hypothèses suffisantes les plus simples sont les plus vraisemblables »(Akaike, 1974). Le critère d'AIC, fondé sur les principes de la théorie de l'information, intègre le nombre de paramètres k d'un modèle M , la vraisemblance l , et s'exprime de la façon suivante :

$$\text{AIC} = -2 \ln(l_M) + 2(k + 1)$$

Pour un même jeu de données, le modèle le plus adéquat est celui présentant la plus faible valeur de AIC. Le critère d'AIC est donc un outil de comparaison et de sélection des modèles, mais ne permet pas, contrairement à la déviance, d'évaluer la qualité de l'ajustement du modèle aux données.

3.2.3 Modélisation spatio-temporelle

Il peut être difficile de définir un phénomène physique, pour les précipitations, en ne disposant que d'une série temporelle en un ou des sites donnés, sa structure spatiale étant aussi importante à considérer pour maintes applications. Les processus spatiaux ont été développés à cet effet et regroupent un très grand nombre d'approches. Les premières applications ont été développées pour le domaine minier avec la méthode géostatistique du krigage dans les années 1970 (Krige, 1951; Matheron, 1971). Elles avaient pour but de prédire la valeur d'une variable physique d'intérêt en un point non jaugé en fonction des observations en des sites jaugés voisins et en tenant compte de la corrélation spatiale. Plusieurs champs d'applications, dont l'hydrologie, ont très vite pu bénéficier de ces approches. Elles reposent sur le fait que des observations mesurées dans un voisinage proche sont corrélées et donc plus semblables entre sites voisins qu'entre sites éloignés. D'autres approches, plus complexes, reposent sur la génération stochastique de champs spatiaux (Burton *et al.*, 2008), sur l'application de champs gaussiens latents pour générer ces mêmes champs (Leblois & Creutin, 2013), ou encore sur la combinaison des générateurs stochastiques et des approches de krigage (Vischel *et al.*, 2009). Toutes ces méthodes nécessitent une connaissance du processus physique à étudier (p. ex., précipitation, température) et sont calibrées en fonction des observations mesurées aux sites.

La très grande diversité concernant la modélisation des processus spatiaux ne permet pas d'en dresser une revue exhaustive. On se concentrera ici sur les processus aléatoires gaussiens qui ont été appliqués pour simuler les champs aléatoires spatiaux ainsi que sur les approches de krigage. Ces deux méthodes

ont été implémentées à des fins différentes. La première a servi à générer des séries post-traitées spatialement cohérentes à l'échelle journalière aux sites observés (Section 3.4). La seconde a permis de construire des distributions mixtes de précipitations journalières aux sites non jaugés (Section 3.5). Les prochaines sous-sections exposent brièvement la théorie des processus spatiaux afin d'introduire quelques définitions nécessaires à la suite des développements. Le krigage, ainsi que les champs méta-gaussiens, sont par la suite décrits.

Processus spatiaux: définitions

On note le domaine d'étude $\mathcal{D} \subseteq \mathbb{R}^d$ ($d = 2$, dans notre cas) et s l'ensemble des points du domaine. La modélisation stochastique considère chaque $z(s)$, observation d'un phénomène physique au point s , comme étant la réalisation d'une variable aléatoire $Z(s)$. L'ensemble $\{Z(s): s \in \mathbb{R}^2\}$ est appelé processus stochastique spatial, ou encore champ aléatoire, dans \mathbb{R}^d . La distribution conjointe de ce processus aux différents n sites de s est alors définie par :

$$F(z_1, \dots, z_n, s_1, \dots, s_n) = \mathbb{P}(Z(s_1) \leq z_1, \dots, Z(s_n) \leq z_n), \quad n \in \mathbb{N} \quad (3.5)$$

Modèles d'interpolation

Les méthodes d'interpolation spatiale basées sur le krigage sont des approches déterministes. D'autres approches existent, telles que les méthodes barycentriques, les polygones de Thiessen, ou encore les splines, mais ne font pas l'objet de développements dans ce manuscrit. Le lecteur intéressé peut consulter les ouvrages de Cressie (1993) et de Emery & Arnaud (2000).

Les modèles de krigage permettent d'exprimer la valeur prise par z au point s^* en fonction de la combinaison linéaire des valeurs aux points voisins de sorte que :

$$\hat{Z}(s^*) = \sum_{i \in \mathcal{D}} \lambda_i Z(s_i), \quad (3.6)$$

avec les coefficients λ_i , estimés de façon à ce que la prévision soit non biaisée ($\mathbb{E} [\hat{Z}(s^*) - Z(s^*)] = 0$) et de variance minimale ($\text{Var} [\hat{Z}(s^*) - Z(s^*)]$ minimale).

De façon plus générale, les modèles de krigeage sont des modèles de régression, mais dont les erreurs intègrent la structure spatiale du processus étudié et se définissent comme :

$$Z(s) = \mu(s) + \delta(s), \quad s \in \mathcal{D}, \quad (3.7)$$

L'espérance $\mu(\cdot)$ peut être une constante connue (krigeage simple) ou inconnue (krigeage ordinaire) ou également une fonction de l'espace (krigeage universel). La composante $\delta(\cdot)$ doit être estimée à l'aide de l'analyse spatiale de la variable d'intérêt et requiert que l'une des deux hypothèses de stationnarité du processus spatial soit vérifiée pour procéder au krigeage:

- Stationnarité de second ordre: $\mathbb{E}(\delta(s)) = 0, \quad \forall s \in D$ (même espérance en tous sites) et $C(\delta(s), \delta(s+h)) = C(h), \quad \forall s \in D$, avec C fonction de covariance et h la distance entre les sites.
- Stationnarité intrinsèque: $\mathbb{E}(\delta(s) - \delta(s+h)) = 0, \quad \forall s \in D$ (accroissement de l'espérance est nulle) et $\text{Var}(\delta(s) - \delta(s+h)) = 2\gamma(h), \quad \forall s \in D$, où γ dénote le variogramme.

On utilise de préférence le variogramme pour analyser la structure spatiale dans le cadre du krigeage, car il existe pour l'hypothèse, la moins forte, de stationnarité intrinsèque, contrairement au covariogramme (Cressie & Wikle, 2011). En effet, un processus stationnaire du second ordre est stationnaire intrinsèque, mais l'inverse n'est pas forcément vrai (le variogramme doit être borné pour assurer l'existence du covariogramme).

L'analyse variographique (étude du semi-variogramme) consiste d'abord à estimer le semi-variogramme empirique à l'aide d'estimateurs standards comme les moments (Cressie, 1993). Par la suite, on ajustera une fonction mathématique (p. ex., modèle sphérique ou exponentiel; Cressie, 1993) au semi-variogramme expérimental pour pouvoir estimer les variables inconnues en tout point du domaine (Eq. 3.6). Le lecteur désirant plus de détails sur les différentes méthodes de krigeage se référera à l'ouvrage de Cressie & Wikle (2011).

Champs métgaussiens latents

Un processus aléatoire gaussien est défini de la façon suivante (MacKay, 2003):

Définition: *Le processus aléatoire $\{Z(s): s \in \mathbb{R}\}$ est dit gaussien si toutes ses lois finies dimensionnelles $\mathcal{L}(Z(s_1), \dots, Z(s_n))$ sont gaussiennes. Autrement dit, Z est gaussien si toute combinaison linéaire $\alpha_1 Z_{s_1} + \dots + \alpha_n Z_{s_n}$ est gaussien pour tout $n \in \mathbb{N}$. La densité de probabilité conjointe s'exprime comme suit:*

$$f_{Z(s_1), \dots, Z(s_n)}(z_1, \dots, z_n) = \frac{1}{\sqrt{2\pi^n \det(\mathbf{C})}} \exp \left\{ -\frac{1}{2} [(z - \boldsymbol{\mu})^t \mathbf{C}^{-1} (z - \boldsymbol{\mu})] \right\} \quad (3.8)$$

avec $z = (z_1, \dots, z_n)^t$, $\boldsymbol{\mu} = (\mathbb{E}[Z(s_1)], \dots, \mathbb{E}[Z(s_n)])$ et \mathbf{C} la matrice de covariance dont les éléments $C_{i,j}$ sont égaux à $\text{Cov}[Z(s_i), Z(s_j)]$.

Un processus gaussien est alors complètement défini par ses deux premiers moments. Le processus est dit stationnaire si les lois conjointes restent invariantes sous translation spatiale, impliquant dans le cas gaussien $\mathbb{E}[Z(s_i)] = \mu$ et $C(Z(s_i), Z(s_j)) = C(s_i - s_j)$. Enfin, le processus est dit isotrope lorsque la distribution de probabilité reste inchangée selon la direction spatiale, et dès lors ne dépend que de la distance entre les points, i.e. $C(Z(s_i), Z(s_j)) = C(\|s_i - s_j\|) \quad \forall(i, j) \in \mathbb{N}$.

Les propriétés des champs gaussiens, la relative facilité de leur implémentation (Baxevani & Lenhartsson, 2015; Serinaldi & Kilsby, 2014) et les fondements théoriques développés et appliqués depuis une trentaine d'années en font un candidat de choix pour la modélisation des champs spatiaux (Guillot, 1999). Dans ce projet, l'intégration des champs gaussiens s'effectue à l'étape des simulations aléatoires et on parle alors de champs latents. Or, dans les cas des précipitations journalières, on cherche à disposer

d'un champ distribué uniformément sur $[0;1]$ pour générer ces simulations (Théorème de la réciproque) et dont la structure spatiale est héritée du champ gaussien. On transformera alors ces champs gaussiens en champs uniformes ($\mathcal{U}(0, 1)$). On sera alors dans le cadre métgaussien qui se définit comme suit (Kelly & Krzysztofowicz, 1997).

Définition: *Un champ aléatoire Y est dit métgaussien s'il existe une fonction monotone non décroissante $\Psi(\cdot)$, appelé anamorphose, et un champ aléatoire gaussien Z tels que : $Y = \Psi(Z)$. Ainsi, si l'on note $Z(s)$ le champ gaussien, alors le champ uniforme est donné par l'expression suivante $U(s) = \Phi(Z(s))$, Φ étant la fonction de répartition de la distribution normale centrée réduite.*

3.3 Modèles stochastiques de post-traitement de l'occurrence et de l'intensité: méthode de l'article 1

Les modèles de post-traitement des précipitations de CFSR permettent d'estimer les distributions mixtes des précipitations locales en chacun des sites et pour chaque jour de la période étudiée. L'occurrence (Section 3.3.1) et l'intensité (Section 3.3.2) sont ici post-traitées séparément. On note dans la suite $O(s, t)$ et $Y(s, t)$, respectivement, l'occurrence et la précipitation journalière non nulle, observées sur le domaine au site $s \in \{s_1, \dots, s_n\}$ au pas de temps $t \in \{1, \dots, T\}$, et dont $o(s, t)$ et $y_{(s,t)}$ sont des réalisations respectives. La précipitation journalière de CFSR au point de grille associé est identifiée par la variable $X(s, t)$. Les différentes étapes méthodologiques sont expliquées dans les prochaines sections et sont illustrées à la Figure 3.2.

3.3.1 Post-traitement de l'occurrence

La régression logistique modélise la probabilité d'occurrence des précipitations locales, conditionnelle à la précipitation CFSR, $p_{s,t} = \mathbb{P}(O(s, t) = 1 | X(s, t) = x_{s,t})$, (Wong *et al.*, 2014). Elle fait partie des GLM (Section 3.2.1) dont les variables aléatoires sous-jacentes suivent une loi binomiale. La fonction logit (fonction lien) est ici appliquée pour lier l'espérance journalière à une fonction linéaire des prédicteurs. Dans les modèles de post-traitement, une transformation logarithmique des précipitations CFSR a été retenue, car elle conduisait à de meilleurs résultats (Chandler & Wheater, 2002). Les fonctions cosinus et sinus ont par ailleurs été ajoutées pour tenir compte de la saisonnalité. La probabilité qu'un jour t

soit humide sachant la précipitation CFSR au même jour est donc donnée par :

$$\begin{aligned} g(p_{s,t}) &= \log \left(\frac{p_{s,t}}{1 - p_{s,t}} \right), \\ &= \alpha_0 + \alpha_1 \log(x_{s,t} + 1) + \alpha_2 \cos \left(\frac{2\pi d}{T} \right) + \alpha_3 \sin \left(\frac{2\pi d}{T} \right), \end{aligned} \quad (3.9)$$

où $g(\cdot)$ dénote la fonction logit, d le jour ordinal ($1 \leq d \leq 365$ ou 366), T la durée moyenne d'une année (365.25) et $\boldsymbol{\alpha} = (\alpha_i)_{i \in [0,3]}$ les coefficients de la régression estimés par maximum de vraisemblance (Annexe A).

Ainsi, la probabilité qu'un jour soit pluvieux peut s'exprimer de la façon suivante:

$$p_{s,t} = \frac{\exp \left[\alpha_0 + \alpha_1 \log(x_{s,t} + 1) + \alpha_2 \cos \left(\frac{2\pi d}{T} \right) + \alpha_3 \sin \left(\frac{2\pi d}{T} \right) \right]}{1 + \exp \left[\alpha_0 + \alpha_1 \log(x_{s,t} + 1) + \alpha_2 \cos \left(\frac{2\pi d}{T} \right) + \alpha_3 \sin \left(\frac{2\pi d}{T} \right) \right]} \quad (3.10)$$

3.3.2 Post-traitement de l'intensité

Afin de modéliser la distribution journalière de l'intensité des précipitations non nulles et conditionnelles à celles de CFSR, un modèle de régression VGLM (Section 3.2.1) a été développé. La loi Gamma à deux paramètres $\mu > 0$ et $\gamma > 0$ a été choisie pour représenter la distribution des précipitations journalières. La densité de probabilité de cette loi s'écrit :

$$f_{\mu,\gamma}(r) = \frac{\gamma}{\mu \Gamma(\gamma)} \left(\frac{\gamma r}{\mu} \right)^{\gamma-1} e^{-\gamma r/\mu}, \quad (3.11)$$

avec $r > 0$ l'intensité journalière de précipitations. La moyenne et la variance sont données par μ et μ^2/γ respectivement avec cette paramétrisation. Le modèle VGLM de post-traitement s'écrit comme suit (voir Étape 1, Figure 3.5) :

$$\begin{aligned} h(\mu_{s,t}) &= \eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 \cos \left(\frac{2\pi d}{T} \right) + \eta_3 \sin \left(\frac{2\pi d}{T} \right), \\ h(\gamma_{s,t}) &= \beta_0 + \beta_1 \log(x_{s,t} + 1), \end{aligned} \quad (3.12)$$

avec $h(\cdot)$ la fonction logarithme, et η et β les coefficients de régressions estimés par maximum de vraisemblance.

La distribution mixte des précipitations locales journalières est alors complètement déterminée par la fonction de répartition suivante :

$$F_{s,t}(r) = (1 - p_{s,t}) + p_{s,t} F_{\mu_{s,t}, \gamma_{s,t}}(r), \quad \forall r \in \mathbb{R}^+, \quad (3.13)$$

où $F_{\mu_{s,t}, \gamma_{s,t}}$ note la fonction de répartition de la loi Gamma (Eq. 3.11 et Figure 3.5-étape 2) de paramètres $\mu_{s,t}$ et $\gamma_{s,t}$, définies par le modèle VGLM (Eq. 3.12, étape 1 - Figure 3.5).

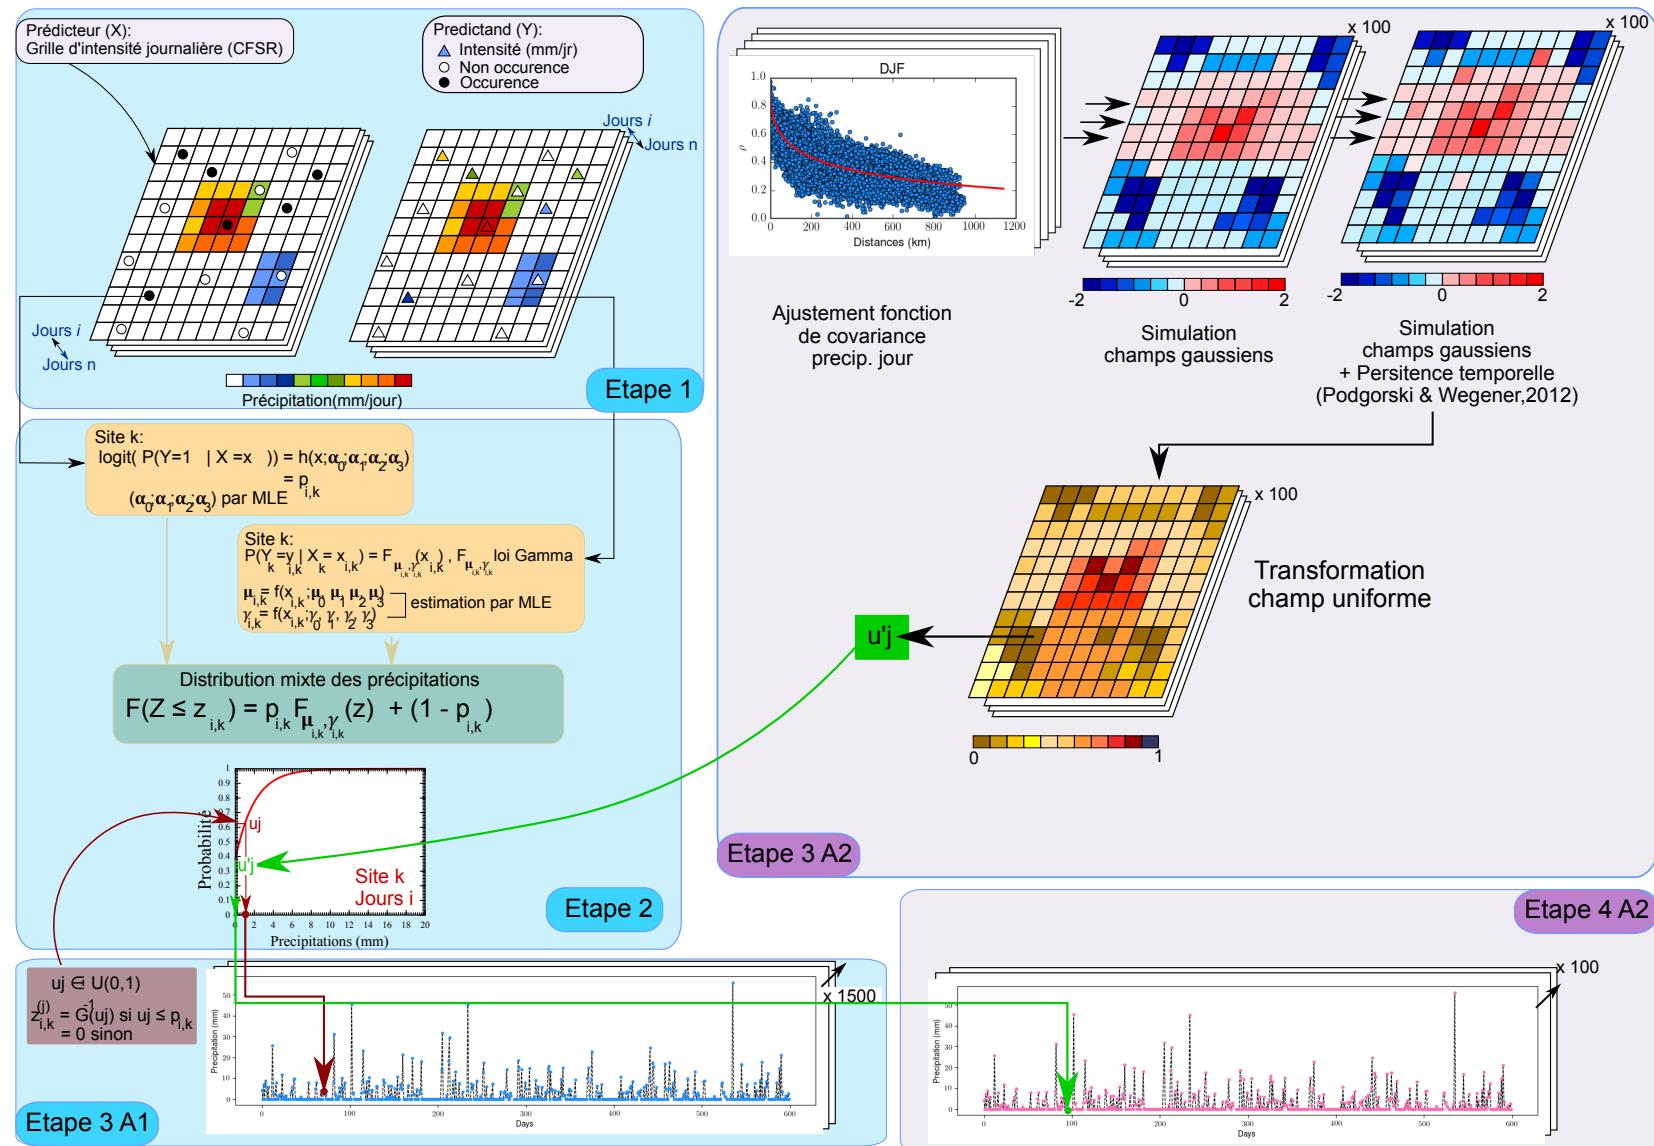


Figure 3.5 – Schématisation des différentes étapes du post-traitement stochastique pour l'article 1 et 2. Les abréviations A1 et A2 associées à certaines étapes font référence à la méthodologie spécifique à l'article 1 et 2 respectivement. Les étapes qui en sont dépourvues signifient qu'elles sont communes aux articles 1 et 2.

3.3.3 Génération aléatoire des précipitations journalières

La génération aléatoire des précipitations à cette étape du projet est réalisée de façon indépendante en chacun des sites et des pas de temps journaliers, selon l'algorithme suivant répété 1500 fois (Étape 3 A1, Figure 3.5):

Algorithm 1 Simulations des précipitations au site s

```

1:  $R_s$  precipitation empty vector of length the number of days of the 1979-209 period
2: for Each day  $t$  do
3:    $p_{s,t}$  using equation 3.10
4:    $F_{s,t}^{-1}$  using equation 3.13
5:    $u$  random value from the distribution  $\mathcal{U}(0, 1)$ 
6:   if  $u \leq p_{s,t}$  then
7:      $R_s(t) = F_{s,t}^{-1}(u)$ 
8:   else
9:      $R_s(t) = 0$ 
10:  end if
11: end for

```

L'évaluation des séries post-traitées est synthétisé dans le résumé étendu du Chapitre 4. Les résultats plus détaillés font l'objet d'un article présenté dans ce même chapitre.

3.4 Modélisation des champs méta-gaussiens spatio-temporels latents : méthode de l'article 2

Pour répondre au second objectif de la thèse, qui consiste à intégrer la structure spatiale et temporelle dans les séquences journalières de précipitations générées aléatoirement, les champs méta-gaussiens sont appliqués durant la phase des simulations aléatoires. La mise en place de ces champs sont décrits dans les sections ci-dessous et sont illustrés à travers les étapes 3 -A2 et 4 -A2 de la Figure 3.5. Les étapes d'estimations des paramètres des distributions mixtes des précipitations journalières restent les mêmes que celles énoncées plus haut (voir les étapes 1 et 2 de la Figure 3.5).

3.4.1 Modèle spatial: la fonction de covariance

On utilise habituellement dans la littérature un champ gaussien latent pour modéliser l'occurrence des précipitations journalières, et, soit une transformation de ce même champ, soit l'estimation d'un autre champ gaussien, pour modéliser leur intensité (Allcroft & Glasbey, 2003; Bárdossy & Pegram,

2009; Baxevani & Lennartsson, 2015). Un seul champ méta-gaussien est ici défini pour modéliser à la fois l'occurrence et l'intensité offrant ainsi une modélisation plus parcimonieuse. Ce champ est complètement déterminé par la fonction de covariance, $C(\cdot)$, des précipitations journalières qui reste à définir. La stationnarité et l'isotropie de $C(\cdot)$ sont les deux hypothèses simplificatrices qui ont été adoptées dans ce qui suit. En se basant sur ces hypothèses, la fonction de covariance ne dépend que de la distance, h , entre les sites.

Dans un premier temps, le covariogramme empirique (covariance en fonction de la distance) des précipitations journalières est estimé pour chaque saison. Par la suite, on choisit parmi les fonctions de covariance référencées (Cressie & Wikle, 2011), celle qui s'ajuste le mieux, suivant le critère des moindres carrées, au covariogramme empirique. Par ailleurs, on n'estimera pas ici une fonction de covariance pour chaque jour de la période [1979-2009], car cela ferait augmenter le nombre de paramètres de façon considérable. On considère pour mettre en place un covariogramme empirique, les corrélations des précipitations journalières d'une même saison entre les paires de points. La dépendance temporelle à court terme (autocorrélation de décalage de 1 jour) des champs méta-gaussiens est introduite séparément et est discutée ci-après (Section 3.4.2).

L'intermittence des précipitations et la distribution de ces dernières étant très asymétrique avec une masse importante en zéro (Habib *et al.*, 2001), la corrélation spatiale entre les paires de points des précipitations journalières est estimée par le coefficient de Kendall, τ_k , au lieu du coefficient de corrélation linéaire de Pearson ρ (Serinaldi, 2008). Les travaux de Habib *et al.* (2001) et de Ciach & Krajewski (2006) ont, en effet, analysé les propriétés de l'estimateur du coefficient classique de Pearson et ont montré l'incertitude des estimations lorsque les échantillons possèdent des distributions fortement dissymétriques. Les coefficients de Kendall, τ_k , sont ensuite transformés en coefficients de Pearson à l'aide de l'équation $\rho = \sin(\pi\tau_k/2)$ (Kendall, 1962) avant l'ajustement de la fonction de covariance. Les fonctions de la famille de Matérn (exponentielle, Whittle, Matérn) ont été considérées (Stein, 1999). Elles s'expriment comme suit :

$$C(h) = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\sqrt{2\nu} \frac{h}{\rho} \right)^\nu \mathcal{K}_\nu \left(\sqrt{2\nu} \frac{h}{\rho} \right), \quad (3.14)$$

avec Γ , la fonction Gamma, \mathcal{K}_ν la fonction de Bessel de seconde espèce, et ν les paramètres saisonniers de la fonction de covariance. La fonction exponentielle correspond au cas particulier où $\nu = 2$.

Un ensemble de 100 simulations aléatoires spatialement corrélées suivant une loi normale, mais temporellement indépendante est généré sur l'ensemble des sites du domaine à l'aide du package RandomField de R (Schlather *et al.*, 2017) (voir étape 3-A2, Figure 3.5). Le nombre de simulations a été réduit par rapport à la Section 3.3 pour des raisons de temps de calcul.

3.4.2 Dépendance temporelle

La dépendance temporelle à court terme est intégrée dans le modèle spatial du champ gaussien, noté $Z(s)$ et dont $z(s)$ est une réalisation, par la relation développée par Podgórski & Wegener (2012) pour donner $W(s, t)$ le nouveau champ spatio-temporel suivant :

$$w(s, t + 1) = \rho_\delta w(s, t) + \sqrt{1 - \rho_\delta^2} z(s) \quad (3.15)$$

où ρ correspond à l'autocorrélation de décalage 1 des séries de précipitations journalières au site s . Comme pour la corrélation spatiale, l'autocorrélation est d'abord estimée à l'aide du coefficient de Kendall avant d'être transformée en coefficient de corrélation de Pearson (ρ_δ).

L'équation 3.15 est ensuite appliquée aux 100 réalisations $z(s)$ simulées aléatoirement pour chaque pas de temps de la période d'étude et en chaque site s (voir étape 3-A2, Figure 3.5). Prenant, comme hypothèse que w suit toujours une distribution gaussienne, on applique le théorème de la réciproque, $\Phi(w)$, pour générer les champs uniformes $u(s, t)$ nécessaires à la simulation des précipitations journalières à partir de l'équation 3.16. Ainsi la modélisation des précipitations $R(s, t)$, illustrée à l'étape 4-A2 de la Figure 3.5, peut se résumer par l'équation suivante :

$$R(s, t) = \begin{cases} F^{-1}(s, t) \circ \Phi(W(s, t)) & \text{si } \Phi[W(s, t)] > p_{s,t} \\ 0 & \text{si } \Phi[W(s, t)] \leq p_{s,t} \end{cases} \quad (3.16)$$

Le champ précédent est complètement déterminé par les paramètres de la fonction de distribution mixte des précipitations (F , équation 3.13) et de la fonction de covariance. Numériquement, l'algorithme 1 est mis en oeuvre, mais diffère lors de la génération aléatoire d'une probabilité issue d'une loi uniforme ($\mathcal{U}(0, 1)$), qui n'est plus indépendante d'un site à l'autre et d'un jour à l'autre, mais est ici donnée par $\Phi[W(s, t)]$.

Le résumé étendu exposé au Chapitre 5 récapitule le processus d'évaluation de cette approche ainsi que les principaux résultats obtenus. Un article scientifique associé à ce travail est également ajouté à ce même chapitre.

3.5 Estimation des distributions mixtes des précipitations journalières aux sites sans observations: méthode de l'article 3

Les modèles précédents permettent de simuler des champs latents ayant la même structure spatio-temporelle que les précipitations journalières. Il n'est cependant pas possible à partir de ces champs de générer les valeurs de précipitations en tout point du domaine. Il faut, en effet, pour cela disposer des paramètres caractérisant les distributions mixtes des précipitations journalières en ces mêmes points. Deux approches ont été appliquées, à savoir l'interpolation des paramètres et l'utilisation d'un VGAM spatial. Le but de ces deux approches consiste à estimer les coefficients de l'équation 3.13 en tout point. La seconde méthode est cependant plus parcimonieuse que la première, car elle requiert un nombre de paramètres beaucoup moins important. La Figure 3.6 illustre les étapes de ces deux méthodes.

L'interpolation par krigage passe par l'établissement du semi-variogramme pour chacun des six paramètres de l'équation 3.13 en suivant la méthodologie décrite à la Section 3.2.3. L'hypothèse d'isotropie a été adoptée et le type de krigage, ordinaire ou universel est choisi selon les paramètres, comme décrit à la Section 3.2.3.

Le VGAM spatial considère un seul modèle spatial régional pour estimer les paramètres de la distribution mixte des précipitations journalières. Il s'agit des mêmes modèles VGAM introduits à la Section 3.2.1, mais pour lesquels une covariable spatiale est ajoutée. Ainsi, pour le post-traitement de l'occurrence ou de l'intensité, la procédure est la suivante (voir étape 2, Méthode 2, Figure 3.6) :

1. Les séries journalières des occurrences (intensité) de tous les sites d'un domaine choisi sont regroupées pour ne former qu'un seul échantillon.

2. Les covariables spatiales explicatives (p. ex., latitudes, distances aux masses d'eau) permettant d'expliquer l'occurrence (l'intensité), à travers les modèles VGAM, sont sélectionnées.
3. Deux fonctions de vraisemblance sont définies sur l'ensemble du domaine, une pour l'occurrence et une pour l'intensité. Dans les modèles VGAM spatiaux, les paramètres $\{\alpha, \eta, \beta\}$ de l'équation 3.13 deviennent des fonctions de l'espace et du temps. En prenant le paramètre de position de la loi Gamma (équation 3.12), le VGAM spatial s'énonce comme suit :

$$\begin{aligned} h(\mu_t(s)) = & \eta_0(s) + \eta_1(s) \log(x_{s,t} + 1) + \\ & \eta_2(s) \cos\left(\frac{2\pi d}{T}\right) + \eta_3(s) \sin\left(\frac{2\pi d}{T}\right) + G(\text{Cov}(s)) \end{aligned} \quad (3.17)$$

avec $G(\cdot)$ une fonction lisse de l'espace (p. ex., spline cubique) et Cov une covariable de l'espace (p. ex., la latitude). Le choix des covariables pour chacun des paramètres de la distribution mixte est discuté au Chapitre 6.

Finalement, pour évaluer la performance de ces deux méthodes à bien reproduire les distributions mixtes des précipitations journalières en des sites non observés, la validation croisée k -fold (*k-fold cross validation*) est utilisée (Stone, 1974). Avec cette approche, l'échantillon initial est aléatoirement subdivisé en k parties d'égales tailles. Le sous-échantillon k est retenu pour la validation tandis que les autres ($k-1$) échantillons sont utilisés pour la calibration. Le processus est répété k fois de façon à ce que chaque sous-échantillon ait été pris en compte une fois pour la validation. Une valeur de $k = 10$ a été utilisée.

Les résultats associés à ce travail sont présentés dans un article au Chapitre 6, précédé par une synthèse en français de ces derniers.

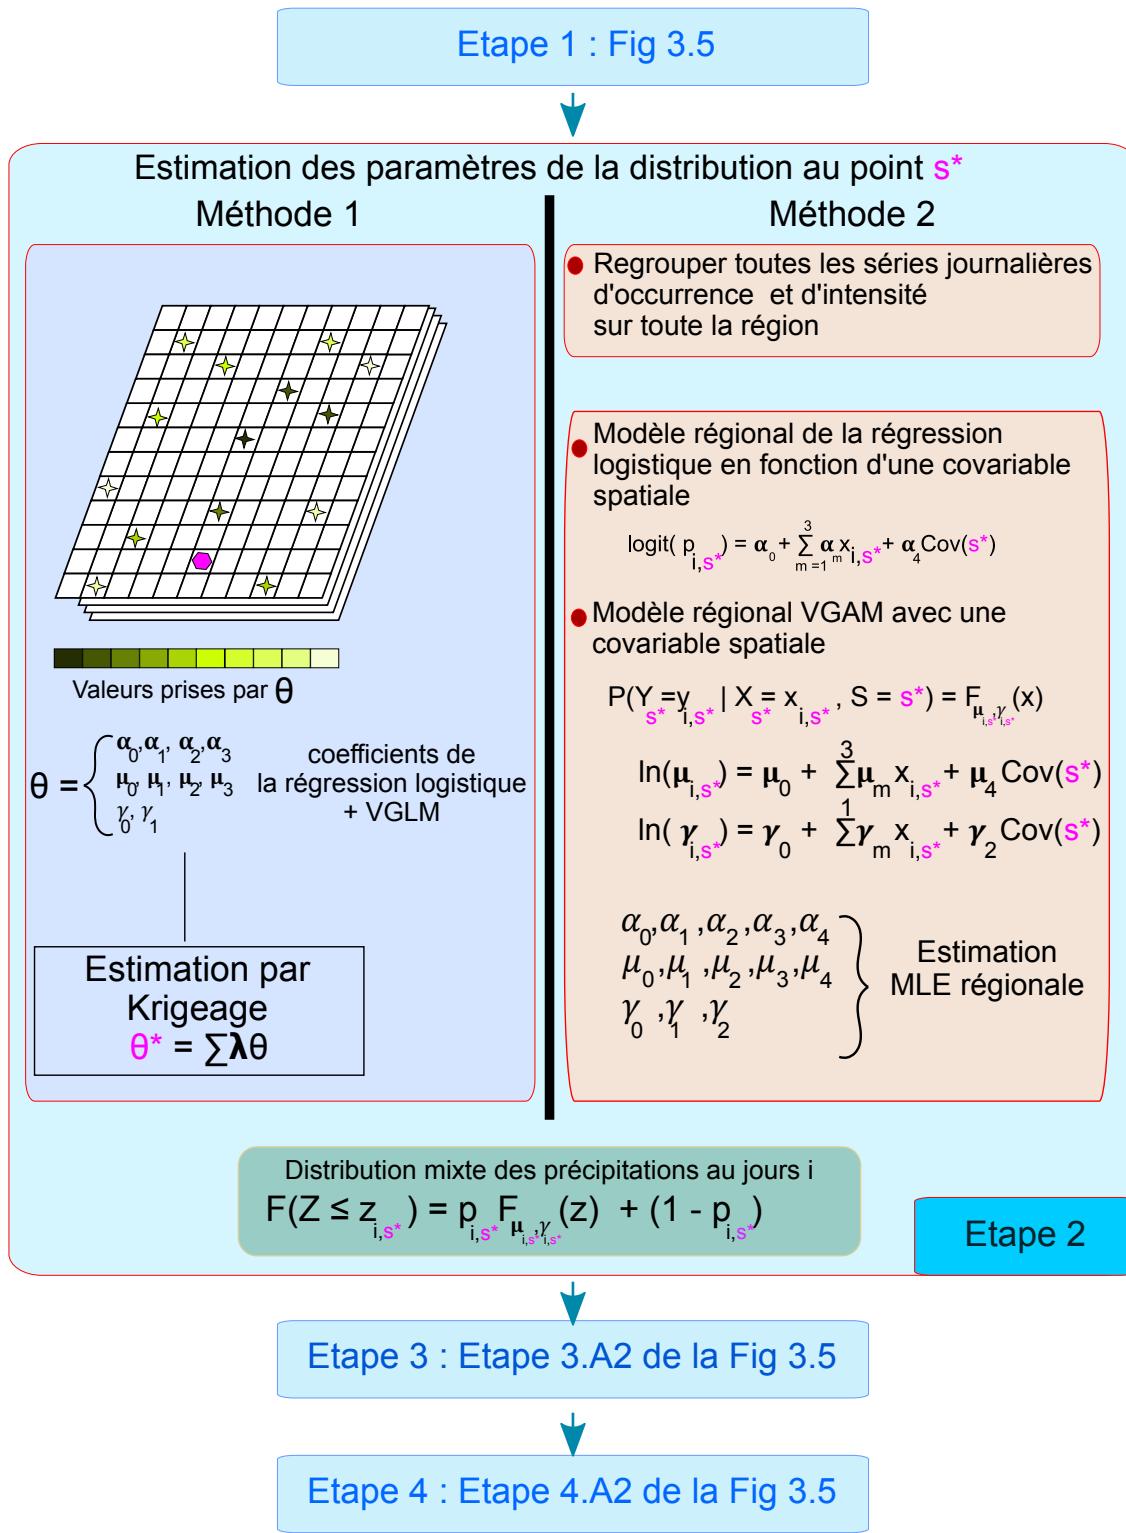


Figure 3.6 – Schématisation de l'estimation de la distribution journalière aux sites s^* sans observation selon le krigage (Méthode 1) et avec les modèles VGAM régionaux (Méthode 2). Les étapes pour l'estimation des champs météo-gaussiens latents et la génération aléatoire des précipitations sont les mêmes que celle de la Figure 3.5 (Étapes 3.A2 et 4.A2, respectivement)

POST-TRAITEMENT STOCHASTIQUE DES PRÉCIPITATIONS JOURNALIÈRES DE CFSR AU CANADA

Sommaire

1	Introduction	47
2	Article: Stochastic post-processing of CFSR daily precipitation across Canada	49

1 Introduction

Ce chapitre vise à répondre à l'objectif 1 de la thèse en explorant la méthode de post-traitement développée et appliquée. L'objectif consiste à voir dans quelle mesure une réanalyse post-traitée permet de reproduire les caractéristiques locales des séries de précipitations.

Le choix de la méthode de post-traitement est entièrement conditionné par l'application finale souhaitée des données de précipitations (Maraun *et al.*, 2010). Dans le présent travail de recherche, la possibilité de corriger les biais de façon systématique tout en garantissant une variabilité temporelle propre aux précipitations journalières locales constitue un point qui a fortement guidé ce choix méthodologique. Par ailleurs, le potentiel pour des développements postérieurs de généralisation de cette approche aux sites avec peu ou pas de données était également un point fondamental dont il fallait tenir compte. Le but ultime vise à utiliser ces séries temporelles de précipitation par exemple comme intrant

de modèles hydrologiques. Tout naturellement, les simulateurs de temps (cf. Section 3.3 du Chapitre 2) se sont imposés comme une approche intéressante pour répondre à ces points.

Les modèles WG sont conditionnels à des variables permettant d'expliquer les précipitations locales. Deux choix restent à faire concernant ces variables: 1) le type de modèles ou de jeu de données à partir duquel les variables seront sélectionnées (p. ex., MRC, réanalyses) et 2) le choix des variables explicatives. Pour répondre au premier point, des données à grande échelle représentatives du climat et de la météorologie passée sont recherchées. Les données de réanalyses sont dès lors des candidats tout désignés. Parmi les réanalyses disponibles, CFSR a été sélectionnée, d'une part, pour sa haute résolution spatiale (relativement à d'autres réanalyses) et, d'autre part, bien qu'on ne puisse parler d'assimilation, pour la prise en compte des précipitations observées dans le modèle numérique. Beaucoup d'auteurs se sont intéressés à la sélection de variables atmosphériques, telles que la pression au niveau de la mer (*Sea Level Pressure*, SLP), ou encore les hauteurs géopotentielles (cf. Asong *et al.*, 2015; Vaittinada Ayar *et al.*, 2015, pour des exemples). Ce choix est justifié par une meilleure simulation de ces variables par les modèles numériques que d'autres variables telles que les précipitations. Cependant, au-delà du travail complexe de sélection de ces variables, leur nombre devient vite assez conséquent. Dans cette thèse, la volonté de développer des modèles statistiques parcimonieux a conduit à choisir directement la précipitation de la réanalyse CFSR. Il a été montré, dans une analyse préliminaire, que CFSR reproduisait adéquatement certaines caractéristiques des précipitations observées. Par ailleurs, les séries de précipitations journalières issues de CFSR présentaient une bonne correspondance temporelle avec celles observées (corrélation temporelle). On rappelle ici que les méthodes mises en oeuvre sont la descente d'échelle appliquée aux variables des modèles climatiques régionaux et globaux (Chapitre 2, Section 3). On parle cependant de post-traitement de la réanalyse pour éviter les confusions.

La suite de ce chapitre est composée de la Section 2 qui constitue la publication en anglais précédée par une synthèse des résultats en français. Les figures du matériel supplémentaire (*supplementary material*), auxquelles il est fait référence dans l'article ci-dessous, sont regroupées à la Section 1 de l'Annexe B.

2 Article: Stochastic post-processing of CFSR daily precipitation across Canada

Auteurs

Dikra Khedhaouiria¹, Alain Mailhot¹, Anne-Catherine Favre²

¹ Institut national de la recherche scientifique, Centre Eau Terre Environnement (INRS-ETE), 490 de la Couronne, Québec, Québec/Canada.

² Univ. Grenobles Alpes, CNRS, IRD, IGE, Grenoble INP*, F-38000 Grenoble, France

Publication ciblée

Article accepté pour publication dans *Atmosphere-Ocean*

Date d'acceptation : 12 décembre 2017

Résumé étendu

Les objectifs de cette publication consistent à évaluer la performance d'une approche de post-traitement stochastique de type régression appliquée aux précipitations de la réanalyse CFSR, à reproduire des indices climatiques locaux. Le résumé suivant présente un rappel succinct du cadre statistique (plus de détails sont donnés à la Section 3.3 du Chapitre 3), les méthodes d'évaluation des modèles de post-traitement, ainsi que les principaux résultats.

Cadre statistique et méthode d'évaluation

L'approche de post-traitement de l'occurrence et de l'intensité de la réanalyse CFSR à l'aide respectivement des GLM et des VGLM est détaillée à la Section 3.3 du Chapitre 3.

L'évaluation de l'approche porte, dans un premier temps, sur les deux modèles de post-traitement pris séparément à l'aide du score de Brier (*Brier Score*; BS) et du CRPS (*Continous Ranked Probability Score*) pour l'occurrence et l'intensité respectivement (Friederichs & Thorarinsdottir, 2012; Wilks, 2011).

$$\text{BS} = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2, \quad (4.1)$$

$$\text{CRPS} = \frac{1}{N} \sum_{i=1}^N \int_{z=-\infty}^{z=+\infty} [F_i(z) - \mathbb{1}(z - x_i)]^2 dz, \quad (4.2)$$

avec N le nombre de jours, o_i , p_i sont, respectivement, l'occurrence observée au jour i (1 ou 0) et la probabilité qu'il y ait une précipitation non nulle ce jour-là. F_i est la fonction de répartition de la variable Z au jour i et $\mathbb{1}(.)$ la fonction de Heaviside pour l'intensité x_i . Le BS et le CRPS sont deux scores équivalents au *Root Mean Squared Error* (RMSE) mais dans un espace probabiliste (Wilks, 2011). Ils sont de ce fait orientés négativement, *i.e.* plus les valeurs sont proches de zéro plus le système de prédition est bon. Afin de comparer les performances à travers les différents sites, on utilise généralement le *Brier Skill Score* (BSS) et le *Continuous Ranked Probability Skill Score* (CRPSS) qui compare la performance d'un système de prédition (ici le post-traitement) par rapport à une référence, généralement la prédition climatologique. Ainsi pour l'occurrence, la fréquence empirique des précipitations constitue la prédition climatologique. Pour l'intensité, la distribution empirique ou une distribution gamma ajustée sur les précipitations observées non nulles correspond au système de référence. Les deux *Skill Scores* s'écrivent :

$$\text{BSS} = 1 - \frac{\text{BS}}{\text{BS}_{ref}} \quad (4.3)$$

$$\text{CRPSS} = 1 - \frac{\text{CRPS}}{\text{CRPS}_{ref}} \quad (4.4)$$

$$(4.5)$$

Le BSS et le CRPSS sont définis sur $-\infty$ et 1 et s'interprètent de la même façon. Un *Skill Score* égal à 1 indique un système de prédition parfait alors que des valeurs négatives suggèrent de meilleures prédictions en utilisant la climatologie.

Les paramètres des approches GLM et VGLM en chaque site permettent de définir les distributions des précipitations pour chaque jour de l'année à chacun de ces sites et à partir desquelles sont simulées aléatoirement 1500 séries temporelles journalières probables. Les séquences sont évaluées à travers certains indices annuels développés par *Expert Team on Climate Change Detection and Indices* (ETCCDI) décrits au Tableau 4.1 :

Tableau 4.1 – Indices climatiques de précipitations de la liste de l'ETCCDI calculés aux échelles annuelles et saisonnières (adapté de Zhang *et al.* (2011))

Identifiant	Nom	Description	Unité
<i>Durée</i>			
CDD	Nombre de jours secs consécutifs	Maximum annuel du nombre de jours secs consécutifs (< 1 mm)	jour
CWD	Nombre de jours humides consécutifs	Maximum annuel du nombre de jours humides consécutifs (≥ 1 mm)	jour
<i>Fréquence</i>			
R10mm	Nombre de jours avec fortes précipitations	Nombre annuel de jours avec des précipitations ≥ 10 mm	jours
R20mm	Nombre de jours avec très fortes précipitations	Nombre annuel de jours avec des précipitations ≥ 20 mm	jours
<i>Intensité</i>			
PRCPTOT	Précipitation totale annuelle	Précipitation totale annuelle	mm
SDII	Intensité des jours humides	Moyenne annuelle des précipitations pour les jours humides (≥ 1 mm)	mm/jour
Rx1day	Précipitation maximale sur 1 jour	Maximum annuel des précipitations 1 jour	mm
Rx5day	Précipitation maximale sur 5 jours consécutifs	Maximum annuel des précipitations 5 jours consécutifs	mm
R95p	Jours très humides	Totaux annuels des précipitations journalières >95th percentile de la distribution des précipitations journalières observées sur la période de référence	mm
R99p	Jours extrêmement humides	Totaux annuels des précipitations journalières >99th percentile de la distribution des précipitations journalières observées sur la période de référence	mm

Les séries annuelles et saisonnières des indices sont calculées pour les observations, les précipitations CFSR et pour chacune des 1500 séries post-traitées. Les distributions des valeurs annuelles de ces indices sont comparées dans un premier temps en utilisant les tests de Anderson-Darling et de Kolmogorov-Smirnov (ADKS) à un seuil de confiance à 95%. Dans un second temps, le biais, la variabilité interannuelle et le RMSE de ces séries sont examinés.

Principaux résultats

Les modèles de post-traitement combinés à la précipitation CFSR présentent un meilleur pouvoir prédictif que la simple climatologie, aussi bien pour l'occurrence que pour l'intensité des précipitations. En d'autres termes, la probabilité d'occurrence pour une journée donnée est, en moyenne, mieux prédite que la climatologie observée pour ce même jour, de même pour l'intensité.

Les séries annuelles des indices climatiques analysées en termes de moyenne, de variabilité et d'erreurs quadratiques moyennes (RMSE) ont montré des performances variables selon les régions et les saisons. On retiendra les points suivants :

- Pour tous les indices, on note qu'aux sites initialement bien simulés par la réanalyse CFSR selon les statistiques retenues, les séries post-traitées ne montrent pas de dégradation de ces performances. Par contre, les sites affichant de moins bonnes performances, voire de mauvaises performances, ce qui représente un pourcentage important de stations, montrent systématiquement de meilleures estimations pour tous les indices relativement aux observations;
- Les indices liés aux intensités de précipitations sont très bien reproduits dans les séries post-traitées, surtout les indices PRCPTOT, SDII et, dans une moindre mesure, les indices liés aux

précipitations extrêmes tels que Rx1day et Rx5day, aussi bien en termes de biais et que de variabilité interannuelle;

- Les indices associés à la fréquence des précipitations, R10mm et R20mm, sont également bien représentés avec un biais considérablement réduit et une variabilité interannuelle de ces séries d'indices proches des observations, surtout à l'échelle annuelle;
- Enfin, les indices caractérisant les durées maximales annuelles de jours secs et humides (CDD et CDW) sont en moyenne sous-estimés dans les séries post-traitées. Bien que ces indices ne caractérisent qu'une partie de la durée des événements (maximum), le manque de persistance, quantifié par l'autocorrélation temporelle, dans les séries post-traitées est généralement observé.

Les principaux résultats montrent la pertinence de post-traiter les réanalyses. On peut constater, en effet, que CFSR sans post-traitement montre des biais très importants et une variabilité sous-estimée pour beaucoup d'indices, qui peuvent en partie être expliqués par des effets d'échelles (problème de représentativité). Cette étude montre également l'intérêt de cette approche statistique utilisant des modèles simples avec peu de paramètres, et pouvant corriger simultanément plusieurs aspects des séries de précipitations issues de CFSR. Cependant, des caractéristiques comme la persistance des séries journalières (autocorrélation temporelle), la variation interannuelle des extrêmes restent encore à améliorer et font partie des développements exposés dans le Chapitre 5.

Abstract

Reanalyses, based on Numerical Weather Prediction (NWP) methods assimilating past observations, provide continuous precipitation datasets and represent interesting options to assess the climatology of regions with sparse station networks (e.g., Northern Canada). However, reanalysis series cannot be directly used due to possible biases and mismatch between their spatial and temporal resolutions with the one needed for local applications. To address these issues, a Stochastic Model Output Statistics (SMOS) approach was selected to post-process precipitation series simulated by the Climate Forecast System Reanalysis (CFSR) across Canada. This approach uses CFSR precipitation as a covariate and is based on two regression models, the first one, a logistic regression, that deals with precipitation occurrence, and, the second, a vector generalized linear model (VGLM), for precipitation intensity. At-site post-processed daily precipitation series are randomly generated using the SMOS approach, and selected climate indicators from the CCI/CLIVAR/JCOMM Expert Team (ET) on Climate Change Detection and Indices (ETCCDI) are estimated and compared to corresponding observed and CFSR values. The two models in the SMOS approach, in addition to adequately correcting systematic biases, produced better predictions than the climatology of the wet and dry and intensity sequences. Additionally, the SMOS generally yields consistent climate indices when compared to those from CFSR without post-processing, though there is still room for improvement for specific indices (e.g., annual maximum of cumulative wet days).

1 Introduction

Precipitation records are essential for urban infrastructure design, power production, and flood control (Devine & Mekis, 2008). Accurate rainfall datasets over long periods of time, from dense station networks, are necessary for several applications like the design of urban infrastructures based on Intensity-Duration-Frequency (IDF) curves (Canadian Standards Association, 2012) or for agricultural impact assessments (Ambrosino *et al.*, 2014).

First available precipitation records across Canada date back to the 1870s (Metcalfe, Routledge, and Devine, 1997), and cover relatively short periods of time with limited and uneven spatial coverage. The need to access alternative daily precipitation datasets extending the coverage of the current network is then particularly important in Canada, especially in northern regions which are expected to develop in the near future (Allard & Lemay, 2012).

Among the newly available datasets, reanalyses represent an attractive alternative for assessing the

historical climate of poorly monitored regions. Reanalysis reconstructs the past state of the atmosphere by using Numerical Weather Prediction models that assimilate past observations, generating spatially- and temporally-continuous meteorological fields, which are also consistent (Bengtsson & Shukla, 1988). Several reanalysis datasets have been developed in recent years. They differ, including other aspects, by their assimilation techniques, atmospheric models, spatial and temporal resolutions, and the covered time periods. Reanalysis products are extensively used to drive Regional Climate Models (RCM) for reference periods, but are also increasingly employed to directly assess historical climate and weather series (Bosilovich *et al.*, 2008; Donat *et al.*, 2014; Zhang *et al.*, 2013, among others). Many studies have used precipitation datasets from reanalysis over different climatic regions (e.g., Southern Africa for Zhang *et al.*, 2013), at different time scales (e.g., seasonal mean by Higgins *et al.*, 2010) and investigated different characteristics (e.g., analysis of extremes by Donat *et al.*, 2014). This literature review highlights that reanalysis performance depends on the selected characteristics (e.g., annual maximum), the statistics (e.g., mean over a given period), the regions, the period, and the temporal scale. Comparisons of various reanalyses over different regions (Bromwich *et al.*, 2011; Eum *et al.*, 2014; Rusticucci *et al.*, 2014, among others) have not demonstrated that a particular reanalysis is systematically better than the others.

Precipitation reanalysis may need to be post-processed before it can be used (e.g., as input data for hydrological models or impact studies). The post-processing of the precipitation reanalysis aims to correct possible bias and scale mismatch (representativeness error; Tustison *et al.*, 2001) between the grid-cells and at-site precipitation. Several approaches dealing with the scale discrepancy between the Global or Regional Climate Model (GCM or RCM) and the local scale variables, also known as downscaling methods, have been proposed in the literature. These methods can be physically- (Fowler *et al.*, 2007) or statistically-based (see Maraun *et al.*, 2010, for an extensive review of these approaches). The post-processing used in this study is based on statistical tools that belong to the "Stochastic Model Output Statistics" family of methods (SMOS, Maraun *et al.*, 2010; Wong *et al.*, 2014). The SMOS enables local-scale time series generation by explicitly modeling the local scale variability of precipitation through a statistical link (usually regression models) between large-scale and its local-scale weather observation (Maraun, 2013). This approach therefore differs from deterministic Model Output Statistics (MOS) approaches in which biases are "removed" through a correction function relating simulated and observed variables that do not account for any noise unexplained by the predictors (e.g., Quantile mapping; Piani *et al.*, 2010). The current research also showed similarities with the fields of the statistical modeling of precipitation (Wilks & Wilby, 1999) but differed by the condition-

ning physical variable. In fact, the statistical modeling of precipitation generally uses several reanalysis synoptic covariates (exogenous to the precipitation) that drive the precipitation process such as the Sea Level Pressure (SLP), the geopotential height or the specific humidity (Lavers *et al.*, 2013).

The objective of this paper is to investigate how a stochastic post-processing, based on reanalysis daily precipitation series, may be used to estimate at-sites climate indicators (e.g., annual maximum of wet spell durations). This study is a first step in the development of a post-processing method whose objective is to take advantage of the post-processed information provided by the reanalysis to stochastically generate precipitation series at ungauged sites. The SMOS approach was therefore first applied at sites where observations were available to check the performance consistency of this approach across a large domain with contrasting climatic regions. Further works will consider more advanced models to improve, for instance, the representation of the spatio-temporal structure (Ben Alaya *et al.*, 2017; Serinaldi & Kilsby, 2014). The goal is to generate various historical statistics at sites with short or incomplete records or at ungauged sites. This is a particularly important issue in Canada, where the station network density is very low, especially in the northern regions. The Climate Forecast System Reanalysis (CFSR, Saha *et al.*, 2010) was considered. The relative performance of post-processed and CFSR precipitation

series in terms of estimated annual and seasonal climate indicators was also investigated. The selected approach enabled to correct and to downscale daily CFSR precipitation. However, other climate characteristics at different time scale, like annual duration of wet spells, were not explicitly corrected by the post-processing approach therefore and were then worth being evaluated even at calibration sites. Comparison with CFSR datasets is relevant as it could be expected that CFSR displayed good performance for climatic indicators at annual or seasonal time scale. The selected post-processing approach proceeds in two steps, the first one dealing with precipitation occurrence, and the second with intensity on the day with precipitation.

Few studies using stochastic approaches to downscale reanalysis-driven GCM/RCM precipitation have been carried out (Eden *et al.*, 2014; Wong *et al.*, 2014), and, to our knowledge, only Eum *et al.* (2017) has directly used reanalysis precipitation for downscaling purposes. Wong *et al.* (2014) used this methodology to post-process reanalysis-driven RCMs for nine stations across the United Kingdom. The authors also explicitly modeled precipitation extremes through a mixture of gamma and Generalized Pareto distributions. The authors demonstrated the ability of this approach to correct systematic bias and to provide good estimates of local precipitation distributions for a wide range of quantiles. Very high quantiles were better represented by the mixture distribution, but were computationally

expensive. Eden *et al.* (2014) used a similar approach to assess the added value of post-processed RCMs relative to post-processed GCMs. They showed that, according to some skill scores, downscaled precipitation using GCM as a predictor outperformed the one using RCM as a predictor. The differences in the atmospheric modeling in the GCM and the RCM were mentioned by these authors as a possible explanation for these counterintuitive findings. Vaittinada Ayar *et al.* (2016) reached a similar conclusion after applying six statistical downscaling methods, including SMOS, to reanalysis-driven GCM precipitation and five reanalysis-driven RCM. Across Canada, Asong *et al.* (2016a) used a multi-site Generalized Linear Model (GLM) framework to simulate daily precipitation series and temperature over the Prairie Provinces by using large-scale variables from the NCEP/NCAR Reanalysis I (Kalnay *et al.*, 1996). However, their aim was not to post-processed reanalysis precipitation, as in the current study, but to simulate from large-scale weather variables (e.g., relative humidity) local-scale daily precipitation distributions (Perfect Prog method, Maraun *et al.*, 2010). They also applied the multi-site GLM model parameters to regrid large-scale covariates from the Earth System Model (ESM) in order to evaluate climate change impact on daily precipitation and temperature (Asong *et al.*, 2016b). The two novel contributions brought by this paper were, first, to only use precipitation from the reanalysis as a covariate, which results in a simple approach that can be readily implemented and second, to investi-

gate a much larger geographic region encompassing a range of diverse climates.

The paper is structured as follows. Available datasets are presented in Section 2, while the stochastic post-processing framework is described in Section 3. Section 4 presents the evaluation approach and results are summarized in Section 5. Finally, the conclusion is given in Section 6.

2 Study domain and datasets

Daily-observed precipitation series at 4 881 stations were initially considered, 463 of these belonging to the second generation Adjusted Precipitation for Canada dataset (APC2; Environment and Climate Change Canada, 2013; Mekis & Vincent, 2011). APC2 series were adjusted to account for wind undercatch, evaporation, funnel wetting, with regards to rain, and improved snow density assessment (Devine & Mekis, 2008; Mekis & Vincent, 2011). The remaining stations were provided by Environment and Climate Change Canada and the *Ministère du Développement Durable, de l'Environnement et de la Lutte contre les Changements Climatiques* (MDDELCC) of Québec. For this study, station records were preferred to interpolated datasets since interpolation errors in gridded products based on sparse station networks can be high, especially for extremes and climate indices (e.g., Contractor *et al.*, 2015; Gervais *et al.*, 2014b; Hofstra *et al.*, 2010; Way *et al.*, 2016).

Quality control of the observed series required the following criteria: 1) each year was required to have less than 10% missing daily values to be considered as a valid year; 2) stations were required to have at least 10 valid years in the study period (1979-2009) with more than five consecutive valid years. This last criterion was imposed to keep the short-length northern stations in the studied

network and to avoid datasets which were excessively sparse at the annual scale. Further quality control steps, presented in Appendix A, were also applied. A total of 1,891 valid precipitation series were identified and further considered for analysis. Figure 1 presents the spatial distribution of the selected stations and the climate regions as defined by Plummer *et al.* (2006).

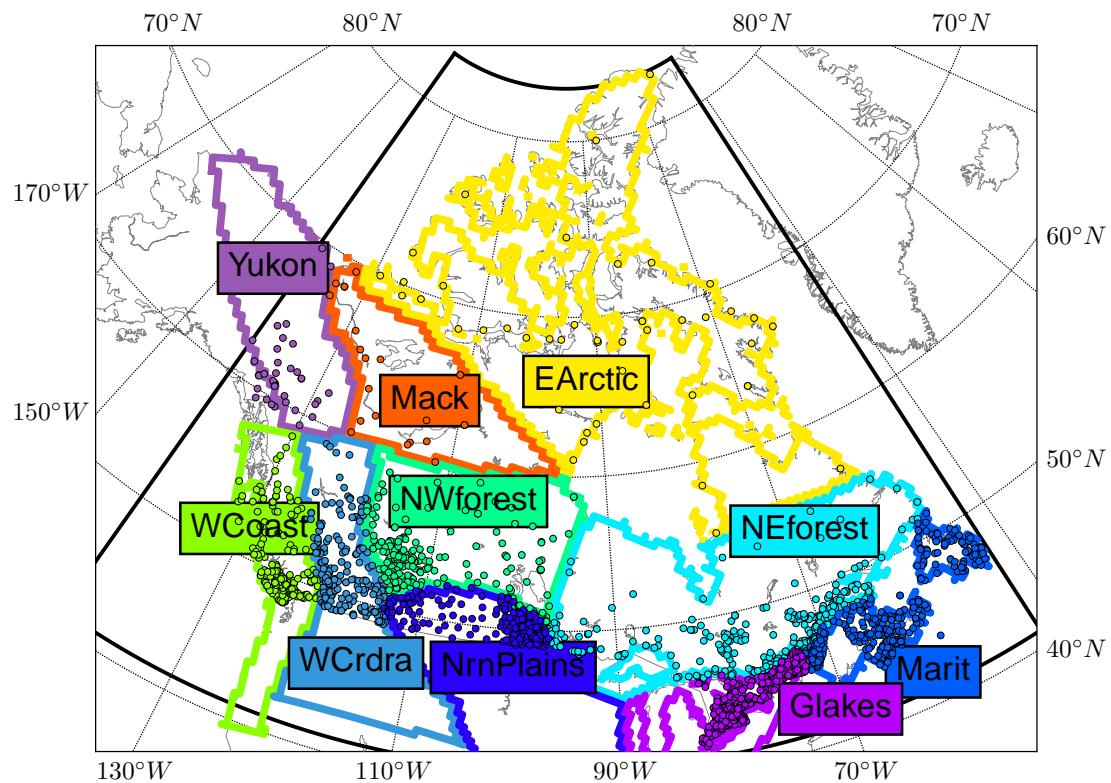


Figure 1 – Rainfall network used and the CFSR domain (thick black frame). Climatic regions are: Yukon (Yukon), Mackenzie (Mack), East Arctic (EArctic), West Coast (WCoast), Western Cordillera (WCrdr), North Western Forest (NWforest), Northern Plains (NrnPlains), North East Forest (NEforest), Great Lakes (GLakes) and Maritimes (Marit) (Plummer *et al.*, 2006).

The Climate Forecast System Reanalysis (CFSR) was produced by the National Centers for Environmental Prediction (NCEP) with the Coupled Forecast System (CFS) model. It covers the 1979-2009 period (Saha *et al.*, 2010). This model simulates the past state of the ocean and atmosphere at a horizontal resolution of 0.312° latitude $\times 0.312^\circ$ longitude ($\sim 25\text{km}$ at 45°N), by assimilating quality-controlled observations. CFSR differs from other reanalyses in that it uses a coupled atmosphere-ocean-sea ice-land model (Bromwich *et al.*, 2011), it assimilates satellite radiances during the entire period; and it includes the time evolution of CO_2 concentrations (for more details see Mesinger *et al.*, 2006). CFSR includes also in the Land model two gridded precipitation products: 1) the pentad dataset of CMAP, and 2) the CPC unified global daily gauge analysis (Saha *et al.*, 2010, and references therein). The CFSR hourly precipitation amounts were aggregated to daily values over a domain covering Canada (Figure 1). The CFSR precipitation was selected in this study as preliminary analysis (not shown for conciseness). It could be shown that CFSR precipitation provides an overall good representation of the spatial distribution and precipitation amounts when compared to observations. Moreover, on a daily basis, despite biases in the intensities, the temporal correspondence, necessary for probabilistic regression models, between the observed and the corresponding CFSR daily precipitation series was generally good.

3 Stochastic post-processing of daily precipitation

Stochastic post-processing includes defining precipitation occurrence and intensity for a given day in terms of conditional probability distribution given CFSR precipitation intensity for the same day at the corresponding grid-cell. The main goal is to provide local precipitation intensity distributions for each day, conditional on CFSR precipitation for the same day, before creating multiple possible time series by randomly sampling these distributions (Maraun *et al.*, 2015). Post-processing of CFSR precipitation therefore proceeded in two steps (Chandler & Wheater, 2002; Coe & Stern, 1982; Wong *et al.*, 2014): post-processing was first applied to precipitation occurrence and then, to precipitation intensity for “wet” days. Post-processing was achieved independently on each CFSR grid-cell with at least one corresponding station. CFSR precipitation were compared to each station series independently when more than one station was included in a CFSR grid-cell (around 35 % of the grid-cells).

Daily precipitation series were modeled with mixed discrete and continuous distributions to account for, respectively, the occurrence of dry and wet days and precipitation intensity on wet days (Neykov *et al.*, 2014). In the following, a “wet” day was defined as a day with more than 1 mm of precipitation (Dai, 2006; Schmidli *et al.*, 2006; Sun *et al.*, 2006, among others). Such a threshold value

is necessary, as reanalysis as well as regional and global climate models simulate too frequently low intensity precipitation (see, e.g., Sun *et al.*, 2006).

3.1 Post-processing of precipitation occurrence

The conditional probability of the occurrence of precipitation, p_i , at a given station on a given day i was estimated using a Logistic Regression (LR; Buishand *et al.*, 2004; Wong *et al.*, 2014). The LR is a linear regression model where the predictand is binary and the predictor may be binary or continuous (Stern & Coe, 1984). In the present study, the predictand of the LR model was the wet or dry condition of day i , respectively one or zero, as recorded at the station. The log-transformed (Chandler, 2002) daily CFSR precipitation x_i was used as a predictor, and to account for possible seasonality in the post-processing of occurrence probabilities, sine and cosine correction terms were also considered. The conditional probability, p_i , that day i is wet was therefore defined as:

$$\begin{aligned} g(p_i) &= \log \left(\frac{p_i}{1 - p_i} \right) \\ &= \alpha_0 + \alpha_1 \log(x_i + 1) + \\ &\quad \alpha_2 \cos \left(\frac{2\pi d}{T} \right) + \alpha_3 \sin \left(\frac{2\pi d}{T} \right), \end{aligned} \quad (1)$$

where $g(\cdot)$ the logit function, d the Julian day, $T = 365.25$ days is the averaged yearly period for cosine and sine waves accounting for leap years and

$\{\alpha_k\}_{k \in [0,3]}$ are the regression coefficients estimated by maximum likelihood (MLE).

3.2 Post-processing of precipitation intensity

The gamma distribution was selected to model daily precipitation intensity (Katz, 1977; Wilks, 2011, among others). Preliminary works demonstrated the overall good fit of the gamma distribution on the observed precipitation intensity. However, the light tail of the gamma led to underestimations of the very high quantiles at specific sites (Katz, 1977; Vrac & Naveau, 2007). Shape ($\gamma > 0$) and mean ($\mu > 0$) parameters were considered (McCullag & Nelder, 1989) and the scale parameter is therefore given by μ/γ and the variance by μ^2/γ . The probability density function $f_{\mu,\gamma}$ is given by:

$$f_{\mu,\gamma}(z) = \frac{\gamma}{\mu \Gamma(\gamma)} \left(\frac{\gamma z}{\mu} \right)^{\gamma-1} e^{-\gamma z/\mu}, \quad (2)$$

where Γ is the gamma function and $z > 0$ the daily precipitation intensity.

The daily local precipitation intensity distribution, conditional on CFSR precipitation, was defined within the vector generalized linear model (VGLM) framework (Yee & Wild, 1996). Parameters μ_i and γ_i of the gamma distribution on day i were expressed as a function of the log-transformed

CFSR daily intensity (x_i). Seasonal post-processing terms were also considered for the mean μ_i . The resulting expressions are:

$$h(\mu_i) = \eta_0 + \eta_1 \log(x_i + 1) + \eta_2 \cos\left(\frac{2\pi d}{T}\right) + \eta_3 \sin\left(\frac{2\pi d}{T}\right), \quad (3)$$

$$h(\gamma_i) = \beta_0 + \beta_1 \log(x_i + 1),$$

where $h(\cdot)$ is the log link function, $T = 365.25$ days and $\{\eta_k\}_{k \in [0,3]}$, and $\{\beta_k\}_{k \in [0,1]}$ are the regression coefficients estimated using MLE (Yee, 2016b, CRAN R VGAM Package). As the 1 mm threshold defining wet days ($z > 1\text{mm}$) leading to misfits of the small intensities, all precipitation on wet days were shifted by -1 mm before estimating parameter values and then shifted back by +1 mm (Wong *et al.*, 2014). Model selection is discussed in Section 5.

Combining the conditional probability of occurrence p_i (eq. 1) and the cumulative distribution function (CDF) of the daily precipitation intensity F_{μ_i, γ_i} (CDF from eq. 2 and 3), the CDF of the local precipitation intensity on day i , Z_i , can be written as:

$$\mathbb{P}(Z_i \leq z) = p_i F_{\mu_i, \gamma_i}(z) + (1 - p_i) \quad (4)$$

In the following, F_{μ_i, γ_i} will be written as F_i to simplify notations.

4 Evaluation of the post-processing models

4.1 Predictive power of regression models

In order to evaluate the predictive power of the LR and VGLM models, two forecast skill scores were considered (Wilks, 2011). Skill scores compared forecasts from a given model to a reference, here the climatological forecast (Friederichs & Thorarinsdotir, 2012). Their values range from $-\infty$ to 1 with negative values indicating a forecast skill worse than the climatology, a zero value indicating a forecast skill similar to the climatology, and a value of one indicating a perfect forecast.

The Brier Skill Score (BSS) was used to evaluate the LR regression. The Brier Score (BS; Wilks, 2011) assesses the synchronicity of observed dry and wet days ($o_i = 0$ or 1, respectively, for the dry or wet condition at day i) with the LR-estimated conditional probability of occurrence (p_i , ranging from 0 to 1) (Wong *et al.*, 2014):

$$BS = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2, \quad (5)$$

here N denotes the total number of days in the time series. The Brier Skill Score was computed to compare the performance of the LR model to a

climatological forecast, *i.e.* the probability of precipitation occurrence from observations over the studied period. A BSS value larger than zero therefore indicates that post-processed reanalysis provides a “better” forecast than the one based on the probability of occurrence of dry and wet days.

The Continuous Rank Probability Skill Score (CRPSS) was used to assess the skills of the VGLM model. The Continuous Rank Probability Skill Score (CRPS, Hersbach, 2000) provides an overall evaluation of the predictive skill of a model forecast by comparing the forecast distribution (F_i) with the empirical CDF of daily recorded intensities (\hat{F}_i) (Bentzien & Friederichs, 2014; Friederichs & Thorarinsdottir, 2012):

$$\text{CRPS} = \frac{1}{N} \sum_{i=1}^N \int_{z=-\infty}^{z=+\infty} \left[F_i(z) - \hat{F}_i(z) \right]^2 dz, \quad (6)$$

where \hat{F}_i corresponds to the Heaviside function with the step at the observed precipitation intensity on day i and N is the sample size. Reference CRPS used for the skill score estimates (CRPSS) compared the CDF of the fitted gamma distribution without covariates to \hat{F}_i .

Annual and seasonal skill scores were evaluated to identify possible seasonal differences in model predictive power. In the following, the year is split in winter (December, January, February: DJF), spring (March, April, May: MAM), summer (June, July, August: JJA) and autumn (September, October, November: SON). In the seasonal case, reference forecasts were assessed for each season, for instance a gamma distribution without covariates was fitted over the SON months for the studied period.

4.2 Evaluation of annual precipitation index series

In addition to the aforementioned model evaluation, the post-processing approach was also investigated in term of its ability to reproduce annual precipitation index series. Annual and seasonal precipitation indices, selected among the joint CCI/CLIVAR/JCOMM Expert Team (ET) on Climate Change Detection and Indices (ETCCDI) list (Peterson *et al.*, 2001), representing three main attributes of precipitation, were considered: 1) persistence through the maximum length of wet and dry spells (CDD and CDW); 2) frequency of daily precipitation for moderate precipitation (R10mm and R20mm); 3) intensity for various precipitation regimes (PRCPTOT, SDII, Rx1day, Rx5day, R95p and R99p; see Table 1). These indices were estimated at each site from three daily datasets: 1) station series, 2) CFSR series and 3) post-processed daily precipitation series over the 1979-2009 period using LR and VGLM models (eq. 4). Preliminary tests using 100 to 3,000 randomly-generated post-processed daily precipitation series demonstrated that mean climate indices estimated from these series stabilized after 1,500 samples. Therefore, 1,500 generated series were estimated and analyzed.

Table 1 – Precipitation indices from the ET DCCI list computed at the annual and seasonal scales (adapted from Donat *et al.* (2014))

Climate index identifier	Name	Description	Units
CDD	Consecutive dry days	Annual maximum number of consecutive dry days (< 1 mm)	days
CWD	Consecutive wet days	Annual maximum number of consecutive wet days (≥ 1 mm)	days
R10mm	Number of heavy precipitation	Annual number of days with precipitation ≥ 10 mm	days
R20mm	Number of very heavy precipitation	Annual number of days with precipitation ≥ 20 mm	days
PRCPTOT	Total wet day precipitation	Annual total precipitation	mm
SDII	Simple daily intensity index	Annual average precipitation on wet days (≥ 1 mm)	mm/day
Rx1day	Maximum 1-day precipitation	Annual maximum 1-day precipitation	mm
Rx5day	Maximum 5-day precipitation	Annual maximum 5-day precipitation	mm
R95p	Very wet days	Annual amount when daily precipitation is >95 th percentile of the observed daily precipitation over the reference period	mm
R99p	Extremely wet days	Annual amount when daily precipitation is >99 th percentile of the observed daily precipitation over the reference period	mm

Distributions of annual and seasonal indices over the reference period (1979–2009) from CFSR or post-processed CFSR series were first compared with corresponding distributions estimated from recorded series using the two-sample Anderson–Darling (AD) and Kolmogorov–Smirnov (KS) tests (Conover, 1999) at the 95% confidence level (hereafter 95% c.l.). These two tests share the same null hypothesis, *i.e.* that two samples come from the same underlying distribution, and compare distances between two empirical cumulative distribution functions (CDFs). However, the test statistics focus on different parts of these empirical CDFs. To provide a more conservative assessment of the statistical significance at the given confidence level, both tests were used, and if AD or KS (hereafter denoted ADKS) test rejected the null hypothesis, the two given samples were considered different (at the 95% c.l.).

Since the performance of CFSR in reproducing annual or seasonal distribution was very good for some regions and indices, sites were subdivided into

two groups according to CFSR performance. The first group included sites where CFSR already displayed good performances, here defined by the failure to reject ADKS null hypothesis between observed and CFSR index distributions. The second group included sites where CFSR displayed poor performances (at least one of the tests resulted in the rejection of the null hypothesis). It is worth noting that these groups may differ according to the index or the period (annual or seasonal) considered. The ADKS test was then applied at each site between the observed index and the sample of 1,500 randomly generated index series. The percentage of time that the null hypothesis was not rejected at the 95% c.l. among these 1,500 samples was used for evaluation. The aim here was to assess if the performance after post-processing was preserved for the first group and improved for the second group.

Three performance criteria were also considered to compare annual climate index series to observed series:

— Relative bias (B) and standardized variability (NSTD) were estimated to determine, respectively, under- ($B < 0$) or overestimations ($B > 0$) of mean indices and under- ($NSTD < 1$) or overdispersion ($NSTD > 1$) of climate index series. These criteria are defined as:

$$\begin{aligned} B(I_{\text{obs}}, I_m) &= \frac{\bar{I}_{\text{obs}} - \bar{I}_m}{\bar{I}_{\text{obs}}}, \\ NSTD(I_{\text{obs}}, I_m) &= \frac{S(I_m)}{S(I_{\text{obs}})}, \end{aligned} \quad (7)$$

where I corresponds to a given annual or seasonal index and \bar{I} to the average value over the reference period, S to the standard deviation, obs subscript refers to the observed index, $m = \text{PS}$ to post-processed index and $m = \text{CFSR}$ to non-post-processed CFSR index. B and NSTD values were estimated from each randomly generated daily series and then averaged over the 1,500 samples.

— the Normalized Root Mean Squared Error (NRMSE) was estimated to evaluate the agreement between annual and seasonal index series from observations, CFSR and post-processed CFSR:

$$\text{NRMSE}(I_{\text{obs}}, I_m) = \frac{\text{RMSE}(I_{\text{obs}}, I_m)}{\bar{I}_{\text{obs}}} \quad (8)$$

The NRMSE was also averaged over the 1,500 samples when comparing post-

processed index series to the observed series.

5 Results and discussion

5.1 Selection of the post-processing model

The Akaike information criterion (AIC; Akaike, 1974) was used to select the most appropriate LR and VGLM models. For 97% of sites, models including seasonal terms were selected for the post-processing of daily precipitation occurrence. Consideration of seasonality was also supported by the monthly Pearson residual analysis (not shown for conciseness; Chandler & Wheater, 2002). For the intensity post-processing, three VGLM nested models were tested (all with $\eta_0 \neq 0$ and $\beta_0 \neq 0$ in eq. 3): 1) Non Seasonal Conditional Mean (NS-M) model $(\beta_1, \eta_2, \eta_3) = \mathbf{0}, \eta_1 \neq 0$; 2) Non Seasonal Conditional Mean and Shape (NS-MS) model $(\eta_2, \eta_3) = \mathbf{0}, \eta_1 \neq 0, \beta_1 \neq 0$; and 3) Seasonal Conditional Mean and Shape (S-MS) $\beta_1 \neq 0, \eta_1 \neq 0, \eta_2 \neq 0, \eta_3 \neq 0$. According to the AIC criteria, the S-MS was selected at 98% of the sites. The extremely small AIC differences between models with and without seasonality coefficients for the remaining 3% and 2% of sites, for respectively occurrence and intensity post-processing, and their random distribution in space led to the application of the models defined by equations 1 and 3 to all sites.

Finally, the gamma-distributed daily precipitation hypothesis was supported by the Anscombe residuals analysis, expressed as $r_i = (y_i/\mu_i)^3$ where y_i is the observed precipitation on day i , which displayed nearly normal distributions (Chandler & Wheater, 2002).

5.2 Predictive power of the SMOS statistical models

BSS and CRPSS for each grid-point/station pair were estimated. Figure 2 presents the corresponding values over each region. At the annual scale (Figure 2), BSS and CRPSS were positive across all regions, meaning that the proposed LR and VGLM models outperformed forecasts based on climatology. However, performances differed among regions. Regions closer to large water bodies, as well as those with larger fractions of wet days (WCoast, NEforest, Marit and GLakes), displayed better predictive skills (average BSS and CRPSS around 0.35) than central (NWforest and NrnPlains), mountainous (WCrdra) and northern regions (Yukon, Mack, EArctic). The differences among regions could be attributed to the topography and the precipitation regime dominating those regions. Synoptic precipitation in the East Coast (NEforest, Marit) and orographic precipitation in the WCoast region were better simulated by the reanalysis in terms of occurrence and intensity in comparison with the very dry northern and central regions dominated by less frequent and more likely convective precipitation. The Canadian Cor-

dilla (WCrdra and part of the Mack and Yukon regions) also displayed a particular regime as precipitation are influenced both by the high elevation and the natural barrier to the westerlies which lead less moisture leeward. In these regions, some stations displayed lower BSS and CRPSS than elsewhere, which may be partly explained by the misrepresentation of the topography in CFSR due to its intrinsic spatial resolution, in addition to the fact that stations are usually located in valleys. Finally, Arctic regions displayed the lowest skill scores, though these were still positive. However, Arctic regions have a lower density network with unevenly distributed stations, making comparisons with other regions more difficult.

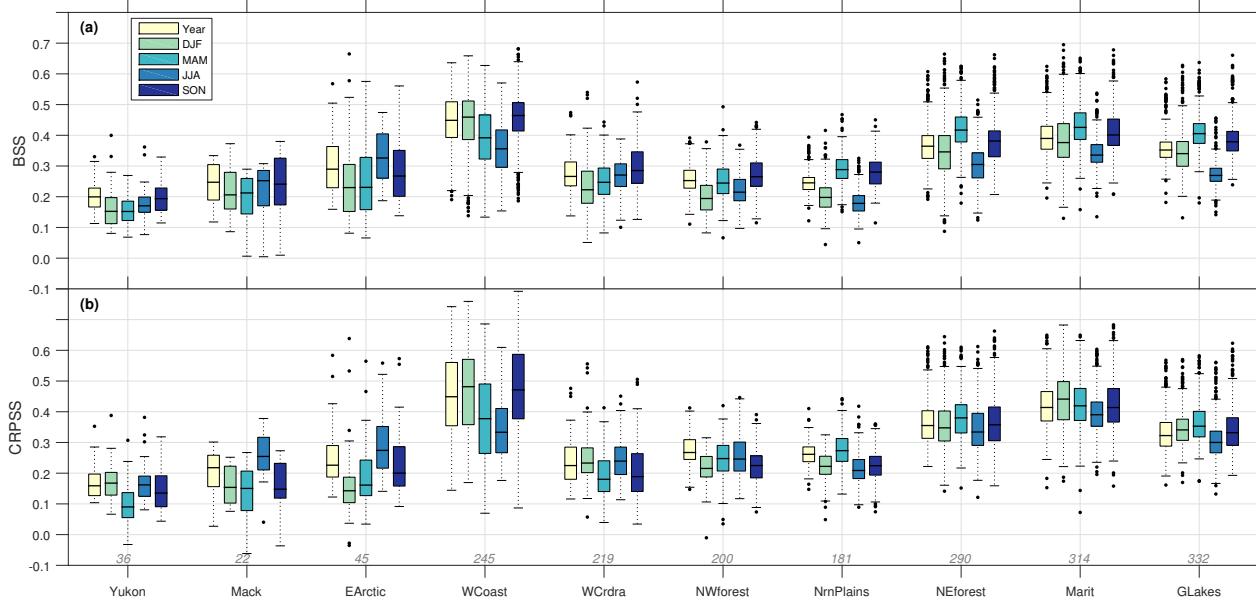


Figure 2 – Boxplots of (a) BSS and (b) CRPSS over each region and for each season. Numbers below each box plot indicate the number of stations within each region. Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), horizontal line defines the median (q_{50}), while the whiskers lower and upper limits correspond, respectively, to $q_{25}-1.5\times\text{IQR}$ and $q_{75}+1.5\times\text{IQR}$. Outliers are marked by black circles.

The precipitation regime impacted the forecast skill of the regression models at the seasonal scale for some regions (Figure 2, colored boxplots). During the summer, most regions experience convective systems defined by short durations and relatively high intensity precipitation events. Such systems are known to be partially resolved by numerical weather models both in terms of spatio-temporal resolution and underlying physical representation. As a result CFSR was less efficient in representing those precipitation events. Therefore, BSS and CRPSS values were smaller in the summer season (JJA in Figure 2) in the eastern (NEforest, Marit and GLakes), the NrnPlains, and the WCoast regions. However, since autumn and winter seasons (SON and DJF) are characterized by synoptic systems (*i.e.* long duration and low intensity with rela-

tively high spatial extent systems), they were more adequately represented by CFSR, as illustrated by the higher BSS and CRPSS values. It is worth noting that in the East (NEforest, GLakes and Marit) and in the NrnPlains regions, BSS, and to a lesser extent CRPSS, displayed, on average, higher values during spring than winter and autumn. Northern regions displayed different seasonal patterns, with generally higher CRPSS and BSS during the summer than during winter. This may be partly related to the difficulty of measuring and simulating winter light precipitation in Arctic regions, whereas summer wet synoptic system precipitation, which compose a large fraction of the annual amount, were better simulated by CFSR. However, it seems reasonable to assume that reanalysis should be less performant over the northern region where the vo-

lume of assimilated data is presumably smaller than for southern region.

5.3 Performance of post-processed precipitation index annual series

CFSR displayed good performances for some indices and regions in terms of reproducing the observed annual index distributions (ADKS test; see Section 4.2) as shown in Figure 3 a). Less than 50 % of the sites in the central (NWforest, Nrn-Plains) and eastern (NEforest, Marit, GLakes) regions had CFSR index distributions different from the observed distributions (95% c.l.) for R10mm, R20mm, Rx1day, Rx5day, R95p and R99p. There was a greater contrast among results for these indices for Northern (Yukon, Mack, EArctic) and western (WCrdra, WCoast) regions with generally a better performance for Mack and EArctic regions. However, CFSR poorly performed for CDD, CDW, and SDII as only about 20% of the sites with CFSR distributions were not statistically different from observed distributions at the 95% c.l., the only exception being the WCoast region for the CDD indices. A more detailed analysis showed that the WCoast region could be subdivided into two regions with contrasting performances. CDD values at sites along the Pacific Ocean were very well estimated by CFSR, while CDD indices at the other sites located far from the coast were highly underestimated by CFSR series. Finally, PRCPTOT were poorly represented in northern, western and NWforest regions

(only 20% of sites). Comparison of the CFSR and observed seasonal index distributions (Figure 3 b) indicated that CFSR performances depend strongly on the season with overall poorer performances in summer and autumn compared to winter and spring. Although observed annual distributions for some indices were rather well reproduced by CFSR (e.g., CDW), corresponding performances for some of the seasonal distributions were much less convincing. These results confirmed that daily CFSR precipitation series need to be post-processed for some regions before they can be used for the estimation of annual climate indices. The important issue is, therefore to see if the post-processing of daily series improved the climate index distributions at sites where it was originally poor without significantly deteriorating the distributions at sites where it was originally good.

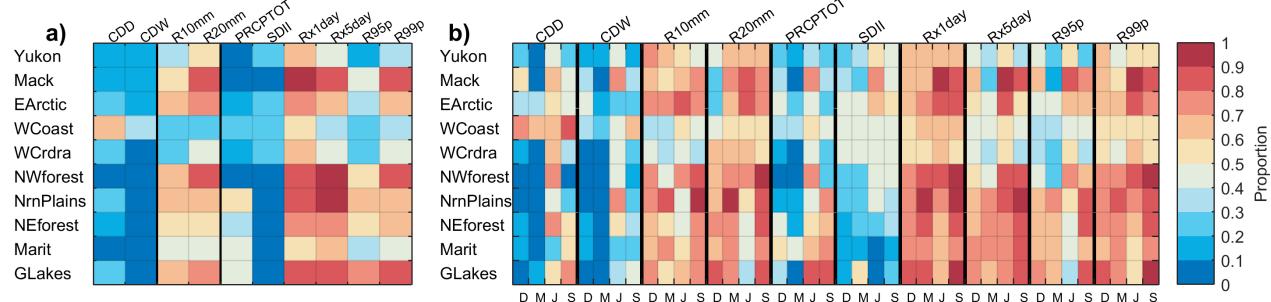


Figure 3 – a) Proportion of sites within regions (rows) where observed and raw index (columns) distributions were not different at the 95% c.l. according to the ADKS tests; **b)** same as a) but at the seasonal scale. For clarity, D, M, J and S refer to DJF, MAM, JJA and SON.

Figure 4 a.i) summarizes the results of the comparisons between the post-processed and observed index distributions based on the ADKS test. The analysis was first conducted separately at sites where CFSR displayed good and poor performances (Section 4.2), but regionally-averaged percentage of post-processed index distributions were similar to the observed distributions. Thus, results of all sites were pooled in one figure, and results separating these two types of sites are presented in the supplemental material (Figures S1 and S2). Figure 4 a.i) shows that on average, more than 90% of the obtained post-processed annual index distributions were similar to the observed distributions in many regions. This percentage was slightly lower for R20mm, Rx1day, Rx5day and R99p indices, but still between 60 and 70% for Rx5day and between 80 and 90% for the other indices. These percentages remained high for seasonal index distributions (Figure 4 a.ii), with, on average, more than 80%,

and in many cases more than 90%, of the post-processed index distributions similar to the observed ones (95% c.l.), except during winter where a slight decrease in performance was observed compared to the other seasons. Seasonal and annual duration index (CDD and CDW) distributions were, on average, poorly reproduced over all regions as shown by the higher rejections of the ADKS null hypothesis, in all regions except Marit and GLakes. Winter and summer CDD index distribution were globally better reproduced, as 70 to 100% of the post-processed index distributions were not significantly different from observed distributions, while spring and autumn index distributions were better reproduced for CDW (60 to 80% of sites with not statistically different distributions). Eastern and central regions showed better results on average, with high spatial variability in the performances within the same regions (not shown) unlike the other indices.

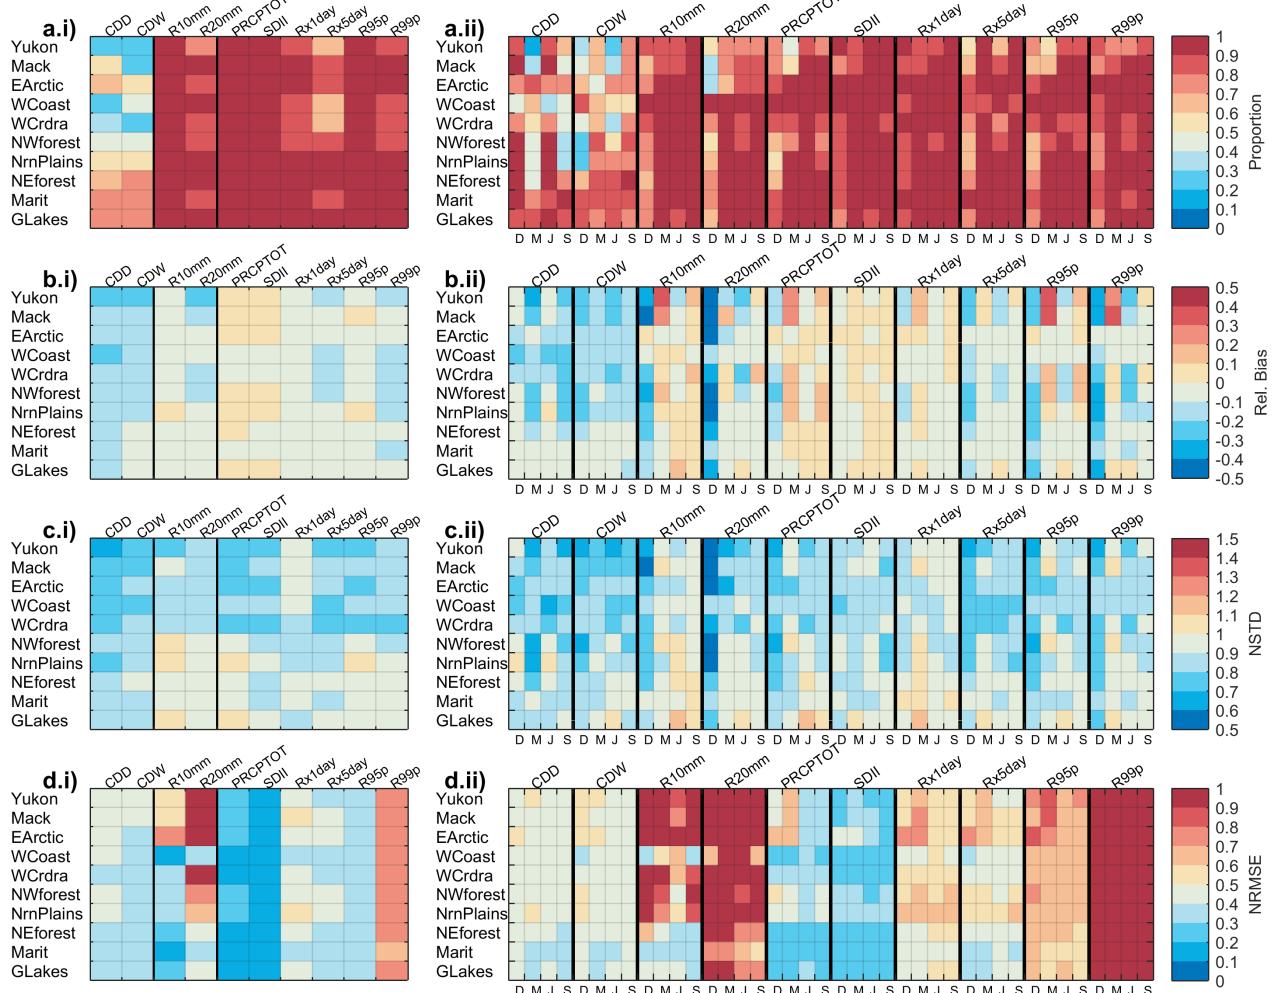


Figure 4 – Regional average of a) the proportion of post-processed index distributions different from observed ones at the 95% c.l. according to the ADKS tests ; b) the relative bias between the post-processed and observed index series; c) the NSTD; and d) the NRMSE. The left panels (i) refer to the annual scale and right panels (ii) to the seasonal scale. For clarity, D, M, J and S refer to DJF, MAM, JJA and SON.

Results of the bias analysis (Figure 4 b.i) indicated that index mean values were underestimated, on average, by less than 10% for intensity and frequency indices, except for PRCPTOT and SDII indices, where slight overestimations were observed over northern, central, and GLakes regions. Bias was higher (in absolute values) for CDD and CDW indices with underestimations of around 30%, except in the eastern regions ($\leq 10\%$). The seasonal

frequency of days with more than 10 and 20 mm, R10mm and R20mm, were relatively high in post-processed index series as illustrated in Figure 4 b.ii), especially in northern regions during winter and spring season, which can be partly explained by the extremely small values of R10mm and R20mm (even zero for some years) over these regions. Biases between observed and CFSR indices were considerably reduced at sites where CFSR per-

formance was poor, and remained nearly unchanged (in absolute values) at sites where CFSR performance was already good, both for annual and seasonal index series (see Figure S3.a.i) - a.ii) and S2.a.i) -a.ii) in supplemental material). Interestingly, biases changed their sign for CDW, going from highly overestimated values by CFSR (longer wet spells than observed) to underestimated values for post-processed indices, which may be partly explained by the lack of persistence of the post-processed daily precipitation series. Bias was lower during winter and summer for CDD and spring and autumn for CDW, except in the eastern regions which displayed less marked seasonal differences and lower bias values.

The variability of post-processed annual index series was in general smaller than observed variability (NSTD values lower than one in Figure 4 c.i). Standard deviations for annual CDD and CDW index series were on average 20 to 30% smaller than for observed series over many regions with similar underestimations for the various seasons (Figure 4 c.ii). Slightly fewer underestimations of the inter-annual index variability were observed for the other indices with NSTD values around 0.8 for northern and western regions, and close to 1.0 for central and eastern regions. NSTD values were even slightly superior to 1.0 in the NrnPlains and GLakes for some indices for specific seasons (e.g. Rx1day in spring for GLakes region). R10mm and R20mm displayed highly under-dispersed series during winter, espe-

cially for northern and western regions. Here again, zero values in the observed index series may have an impact on these performances. Post-processing helped to reduce the over or underestimations of the standard deviations in the annual and seasonal index series at sites with good and bad performances (Figures S3.b.i) - b.ii) and S4. b.i) -b.ii) in supplemental material).

Results for the NRMSE (Figure 4 d.i) indicated that PRCPTOT and SDII globally outperformed the other indices followed by R95p and Rx5day. Overall, the extreme indices R99p, R95p, and Rx1day generated large NRSME values. The very small annual R20mm values, and small seasonal R10mm and R20mm values, observed in many regions, especially in winter, may partly explain the large reported NRMSE values for these indices (Figure 4 d.ii). Similar results were observed for R99p over all season. As indicated in Table 1, this index accounts for annual amounts greater than the observed 99th quantile, R99p contained by construction very high to very low (and even zero) values for both the observed and post-processed series, but not necessarily occurring during the same year, leading to very high NRMSE with though on good performance as regards averaged values of R99p during the studied period (Figure 4 a.ii and b.ii). Once again, the regionally-averaged NRMSE between the observed and post-processed series were similar to those estimated with CFSR at sites where CFSR performed well, while they were considerably

reduced at the other sites (Figures S3. c.i) - c.ii) and S4. c.i) -c.ii) of supplemental material).

6 Conclusion and Discussion

Reanalysis are constructed from numerical weather prediction models assimilating various observational datasets over a given historical period. However, reanalysis series should be post-processed in order to correct biases and possible spatial mismatch due to their resolution. In this study, a stochastic post-processing (Wong *et al.*, 2014) using CFSR daily precipitation as a covariate was locally applied to 1 884 sites across Canada. This is the first step to the development of an approach where precipitation series with local properties could be stochastically generated. Various applications require precipitation data at local scales such as floods predictions (Vaittinada Ayar *et al.*, 2016), impact studies (Maraun, 2016), agricultural modeling (Ambrosino *et al.*, 2014) or water resource management. Enlarging the current post-processing approach at sites where reanalyses are available but without observations would also benefit to regions with low station density for their socio-economic and environmental development. The post-processing was based on two regression approaches to model separately the wet/dry day occurrences with a logistic model (LR) and the daily precipitation intensities, represented by a gamma distribution, in a Vector Generalized Linear Model (VGLM) frame-

work. Both models used the log-transformed CFSR daily precipitation as predictors and the observed daily occurrence (LR model) or intensity (VGLM) as predictand. Regression model parameters were also allowed to vary seasonally. The predictive power of the two regression models was first assessed separately through two skill scores, BSS and the CRPSS for the occurrences and the intensities respectively, using the observed climatology as a reference dataset. The two models were then evaluated jointly by analyzing randomly-generated series from the at-site daily precipitation distributions provided by the mixed distribution (occurrence and intensity). In this case, annual and seasonal climate series indices from the ETCCDI list (Peterson *et al.*, 2001) allowed to study further aspects of these post-processed precipitation sequences.

The probabilistic evaluation of the post-processing models showed systematically better forecast skill than the observed climatology for wet/dry occurrences and intensity, with regional and seasonal differences. Overall, BSS and CRPSS displayed similar regional patterns, with the WCoast, the NEForest, and the Marit being the regions with the highest skill scores, especially during autumn and winter. The convection, characterizing summer precipitation in those regions, were more poorly represented by the models. The WCr-dra and the central regions displayed lower skill scores, mainly explained, respectively, by the topography and the small and infrequent occurrence

of precipitation. Northern regions showed similar scores with better performances during summer (liquid precipitation). The other seasons are generally very dry, making the precipitation more difficult to measure (precipitation trace) and to simulate by CFSR. Moreover, the paucity of assimilated weather data in the reanalysis may explain the poor performances of the models for those regions. Differences across regions and seasons also highlighted the importance of predictors choice (here CFSR precipitation and seasonal terms), as skill scores were consistently higher at sites where CFSR without post-processing already performed well (preliminary analysis not shown).

Annual and seasonal series of duration (CDD and CDW), frequency (R10mm and R20mm), and intensity indices (PRCPTOT, SDII, R95p, R99p, Rx1day and Rx5day) were estimated from the randomly-generated daily precipitation, referred to as post-processed series, and from recorded and CFSR daily series. The aim was to investigate if the post-processing was able to reproduce some of the observed precipitation attributes and to quantify the gain or loss of information by using the post-processing instead of CFSR. This assessment was, all in all, the more interesting one as CFSR may already demonstrate good performances when dealing with upscaled series (e.g., annual amount series). The ADKS test conducted at the 95% c.l. compared at-site observed annual and seasonal index distributions to corresponding post-processed

and CFSR index distributions. The relative bias (B), normalized standard deviation (NSTD) and the normalized root mean squared error (NRMSE) enabled the further investigation of differences among these three datasets.

The main results were:

- ADKS test showed CFSR indices distributions were different (95% c. l.) from the observed ones for an important number of sites, especially for CDD, CDW, PRCPTOT and SDII.
- For a given site, low percentages of post-processed CDD and CDW distributions were similar (according to ADKS test) to observed distributions, especially in northern and western regions. These two indices were generally underestimated in the post-processed series. However, the absolute values of the bias were noticeably reduced when compared to CFSR. The post-processing showed some weaknesses for indices related to the duration of the wet and dry spells.
- The annual R10mm and R20mm distributions were well represented in the post-processed series, and bias was reduced when compared to CFSR. For some seasons, especially winter, R10mm and R20mm remained relatively low (even zero for some years) compared to observations and therefore per-

formances (B, NSTD and NRMSE) tended to be generally inferior.

— Intensity related indices (PCRPTOT, SDII, Rx1day, Rx5day, R95p and R99p) were the best represented indices in the post-processed series for both annual and seasonal scales, especially for PCRPTOT, SDII and to a lesser extent Rx1day and Rx5day. For the R95p and R99p distributions, relative bias and variability also displayed good performances when compared to the observed distributions. However, year to year errors were relatively high, especially for R99p, as by construction this index may contain both very low (zero values) and very high values, especially at the seasonal time-scale.

The post-processing provided very interesting correction of the reanalysis, especially when one focuses on the distributions, as demonstrated by the ADKS results across upscaled precipitation indices. Moreover, the post-processed annual index series displayed considerably reduced bias values and better inter-annual variability estimated than CFSR without post-processing; except for some indices in regions where the precipitation estimates, for either observation or simulation, was challenging. Finally, while the NRMSE in post-processed series was reduced when compared to CFSR, its values were generally elevated, suggesting that there is scope for further improvement with regard to the

synchronicity between post-processed indices and the observed ones.

Preliminary analysis demonstrated that the post-processing had very high skill when comparing statistics of at-site daily post-processed series such as the mean, the variance, and a large range of quantiles (up to 95th) to those obtained from daily observed series. This highlighted that even if the gamma distribution is not recommended to represent the upper tail of the daily precipitation distribution, the VGLM framework, allowing a varying shape parameter, allowed for a tractable model and provide good estimates of moderately high quantiles. Future applications could involve the extended Generalized Pareto proposed by Naveau *et al.* (2016) to better represent quantiles of high order ($> 95\text{th}$).

Future work should consider more persistence in the models, as the post-processed series partially reduced the CFSR autocorrelation. Several tests conducted with the same models, including CFSR precipitation on the previous day as a covariate, led to very similar results, suggesting another avenue of investigation (for example, integrating temporal structure in a latent field Serinaldi & Kilsby, 2014). Moreover, a spatial structure of daily precipitation should be added to insure spatial consistency of the simulated random field, which was not investigated in this paper.

Acknowledgements

The authors would like to thank Eva Mekis from Environment Canada who provided the daily series from the Adjusted Precipitation for Canada (APC2) dataset, the *Ministère du Développement Durable, de l'Environnement et de la Lutte contre les Changements Climatiques (MD-DELCC)* of Québec [data available upon request; Info-Climat@mddelcc.gouv.qc.ca] for the daily records, and Silvia Innocenti for advices on statistical tests. The authors also thank the two referees, Mohamed Ali Ben Alaya and Korbinian Breinl, for their constructive suggestions, which led to a significant improvement of the manuscript. This research was partly funded by a Collaborative Research and Development Grant from the Natural Sciences and Engineering Research Council of Canada (NSERC).

Appendix A. Statistical homogeneity of annual series

In this section, the protocol to check the statistical homogeneity is presented. In fact, some stations may have recording inconsistencies due to factors such as changes in recording equipment, changes in the definition and measurements of precipitation trace (Mekis, 2005), missing values, choices of time windows to record daily precipitation (Hopkinson *et al.*, 2011), and other site disturbances (Beaulieu *et al.*, 2008). To further scrutinize the data, especially at stations that were not part of the APC2 dataset, the statistical homogeneity of annual precipitation series was also assessed using the method proposed by Wijngaard *et al.* (2003), which relies on the application of four statistical tests. The sites with homogeneous series classified as “useful”- according to terminology of Wijngaard *et al.* (2003) were selected (in these cases three or more of the tests do not reject the null hypothesis that the temporal series are independently and identically distributed at the 99% level). Though, some “useful ” gaging stations were discarded as they displayed increasing annual number of wet days over time, whereas the recording resolution was also increasing, leading to spurious trends. Twenty-two stations, in the southern Saskatchewan, were not considered as there were numerous missing years over the study period, despite the applied quality control.

References

- Akaike H (1974). A new look at the statistical model identification. *IEEE Trans. Autom. Control*, 19:716–723.
- Allard M & Lemay M (2012). Nunavik and Nunaatsiavut: From science to policy. An Integrated Regional Impact Study (IRIS) of climate change and modernization. ArcticNet Inc. 303 pages.
- Ambrosino C, Chandler RE & Todd MC (2014). Rainfall-derived growing season characteristics for agricultural impact assessments in South Africa. *Theor. Appl. Climatol.*, 115(3-4):411–426.
- Asong ZE, Khalil MN & Wheater HS (2016a). Multisite multivariate modeling of daily precipitation and temperature in the Canadian Prairie Provinces using generalized linear models. *Climate Dynamics*, pages 1–21.
- Asong ZE, Khalil MN & Wheater HS (2016b). Projected changes in precipitation and temperature over the Canadian Prairie Provinces using the Generalized Linear Model statistical downscaling approach . *Journal of Hydrology*, pages 429 – 446.
- Beaulieu C, Seidou O, Ouarda TBMJ, Zhang X, Boulet G & Yagouti A (2008). Intercomparison of homogenization techniques for precipitation data. *Water Resources Research*, 44(2):n/a–n/a. W02425.

- Ben Alaya MA, Ouarda TBMJ & Chebana F (2017). Non-gaussian spatiotemporal simulation of multisite daily precipitation: downscaling framework. *Climate Dynamics*.
- Bengtsson L & Shukla J (1988). Integration of Space and In Situ Observations to Study Global Climate Change. *Bulletin of the American Meteorological Society*, 69:1130–1143.
- Bentzien S & Friederichs P (2014). Decomposition and graphical portrayal of the quantile score. *Quarterly Journal of the Royal Meteorological Society*, 140(683):1924–1934.
- Bosilovich MG, Chen J, Robertson FR & Adler RF (2008). Evaluation of Global Precipitation in Reanalyses. *Journal of Applied Meteorology and Climatology*, 47(9):2279–2299.
- Bromwich DH, Nicolas JP & Monaghan AJ (2011). An Assessment of Precipitation Changes over Antarctica and the Southern Ocean since 1989 in Contemporary Global Reanalyses *. *Journal of Climate*, 24(16):4189–4209.
- Buishand TA, Shabalova MV & Brandsma T (2004). On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation. *Journal of Climate*, 17(9):1816–1827.
- Chandler & Wheater HS (2002). Analysis of rainfall variability using generalized linear models: A case study from the west of Ireland. *Water Resources Research*, 38(10):10–1–10–11.
- Chandler RE (2002). GLIMCLIM: generalized linear modelling for daily climate time series (software and user guide). Department of Statistical Science, University College London.
- Coe R & Stern R (1982). Fitting Models to Daily RainfallData. *Journal of Applied Meteorology*, 21(7):1024–1031.
- Conover W (1999). *Practical Nonparametric Statistics*. John Wiley & Sons, New York, third edition, 592 pages.
- Contractor S, Alexander LV, Donat MG & Herold N (2015). How Well Do Gridded Datasets of Observed Daily Precipitation Compare over Australia? *Advances in Meteorology*, 2015.
- CSA (2012). *Technical guide Development, interpretation, and use of rainfall intensity-duration-frequency (IDF) information: Guideline for Canadian water resources practitioners*. 214 pages.
- Dai A (2006). Precipitation Characteristics in Eighteen Coupled Climate Models. *Journal of Climate*, 19(18):4605–4630.
- Devine KA & Mekis E (2008). Field accuracy of Canadian rain measurements. *Atmosphere-Ocean*, 46(2):213–227.
- Donat MG, Sillmann J, Wild S, Alexander LV, Lippmann T & Zwier FW (2014). Consistency of Temperature and Precipitation Extremes across Various Global Gridded In Situ and Reanalysis Datasets. *Journal of Climate*, 27:5019–5035.

- Eden JM, Widmann M, Maraun D & Vrac M (2014). Comparison of GCM- and RCM-simulated precipitation following stochastic post-processing. *Journal of Geophysical Research: Atmospheres*, 119(19):11,040–11,053.
- Environment and Climate Change Canada (2013). *Adjusted Precipitation and Homogenized Canadian Climate Data (AHCCD)*. <http://ec.gc.ca/dccahccd/default.asp?lang=En&n=9AA530BE-1>. 2014-10-27.
- Eum HI, Cannon AJ & Murdock TQ (2017). Intercomparison of multiple statistical downscaling methods: multi-criteria model selection for South Korea. *Stoch. Environ. Res. Risk Assess.*, 31(3):683–703.
- Eum HI, Dibike Y, Prowse T & Bonsal B (2014). Inter-comparison of high-resolution gridded climate data sets and their implication on hydrological model simulation over the Athabasca Watershed, Canada. *Hydrological Processes*, 28(14):4250–4271.
- Fowler H, Blenkinsop S & Tebaldi C (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12):1547–1578.
- Friederichs P & Thorarinsdottir TL (2012). Forecast verification for extreme value distributions with an application to probabilistic peak wind prediction. *Environmetrics*, 23(7):579–594.
- Gervais M, Tremblay LB, Gyakum JR & Atallah E (2014). Representing Extremes in a Daily Gridded Precipitation Analysis over the United States: Impacts of Station Density, Resolution, and Gridding Methods. *Journal of Climate*, 27(14):5201–5218.
- Hersbach H (2000). Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. *Weather and Forecasting*, 15(5):559–570.
- Higgins RW, Kousky VE, Silva VBS, Becker E & Xie P (2010). Intercomparison of Daily Precipitation Statistics over the United States in Observations and in NCEP Reanalysis Products. *Journal of Climate*, 23(17):4637–4650.
- 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.
- Hopkinson RF, Mckenney DW, Milewska EJ, Hutchinson MF, Papadopol P & Vincent LA (2011). Impact of aligning climatological day on gridding daily maximum-minimum temperature and precipitation over Canada. *Journal of Applied Meteorology and Climatology*, 50(8):1654–1665.
- Kalnay E, Kanamitsu M, Kistler R, Collins W, Deaven D, Gandin L, Iredell M, Saha S, White G,

- Woollen J, Zhu Y, Leetmaa A, Reynolds R, Chelliah M, Ebisuzaki W, Higgins W, Janowiak J, Mo KC, Ropelewski C, Wang J, Jenne R & Joseph D (1996). The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77(3):437–471.
- Katz RW (1977). Precipitation as a Chain-Dependent Process. *Journal of Applied Meteorology*, 16(7):671–676.
- Lavers D, Prudhomme C & Hannah DM (2013). European precipitation connections with large-scale mean sea-level pressure (mslp) fields. *Hydrological Sciences Journal*, 58(2):310–327.
- Maraun D (2013). Bias Correction, Quantile Mapping, and Downscaling: Revisiting the Inflation Issue. *Journal of Climate*, 26(6):2137–2143.
- Maraun D (2016). Bias Correcting Climate Change Simulations - a Critical Review. *Curr. Clim. Chang. Reports*, 2(4):211–220.
- Maraun D, Wetterhall F, Ireson AM, Chandler RE, Kendon EJ, Widmann M, Brienen S, Rust HW, Sauter T, Themeßl M, Venema VKC, Chun KP, Goodess CM, Jones RG, Onof C, Vrac M & Thiele-Eich I (2010). Precipitation downscaling under climate change : recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, (2009):1–34.
- Maraun D, Widmann M, Gutiérrez JM, Kotlarski S, Chandler RE, Hertig E, Wibig J, Huth R & Wilcke RA (2015). VALUE: A framework to validate downscaling approaches for climate change studies. *Earth's Future*, 3(1):1–14.
- McCullag P & Nelder JA (1989). *Generalized linear models*. Chapman and Hall, New York, 2nd edition edition, 532 pages.
- Mekis E (2005). Adjustments for trace measurements in Canada. *15th Conference on Applied Climatology*, Savannah, Georgia, USA.
- Mekis E & Vincent LA (2011). An Overview of the Second Generation Adjusted Daily Precipitation Dataset for Trend Analysis in Canada. *Atmosphere-Ocean*, 49(2):163–177.
- Mesinger F, DiMego G, Kalnay E, Mitchell K, Sharpen PC, Ebisuzaki W, Jović D, Woollen J, Rogers E, Berbery EH, Ek MB, Fan Y, Grumbine R, Higgins W, Li H, Lin Y, Manikin G, Parrish D & Shi W (2006). North American Regional Reanalysis. *Bulletin of the American Meteorological Society*, 87(3):343–360.
- Naveau P, Huser R, Ribereau P & Hannart A (2016). Modeling jointly low, moderate, and heavy rainfall intensities without a threshold selection. *Water Resources Research*, 52(4):2753–2769.
- Neykov NM, Neytchev PN & Zucchini W (2014). Stochastic daily precipitation model with a heavy-tailed component. *Natural Hazards and Earth System Science*, 14(9):2321–2335.

- Peterson TC, Folland C, Gruza G, Hogg W, Mokssit A & Plummer N (2001). Report on the Activities of the Working Group on Climate Change Detection and Related Rapporteurs 1998-2001. WMO. Geneve, 143 pages.
- Piani C, Haerter JO & Coppola E (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. *Theoretical and Applied Climatology*, 99(1-2):187–192.
- Plummer DA, Caya D, Frigon A, Côté H, Giguère M, Paquin D, Biner S, Harvey R & de Elia R (2006). Climate and climate change over North America as simulated by the Canadian RCM. *Journal of Climate*, 19(13):3112–3132.
- Rusticucci M, Zazulie N & Raga GB (2014). Regional winter climate of the southern central Andes: Assessing the performance of ERA-Interim for climate studies. *Journal of Geophysical Research: Atmosphere*, 119(14):8568–8582.
- Saha S, Moorthi S, Pan HL, Wu X, Wang J, Nadiga S, Tripp P, Kistler R, Woollen J, Behringer D, Liu H, Stokes D, Grumbine R, Gayno G, Hou YT, Chuang HY, Juang HMH, Sela J, Iredell M, Treadon R, Kleist D, Van Delst P, Keyser D, Derber J, Ek M, Meng J, Wei H, Yang R, Lord S, Van Den Dool H, Kumar A, Wang W, Long C, Chelliah M, Xue Y, Huang B, Schemm JK, Ebisuzaki W, Lin R, Xie P, Chen M, Zhou S, Higgins W, Zou CZ, Liu Q, Chen Y, Han Y, Cucurull L, Reynolds RW, Rutledge G & Goldberg M (2010). The NCEP Climate Forecast System Reanalysis. *Bulletin of the American Meteorological Society*, 91(8):1015–1057.
- Schmidli J, Frei C & Vidale PL (2006). Downscaling from GCM precipitation: a benchmark for dynamical and statistical downscaling methods. *International Journal of Climatology*, 26(5):679–689.
- Serinaldi F & Kilsby CG (2014). Simulating daily rainfall fields over large areas for collective risk estimation. *Journal of Hydrology*, 512:285–302.
- Stern RD & Coe R (1984). A Model Fitting Analysis of Daily Rainfall Data. *Journal of the Royal Statistical Society. Series A (General)*, 147(1):1–34.
- Sun Y, Solomon S, Dai A & Portmann RW (2006). How often does it rain? *Journal of Climate*, 19(6):916–934.
- Tustison B, Harris D & Foufoula-Georgiou E (2001). Scale issues in verification of precipitation forecasts. *Journal of Geophysical Research*, 106(D11):11775–11784.
- Vaittinada Ayar P, Vrac M, Bastin S, Carreau J, Déqué M & Gallardo C (2016). Intercomparison of statistical and dynamical downscaling models under the euro- and med-cordex initiative framework: present climate evaluations. *Climate Dynamics*, 46(3):1301–1329.
- Vrac M & Naveau P (2007). Stochastic downscaling of precipitation: From dry events to heavy rainfalls. *Water Resources Research*, 43(7).

- Way RG, Oliva F & Viau AE (2016). Underestimated warming of northern Canada in the Berkeley Earth temperature product. *International Journal of Climatology*.
- Wijngaard JB, Klein Tank AMG & Können GP (2003). Homogeneity of 20th century European daily temperature and precipitation series. *International Journal of Climatology*, 23(6):679–692.
- Wilks D (2011). *Statistical Methods in the Atmospheric Sciences*. Academic Press, New York, USA, 3rd edition edition, 676 pages.
- Wilks D & Wilby RL (1999). The weather generation game: a review of stochastic weather models. *Progress in Physical Geography*, 23(3):329–357.
- Wong G, Maraun D, Vrac M, Widmann M, Eden JM & Kent T (2014). Stochastic model output statistics for bias correcting and downscaling precipitation including extremes. *Journal of Climate*, 27(18):6940–6959.
- Yee TW (2016). *VGAM: Vector Generalized Linear and Additive Models*. R package version 1.0-3.
- Yee TW & Wild CJ (1996). Vector Generalized Additive Models. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(3):481–493.
- Zhang Q, Körnich H & Holmgren K (2013). How well do reanalyses represent the southern African precipitation? *Climate Dynamics*, 40(3-4):951–962.

MODÉLISATION DES CHAMPS DE PRÉCIPITATIONS JOURNALIÈRES EN UTILISANT LA RÉANALYSE CFSR

Sommaire

1	Introduction	81
2	Article: Daily precipitation fields modeling across the Great Lakes reion (Canada) by using the CFSR reanalysis	83

1 Introduction

Ce chapitre s'inscrit dans la suite des résultats obtenus au Chapitre 4 et intègre dans la méthode de post-traitement à la fois la structure spatiale et la persistance temporelle des précipitations journalières, ce qui correspond à l'objectif 2 du travail de thèse.

À l'échelle journalière, la structure spatiale des précipitations n'était pas convenablement reproduite dans les séries post-traitées, deux sites voisins pouvaient présenter des séries très peu corrélées, contrairement à ce que l'on observe en réalité pour le processus de précipitation. Or, par construction les approches ne modélisent à aucun moment la structure spatiale particulière des précipitations journalières, car même si les coefficients des modèles de post-traitement présentaient une structure spatiale, la façon dont les simulations aléatoires ont été réalisées ne permet pas de conserver cette structure. Les caractéristiques de précipitations aux échelles temporelles plus grossières (p. ex., les moyennes climatiques) possédaient une certaine distribution spatiale (sites voisins présentant des estimations similaires) héritée de la covariable

précipitation de CFSR. Dans une optique où l'on désire proposer des séries continues de précipitations utilisables comme *proxy* de la précipitation locale sur un domaine donné, il est essentiel de disposer d'une structure spatiale cohérente de ces séries journalières. De plus, la persistance des précipitations journalières n'était également pas bien reproduite par les séries post-traitées (Chapitre 4). L'impact était alors observé sur les caractéristiques associées à la durée des événements à l'échelle journalière (p. ex., CWD-*Consecutive Wet Days*). Plusieurs analyses, non développées dans le présent manuscrit, ont montré que l'ajout de covariables dans les modèles de post-traitement (p. ex., l'occurrence ou non de précipitation au jour précédent) n'avait que peu d'incidence sur les simulations et ne permettait pas de remédier à ce problème. En effet, les modèles étaient plus complexes sans pour autant améliorer l'estimation de l'autocorrélation temporelle des séries post-traitées. Pour répondre à ces deux problématiques, des champs spatiaux météo-gaussiens latents ont été combinés aux modèles de post-traitements locaux du Chapitre 4.

L'approche théorique de post-traitement, dont les détails sont exposés dans le Chapitre 3, a été appliquée sur la région des Grands Lacs (Figure 3.1). Le nombre de stations relativement important par rapport aux autres régions et le processus des précipitations fortement influencé par la présence d'importantes masses d'eau (*snow Lake-effect*; Lucas-Picher *et al.*, 2017) présentant un défi pour le post-traitement justifient le choix de cette région. Ce travail a fait l'objet d'un article présenté à la Section 2 suivante et est introduit par un résumé en français. Enfin, les figures du matériel supplémentaire (*supplementary material*), auxquelles il est fait référence dans l'article ci-dessous, sont regroupées à la Section 2 de l'Annexe B.

2 Article: Daily precipitation fields modeling across the Great Lakes region (Canada) by using the CFSR reanalysis

Auteurs

Dikra Khedhaouiria¹, Alain Mailhot¹, Anne-Catherine Favre²

¹ Institut national de la recherche scientifique, Centre Eau Terre Environnement (INRS-ETE), 490 de la Couronne, Québec, Québec/Canada.

² Univ. Grenoble Alpes, CNRS, IRD, IGE, Grenoble INP*, F-38000 Grenoble, France

Publication ciblée

Article soumis pour publication dans *Journal of Applied Meteorology and Climatology* le 19 janvier 2018

Résumé étendu

Le but de cet article consiste à proposer et valider une approche de post-traitement stochastique qui intègre la structure spatio-temporelle des précipitations journalières. La méthodologie a été appliquée à la région des Grands Lacs et les séries post-traitées sont évaluées par leur performance à : (i) reproduire des caractéristiques standards des distributions de précipitations ; (ii) représenter la météorologie (*i.e.*, la séquence) de certains indices annuels à l'échelle du site et (iii) présenter des structures spatiales proches de celles observées. Le résumé suivant présente succinctement les méthodes d'évaluation des modèles de post-traitement, ainsi que les principaux résultats. Le cadre statistique de la méthode est introduit à la Section 3.3 du Chapitre 3.

Outils d'évaluation des séries post-traitées

Cent (100) séries ont été générées aléatoirement (et constituent les séries post-traitées) à partir des distributions journalières des précipitations locales combinées aux champs méta-gaussiens spatio-temporels latents. Les séries post-traitées, observées, et de CFSR (sans post-traitement) sont analysées à l'échelle des sites à travers les caractéristiques statistiques de base des précipitations journalières (la moyenne, l'écart-type, le nombre de jours avec précipitations). Les indices climatiques annuels de l'ETCCDI, présentés au Chapitre 4, ont également été analysés selon une évaluation météorologique en investiguant la qualité de la correspondance temporelle entre les valeurs annuelles de ces séries. Enfin, pour mettre

en évidence la valeur ajoutée des champs méta-gaussiens spatio-temporels latents, la corrélation spatiale des précipitations journalières a été investiguée. Certains indices de l'ETCCDI agrégés spatialement sur l'ensemble de la région ont également été étudiés à ces fins.

Le cadre *Comprehensive And Systematic Evaluation* (CASE) développé par Bennett *et al.* (2018) a été choisi comme outil d'évaluation et de comparaison des caractéristiques produites par les différents ensembles considérés (i.e. séries post-traitées, observées, et de CFSR). Le cadre CASE possède l'avantage de permettre la comparaison entre un ensemble de valeurs (distribution de valeurs simulées) et une valeur observée et attribue trois catégories de performance : 1) bonne (*good*) si l'observation se situe dans l'intervalle 95% de la distribution des valeurs simulées ; 2) acceptable (*fair*) si l'observation se situe dans l'intervalle à 99% ou si la différence relative entre la moyenne des simulations et l'observation est inférieure à 5% et 3) mauvaise (*poor*) autrement.

Pour intégrer dans l'analyse de performance, les caractéristiques statistiques et les indices climatiques issus de CFSR , tout en gardant le même cadre du CASE, ce dernier a dû être adapté. En effet, le CASE compare une valeur observée à un ensemble de valeurs issues de plusieurs simulations stochastiques. Or, évaluer CFSR aux observations revient à comparer deux valeurs (ou séries) entre elles. Il a donc été choisi de modifier le CASE pour le jeu de données de CFSR, tout en s'inspirant de la version de Bennett *et al.* (2018) de la façon suivante : i) la catégorie est bonne si la différence relative entre CFSR et les observations est inférieure à 2.5% ; ii) la catégorie est acceptable si la différence relative entre CFSR et les observations est inférieure à 5% mais strictement supérieure à 2.5% et iii) la catégorie est mauvaise pour les autres cas. L'objectif est similaire à celui du Chapitre 4, à savoir évaluer les performances relatives des séries CFSR et post-traitées relativement aux observations.

Principaux résultats

Les caractéristiques climatiques des séries journalières définissant l'intensité (p. ex., précipitation moyenne journalière) et l'occurrence (p. ex., nombre de jours pluvieux) sont, pour la très grande majorité des sites, bien reproduits par les séries post-traitées selon la définition du CASE. La persistance des événements de précipitations, évaluée à partir de l'autocorrélation temporelle des séries journalières pour différents décalages et la probabilité d'occurrence de ces événements selon des durées définies, a également montré de très bons résultats. Par ailleurs, lorsque comparées à CFSR sans post-traitement, les performances étaient systématiquement meilleures. Le modèle de post-traitement permet donc de reproduire plusieurs caractéristiques de la climatologie des séries journalières de précipitations en chacun des sites.

Les séries annuelles post-traitées des indices de l'ETCCDI sont également bien reproduites. En effet, environ 20% (80%) des sites possèdent 100% (entre 60 et 80%) de leurs valeurs annuelles post-traitées classées dans la catégorie "bonne", le reste des années se retrouvant généralement dans la catégorie "acceptable", et ce pour tous les indices avec cependant de plus faibles performances constatées pour les indices caractérisant les précipitations extrêmes. Par ailleurs, la proportion d'années se trouvant dans la catégorie bonne était systématiquement plus faible durant l'été, saison plus difficile à reproduire (cause de la présence de systèmes convectifs). La répartition annuelle des précipitations, importante pour plusieurs applications (p. ex., agriculture) a été analysée à travers les cycles annuels de précipitations, et a également été mieux simulée par les modèles de post-traitement que par CFSR. Les coefficients de corrélation sur ces cycles avec les observations étaient en effet plus élevés dans les séries post-traitées. Le cycle régional des cumuls mensuels des Grands Lacs, obtenu en moyennant spatialement les précipitations mensuelles, caractérisées par une augmentation des cumuls mensuels à partir du mois d'avril pour atteindre un maximum au mois de juillet et se stabiliser jusqu'au mois de novembre, est très bien reproduit avec les séries post-traitées, contrairement au cycle obtenu avec CFSR.

La structure spatiale, définie à partir des corrélogrammes, des séries journalières post-traitées reproduit bien la structure observée. De faibles sous-estimations des corrélations à courtes distances ont cependant été observées. Les corrélations spatiales post-traitées restent tout de même de meilleures estimations que celles fournies par CFSR. Les corrélations spatiales de CFSR étaient systématiquement supérieures à celles observées, ce qui est attendu pour des précipitations sur grilles. En moyennant les précipitations journalières sur le domaine, pour reconstituer une seule série des précipitations journalières spatiales, les performances étaient "bonnes" à la fois pour les séries post-traitées et pour CFSR, si l'on considère les séries des cumuls annuels.

Abstract

Reanalyses, generated by Numerical Weather Prediction methods assimilating past observations, provide consistent and continuous meteorological fields for a specific period. In regards to precipitation, reanalysis cannot be used as a climate proxy of the observed precipitation, as biases and scale mismatch exist between the datasets. In the present study, a Stochastic Model Output Statistics (SMOS) approach combined with meta-Gaussian spatio-temporal random fields were employed to cope with these caveats. The SMOS is based on the Generalized Linear Model (GLM) and Vector Generalized Linear model (VGLM) frameworks to model the precipitation occurrence and intensity, respectively. Both models use the Climate Forecast System Reanalysis (CFSR) precipitation as covariate and were locally calibrated at 331 sites across the Great Lakes region. Combined with meta-Gaussian random fields, the GLM and VGLM models allowed for the generation of spatially coherent daily precipitation fields across the region. The results indicated the approach corrected systematic biases and provided accurate spatio-temporal structure of the daily precipitation. Performances of selected precipitation indicators from the joint CCI/CLIVAR/JCOMM Expert Team on Climate Change Detection and Indices (ETCCDI) were good and were systematically improved when compared to CFSR.

1 Introduction

Precipitation fields are necessary to adequately represent the spatial distribution of precipitation event intensities, but also the temporal persistence in the precipitation sequences (Serinaldi & Kilsby, 2014). Hydrological modeling over large areas is one of the important applications for which spatially and temporally continuous precipitation inputs are ideally required (Lamb *et al.*, 2016). Infiltration-runoff and other physical processes are indeed better modeled with continuous input series and provide better tools for risk assessment than,

for example, using the classical design storm approach (Li *et al.*, 2014; Lamb *et al.*, 2016).

Many available gridded precipitation datasets may result from interpolation of station series (e.g., NRCan; Hopkinson *et al.*, 2011), from a combination of satellite estimates and gauge records (Huffman *et al.*, 1995), or from dynamically-based models (e.g., reanalyses) (see Table 1 in Beck *et al.*, 2017, for a non-exhaustive list of available precipitation datasets). Interpolated datasets are dependent on the interpolation method, on the density of stations, and tend to underestimate extreme precipitation (Contractor *et al.*, 2015; Gervais *et al.*, 2014b; Hofstra *et al.*, 2010; Way *et al.*,

2016). Regions where available records cover relatively short periods of time, and where spatial coverage remains sparse (e.g., northern regions) are impacted by interpolation errors (Contractor *et al.*, 2015; Gervais *et al.*, 2014b; Hofstra *et al.*, 2010; Way *et al.*, 2016). Satellite-based precipitation datasets cover short time periods, have issues with the estimation of certain kind of precipitation (e.g., shallow precipitation and snowfall; Behrangi *et al.*, 2014), and underestimate extremes (Contractor *et al.*, 2015; Sun *et al.*, 2010; Gervais *et al.*, 2014a). Dynamically-based datasets, produced by reanalyses, differ from interpolated and satellite products. Reanalyses models assimilate several past observations over a given period (Bengtsson & Shukla, 1988) and provide valuable (to some extent) spatio-temporal information for several physical fields. However, reanalyses are subject to systematic and random errors (due, for example, to parametrization of physical processes occurring at the sub-grid scale; Lorente-Plazas & Hacker, 2017), that could prevent their use in impact studies or hydrological modeling.

Therefore, it is essential to post-process the precipitation from reanalysis with approaches that preserve some spatial and temporal structures. The objective of this study is to correct and to downscale gridded daily CFSR precipitation up to local scale. Stochastic spatio-temporal post-processing models were developed for this purpose. Different statistical approaches have been proposed in the literature to enable the spatio-temporal modeling of daily precipitation. Haberlandt *et al.* (2011) proposed the classification of these statistical approaches into five groups: 1) Time series models to generate long time series with a Generalized Linear Model (GLM) or Chain-dependent process (Bardossy & Plate, 1992), 2) Alternating renewal processes based on the analyses of wet and dry-spell events (Pegram & Clothier, 2001); 3) Point processes to provide probabilistic arrival times of precipitation at the sub-daily scale (Onof *et al.*, 2000); 4) Disaggregation models based on the scaling properties of precipitation to temporally and spatially disaggregate precipitation (Lombardo *et al.*, 2017); and 5) Resampling techniques that do not require distribution assumptions of the random process and are based on sampling of observed values (Buishand & Brandsma, 2001). Haberlandt *et al.* (2011) and Wheater *et al.* (2005) proposed an extensive review of these approaches. Among these techniques, the time-series models combined with meta-Gaussian spatio-temporal random fields, appeared as the most efficient to post-process CFSR precipitation while providing at-site and spatially consistent daily precipitation series (Serinaldi & Kilsby, 2014). The time-series model proposed in the present study combines GLMs to model the precipitation occurrences and VGLMs to model the intensity on wet days, both using the daily CFSR precipitation as predictor. Binomial and a two-parameter Gamma distributions were chosen to model, respectively, the discrete component (wet and dry state) and

the continuous component (intensities on wet days) of the mixed daily precipitation distribution. The meta-Gaussian spatio-temporal latent field, calibrated separately, was used at the random simulation stage to enable stochastic simulation of daily precipitation fields with spatio-temporal structure similar to observations (Serinaldi & Kilsby, 2014).

Very few studies have developed processing models based on reanalysis precipitation. Actually, only Eum *et al.* (2017) has directly used reanalysis precipitation for downscaling purposes. Commonly, stochastic simulations of the daily precipitation use several large-scale predictors exogenous to the precipitation (Asong *et al.*, 2016a; Vaittinada Ayar *et al.*, 2015). Asong *et al.* (2016a) used a multisite GLM framework with several covariates from the NCEP/NCAR Reanalysis I (Kalnay *et al.*, 1996) across the Canadian Prairies to explore stochastic simulations of daily precipitation. However, while the authors adopted a multisite approach, they did not aim to provide spatially consistent daily precipitation fields. Serinaldi & Kilsby (2014) employed similar statistical tools to those of the present study across the Danube basin with the Sea Level Pressure (SLP) from the NCEP reanalysis as predictor. Besides using CFSR precipitation as a predictor, one major difference of the present paper with respect to Serinaldi & Kilsby (2014) is to propose local-scale daily precipitation (the authors simulated precipitation on a 25 km-resolution grid). These authors modeled the precipitation intensity using

the Generalized Pareto and Weibull distributions and demonstrated the generally good performances of this method for different temporal and spatial scales. Similar approaches were applied by Baxevani & Lennartsson (2015) to 12 stations in Sweden with one latent Gaussian field modeling both the occurrence and intensity processes, without considering, however, any physical large scale covariates. Baxevani & Lennartsson (2015) highlighted the advantages of their approach to represent some precipitation properties, but underlined the potential of the climate variables as covariates to further improve the realism of the simulated precipitation fields. Bennett *et al.* (2018) also demonstrated the relevance of a latent Gaussian field to model precipitation occurrence and intensity jointly across 22 stations in South Australia while also providing an evaluation framework for daily precipitation fields. In summary, this paper brought several contributions with, first, to use of the precipitation from the reanalysis as a covariate, which results in a simple approach to generate local-scale precipitation that can be readily implemented. Second, it also enabled the implementation of one latent field to ensure consistent daily precipitation fields across geographic region encompassing interesting climatic features (snowbelts around the Great Lakes Lucas-Picher *et al.*, 2017).

The present paper is structured as follows. Available datasets are presented in Section 2, while the stochastic spatio-temporal post-processing frame-

work is described in Section 3. Section 4 presents the evaluation approach, and results are summarized in Section 5. Finally, the conclusion is given in Section 6.

2 Datasets

Daily-observed precipitation series at 857 stations, covering the Great Lakes (GLakes) region, as defined by Plummer *et al.* (2006), were initially considered. Precipitations in this region are highly influenced by the lake effect, with high spatial variability of the annual amounts (Figure 1). Forty-one of these stations belong to the second generation Adjusted Precipitation for Canada dataset (APC2; Environment and Climate Change Canada, 2013; Mekis & Vincent, 2011). APC2 series were adjusted to account for wind undercatch, evaporation, and funnel wetting, with regards to rain, and improved snow density assessment (Devine & Mekis, 2008; Mekis & Vincent, 2011). The remaining stations (816) also provided by Environment and Climate Change Canada did not undergo any preliminary processing.

The following criteria were applied to control quality of observed series: 1) each year was required to have fewer than 10% missing daily values to be considered as a valid year; 2) stations nee-

ded to have at least 10 valid years during the study period (1979-2009) and more than five consecutive valid years. This last criterion was imposed to avoid datasets with sparse valid years. Importantly, some stations may have had recording inconsistencies due to factors such as changes in recording equipment, changes in the definition and measurements of precipitation trace (Mekis, 2005), missing values, choices of time windows to record daily precipitation (Hopkinson *et al.*, 2011), and other site disturbances (Beaulieu *et al.*, 2008).

To further scrutinize the data, especially at stations that were not part of the APC2 dataset, statistical homogeneity of annual precipitation series was also assessed with the Wijngaard *et al.* (2003) approach. On the basis of four statistical tests (Standard normal homogeneity test, Buishand range test, Von Neumann ratio test, and Pettitt test, Wijngaard *et al.*, 2003, references therein), the series were classified as “useful”, “doubtful” or “suspect”. In the following, only stations with “useful” series were selected, i.e. when at least three of the tests do not reject the null hypothesis that the temporal series are identically distributed at the 99% confidence level. A total of 331 valid precipitation series were identified and further considered for analysis. Figure 1 presents a map of the retained stations. Distances between pairs of stations ranged between 1 and 950 km.

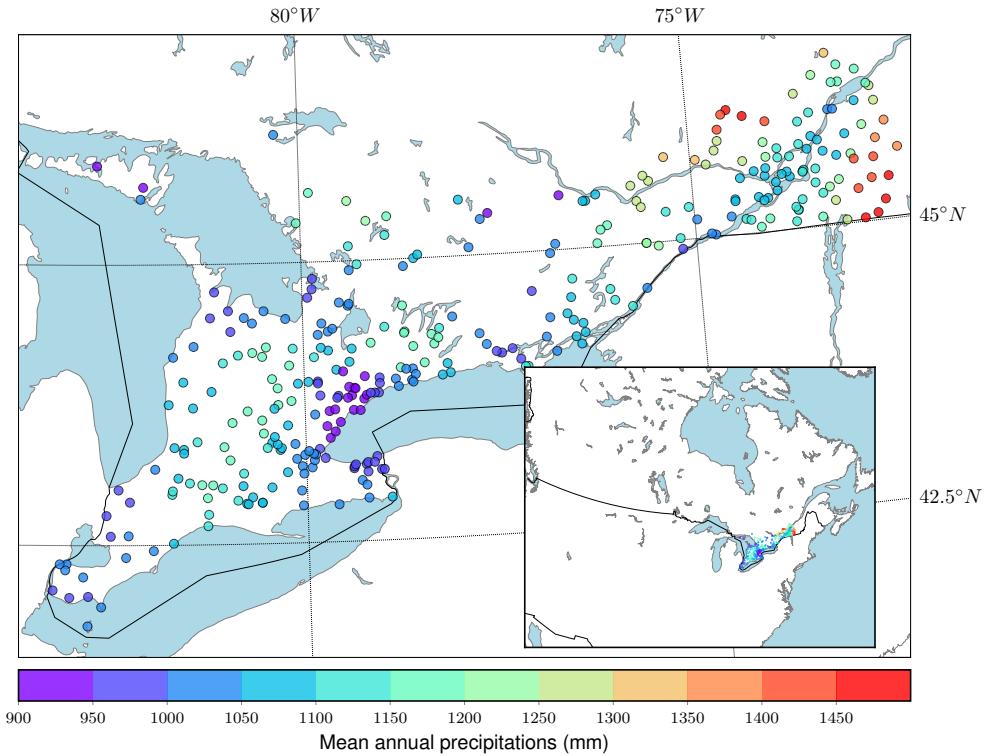


Figure 1 – Rainfall network used across the Great Lakes region with the corresponding recorded mean annual precipitation over the 1979-2009 period.

The Climate Forecast System Reanalysis (CFSR) was produced by the National Centers for Environmental Prediction (NCEP) with the Coupled Forecast System (CFS) model, and covers the 1979-2009 period (Saha *et al.*, 2010). This model simulates the past state of the ocean and atmos-

sphere at a horizontal resolution of 0.312° latitude $\times 0.312^\circ$ longitude (~ 38 km at 45°N), by assimilating quality-controlled observations (Saha *et al.*, 2010). CFSR also includes in the Land model two gridded precipitation products: 1) the pentad dataset of CMAP, and 2) the CPC unified global daily gauge analysis (Saha *et al.*, 2010, and references therein). CFSR differs from other reanalyses in that it uses a coupled atmosphere-ocean-sea ice-land

model (Bromwich *et al.*, 2011), assimilates satellite radiances during the entire period, and includes the time evolution of CO_2 concentrations (for more details see Mesinger *et al.*, 2006). The CFSR hourly precipitation amounts were aggregated to daily values.

3 Methodology

The proposed stochastic spatio-temporal post-processing proceeds in four steps, each illustrated in Figure 2. First, daily precipitation distributions were modeled. The mixed discrete and continuous distribution of precipitation led us to consider the

occurrence of wet and dry days separately (a wet day is defined as a day with more than 1 mm of precipitation; Dai, 2006; Schmidli *et al.*, 2006; Sun *et al.*, 2006, among others) and the precipitation intensity on wet days (Chandler & Wheater, 2002; Coe & Stern, 1982; Neykov *et al.*, 2014). The marginals were modeled within the GLM/VGLM framework (Yee & Wild, 1996), both using CFSR precipitation as a predictor. These models were built independently at each site with the corresponding CFSR grid-cell (Section 3.1). The main goal here was to provide precipitation distributions for each day, conditional on CFSR precipitation for the same day (Step 2 in Figure 2). The third steps involved the implementation of the latent meta-Gaussian fields to generate spatially and temporally-dependent uniform random fields (Figure 2, Step 3). The previous were combined with the GLM/VGLM models to generate daily precipitation series with consistent spatio-temporal structure (Figure 2, Step 4). The models building the post-processing approach are described hereafter.

3.1 Occurrence and Intensity Modeling

The marginal distribution of precipitation occurrence was modeled in a GLM framework using a binomial family function (Buishand *et al.*, 2004; Stern & Coe, 1984). In this logistic regression, the predictand was the recorded wet or dry state and the predictor was the log-transformed (Chandler 2002) daily CFSR intensity x_i . To account for sea-

sonality, sine and cosine functions were added. The conditional probability, p_i , of a day i being wet was therefore defined as:

$$\begin{aligned} g(p_i) &= \log\left(\frac{p_i}{1-p_i}\right) \\ &= \alpha_0 + \alpha_1 \log(x_i + 1) + \\ &\quad \alpha_2 \cos\left(\frac{2\pi d}{T}\right) + \alpha_3 \sin\left(\frac{2\pi d}{T}\right), \end{aligned} \quad (1)$$

where $g(\cdot)$ is the logit function, d the ordinal day, $T = 365.25$ days (the average yearly period for cosine and sine functions accounting for leap years). The $\{\alpha_k\}_{k \in [0,3]}$ are the regression coefficients estimated by maximum likelihood (MLE) with an iteratively reweighted least squares (IRLS) procedure (Buishand *et al.*, 2004).

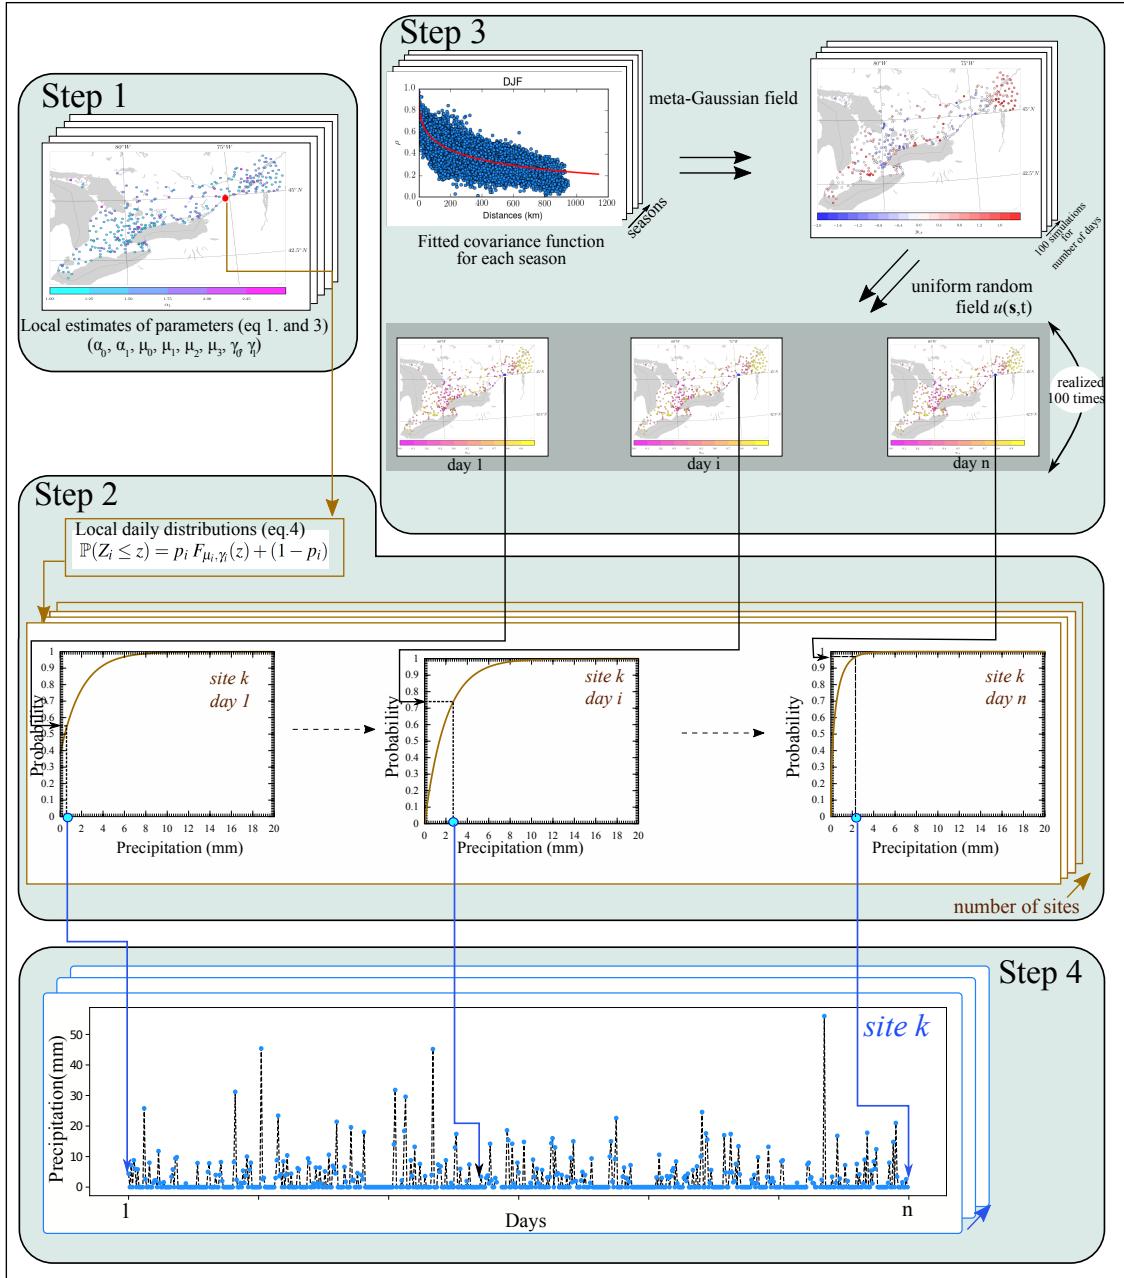


Figure 2 – Different steps of the post-processing approach

The two-parameter Gamma function was selected to model the marginal distribution of the precipitation intensity for wet days. The parameterization using the shape ($\gamma > 0$) and mean($\mu > 0$) parameters was chosen (McCullag & Nelder, 1989). With this parametrization, the scale parameter is

given by μ/γ and the variance by μ^2/γ . The probability density function $f_{\mu, \gamma}$ expressed as:

$$f_{\mu, \gamma}(z) = \frac{\gamma}{\mu \Gamma(\gamma)} \left(\frac{\gamma z}{\mu} \right)^{\gamma-1} e^{-\gamma z/\mu}, \quad (2)$$

where Γ is the gamma function and $z > 0$ the daily precipitation intensity. The daily local precipitation intensity distribution, conditional on CFSR precipitation, was defined within the VGLM framework (Yee & Wild, 1996). VGLMs are generalizations of GLMs that encompass the exponential distribution family and that enable for each distribution parameter to vary linearly according to several predictors (Yee, 2016b). Parameters μ_i and γ_i of the Gamma distribution on day i were expressed as a function of the log-transformed CFSR daily intensity (x_i). Seasonal post-processing terms (first order harmonic regression) were also considered for the mean μ_i . The resulting expressions are:

$$\begin{aligned} h(\mu_i) &= \eta_0 + \eta_1 \log(x_i + 1) + \\ &\quad \eta_2 \cos\left(\frac{2\pi d}{T}\right) + \eta_3 \sin\left(\frac{2\pi d}{T}\right), \quad (3) \\ h(\gamma_i) &= \beta_0 + \beta_1 \log(x_i + 1), \end{aligned}$$

where $h(\cdot)$ is the log link function, $T = 365.25$ days and $\{\eta_k\}_{k \in [0,3]}$, and $\{\beta_k\}_{k \in [0,1]}$ are the regression coefficients obtained using the MLE method (Yee, 2016b, CRAN R VGAM Package). The 1 mm threshold defining wet days ($z > 1$ mm) leading to misfits of the small intensities, all precipitation on wet days were shifted by -1 mm before estimating parameter values and then shifted back by +1 mm (Wong *et al.*, 2014). Model selection is discussed in Section 5.

Combining the conditional probability of occurrence p_i (eq. 1) and the cumulative distribution function (CDF) of the daily precipitation intensity F_{μ_i, γ_i} (from eq. 2 and 3), the mixed CDF of the local precipitation on day i , Z_i , can be written as (Figure 2, Steps 1 and 2):

$$\mathbb{P}(Z_i \leq z) = p_i F_{\mu_i, \gamma_i}(z) + (1 - p_i) \quad (4)$$

3.2 Meta-Gaussian random field

One meta-Gaussian random field was used to generate spatio-temporal uniform random fields with spatial and temporal structures similar to those of recorded daily precipitation. This parsimonious approach, developed by Serinaldi & Kilsby (2014), was used to model these structures using both the occurrence and intensity of the daily precipitation.

3.2.1 Spatial component

The modeling of the random process $Z(s, t)$, where s and t are, respectively, the position in a d -dimensional space \mathbb{R}^d ($d \geq 1$) and the time, were here based on a multivariate Gaussian framework. The process was then defined by its covariance function $C(s, t)$ (Stein, 1999). To enable the use of the theory of random field simulations, a covariance function of the daily precipitation must be specified and adjusted to the empirical covariogram (the correlation between the pair of spatial observations varying in accordance with the distances, Step 3 in Figure 2). For sake of simplicity, the covariance

function was assumed stationary and isotropic but with different covariance according to seasons. The covariance is only a function of the distance between pairs of points, $C(\mathbf{h})$, where $h = ||s_i - s_j||_{i \neq j}$. Due to the skewness of the daily precipitation distribution, Kendall correlation coefficient, τ_k , was used instead of Pearson coefficient to estimate the inter-station correlation. The Kendall's τ_k is also advantageous in that it can be directly linked to the Pearson coefficient of correlation, ρ_s , with the following expression $\rho_s = \sin(\tau_k\pi/2)$ (Kendall, 1962), and then can be used in the random field simulations. Several parametric covariance functions were tested (Cressie & Huang, 1999) and the one that best fit the empirical covariance, according to the weighted least squares criterion, was selected. Finally, 100 random field simulations were carried out with the CRAN R VGAM Package (Schlather *et al.*, 2017, Step 3 in Figure 2).

3.2.2 Temporal component

The definition of a spatial covariance structure allows for the simulation of a random field but without taking into account the temporal autocorrelation. Following Serinaldi & Kilsby (2014), a lag-1 autocorrelation, ρ_Δ , was introduced to ensure temporal dependence in the random field by using the following expression (Podgórski & Wegener, 2012):

$$y(s, t + 1) = \rho_\Delta y(s, t) + \sqrt{1 - \rho_\Delta^2} z(s) \quad (5)$$

where y is the spatio-temporal Gaussian random field and z the spatial random field varying according to seasons (Section 3.2). As for the spatial analysis, the lag-1 temporal autocorrelations were first assessed using Kendall τ_k and then linked to Pearson correlation coefficients. As the temporal autocorrelations, simulated by CFSR, were in agreement with the recorded values (not shown here), CFSR daily precipitation autocorrelations were used in the post-processing. This choice was guided by outside purposes, not developed in the present study, to simulate at sites without records. Finally, to generate simulations from the daily precipitation distribution (eq. 4), the Gaussian random field was transformed to spatio-temporal uniform fields: $u(s, t) = \phi^{-1}(y(s, t))$, where ϕ^{-1} is the inverse Gaussian cumulative distribution function (Steps 3 and 4 in Figure 2).

4 Evaluation framework of the post-processed series

One hundred (100) precipitation series, referred hereafter as post-processed series, were randomly generated according to the methodology developed in the previous section (Figure 2, Step 4). Several characteristics of the post-processed series at different temporal and spatial scales were assessed. First, the daily characteristics that define the occurrence, persistence and intensity of the at-site daily precipitation were estimated. Then, annual and sea-

Table 1 – Precipitation indices from the ETCCDI list computed at the annual and seasonal time scales (adapted from Donat *et al.*, 2014)

Climate index identifier	Name	Description	Units
<i>Duration</i>			
CDD	Consecutive dry days	Annual maximum number of consecutive dry days (< 1 mm)	days
CWD	Consecutive wet days	Annual maximum number of consecutive wet days (≥ 1 mm)	days
<i>Frequency</i>			
R10mm	Number of heavy precipitation	Annual number of days with precipitation ≥ 10 mm	-
R20mm	Number of very heavy precipitation	Annual number of days with precipitation ≥ 20 mm	-
<i>Intensity</i>			
PRCPTOT	Total wet day precipitation	Annual total precipitation	mm
Rx1day	Maximum 1-day precipitation	Annual maximum 1-day precipitation	mm
Rx5day	Maximum 5-day precipitation	Annual maximum 5-day precipitation	mm
R95p	Very wet days	Annual amount when daily precipitation is >95 th percentile of the daily precipitation over the reference period	mm
R99p	Extremely wet days	Annual amount when daily precipitation is >99 th percentile of the daily precipitation over the reference period	mm

sonal precipitation were investigated for selected climate indices (Table 1). Finally, spatial characteristics of the precipitation field were investigated through spatially averaged precipitation series (see Section 4.2). Table 2 summarizes all the indices and characteristics that were evaluated. The evaluation of the proposed methodology aimed to answer two questions: 1) Are the characteristics/indices of the observed series more adequately reproduced by the post-processed series than by the CFSR series ? 2) Does the post-processed series provide good estimates when compared to the observations ?

Following Bennett *et al.* (2018), an adaptation of the Comprehensive And Systematic Evaluation (CASE) framework was used to evaluate and compare the observed and post-processed series. The CASE framework allows comparisons of stochastic precipitation simulations to observations by classifying the performances into three categories: 1)

good, if the observation lies within the simulation's 90% probability limits; 2) fair if the observation lies within the simulation's 99.7% probability limits, assuming the uncertainty is normally distributed, or if the absolute relative difference between the observation and the averaged simulations is under 5%; and 3) poor otherwise. Since the CASE framework allows for the comparison of single values to intervals, it was adapted, as illustrated in Figure 3, to compare single observed value to corresponding CFSR value. The good and fair categories were attributed to performances when the absolute relative differences between these two datasets were smaller than, respectively, 2.5 and 5% and poor otherwise. The following sections provide further details about the selected climate indices and how the CASE framework was adapted to allow year-to-year assessment. The spatio-temporal evaluation of the post-processed time series was also further developed.

Table 2 – Summary of the characteristics assessed at the corresponding temporal and spacial scale.

Spatial scale	Time-scale	Time series from which characteristics are derived	characteristics to be assessed
At-site	Climate	Daily precipitation	Mean, mean on wet days, standard-deviation, 95th percentile, number of wet days, and autocorrelation from lag 1 to 3
		Dry and wet events durations (1 to 5 days) days	Frequency of occurrence of the dry and wet events for various durations
		Time series of occurrences of dry and wet days	Markov transition probabilities
		Monthly amount averaged over the 1979-2009 period from daily precipitation at each site (annual cycle)	Pearson correlation for the annual cycle
	Annual	Annual and seasonal series for selected ETDCCI indices (see Table 1)	Index estimates per year and per year per season
Region	Climate	Daily precipitation	Spatial correlation between pairs of sites
		Time series of occurrences of dry and wet days	Proportion of days when the pair of sites are simultaneously wet or dry
		Monthly amount averaged over the 1979-2009 period from the spatially-averaged daily precipitation across the region (One time series for the region with 12 values, each is a climate average for a month)	Pearson correlation on the annual cycle
	Annual	Annual and seasonal time series of index selected from the ETCCDI list (Table 1) for the unique spatially-averaged daily precipitation across the region	Index estimates per year and per year per season

4.1 Annual and seasonal assessment

The at-site precipitation annual cycle is an important feature that must be well represented by the post-processing approach. Monthly precipitation averaged over the 1979-2009 period were computed to analyze these cycles. CFSR and post-processed annual cycles were then compared to observed cycles with the Pearson correlation.

Annual and seasonal precipitation indices were selected among the Joint CCI/CLIVAR/JCOMM Expert Team on Climate Change Detection and Indices (ETCCDI) list (Peterson *et al.*, 2001). They are related to three main attributes of precipitation: 1) persistence through the annual maximum length of wet and dry spells (CDD and CDW); 2) frequency of daily precipitation for moderate annual precipitation events (R10mm and R20mm); 3)

intensity for various precipitation regimes (PRCP-TOT, Rx1day, Rx5day, R95p and R99p; see Table 1). All indices were estimated for each year (e.g., PRCP-TOT characterize the precipitation annual amount for each year).

Initially developed to compare characteristic climate means or distributions (Baxevani & Lennartsson, 2015), the CASE framework was slightly adapted for the annual ETCCDI indices to allow year-to-year analyses. Each ensemble of the 100 post-processed indices $\{I_{sim_k}^{(j)}\}_{k \in [1, 100]}$ were compared to the corresponding $I_{obs}^{(j)}$ within the CASE framework, where j , sim_k , and I correspond to a given year, the k^{th} simulation and one ETCCDI index, respectively. The results were reported as the fraction of years being classified as “good”, “fair” or “poor” at each site and for each index.

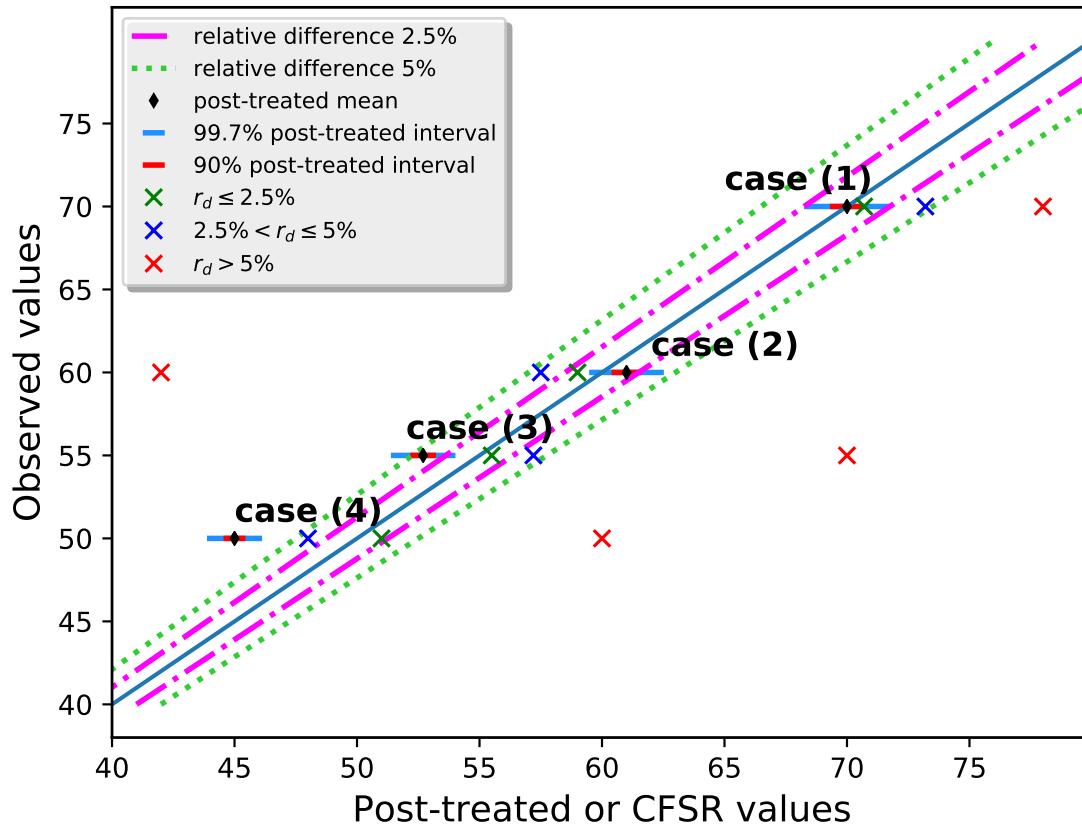


Figure 3 – Four possible cases when comparing CFSR (crosses) or post-processed (confidence intervals) to observations : case (1) “good” performances (90% simulated intervals) ; cases (2) and (3) “fair” performance; and case (4) “poor” performances. CFSR performances (crosses) for the four cases were considered “good”, “fair” or “poor” if the relative differences with the observations rd were $\leq 2.5\%$, $> 2.5\%$ and $\leq 5\%$, or $> 5\%$, respectively (adapted from Bennett *et al.*, 2018).

4.2 Spatial evaluation

The spatial evaluation was based on the empirical covariograms of the daily precipitation, smoothed with Loess curves (Cleveland & Devlin, 1988), for the three different datasets (observed, CFSR, 100 post-processed). The proportion of days being simultaneously dry or wet for each pair of sites was also estimated to characterize the spatial intermittence of the precipitation and also to evaluate the chosen covariance function. The aim here was to jointly assess the spatial structure of the occurrence

and the intensity of the daily precipitation (Baxe-vani & Lennartsson, 2015).

As suggested by Kleiber *et al.* (2012) and Baxe-vani & Lennartsson (2015), spatio-temporal characteristics of the post-processed, observed and CFSR precipitation fields are also relevant to assess simultaneously spatial and temporal structure in the models. To this end, the precipitation was spatially-averaged across the region for each day, and only days with valid observed values were considered in the analysis. The regional-averaged time series were

used to estimate the following ETCCDI indices: PRCPTOT, Rx1day and Rx5day. The annual cycle was finally examined with the regional series to investigate the extent to which post-processed and CFSR reproduced the monthly precipitation evolution at the domain scale.

5 Results and discussion

5.1 Selection of the post-processing models

Several GLMs and VGLMs were tested by sequentially adding linear predictors (seasonal terms and CFSR precipitation) in the parameters of the occurrence and intensity distributions. The most appropriate model for both distributions was selected using the Akaike Information Criterion (AIC; Akaike, 1974). According to AIC, the precipitation occurrence was better modeled with seasonal terms

for all sites, i.e. with $[\alpha_0, \alpha_1, \alpha_2, \alpha_3] \neq \mathbf{0}$ (eq. 1). With regard to the intensity modeling, three VGLM nested models, presented in Table 3, were tested for the post-processing. The S-MS model, i.e. with $[\eta_0, \eta_1, \eta_2, \eta_3] \neq \mathbf{0}$ and $[\beta_0, \beta_1] \neq \mathbf{0}$, (eq. 3) was selected at all sites, according to AIC.

The two-parameter isotropic Matérn function (Stein, 1999) was selected to model the empirical spatial covariance structure and was therefore used for the meta-Gaussian random field:

$$C(h) = \frac{1}{2^{\nu-1}\Gamma(\nu)} \left(\sqrt{2\nu} \frac{h}{a} \right)^{\nu} K_{\nu} \left(\sqrt{2\nu} \frac{h}{a} \right), \quad (6)$$

where $a > 0$ is the scale parameter, $\nu \geq 0$ the order of the modified Bessel function $K_{\nu}(.)$ of the second kind, $\Gamma(.)$ the Gamma function, and h the distances between the pair of sites. Figure S1 in the supplementary material displays the empirical covariogram as well as the four tested covariance functions (Stable, Cauchy, Whittle and Matérn functions).

Table 3 – List of the nested VGLM models used to post-process precipitation intensity (see eq.3 and Section 3.1 for the terminology and definition of variables)

Model name	Daily mean parameter function $h(\mu_i)$	Daily shape parameter function $h(\gamma_i)$
Non Seasonal Conditional Mean (NS-M)	$\eta_0 + \eta_1 \log(x_i + 1)$	β_0
Non Seasonal Conditional Mean and Shape (NS-MS)	$\eta_0 + \eta_1 \log(x_i + 1)$	$\beta_0 + \beta_1 \log(x_i + 1)$
Seasonal Conditional Mean and Shape (S-MS)	$\eta_0 + \eta_1 \log(x_i + 1) + \eta_2 \cos\left(\frac{2\pi d}{T}\right) + \eta_3 \sin\left(\frac{2\pi d}{T}\right)$	$\beta_0 + \beta_1 \log(x_i + 1)$

5.2 At-site daily statistic performances

Figure 4 shows the at-site daily statistics for CFSR and post-processed series compared to the observations. All the four post-processed daily statistics, the mean on all day and on wet days, the 95th percentile, the standard deviation and the number of wet days, clearly outperformed CFSR as shown by the scattered points in Figure 4. Good performances were observed for 90% or more of the sites (and up to 98% for the mean precipitation values), while the performance for the remaining sites was “fair”. Of the sites with fair or good performances, almost 100% outperformed CFSR, meaning that when a site was “good”, respectively “fair”, for given post-processed metrics, the associated CFSR metrics fell in the “fair” or “poor”, respectively “poor”, category. At the seasonal scale, Table 4 shows that post-processed daily mean precipitation and precipitation for wet days were by far better represented during spring (MAM) and autumn (SON), with more than 96% of sites displaying “good” or “fair” performances. These percentages were below 90% for winter (DJF) and summer (JJA) as post-processed estimates generally underestimated observed values (not shown for conciseness). The 95th percentile precipitation was also well represented for all seasons, with more than 94% of sites with post-processed “good” or “fair” performances, except DJF where this value decreased to 76%. Again, performances for post-

processed series were improved for a majority of sites compared to CFSR. These results demonstrated that the post-processing approach significantly improved at-site daily statistics at both annual and seasonal scales.

The transition probabilities between wet and dry consecutive day performances are presented in Figure 5. The probability of a wet day preceded by a wet (p_{11}) or dry day (p_{01}) remains (slightly) over or underestimated, respectively, by post-processed series while performances are “fair” for a majority of sites (around 50-60%) for these transition probabilities. Post-treated series systematically outperformed those in CFSR for all sites (not shown for conciseness). The seasonal analysis (Figure S2 in supplementary material) showed similar results for MAM, whereas the post-processing performances were “good” for a higher proportion of sites for the other seasons. Performances for post-processed series were much better for transitions to dry days (p_{00}, p_{10}) with more than 70% (25%) of sites having “good” (“fair”) performances.

Table 4 – Percentage of sites with post-processed statistics (columns) being in the “good” or “fair” category categories for each season (lines). Numbers in parentheses indicate the percentage of sites in the “good” or “fair” categories that had improved (first number), similar (second number), or worse performances compared with CFSR. For instance, for the post-processed daily DJF mean precipitation (first line, first column entry), of the 81% of sites with “good” or “fair” performances, 96% outperformed CFSR, 3% displayed similar performances, and 1% were outperformed by CFSR.

	Mean	Mean on wet days	Standard deviation	p95	Number of wet days
DJF	81 (96 - 3 - 1)	86 (99 - 1 - 0)	100 (88 - 7 - 5)	77 (86 - 6 - 10)	99 (100 - 0 - 0)
MAM	100 (79 - 18 - 4)	98 (86 - 13 - 1)	100 (88 - 12 - 0)	98 (68 - 23 - 10)	98 (96 - 4 - 0)
JJA	87 (82 - 14 - 4)	84 (87 - 13 - 0)	98 (87 - 13 - 0)	95 (70 - 20 - 10)	100 (96 - 4 - 0)
SON	99 (80 - 17 - 4)	95 (86 - 13 - 1)	99 (87 - 12 - 1)	98 (69 - 21 - 10)	99 (96 - 4 - 0)

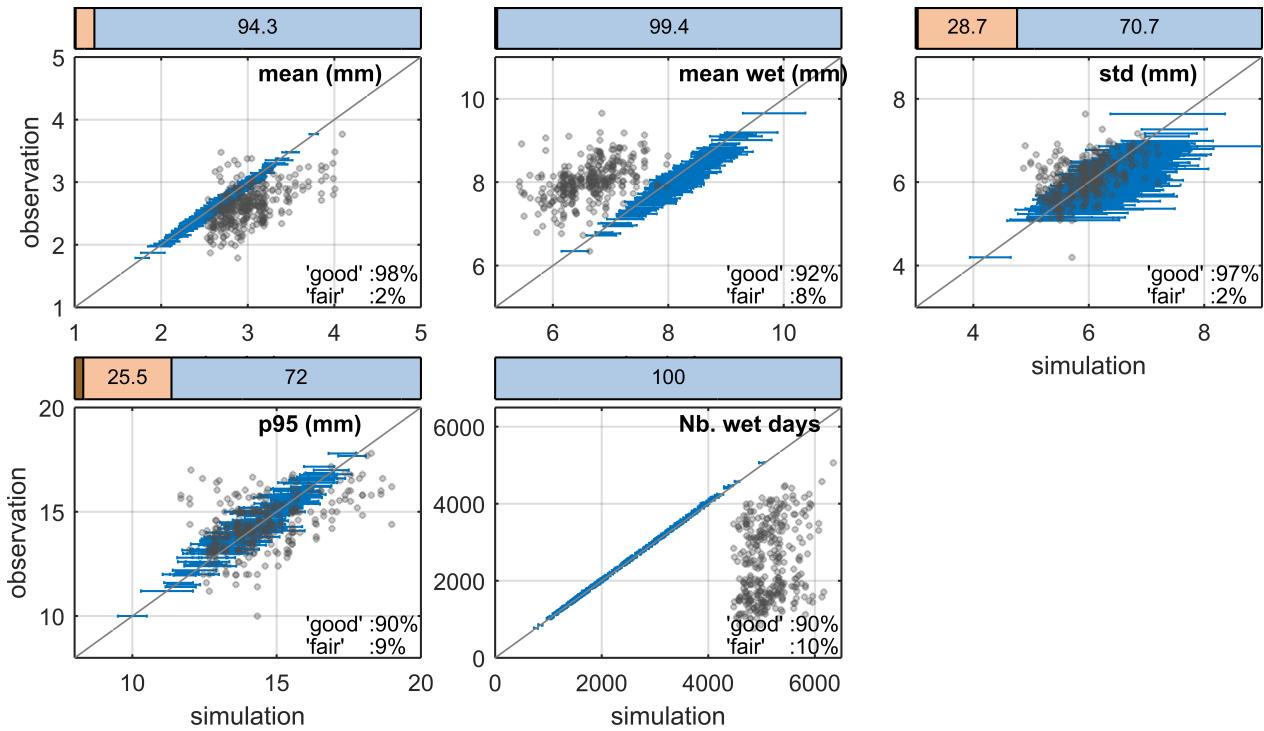


Figure 4 – At-site precipitation mean (mean), mean on wet days (mean wet), standard deviation (std), 95th percentile (p95), and number of wet days (Nb. wet days) estimated from recorded series (*y*-axis) as a function of the corresponding values estimated from post-processed (90% confidence interval; blue lines) or CFSR daily series (gray points). Proportion of sites with “good” and “fair” performances are indicated in the lower right corner of each panel. The scale above each panel indicates the percentage of sites with “good” or “fair” performances after post-processing that displayed better (pale blue), similar (pale brown) or poorer (dark brown) performances compared to CFSR (percentages are not indicated when below 20%).

Figure 6 summarizes the results for the probability of occurrence of wet and dry spells of various durations. Performances for wet spell probabilities improved as duration increased, with 34% (23%) of the sites for 1-day duration to 91% (8%) for 5-day classified in the “good” (“fair”) performance category. The $p_{wet}^{(1)}$ were generally overestimated by post-processed series and to a greater extent by CFSR, a result that may be explained by the so-called drizzle effect (Dai, 2006). Performances for dry-spells probabilities were similar with slightly higher percentages of stations in the “good” category, with 42% (23%) of sites for 1-day duration and above 86% (12%) for higher durations in the “good” (“fair”) performance category. Results for the post-processed daily series autocorrelation sho-

wed that 80% (15%), 35% (25%) and 65% (20%) of the sites displayed “good” (“fair”) performances for, respectively, lag-1, -2, and -3 day autocorrelations. Furthermore, all autocorrelation statistics were systematically improved when compared to CFSR.

Pearson correlation coefficients between observed monthly precipitation averaged over the 1979–2009 period and corresponding values from CFSR and post-processed series were estimated (see supplementary material, Figure S3). CFSR correlations were significantly improved at almost all sites with post-process median correlation values ranging from 0.6 to 0.9, while CFSR correlations were rather poor with correlations below 0.4 (even negative) for almost 60% of stations.

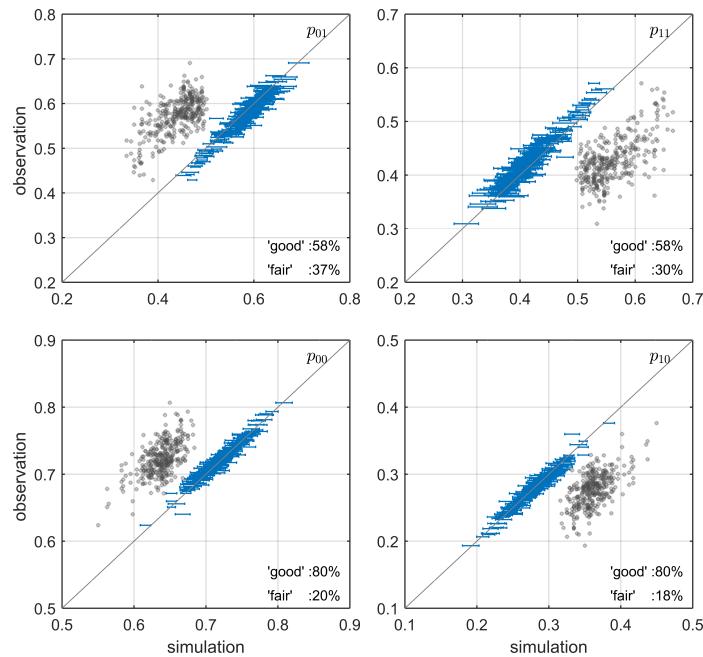


Figure 5 – At-site two-state transition probabilities p_{01} , p_{11} , p_{00} and p_{10} (dry:0; wet:1) estimated from the observed series as a function of the corresponding values estimated from the post-processed (90% confidence interval) or CFSR daily time series (gray points). Proportion of sites with “good” and “fair” performances are indicated in the lower right corner of each panel.

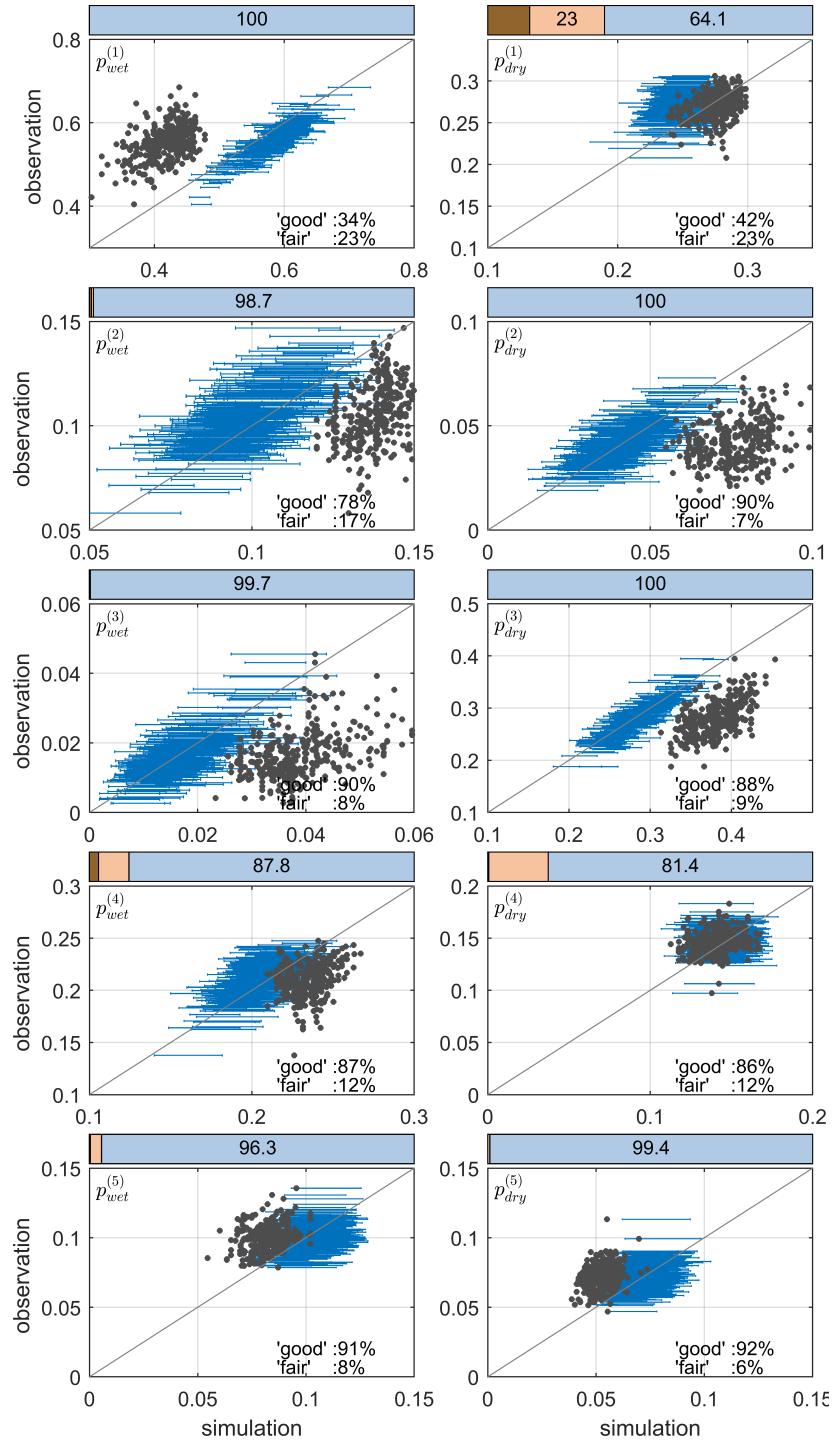


Figure 6 – At-site probabilities of occurrence of wet (first column) or dry (second column) spells of various durations (from 1 to 5 days) ($p_{wet/dry}^{(duration)}$) estimated from observed series as a function of the corresponding values estimated from the post-processed (90% confidence interval) or CFSR daily time series (gray points). Proportion of sites with good and fair performances are indicated in the lower right corner of each panel. The scale above each panel indicates the percentage of sites with good or fair performances after post-processing that displayed higher (pale blue), similar (pale brown) or smaller (dark brown) performances compared to CFSR (percentages are not indicated when below 20%).

5.3 At-site ETCCDI index performances

The year-to-year ETCCDI index series performances at the annual and seasonal time scale are illustrated series Figures 7 and 8. A large number of sites displayed post-processed index values with high fractions of years in the “good” and “fair” performance categories. All indices had approximately 20% of the sites with all annual index values in the good category. In comparison, for about 40% of the sites the percentage of annual values classified as good ranged from 90 to 95%, and for the remaining 40% of the sites this percentage was generally above 80%. For many stations, a large fraction of years that were not classified as good were classified as fair (green curves in Figure 7).

Small differences among the indices can be observed. For instance, the post-processed CDW series were more likely to have their annual values in the good category than the post-processed CDD series. Indices characterizing moderate extreme events, such as R10mm and R95p, also had their performances degraded when extreme events went even more extreme, i.e. R20mm and R99p. This may be partly explained by the light tail of the Gamma distribution preventing from capturing heavy precipitation. Comparisons at the seasonal time scale are presented in Figure 8 (only years with “good” performances were considered for conciseness). The proportion of years with good performances was higher for MAM and SON than for

DJF or JJA for most indices. Post-processing performance was systematically lower during JJA, as previously mentioned (Section 5.2). However, more than 90% of the annual series for all indices and more than 90% of sites were in good or fair categories for all seasons, the only exception being the PRCPTOT index during JJA (Supplementary material, Figure S3). Finally, comparing performances of post-processed series to those of CFSR indicated that, for given sites and indices, on average around 95% of the post-processed annual values in the good and fair categories (boxplots (a) in Figure 7), outperformed corresponding CFSR values. This percentage averaged from 80 to 90% (boxplots in Figure S4) at the seasonal scale. Generally, years for which the post-processed index performances were not better than for CFSR, displayed similar performances to CFSR (boxplot (b) in Figure 7 and Figure S4).

5.4 Spatial evaluation

Spatial correlations between post-processed, CFSR, and observed daily precipitation series for all pairs of sites were estimated at the annual and seasonal time scales (Figure 9). Although overestimated, seasonal dependence of spatial correlation obtained from CFSR is consistent with the one estimated from observations (e.g., weaker correlations in summer and larger in winter). Slight overestimations of the post-processed spatial correlations, at relatively short (<250 km) and at very large distances (>750 km), were obtained during each sea-

son. Otherwise, for distances between 250 km and 750 km, the observed correlation fell in the good category during JJA and even at the year scale, poorer performances were observed during DJF. The hypothesis of the spatial isotropy may partly explain these performances, especially during winter where

snow accumulates most likely south of the Great Lakes (snow-lake effect, Lucas-Picher *et al.*, 2017). The use of covariance functions to fit scattered empirical spatial correlations may also contribute to these discrepancies.

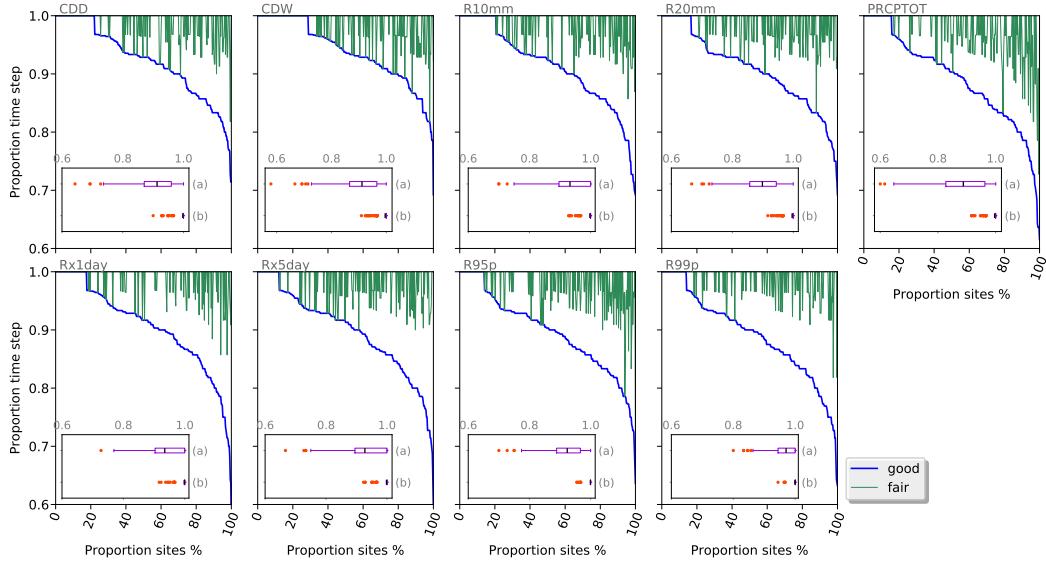


Figure 7 – Fraction of annual values displaying a good performance (blue curve; *y*-axis) for each sites (sites are presented as percentage and ordered with decreasing fractions of years with good performance) and for various ETCCDI indices. For example, around 20% of sites had their entire annual CDD series (proportion equal to 1) in the good category. Green lines indicate the corresponding fractions of years with fair performances. Boxplots in each panel illustrate the distribution of the fraction of years with post-processed good or fair performances that: (a) strictly outperformed CFSR; (b) display similar performance to CFSR or outperformed CFSR. Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the mean value, while the whiskers lower and upper limits correspond to $q_{25}-1.5 \times \text{IQR}$ and $q_{75}+1.5 \times \text{IQR}$. Outliers are indicated with orange circles.

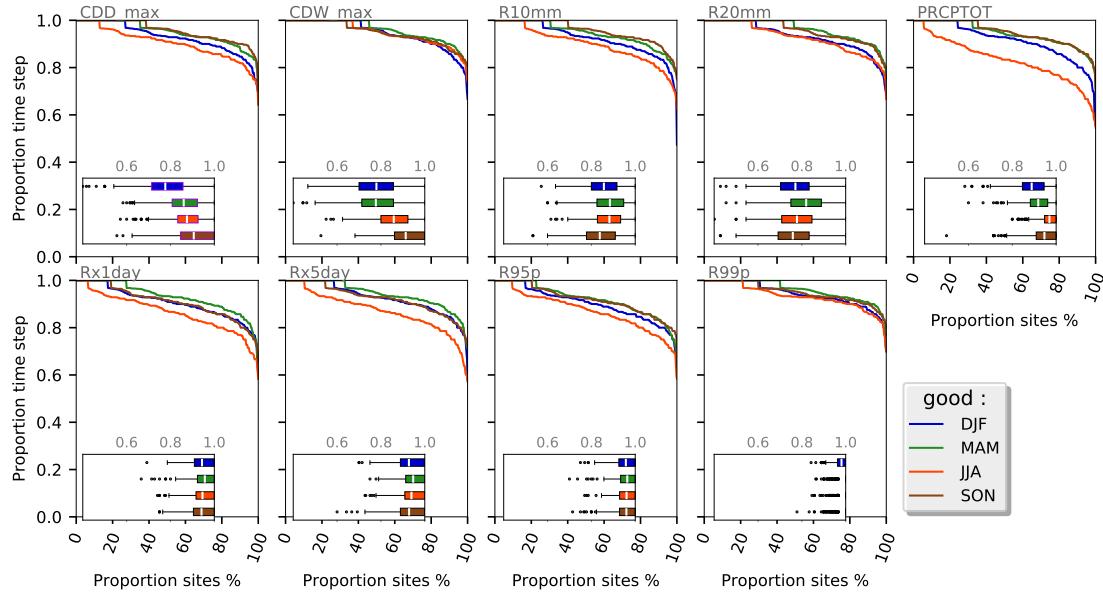


Figure 8 – Fraction of annual values displaying a good performance for each sites (sites are presented as percentage and ordered with decreasing fractions of years with good performance) and for various ETCCDI indices and season (DJF-blue, MAM-green, JJA-red, and SON-brown). Boxplots in each panel illustrate the distribution of the fraction of years with post-processed good performance which have similar performance to CFSR or outperformed CFSR. Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the mean value, while the whiskers lower and upper limits correspond to $q_{25}-1.5\times\text{IQR}$ and $q_{75}+1.5\times\text{IQR}$. Outliers are indicated with black circles.

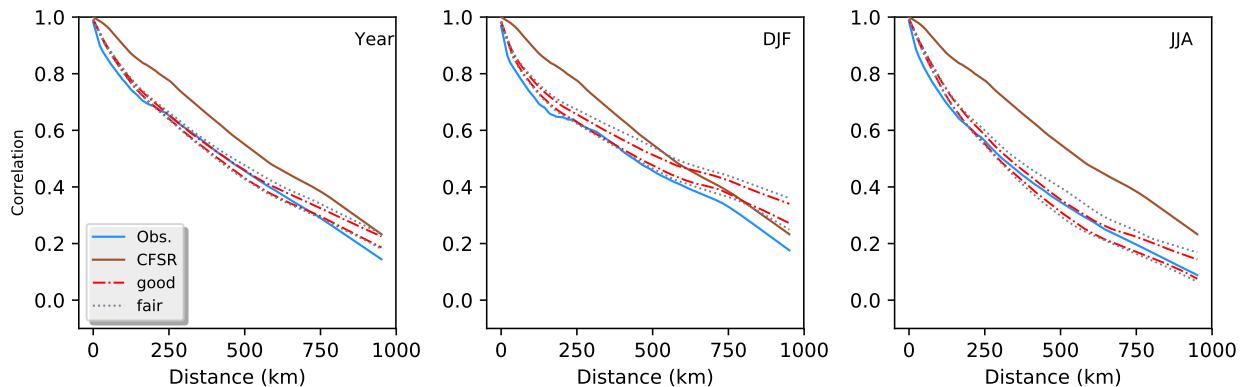


Figure 9 – Spatial correlations of the daily precipitation series at the annual and seasonal (DJF and JJA) time scales for observed (blue) and CFSR (brown) datasets. The post-processed series are illustrated with the 90% (dashed red line, “good”) and 99.7% (dotted grey lines, “fair”) confidence intervals.

The proportions of simultaneous wet or dry days for each pair of sites were also estimated (Figure 10) to assess the ability of the latent Gaussian field to represent the wet and dry sites each day. The frequencies of simultaneous dry days were more ade-

quately reproduced by post-processed series than simultaneous wet days with approximately 90% of the pairs falling in the “good” or “fair” categories (for both seasons) for dry days compared to approximately 70% for wet days. Even though the

post-processing produced better results than the CFSR, further improvements to the spatial modeling are needed, especially during the summer.

PRCPTOT and Rx1day annual series averaged over the study area are presented in Figure 11. Post-processed series fell within the “good” performance intervals, while CFSR broadly produced “fair” performances over many years, mainly because of poor performances during DJF and MAM seasons (Supplementary material, Figure S5). Unlike PRCP-TOT, median values across post-processed Rx1day produced low inter-annual variability (black line Figure 11) compared to observations, which was explained by the noisy character of the Rx1day post-

treated series. However, the inter-annual variability of each post-treated annual serie was similar to those observed. Very alike results were obtained for Rx5day and are not shown for conciseness. Finally, the annual cycle, computed with spatially-averaged daily precipitation, was significantly improved by the post-processing method as shown in Figure 12. The shape of the annual cycle with its plateau from June to December, and its lower precipitation, in February were adequately reproduced in the post-processed series. Almost all months were classified as “good” or “fair”, except January, February and July. Noticeable improvements were observed compared to CFSR.

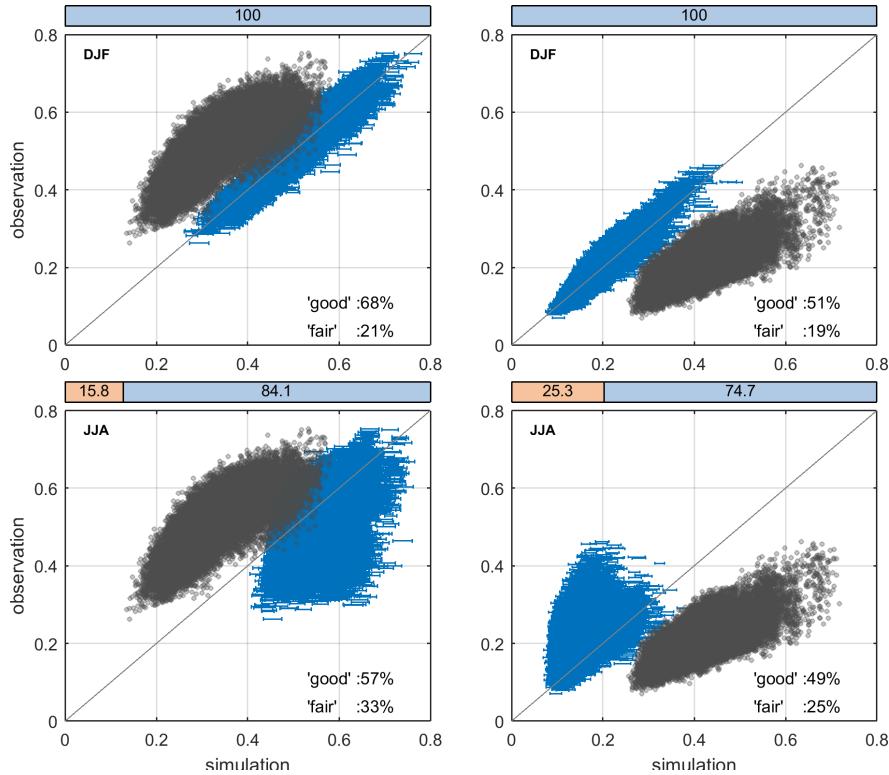


Figure 10 – Proportion of simultaneous dry days (right panel) or wet days (left panel) for each pair of sites during DJF (first line) and JJA (second line) estimated from observed series (y -axis) and post-processed series (90% confidence interval represented by blue lines) or CFSR (gray dots). The scale above each panel indicates the percentage of sites with “good” or “fair” performances after post-processing that displays higher (pale blue), similar (pale brown) or smaller (dark brown) performances compared to CFSR (percentages are not indicated when below 20%).

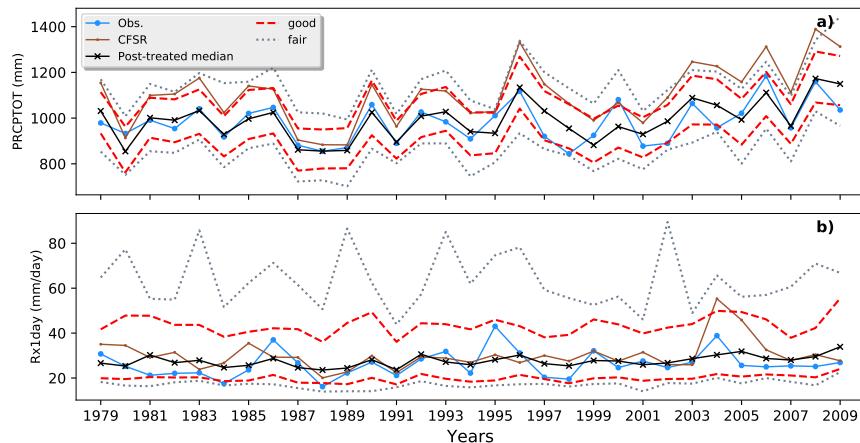


Figure 11 – PRCPTOT (a) and Rx1day (b) estimated at the domain scale from the observed (blue), the CFSR (brown) datasets. The post-processed series are illustrated with the median values (black line with crosses), and the 90% (dashed red line, good) and 99.7 % (dotted gray lines, fair) confidence intervals.

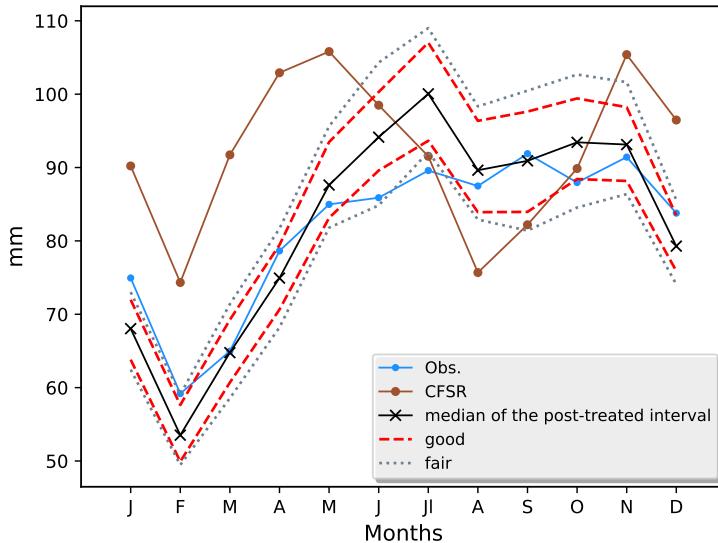


Figure 12 – Monthly precipitation averaged over the study region as estimated from observed (blue), CFSR (brown), and post-processed series. Median values (black line with crosses) and confidence intervals for post-processed values are presented (90%: dashed red lines; 99.7 %: dotted gray lines).

6 Conclusions

This study aimed to post-process CFSR daily precipitation by using observed time series in order to provide continuous precipitation fields at the local scale. The key idea was to take advantage of the continuous and consistent reanalysis datasets, which are outputs from dynamically based models that assimilate, at a given time step (e.g., 6h), past observations, to get information at sites and during periods where no observed series are available. However, reanalyses should be post-processed as biases and scale mismatch with at-site observations exist. The main objective of this study was to evaluate a stochastic approach (Wong *et al.*, 2014) combined to a meta-Gaussian random field model to post-process CFSR daily precipitation fields (Serinaldi & Kilsby, 2014). Post-processed precipita-

tion were compared to observations and CFSR without post-processing for 331 sites across the Great Lakes region. Regression approaches were used to develop mixed daily precipitation distributions with local scale properties by using CFSR and observations as, respectively, predictor and predictand. The logistic regression and the more general VGLM framework were used to model, respectively, the occurrence and the intensity for wet days. Following Serinaldi & Kilsby (2014), one meta-Gaussian latent field was employed at the simulation stage to provide uniform random fields having spatial (correlograms) and temporal structure (autocorrelation lag-1) similar to the observed precipitation process. The latter fields were then used to simulate daily precipitation sequences from the local daily mixed precipitation distributions.

Seasonal covariance functions and the lag-1 autocorrelation were both used in the meta-Gaussian random field. One hundred daily precipitation series were randomly generated and assessed through daily statistics and chosen indices from the ETCCDI list at both the site and domain scale. The evaluation framework developed by Bennett *et al.* (2018) was considered, as it allows a simple and intuitive framework for the comparisons of observed, CFSR and post-processed statistics. Three performance categories “good”, “fair” and “poor” were proposed in the CASE framework and were based on how the post-processed interval or CFSR value compared to the corresponding observation.

The results demonstrate that the proposed post-processing approach was able to reproduce several at-site daily statistics of the two marginal distributions (occurrences and intensity). For almost all sites, post-processed estimates fell in the “good” category. The winter and summer seasons produced slightly weaker performances, although high proportions of sites remained in the “good” or “fair” category. The model was also able to reproduce the temporal at-site persistence as well as the autocorrelation structure, the transition probabilities between wet and dry days, and the probabilities of the occurrence of wet and dry spells. Moreover, the post-processed statistics estimates were significantly improved compared to CFSR. The year-to-year comparisons of the ETCCDI indices again demonstrated the high potential of the

post-processing approach, as for all sites and for the majority of indices, high proportions (ranging from 85 to 100%) of years were classified in the “good” category. Again, winter and especially summer produced weaker performances. The post-processing model effectively captured the spatial correlation of the precipitation, with slight over-estimations of the correlations at relatively short distances. The post-processed daily precipitation spatial correlations were better estimates than those obtained with CFSR, which produced unacceptably high spatial correlation values. Very similar CFSR and post-processed (median value) statistics related to domain-averaged daily precipitation were obtained, though the fair intervals in the post-processing were too large. Additionally, one interesting feature of the post-processed series was their ability to reproduce the annual cycle at the local and domain scale as illustrated by the high correlation values with observed cycles.

In general, the proposed post-processing stochastic approach demonstrated a high potential for providing precipitation series that reproduce at-site statistics, indices, and the specific annual cycle of the Great Lakes region. Further research may include more complex spatial model by considering anisotropy, especially in the studied region where the large water bodies have an influence on the precipitation regimes. Other promising research avenues include the interpolation of at-site coefficients that characterize the local mixed daily precipitation

distributions. Simulations of consistent precipitation fields, even at ungauged locations would then be possible. To enhance estimates of the full precipitation range (including extremes), more heavy-tailed distributions, such as the probability mixture model of Gamma and Generalized Pareto (GP) distributions (Vrac & Naveau, 2007; Wong *et al.*, 2014) or the threshold-independent GP model of Naveau *et al.* (2016), instead of the Gamma could be considered. Finally, the generalization of this approach to regional climate model outputs would offer interesting tools for hydrological modeling in a changing climate.

References

- Akaike H (1974). A new look at the statistical model identification. *IEEE Trans. Autom. Control*, 19:716–723.
- Asong ZE, , Khaliq MN, & Wheater HS (2016). Multisite multivariate modeling of daily precipitation and temperature in the Canadian Prairie Provinces using generalized linear models. *Clim. Dyn.*, pages 1–21. DOI:10.1007/s00382-016-3004-z.
- Bardossy A & Plate EJ (1992). Space-time model for daily rainfall using atmospheric circulation patterns. *Water Resour. Res.*, 28(5):1247–1259. DOI:10.1029/91WR02589.
- Baxevani A & Lennartsson J (2015). A spatiotemporal precipitation generator based on a censored latent Gaussian field. *Wa-*
ter Resources Research, 51(6):4338–4358. DOI:10.1002/2014WR016455.
- Beaulieu C, Seidou O, Ouarda TBMJ, Zhang X, Boulet G & Yagouti A (2008). Intercomparison of homogenization techniques for precipitation data. *Water Resources Research*, 44(2):n/a–n/a. DOI:10.1029/2006WR005615. W02425.
- Beck HE, van Dijk AIJM, Levizzani V, Schellekens J, Miralles DG, Martens B & de Roo A (2017). MSWEP: 3-hourly 0.25 global gridded precipitation (1979–2015) by merging gauge, satellite, and reanalysis data. *Hydrol. Earth Syst. Sci.*, 21(1):589–615. DOI:10.5194/hess-21-589-2017.
- Behrangi A, Tian Y, Lambrightsen BH & Stephens GL (2014). What does cloudsat reveal about global land precipitation detection by other spaceborne sensors? *Water Resources Research*, 50(6): 4893–4905. DOI:10.1002/2013WR014566.
- Bengtsson L & Shukla J (1988). Integration of Space and In Situ Observations to Study Global Climate Change. *Bulletin of the American Meteorological Society*, 69:1130–1143. DOI:10.1175/1520-0477(1988)069<1130:IOSAIS>2.0.CO;2.
- Bennett B, Thyer M, Leonard M, Lambert M & Bates B (2018). A comprehensive and systematic evaluation framework for a parsimonious daily rainfall field model. *Journal of Hydrology*. DOI:10.1016/j.jhydrol.2016.12.043.

- Bromwich DH, Nicolas JP & Monaghan AJ (2011). An Assessment of Precipitation Changes over Antarctica and the Southern Ocean since 1989 in Contemporary Global Reanalyses. *Journal of Climate*, 24(16):4189–4209. DOI:10.1175/2011JCLI4074.1.
- Buishand TA & Brandsma T (2001). Multisite simulation of daily precipitation and temperature in the Rhine Basin by nearest-neighbor resampling. *Water Resour. Res.*, 37(11):2761–2776. DOI:10.1029/2001WR000291.
- Buishand TA, Shabalova MV & Brandsma T (2004). On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation. *Journal of Climate*, 17(9):1816–1827. DOI:10.1175/1520-0442(2004)017<1816:OTCOTT>2.0.CO;2.
- Chandler RE & Wheater HS (2002). Analysis of rainfall variability using generalized linear models: A case study from the west of Ireland. *Water Resources Research*, 38(10):10–1–10–11. DOI:10.1029/2001WR000906. 1192.
- Cleveland WS & Devlin SJ (1988). Locally weighted regression: An approach to regression analysis by local fitting. *Journal of the American Statistical Association*, 83(403):596–610. DOI:10.1080/01621459.1988.10478639.
- Coe R & Stern R (1982). Fitting Models to Daily RainfallData. *J. Appl. Meteorol.*, 21(7):1024–1031. DOI:10.1175/1520-0450(1982)021<1024:FMTDRD>2.0.CO;2.
- Contractor S, Alexander LV, Donat MG & Held N (2015). How Well Do Gridded Data-sets of Observed Daily Precipitation Compare over Australia? *Advances in Meteorology*, 2015. DOI:10.1155/2015/325718.
- Cressie N & Huang HC (1999). Classes of Nonseparable, Spatio-Temporal Stationary Covariance Functions. *J. Am. Stat. Assoc.*, 94(448):1330. DOI:10.2307/2669946.
- Dai A (2006). Precipitation characteristics in eighteen coupled climate models. *Journal of Climate*, 19(18):4605–4630. DOI:10.1175/JCLI3884.1.
- Devine KA & Mekis E (2008). Field accuracy of Canadian rain measurements. *Atmosphere-Ocean*, 46(2):213–227. DOI:10.3137/ao.460202.
- Environment and Climate Change Canada (2013). *Adjusted Precipitation and Homogenized Canadian Climate Data (AHCCD)*. <http://ec.gc.ca/dccha-ahccd/default.asp?lang=En&n=9AA530BE-1>. 2014-10-27.
- Eum HI, Cannon AJ & Murdock TQ (2017). Intercomparison of multiple statistical downscaling methods: multi-criteria model selection for South Korea. *Stoch. Environ. Res. Risk Assess.*, 31(3):683–703. DOI:10.1007/s00477-016-1312-9.

- Gervais M, Gyakum J, Atallah E, Tremblay LB & Neale RB (2014a). How Well Are the Distribution and Extreme Values of Daily Precipitation over North America Represented in the Community Climate System Model? A Comparison to Reanalysis, Satellite, and Gridded Station Data. *Journal of Climate*, 27(14):5219–5239. DOI:10.1175/JCLI-D-13-00320.1.
- Gervais M, Tremblay LB, Gyakum JR & Atallah E (2014b). Representing Extremes in a Daily Gridded Precipitation Analysis over the United States: Impacts of Station Density, Resolution, and Gridding Methods. *Journal of Climate*, 27(14):5201–5218. DOI:10.1175/JCLI-D-13-00319.1.
- Haberlandt U, Hundecha Y, Pahlow M & Schumann AH (2011). Rainfall Generators for Application in Flood Studies. *Flood Risk Assess. Manag. How to Specify Hydrol. Loads, Their Consequences Uncertainties*. Schumann AH, éditeur, Springer Netherlands, pages 117–147.
- 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.
- Hopkinson RF, Mckenney DW, Milewska EJ, Hutchinson MF, Papadopol P & Vincent LA (2011). Impact of aligning climatological day on gridding daily maximum-minimum temperature and precipitation over Canada. *J. Appl. Meteorol. Climatol.*, 50(8):1654–1665. DOI:10.1175/2011JAMC2684.1.
- Huffman GJ, Adler RF, Rudolf B, Schneider U & Keehn PR (1995). Global Precipitation Estimates Based on a Technique for Combining Satellite-Based Estimates, Rain Gauge Analysis, and NWP Model Precipitation Information. *J. Clim.*, 8(5):1284–1295. DOI:10.1175/1520-0442(1995)008<1284:GPEBOA>2.0.CO;2.
- Kalnay E, Kanamitsu M, Kistler R, Collins W, Deaven D, Gandin L, Iredell M, Saha S, White G, Woollen J, Zhu Y, Leetmaa A, Reynolds R, Chelliah M, Ebisuzaki W, Higgins W, Janowiak J, Mo KC, Ropelewski C, Wang J, Jenne R & Joseph D (1996). The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77(3):437–471. DOI:10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2.
- Kendall MG (1962). *Rank correlation methods*. London : Charles Griffin & Co. Ltd, 3rd ed edition. Previous ed.(B55-8618) 1955.
- Kleiber W, Katz RW & Rajagopalan B (2012). Daily spatiotemporal precipitation simulation using latent and transformed Gaussian processes. *Water Resources Research*, 48(1):W01523. DOI:10.1029/2011WR011105.
- Lamb R, Faulkner D, Wass P & Cameron D (2016). Have applications of conti-

- nuous rainfall-runoff simulation realized the vision for process-based flood frequency analysis? *Hydrological Processes*, 30(14):2463–2481. DOI:10.1002/hyp.10882.
- Li J, Thyer M, Lambert M, Kuczera G & Metcalfe A (2014). An efficient causative event-based approach for deriving the annual flood frequency distribution. *J. Hydrol.*, 510:412–423. DOI:10.1016/j.jhydrol.2013.12.035.
- Lombardo F, Volpi E, Koutsoyiannis D & Serinaldi F (2017). A theoretically consistent stochastic cascade for temporal disaggregation of intermittent rainfall. *Water Resources Research*, 53(6): 4586–4605. DOI:10.1002/2017WR020529.
- Lorente-Plazas R & Hacker JP (2017). Observation and Model Bias Estimation in the Presence of Either or Both Sources of Error. *Mon. Weather Rev.*, 145(7):2683–2696. DOI:10.1175/MWR-D-16-0273.1.
- Lucas-Picher P, Laprise R & Winger K (2017). Evidence of added value in North American regional climate model hindcast simulations using ever-increasing horizontal resolutions. *Clim. Dyn.*, 48(7-8):2611–2633. DOI:10.1007/s00382-016-3227-z.
- McCullag P & Nelder JA (1989). *Generalized linear models*. Chapman and Hall, New York, 2nd edition edition, 532 pages.
- Mekis E (2005). Adjustments for trace measurements in Canada. *15th Conference on Applied Climatology*, Savannah, Georgia, USA.
- Mekis E & Vincent LA (2011). An Overview of the Second Generation Adjusted Daily Precipitation Dataset for Trend Analysis in Canada. *Atmosphere-Ocean*, 49(2):163–177. DOI:10.1080/07055900.2011.583910.
- Mesinger F, DiMego G, Kalnay E, Mitchell K, Sharpen PC, Ebisuzaki W, Jović D, Woollen J, Rogers E, Berbery EH, Ek MB, Fan Y, Grumbine R, Higgins W, Li H, Lin Y, Manikin G, Parrish D & Shi W (2006). North American Regional Reanalysis. *Bulletin of the American Meteorological Society*, 87(3):343–360.
- Naveau P, Huser R, Ribereau P & Hannart A (2016). Modeling jointly low, moderate, and heavy rainfall intensities without a threshold selection. *Water Resour. Res.*, 52(4):2753–2769. DOI:10.1002/2015WR018552.
- Neykov NM, Neytchev PN & Zucchini W (2014). Stochastic daily precipitation model with a heavy-tailed component. *Natural Hazards and Earth System Science*, 14(9):2321–2335. DOI:10.5194/nhess-14-2321-2014.
- Onof C, Chandler RE, Kakou A, Northrop P, Wheater HS & Isham V (2000). Rainfall modelling using Poisson-cluster processes: a review of developments. *Stoch. Environ. Res. Risk Assess.*, 14:0384–0411.

- Pegram Gm & Clothier A (2001). High resolution space-time modeling of rainfall: the "String of Beads" model. *J. Hydrol.*, 241(1-2):26–41. DOI:10.1016/S0022-1694(00)00373-5.
- & Goldberg M (2010). The NCEP Climate Forecast System Reanalysis. *Bulletin of the American Meteorological Society*, 91(8):1015–1057. DOI:10.1175/2010BAMS3001.1.
- Peterson TC, Folland C, Gruza G, Hogg W, Mokssit A & Plummer N (2001). Report on the Activities of the Working Group on Climate Change Detection and Related Rapporteurs 1998-2001. WMO. Geneve, 143 pages.
- Schlather M, Malinowski A, Oesting M, Boecker D, Strokorb K, Engelke S, Martini J, Ballani F, Moreva O, Auel J, Menck PJ, Gross S, Ober U, Christoph Berreth, Burmeister K, Manitz J, Ribeiro P, Singleton R, Pfaff B & R Core Team (2017). *RandomFields: Simulation and Analysis of Random Fields*. R package version 3.1.50.
- Plummer DA, Caya D, Frigon A, Côté H, Giguère M, Paquin D, Biner S, Harvey R & de Elia R (2006). Climate and climate change over North America as simulated by the Canadian RCM. *Journal of Climate*, 19(13):3112–3132. DOI:10.1175/JCLI3769.1.
- Schmidli J, Frei C & Vidale PL (2006). Downscaling from GCM precipitation: a benchmark for dynamical and statistical downscaling methods. *International Journal of Climatology*, 26(5):679–689. DOI:10.1002/joc.1287.
- Podgórski K & Wegener J (2012). Velocities of a spatial-temporal stochastic field with embedded dynamics. *Environmetrics*, 23(3):238–252. DOI:10.1002/env.2135.
- Serinaldi F & Kilsby CG (2014). Simulating daily rainfall fields over large areas for collective risk estimation. *J. Hydrol.*, 512:285–302. DOI:10.1016/j.jhydrol.2014.02.043.
- Saha S, Moorthi S, Pan HL, Wu X, Wang J, Nadiga S, Tripp P, Kistler R, Woollen J, Behringer D, Liu H, Stokes D, Grumbine R, Gayno G, Hou YT, Chuang HY, Juang HMH, Sela J, Iredell M, Treadon R, Kleist D, Van Delst P, Keyser D, Derber J, Ek M, Meng J, Wei H, Yang R, Lord S, Van Den Dool H, Kumar A, Wang W, Long C, Chelliah M, Xue Y, Huang B, Schemm JK, Ebisuzaki W, Lin R, Xie P, Chen M, Zhou S, Higgins W, Zou CZ, Liu Q, Chen Y, Han Y, Cucurull L, Reynolds RW, Rutledge G Stein ML (1999). *Interpolation of Spatial Data: Some Theory for Kriging*. Springer-Verlag, New York, 249 pages.
- Stern RD & Coe R (1984). A Model Fitting Analysis of Daily Rainfall Data. *Journal of the Royal Statistical Society. Series A (General)*, 147(1):1–34. DOI:10.2307/2981736.
- Sun X, Barros AP, Sun X & Barros AP (2010). An Evaluation of the Statistics of Rainfall Extremes in Rain Gauge Observations, Satellite-

- Based and Reanalysis Products Using Universal Multifractals. *J. Hydrometeorol.*, 11(2):388–404. DOI:10.1175/2009JHM1142.1.
- Sun Y, Solomon S, Dai A & Portmann RW (2006). How often does it rain? *Journal of Climate*, 19(6):916–934. DOI:10.1175/JCLI3672.1.
- Vaittinada Ayar P, Vrac M, Bastin S, Carreau J, Déqué M & Gallardo C (2015). Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework: present climate evaluations. *Climate Dynamics*. DOI:10.1007/s00382-015-2647-5.
- Vrac M & Naveau P (2007). Stochastic downscaling of precipitation: From dry events to heavy rainfalls. *Water Resources Research*, 43(7). DOI:10.1029/2006WR005308.
- Way RG, Oliva F & Viau AE (2016). Underestimated warming of northern Canada in the Berkeley Earth temperature product. *International Journal of Climatology*. DOI:10.1002/joc.4808.
- Wheater HS, Chandler RE, Onof CJ, Isham VS, Bellone E, Yang C, Lekkas D, Lourmas G & Segond ML (2005). Spatial-temporal rainfall modelling for flood risk estimation. *Stoch. Environ. Res. Risk Assess.*, 19(6):403–416. DOI:10.1007/s00477-005-0011-8.
- Wijngaard JB, Klein Tank AMG & Können GP (2003). Homogeneity of 20th century European daily temperature and precipitation series. *International Journal of Climatology*, 23(6):679–692. DOI:10.1002/joc.906.
- Wong G, Maraun D, Vrac M, Widmann M, Eden JM & Kent T (2014). Stochastic model output statistics for bias correcting and downscaling precipitation including extremes. *Journal of Climate*, 27(18):6940–6959. DOI:10.1175/JCLI-D-13-00604.1.
- Yee TW (2016). *VGAM: Vector Generalized Linear and Additive Models*. R package version 1.0-3.
- Yee TW & Wild CJ (1996). Vector Generalized Additive Models. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(3):481–493. DOI:10.2307/2345888.

PRÉCIPITATIONS JOURNALIÈRES AUX SITES NON INSTRUMENTÉS AVEC LES PRÉCIPITATIONS DE CFSR COMME PRÉDICTEUR

Sommaire

1	Introduction	117
2	Article: Regional modeling of daily precipitation fields across the Great Lakes region (Canada) using the CFSR reanalysis	119

1 Introduction

Ce chapitre est consacré à l'utilisation de la réanalyse CFSR aux endroits dépourvus de stations de mesure dans le but de caractériser les précipitations locales à ces endroits. Il concerne la troisième étape de ce travail.

Le chapitre 5 a permis de mettre en place des modèles de post-traitement stochastique de la réanalyse CFSR autorisant la génération de séries de précipitations. Ces séries possèdent des caractéristiques locales et des structures spatio-temporelles journalières cohérentes avec les observations. Cependant, ces modèles sont calibrés et définis seulement au regard des sites d'observations. Or, pour généraliser cette approche à l'ensemble des points de grille de CFSR, il est indispensable d'estimer les distributions mixtes des précipitations journalières en ces lieux. On retrouve dans la littérature, plusieurs outils méthodologiques offrant la possibilité de régionaliser des distributions (Panthou, 2012). La méthode *Local Fit and Interpolate* (Villarini *et al.*, 2011) est une approche qui a été considérée. Elle consiste à d'abord estimer

localement les paramètres des distributions, tel que dans les Chapitres 4 et 5, pour ensuite interpoler ces paramètres selon diverses approches (cf. Section 3.2.3 du Chapitre 3). La mise en place d'un seul modèle statistique régionale est une autre approche attrayante qui consiste à établir une seule fonction de vraisemblance régionale intégrant des covariables spatiales à l'aide des GAM/VGAM (Blanchet & Lehning, 2010; Panthou, 2012). À l'instar de la méthode précédente, les approches bayésiennes offrent également la possibilité d'avoir un seul modèle régional, la différence réside dans l'utilisation d'une fonction de covariance spatiale dans l'estimation des paramètres de la distribution (Blanchet *et al.*, 2016).

Le présent chapitre entend utiliser les deux premières approches présentées plus haut (Figure 3.6 du Chapitre 3) pour répondre à l'objectif. Ces deux approches, bien que souvent utilisées pour quantifier l'estimation des précipitations extrêmes à l'échelle régionale, n'ont à ce jour pas été exploitées dans le domaine de la descente d'échelle ou de la modélisation des précipitations journalières. Leurs utilisations dans ce cadre précis seraient donc un apport scientifique intéressant tout en offrant des résultats d'utilité réelle (série de précipitations ayant des caractéristiques locales sur l'ensemble du domaine).

La région des Grands Lacs a encore été au centre de l'application de ces approches. Le présent travail a fait l'objet d'une publication présentée à la Section 2 suivante et est introduit par un résumé synthétisant les résultats en français. Les figures du matériel supplémentaire (*supplementary material*), auxquelles il est fait référence dans l'article ci-dessous, sont regroupées à la Section 3 de l'Annexe B.

2 Article: Regional modeling of daily precipitation fields across the Great Lakes region (Canada) using the CFSR reanalysis

Auteurs

Dikra Khedhaouiria¹, Alain Mailhot¹, Anne-Catherine Favre²

¹ Institut national de la recherche scientifique, Centre Eau Terre Environnement (INRS-ETE), 490 de la Couronne, Québec, Québec/Canada.

² Univ. Grenobles Alpes, CNRS, IRD, IGE, Grenoble INP*, F-38000 Grenoble, France

Article prêt à soumettre

Résumé étendu

Le but de cet article consiste à appliquer deux méthodes, de complexités différentes, afin d'estimer les paramètres des distributions mixtes des précipitations journalières aux sites sans observation. L'objectif ultime vise la génération des séries journalières aux caractéristiques locales en ces sites. Les performances à évaluer sont les mêmes que celles présentées dans le Chapitre 5 mais dans le cadre de la calibration-validation spatiale. Le résumé suivant présente brièvement les méthodes d'évaluation des séries générées ainsi que les principaux résultats. Le cadre statistique de la méthode n'est pas rappelé, car il a déjà été introduit à la Section 3.5 du Chapitre 3.

Évaluation des modèles spatiaux

Les deux méthodes permettant de disposer des distributions mixtes des précipitations ont été évaluées en validation croisée en utilisant l'approche du *k-fold* (Section 3.5, Chapitre 3). L'échantillon des $N = 331$ sites (stations) a été aléatoirement subdivisé en k sous-échantillons de même taille. Chaque sous-échantillon est inclus une fois comme échantillon de validation tandis que le reste des $(k-1)$ échantillons constituent l'échantillon de calibration. La procédure de krigeage a été réalisée k fois pour chacun des paramètres des distributions, avec des variogrammes estimés sur des échantillons de calibration de taille $(k-1)/k \times N$. Sur les mêmes échantillons, les modèles GAM (occurrence) et VGAM (intensité) ont été calibrés pour l'ensemble du domaine. À ce stade-là, on dispose pour chacun des sites de distributions

mixtes des précipitations en mode validation. Cent (100) séries ont été générées aléatoirement à partir de ces distributions combinées aux champs méta-gaussiens spatio-temporels latents estimés au Chapitre 5.

Le cadre du CASE (Bennett *et al.*, 2018) présenté au Chapitre 5 est à nouveau employé ici pour comparer, aux observations, les séries issues des deux modélisations spatiales en mode validation, celles du modèle dit local (distributions avec des paramètres locaux, Chapitre 5) et celles de la réanalyse CFSR. Les métriques des comparaisons comprennent les caractéristiques statistiques de base des précipitations (moyenne, moyenne sur les jours pluvieux, nombre de jours pluvieux) et certains indices climatiques de l'ETCCDI. Une analyse annuelle et saisonnière est effectuée afin de distinguer les différences de performances, et éventuellement identifier les processus de précipitation plus facilement/difficilement reproduits dans les séries post-traitées. Sur ces mêmes métriques, le biais et le RMSE, relativement aux observations, sont estimés pour une quantification des écarts et permettent ainsi de compléter, avec le CASE, l'examen des performances des différents modèles. L'objectif, par ces évaluations, consiste à identifier le pouvoir prédictif (mode validation) des approches de modélisation spatiale à estimer certaines caractéristiques importantes des précipitations journalières, mais aussi d'évaluer dans quelle mesure ces caractéristiques représentent de meilleures estimations que celles issues directement de CFSR.

La structure spatiale des précipitations journalières, introduite à travers les champs méta-gaussiens latents, a aussi été analysée en calibration/validation avec l'approche $k - fold$. Le but visait à constater si un champ méta-gaussian calibré sur un sous-échantillon permet tout de même de reproduire la structure spatio-temporelle des précipitations ayant lieu sur l'ensemble du domaine. Pour ce faire, une fonction de covariance spatiale est calibrée sur les sites ($k - 1$) ème échantillon, un champ méta-gaussian latent est ensuite aléatoirement généré (100 fois) sur l'ensemble des points (N) du domaine. À partir de ces champs et des distributions des précipitations issues du modèle local, les séries de précipitations sont générées sur l'ensemble du domaine. L'opération est répétée k fois sur les ($k - 1$) échantillons différents. Il en résulte $100 \times k$ séries de précipitations en chacun des N sites. Les $100 \times k$ corrélogrammes spatiaux associés aux précipitations journalières sont ensuite comparés à celui estimé à partir des observations en utilisant le cadre d'évaluation CASE.

Principaux résultats

Les résultats montrent généralement que, en validation, l'interpolation des paramètres locaux par le krigage aboutit généralement à des performances légèrement meilleures que l'application des GAM/VGAM spatiaux. Pour beaucoup de caractéristiques, les performances des deux modèles sont similaires en termes de catégorie du CASE, mais les biais à l'échelle saisonnière et annuelle sont généralement plus faibles en utilisant le krigage.

Les deux approches spatiales ont généralement permis d'obtenir de meilleures estimations, pour la plupart des métriques, que CFSR. Cependant, les estimations de beaucoup de caractéristiques ont montré une plus faible variabilité spatiale que dans les observations. Un effet d'échantillonnage peut expliquer ces différences. En effet, deux sites voisins peuvent présenter des paramètres de distribution des précipitations assez différents. Ce dernier point a surtout été observé pour le paramètre de forme de la loi Gamma qui régit les intensités. La longueur des séries ainsi que les données manquantes sont des facteurs pouvant influencer ce paramètre. Des effets très locaux dus à la présence des nombreuses masses d'eau de la région des Grands Lacs peuvent également être considérés comme des facteurs d'influence. Il devient alors difficile pour les modèles spatiaux tels qu'ils sont conçus de capturer ces différences de petites échelles. Les caractéristiques liées à la persistance et à la structure spatiale des précipitations journalières sont elles très bien représentées par les deux approches spatiales.

Abstract

High densities of local scale daily precipitation series across relatively large domains are of special interest for a wide range of applications (e.g., hydrological modelling, agriculture). The focus of the present study is to post-process gridded precipitation from a single reanalysis to correct bias and scale mismatch with observations, and to extend the same post-processing at sites without historic data. A Stochastic Model Output Statistical (SMOS) approach combined with meta-Gaussian spatio-temporal random fields, calibrated at sites, is employed to post-process the Climate Forecast System Reanalysis (CFSR) precipitation. The post-processed data, characterized by local parameters, is then mapped across the Great Lakes region (Canada) using two different approaches: i) kriging, and ii) Vector Generalized Additive Model (VGAM) with spatial covariates. The kriging enables the interpolation of these parameters, while the spatial VGAM helps to spatially post-process CFSR precipitation using a single model. The k -fold cross-validation procedure is employed to assess the ability of the two approaches to predict selected characteristics and climate indices. The kriging and spatial VGAM approaches modeled effectively the distribution of the precipitation process to similar extents (e.g., mean daily precipitation, variability and the number of wet days). The kriging approach produces slightly better estimates of climate indices than the spatial VGAM models. Both approaches demonstrate significant improvement of the metric estimation compared to those of CFSR without post-processing.

1 Introduction

Several applications in hydrology, impact studies or in agricultural impact assessments (Ambrosino *et al.*, 2014), often require high-quality local precipitation series, as opposed to gridded precipitation series. Ideally, spatio-temporal precipitation fields covering large domains and long periods are needed. This allows, for example, continuous modeling of the infiltration-runoff across a basin, and thus improves tools used for risk assessment (Lamb *et al.*, 2016). Across Canada, and for many other

countries, precipitation records do not fulfill these requirements (Kidd *et al.*, 2017), especially in northern regions which are expected to develop in the near future (Allard & Lemay, 2012).

Reanalysis datasets represent an interesting alternative for assessing the historical climate of poorly monitored regions. By contrast with statistically-interpolated or satellite-based precipitation datasets (Lin & Wang, 2011; Newlands *et al.*, 2011) that are generally based, respectively, on precipitation records and radiance observation, reanalysis reconstructs the past state of the

atmosphere by using Numerical Weather Prediction (NWP) models that continuously assimilate past observations of different kinds (Bengtsson & Shukla, 1988). Additionally, reanalysis offers very interesting temporal and spatial coverage, according to the selected reanalysis, with covered periods extending from 30 to 100 hundred years and covering the whole globe. Despite the added value of reanalysis products, the scientific literature shows that their performances depend on the studied region, considered variable, temporal and spatial scales (Bromwich *et al.*, 2011; Eum *et al.*, 2014; Rusticucci *et al.*, 2014, among others). Reanalysis variables, especially precipitation, may also present biases due to non-resolved processes in the NWP models, and scale mismatches (called representativeness errors; Tustison *et al.*, 2001) between the grid cells and the spatial scale of interest. These several aspects prevent the direct use of a reanalysis as a climate proxy, especially when point scale precipitation is needed.

The objective of this study is to propose point-scale daily precipitation series across the Great Lakes region (Canada), by taking advantage of a post-processing model, calibrated on a site-specific basis that used both reanalysis and the observation network. A two-step methodology is developed involving 1) stochastic post-processing of the precipitation reanalysis at observation sites, and 2) regression-based models that simultaneously correct bias and scale mismatch while allowing for

post-processed series to reproduce local variability (Volosciuk *et al.*, 2017; Wong *et al.*, 2014). These probabilistic regression tools used the Climate Forecast System Reanalysis (CFSR, Saha *et al.*, 2010) precipitation as a predictor to estimate at-site daily precipitation distributions. Similar approaches, also referred to as downscaling, were successfully applied to post-process daily precipitation from Regional and Global Climate Models (Eden *et al.*, 2014; Volosciuk *et al.*, 2017; Wong *et al.*, 2014). The selected stochastic post-processing approach also shares similarities with the statistical precipitation modeling proposed by Asong *et al.* (2016a). However, the latter approach made use of different predictors, which must be exogenous to the precipitation. The current methodology with only a single predictor is employed in a downscaling context, contrary to Asong *et al.* (2016a) that handled a relatively high number of reanalysis covariates (e.g., Sea Level Pressure, Humidity) leading to different and less parsimonious models. In this study, a single meta-Gaussian latent field is combined with the regression approach to ensure spatial and temporal consistency in the randomly simulated post-processed series (Serinaldi & Kilsby, 2014). At-site stochastic post-processing of CFSR precipitation has been previously evaluated and showed that different attributes of the local daily precipitation series are adequately reproduced by this approach (Khedhaouiria *et al.*, 2018b,a).

The second step, which is the central subject of the present study, involves extending the stochastic post-processing approach to the entire region therefore enabling the construction of precipitation series anywhere within the studied region. To achieve this objective, the use of kriging and smooth spatial modeling are explored. Kriging is applied since it is a standard method that has been widely documented in the literature (e.g., Deutsch & Journel, 1992). In the present study, we employ different kriging approaches (e.g., simple, ordinary, universal) to spatially interpolate the at-site coefficients that define the stochastic post-processing approach. The daily precipitation model developed by Kleiber *et al.* (2012) introduced a Generalized Linear Model combined with kriging approaches to extend their models at locations with no direct observations. Despite some similarities with the work of Kleiber *et al.* (2012), the current study further develops the approach by including a consistent explanatory variable (CFSR precipitation), by using different modeling tools, and by considering a denser station network. Smooth spatial modeling is a different and interesting tool as it enables the estimation of a single regional regression model with parameters varying as a function of spatial covariates. These models were used for mapping extreme precipitation return levels (Van de Vyver, 2012; Panthou, 2012), for snow depth (Blanchet & Lehning, 2010) and even for atmospheric droughts (Zamani *et al.*, 2016). Although smooth spatial modeling has been introduced in different precipita-

tion studies, it has never been applied to stochastic post-processing models. The Bayesian framework could also be considered for the generation of spatially continuous daily precipitation fields such as the work of Olson & Kleiber (2017) that provided spatio-temporal models for daily precipitation occurrence. However, this approach is beyond the scope of this study.

The paper is organized as follows. Available datasets are presented in Section 2, while the stochastic post-processing framework and the evaluation approach are described in Sections 3 to 5. The results and the discussion are exposed in Section 6. Finally, the conclusions are provided in Section 7.

2 Datasets

The study area covers the Great Lakes (GLakes) region whose boundaries, defined by Plummer *et al.* (2006), were based on climatic considerations. Precipitation in this region is highly influenced by the lakes effect with an average of 1000 mm per year (Figure 1), and mainly falling during summer and winter. The initial daily precipitation network included 857 stations, 41 of these stations belong to the second generation Adjusted Precipitation for Canada datasets (APC2; Environment and Climate Change Canada, 2013; Mekis & Vincent, 2011). APC2 are daily precipitation series adjusted to account for wind undercatch, evaporation, funnel wetting, with regards to rain, and improved snow den-

sity assessment (Devine & Mekis, 2008; Mekis & Vincent, 2011). The remaining stations (816), also provided by Environment and Climate Change Canada, did not undergo any preliminary processing.

The following criteria were sequentially applied to control the quality of the observed series: 1) each valid year contained at least 90% of non missing days, otherwise the year was discarded; 2) stations had at least 10 valid years during the study period (1979-2009) and more than five consecutive valid years. This last criterion was imposed to avoid datasets with sparse years within the studied period.

Importantly, some stations may have recording inconsistencies due to factors such as changes in recording equipment, changes in the definition and measurements of precipitation trace (Mekis, 2005), missing values, choices of time windows to record daily precipitation (Hopkinson *et al.*, 2011), and other disturbances (Van de Vyver, 2012; Tapiador *et al.*, 2017). To further scrutinize these data, especially at stations that are not part of the APC2 dataset, statistical homogeneity of annual precipitation series was tested using the method proposed by Wijngaard *et al.* (2003). On the basis of four statistical tests: 1) Standard normal homogeneity test (Alexandersson, 1986), 2) Buishand range

test (Buishand, 1982), 3) Von Neumann ratio test (von Neumann, 1941), 4) and Pettitt test (Pettitt, 1979); the series were classified as “useful”, “doubtful” or “suspect”. In the following, only

stations with “useful” series were selected, i.e. when at least three of the four tests do not reject the null hypothesis that the temporal series are homogeneous at the 99% confidence level. A total of 331 valid precipitation series (Figure 1), from which 40% corresponds to records of 25-year in duration or more were selected and further considered for analysis. Distances between pairs of stations range between 1 km and 950 km.

The Climate Forecast System Reanalysis (CFSR) was produced by the National Centers for Environmental Prediction (NCEP) with the Coupled Forecast System (CFS) model. It covers the 1979-2009 period (Saha *et al.*, 2010). This model simulates the past state of the ocean and atmosphere at a horizontal resolution of 0.312° latitude $\times 0.312^\circ$ longitude, by assimilating quality-controlled observations. CFSR uses a coupled atmosphere-ocean-sea ice-land model (Bromwich *et al.*, 2011), assimilates satellite radiances during the entire period; and takes into account the time evolution of CO₂ concentrations (for more details see Mesinger *et al.*, 2006). CFSR also includes two gridded precipitation products in its land model: 1) the Climate Prediction Center unified global daily gauge analysis; and 2) the pentad dataset of the Climate Prediction Center Merged Analysis of Precipitation (Saha *et al.*, 2010, and references therein). The CFSR hourly precipitation amounts were aggregated to form daily values by considering the 0600-0600 local time windows.

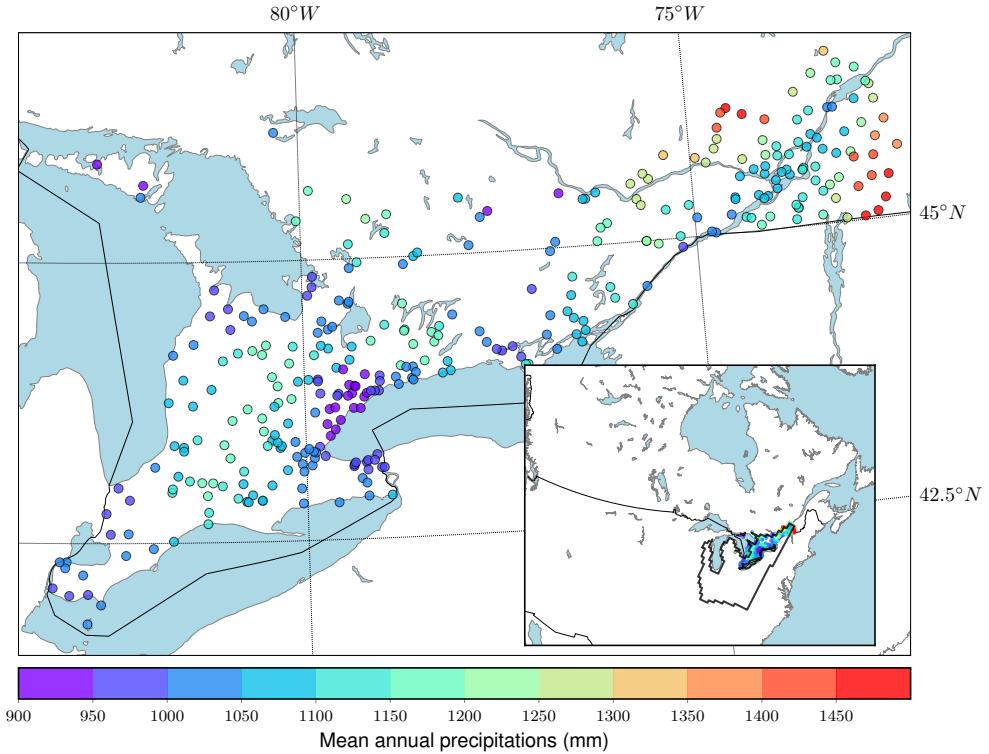


Figure 1 – Rainfall network across the Great Lakes region with the corresponding recorded mean annual precipitation over the 1979-2009 period.

3 At-site estimates of the mixed daily precipitation distribution

The mixed discrete-continuous distribution of daily precipitation is classically made up of an occurrence process (wet or dry days) and an intensity process on wet days (Steps 1 and 2 - Local model, Figure 2) (Chandler & Wheater, 2002; Coe & Stern, 1982) and is defined by the function $G_{s,t}(.)$ as follows:

$$G_{s,t}(r) = p_{s,t} F(r, \psi_{s,t}) + (1 - p_{s,t}), \quad (1)$$

where $p_{s,t}$ is the probability of the day t being wet at the site s , $r \geq 0$ the daily precipitation intensity, and $F(.)$ is the precipitation distribution on wet days defined by its vector of parameters $\psi_{s,t}$. Following the literature, a day with more than 1 mm of precipitation was considered as wet, otherwise it is considered a dry day (Dai, 2006; Schmidli *et al.*, 2006; Sun *et al.*, 2006, among others).

The marginal distribution of the precipitation occurrence was modeled in a GLM framework using a binomial family function, also referred to as the logistic regression (Buishand *et al.*, 2004; Stern & Coe, 1984). The observed wet or dry state constituted the predictand and the log-transformed (Chand-

ler, 2002) daily CFSR precipitation as predictor for the GLM. The two-parameter Gamma function, $F(\cdot)$ in equation 1, was considered to represent the marginal daily precipitation distribution on wet days. Despite the known underestimations of the very high quantiles due to the light tail of this distribution (Katz, 1977), an overall good fit for the observed precipitation intensity was obtained (not shown for conciseness). The Gamma parameterization using the shape ($\gamma > 0$) and mean ($\mu > 0$) parameters was chosen (McCullag & Nelder, 1989). The probability density function $f_{\mu,\gamma}$ is defined by:

$$f_{\mu,\gamma}(r) = \frac{\gamma}{\mu \Gamma(\gamma)} \left(\frac{\gamma r}{\mu} \right)^{\gamma-1} e^{-\gamma r/\mu}, \quad (2)$$

where Γ is the gamma function and $r > 0$ the daily precipitation intensity. With this parametrization, the scale parameter is therefore given by μ/γ and the variance by μ^2/γ . The log-transformed CFSR precipitation was also used to predict the intensity distributions, $F(\cdot)$, with different parameter for each day and sites. A vector generalized linear model (VGLM) as regression model was used in this aim with observed precipitation intensity on wet days as predictand. The VGLM has the advantage to generalize the GLM by encompassing the exponential distribution family. To account for seasonality, sine and cosine functions were also added in the equations. The at-site parameters of the mixed daily precipitation distributions (equation 1)

are expressed as follows:

$$\log \left(\frac{p_{s,t}}{1 - p_{s,t}} \right) = \alpha_0 + \alpha_1 \log(x_{s,t} + 1) + \alpha_2 \cos \left(\frac{2\pi d}{T} \right) + \alpha_3 \sin \left(\frac{2\pi d}{T} \right), \quad (3)$$

$$\log(\mu_{s,t}) = \eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 \cos \left(\frac{2\pi d}{T} \right) + \eta_3 \sin \left(\frac{2\pi d}{T} \right), \quad (4)$$

$$\log(\gamma_{s,t}) = \beta_0 + \beta_1 \log(x_{s,t} + 1),$$

where $x_{s,t}$ denotes the CFSR precipitation, d is the ordinal day, $T = 365.25$ days is the average yearly period for cosine and sine functions accounting for leap years. The log was used in this circumstance as a link function for both the GLM and the VGLM. The ensemble $\{(\alpha_k)_{k \in [0,3]}, (\eta_k)_{k \in [0,3]}, (\beta_k)_{k \in [0,1]} \}$ constituted the regression coefficients estimated using the maximum likelihood estimation (MLE) method (Yee, 2016b, CRAN R VGAM Package) and enabled the estimation of the vector of parameters $\psi_{s,t}$ (equation 1). These models were built independently at each site, leading to different mixed precipitation distributions for each day t and each site s .

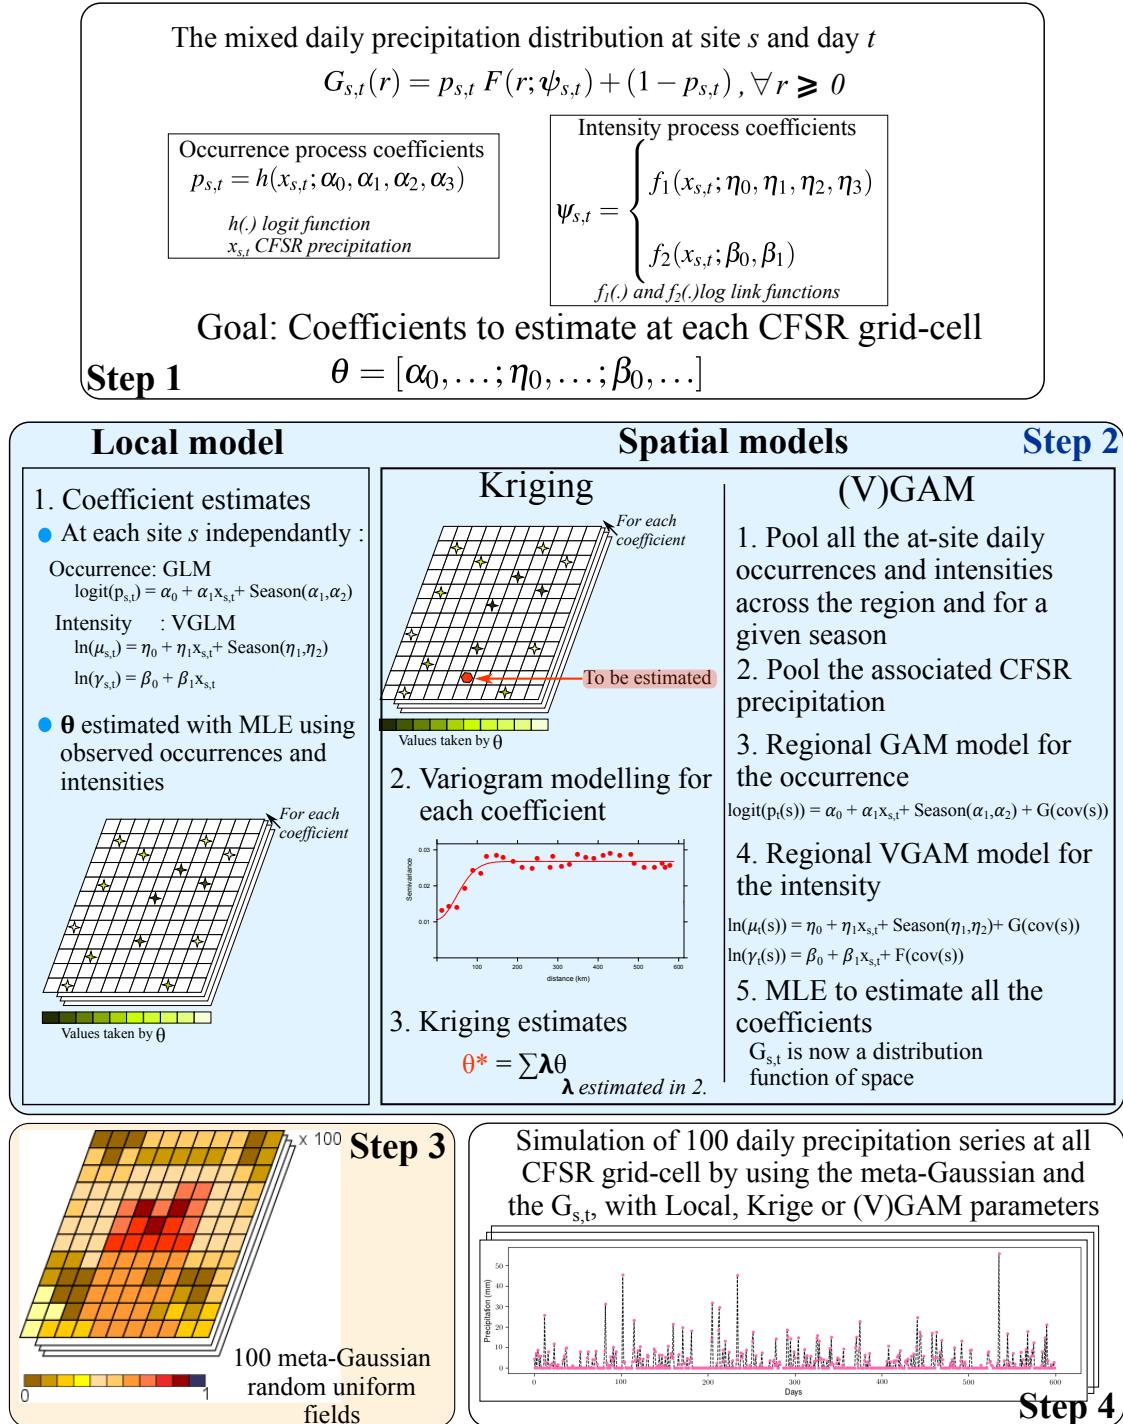


Figure 2 – Different steps of the post-processing approach, either using Local model or Spatial Models, to generate daily precipitation series

4 Spatio-temporal meta-Gaussian latent field

Meta-Gaussian fields were used to ensure spatial consistency and temporal persistence of the daily precipitation sequences generated from the mixed daily precipitation distributions. The meta-Gaussian latent fields framework provided uniformly distributed random fields that follow a chosen spatio-temporal structure to be used at the random simulation stage (Serinaldi & Kilsby, 2014).

Following Serinaldi & Kilsby (2014), the spatial and temporal daily precipitation structures were treated separately to define one meta-Gaussian random field. The spatial structure was handled first, and the analysis of the spatial covariance, denoted $C(\cdot)$, was assumed stationary and isotropic for simplicity. The theoretical covariance function that best fits the empirical spatial covariance was selected from among the valid covariance functions proposed in the literature (Cressie & Huang, 1999). Due to the skewness of the daily precipitation distribution, Kendall's correlation coefficient, τ_k , was preferred for the estimation of the inter-station correlation (Habib *et al.*, 2001). Kendall's rank correlation, τ_k , also has the added advantage to be directly linked to Pearson correlation coefficient, ρ_s , with the following expression $\rho_s = \sin(\tau_k\pi/2)$ (Kendall, 1962). Random Gaussian fields, Z , were generated using the CRAN R RandomFields Package (Schlather *et al.*, 2017).

The temporal structure was addressed in a second step. The lag-1 autocorrelation was implemented in the previous latent Gaussian field to ensure temporal memory of the precipitation process, which is known to be poorly represented in classical stochastic modeling (Wong *et al.*, 2014). Thus, following Podgórski & Wegener (2012), lag-1 autocorrelation, ρ_Δ , was added to the above Gaussian fields as follows:

$$y(s, t + 1) = \rho_\Delta y(s, t) + \sqrt{1 - \rho_\Delta^2} z(s), \quad (5)$$

where y denotes the spatio-temporal Gaussian random field, and z the realizations of the spatial random field presented previously. As for the spatial analysis, the lag-1 temporal autocorrelation was first estimated using Kendall's correlation coefficient and then linked to the Pearson correlation coefficient (ρ_Δ). Unlike the spatial process, the temporal autocorrelation used in equation 5 was estimated from CFSR daily precipitation since a good agreement between the observed and CFSR lag-1 autocorrelation was demonstrated. Finally, the random simulations of the daily precipitation fields can be summarized by the following expressions:

$$R(s, t) = \begin{cases} G^{-1}(s, t) \circ \Phi(Y(s, t)) & \text{if } \Phi[Y(s, t)] > p_{s,t}, \\ 0 & \text{if } \Phi[Y(s, t)] \leq p_{s,t}, \end{cases} \quad (6)$$

where Φ is the standard Gaussian distribution function and G the function defined by equation 1.

One hundred random latent fields of the Gaussian process, y , at each site s of the studied domain were first generated. The autocorrelation was then added using equation 5. Finally, the precipitation series were generated from equation 6.

5 Regional modeling of the mixed daily precipitation distribution

The previous methodology was extended to sites lacking observations in order to propose estimates of the regression coefficients at these sites and then fully define the mixed daily distribution function of equation 1 (see Steps 2 to 4 in Figure2).

Two approaches were applied: 1) the kriging approach (Section 5.a); and 2) the (vector) additive generalized models, (V)GAM, using spatial covariates (Section 5.b). The first approach is a standard interpolation method that takes the advantage of being unbiased and minimizes the standard deviation of errors (Panthou, 2012). The at-site coefficients of the occurrence and intensity model, first estimated at gauged sites (Section 3), were subsequently interpolated across the region. The second approach, is an integrated approach with the development of two regional models in a VGAM fra-

mework (detailed below) fitted for, respectively, the occurrence and the intensity process.

5.1 Kriging

Kriging is an approach that provides the process estimate, θ , at site s^* of the domain \mathcal{D} through linear combination of the process at neighboring sites $s_i \in \mathcal{D}$: $\theta(s^*) = \sum_{s_i \in \mathcal{D}} \lambda_{s_i} \theta(s_i)$ (Cressie, 1993). In the following, θ referred to one of the coefficients $\{\alpha_k\}_{k \in [0,3]}, \{\eta_k\}_{k \in [0,3]}, \{\beta_k\}_{k \in [0,1]}\}$ of equations 3 and 4. The λ_{s_i} are estimated under two constraints, unbiased prediction, $\mathbb{E}[\hat{\theta}(s^*) - \theta(s^*)] = 0$, with minimal variance $\min \{\text{Var}[\hat{\theta}(s^*) - \theta(s^*)]\}$.

Based on regression methods, the kriging represents the spatial structure of the studied process by:

$$\theta(s) = \mu(s) + \delta(s), \quad s \in \mathcal{D}, \quad (7)$$

where $\mu(\cdot)$ and $\delta(\cdot)$ are, respectively, the deterministic and random parts of the process. Three different kinds of kriging may be used and differ by the way the mean, $\mu(\cdot)$, of the process is represented (Diggle *et al.*, 1998): 1) a known constant (simple kriging); 2) an unknown constant (ordinary kriging, OK); and 3) a linear function of spatial covariates (universal kriging, UK). The random structure, $\delta(\cdot)$, is modeled through variogram functions under the hypothesis of intrinsic spatial stationary of the studied process (Cressie, 1993).

Before spatially interpolating the coefficients, preliminary assessments of the linear dependence of each of the coefficients with spatial covariates (defined in Table 1) were conducted to choose between the OK and the UK approaches. If a given spatial covariate had a notable trend for a coefficient, the UK was selected, and the OK otherwise. Results of the spatial covariates selection are further discussed in Section 6.a. The next step consisted of modeling the variogram for each coefficient by selecting the theoretical function (e.g., spherical or exponential; Cressie, 1993) that best fits the empirical variogram (GSTAT package in R; Gräler *et al.*, 2016).

5.2 GAM/VGAM for spatial models

Two models with spatial covariates were calibrated to represent, respectively, the occurrence and intensity process across the studied region. The aim here was to enable the estimation of the distribution of equation 1 at all CFSR grid cells (even without observations). To do so, the GAM and VGAM (Hastie & Tibshirani, 1990; Yee & Wild, 1996) frameworks were applied respectively to model the occurrence and intensity of the daily precipitation. The GAM and VGAM extend, respectively, the GLM and VGLM models presented previously

(equations 3 and 4) by adding smooth functions of explanatory spatial covariates:

$$\begin{aligned} h(\theta_t(s)) = & \eta_0 + \eta_1 \log(x_{t,s} + 1) + \\ & \eta_2 \cos\left(\frac{2\pi d}{T}\right) + \eta_3 \sin\left(\frac{2\pi d}{T}\right) + \\ & F_s(cov_1(s), \dots, cov_p(s)), \end{aligned} \quad (8)$$

where $W_s(.)$ is the smooth function of p spatial covariates ($v_1(s), \dots, v_p(s)$), $h(.)$ the link function of the (V)GAM framework (here the log function), and $x_{t,s}$ is the corresponding CFSR precipitation on day t at site s . One of the advantages of the GAM and VGAM models is the possibility that each covariate may have a nonlinear effect on the distribution parameters, such as the shape parameter of the Gamma distribution (Yee, 2016b). In this study, the smoothing is done with the third order spline functions (see Blanchet & Lehning, 2010, for mathematical developments). The parameters of equation 8 were estimated with the MLE approach (VGAM package in R; Yee, 2016b).

The spatial covariates of the regional (V)GAM models were selected based on the Takeuchi Information Criterion (TIC; Takeuchi, 1976). The spatial correlations in the daily precipitation may lead to misspecified likelihood functions (Van de Vyver, 2012), which led us to select the TIC instead of the classical AIC (Akaike Information Criterion, Akaike,

1974). The model with the lowest TIC was selected.

5.3 Evaluation framework of the spatial models

5.3.1 Cross-Validation approach

The two spatial modeling approaches, namely kriging and spatial VGAM, were compared according to their abilities to predict the mixed daily precipitation distributions. Given the relatively high number of stations, the k -fold cross-validation (k -CV) method was preferred to the classical leave-one-out cross-validation method. The sample of 331 stations was first randomly divided into k non-overlapping and approximately equal subsamples (folds). The $(k - 1)$ folds were then pooled and used as a calibration sample while the remaining fold was used for validation. This procedure was finally iterated through the k folds so all sites of the sample are used once for validation.

The two spatial modeling approaches were fitted using the calibration fold at each iteration of the k -CV procedure. For the kriging approach, this means that a variogram for a given coefficient, that defined the mixed daily precipitation distribution parameters, was fitted to the calibration sample $((k - 1)$ folds). This same variogram was then used to interpolate the coefficients at the corresponding validation sites. For the spatial VGAM, two models (occurrence and intensity) were fitted, separately,

using the daily precipitation series and spatial covariates at the calibration sites $((k - 1)$ folds). These models were subsequently used to predict the mixed daily precipitation distribution at sites of the validation folds.

These two spatial approaches used the same meta-Gaussian latent field calibrated across the entire domain. Preliminary investigation demonstrated that the covariance functions, defining the meta-Gaussian random fields, fitted to each of the k calibration folds were slightly different from those estimated across all sites (no sub-sampling). Precipitation sequences (100 realizations) were then assessed using one meta-Gaussian random field and the mixed daily precipitation distributions, whose parameters were estimated from either kriging or VGAM in the cross-validation framework. The impact of using subsamples to represent the daily precipitation spatial structure of the whole domain was further investigated and is discussed in the following sections.

Results are presented for k equal to 10, k set to 5 was also tested to investigate the performance sensitivity to this parameter and are discussed in Section 2.

5.3.2 Assessment of the performances of post-processed precipitation series

The performances of the proposed approach were evaluated in a k -CV framework by investiga-

Table 1 – Spatial covariates introduced for the universal kriging and the VGAM approaches

Spatial covariates	Abbreviation
Latitude	Lat
Longitude	Lon
Elevation (m)	Elev
CFSR grid-cell distance to the water bodies (km)	DistWat
CFSR mean annual precipitation amount (mm)	MAP

ting different attributes of the precipitation at various time scales. The mean, mean on wet days, the variability through the standard deviation (std), the 95th percentiles (p_{95}) and the number of wet days were estimated over the 1979-2010 period. The temporal persistence, an important aspect to be represented in the daily precipitation series, was also assessed by the probability of dry and wet events of different durations, noted respectively $p_{dry}^{(d)}$ and $p_{wet}^{(d)}$ and where (d) ranges from 1 to 5 days. The impact of the previous day being dry (0) or wet (1) on the next day precipitation occurrence was analyzed through the transition probabilities (p_{00} , p_{01} , p_{11} , p_{10}) (Baxevani & Lennartsson, 2015). Hereafter, these statistics, evaluating the precipitation climatology, are referred to as characteris-

tics. Nine (9) indices were also assessed at the annual and seasonal time scales and were selected among the joint CCI/WCRP/JCOMM Expert Team on Climate Change Detection and Indices (ETCCDI) list (see Table 2). The indices enabled the evaluation of different attributes of the daily precipitation, with CDW and CDD providing insight about the maximum length of wet and dry events. The other indices, R10mm, R20mm, PRCP-TOT, Rx1day, Rx5day, R95p and R99p, characterize jointly the occurrence and intensity precipitation processes. Finally, the evaluation of the spatial structure of the daily precipitation, directly linked to the meta-Gaussian random field definition, was analyzed through pairwise spatial correlations.

Table 2 – Precipitation indices from the ETCCDI list computed at the annual and seasonal time scales
Donat *et al.* (2014)

Climate index identifier	Name	Description	Units
<i>Duration</i>			
CDD	Consecutive dry days	Annual maximum number of consecutive dry days (< 1 mm)	days
CWD	Consecutive wet days	Annual maximum number of consecutive wet days (≥ 1 mm)	days
<i>Frequency</i>			
R10mm	Number of heavy precipitation	Annual number of days with precipitation ≥ 10 mm	–
R20mm	Number of very heavy precipitation	Annual number of days with precipitation ≥ 20 mm	–
<i>Intensity</i>			
PRCPTOT	Total wet day precipitation	Annual total precipitation	mm
Rx1day	Maximum 1-day precipitation	Annual maximum 1-day precipitation	mm
Rx5day	Maximum 5-day precipitation	Annual maximum 5-day precipitation	mm
R95p	Very wet days	Annual amount when daily precipitation is $>95^{\text{th}}$ percentile of the daily precipitation over the reference period	mm
R99p	Extremely wet days	Annual amount when daily precipitation is $>99^{\text{th}}$ percentile of the daily precipitation over the reference period	mm

Assessment of the performance of the two spatial models was conducted through the comparison of the characteristics and indices at validation sites (k -CV framework) to the corresponding observations. Two questions were addressed: 1) to what extent did the estimations from spatial models outperform corresponding values from CFSR (without post-processing) at validation sites? and 2) how do they compare with those obtained from models with at-site coefficients (hereafter referred to as the Local model, Section 3)? Observed characteristics and indices were therefore compared to those estimated from the following four datasets: 1) random simulations using the at-site coefficients (Local model), i.e. not obtained from any spatial model; 2) random simulations based on kriging approaches (KG); 3) random simulations based on the VGAM model; and 4) CFSR (without post-processing).

Comparison of a single value to 100 random realizations of the same characteristic or index generated by one of three models (Local, KG and VGAM)

requires that a specific framework be defined to assess their relative performance. The recently proposed Comprehensive And Systematic Evaluation (CASE) framework was designed for this purpose (Bennett *et al.*, 2018; Evin *et al.*, 2018). The CASE framework, illustrated in Figure 3.a, classifies the performances into three categories: 1) “good”, if the observation value lies within the simulated 90% probability intervals; 2) “fair” if the observation value lies within the simulated 99.7% probability intervals, assuming the uncertainty is normally distributed, or if the absolute relative difference between the observation and the averaged simulations is smaller than 5%; and 3) “poor” otherwise. To keep the same framework for comparing single CFSR values to corresponding observations, the CASE, initially developed for stochastic outputs, was adapted (Figure 3.a). The “good” and “fair” categories were attributed when the absolute relative differences between these two datasets were smaller than, respectively, 2.5 and 5% and “poor” otherwise. This

framework not only intends to compare observed and post-processed statistics and indices, but also to assess if post-processed statistics were improved when compared to CFSR. Aggregate performance categories, also developed by Bennett *et al.* (2018), were used in this study to evaluate the overall performance of a selected metric. Six categories (Overall-Good, Overall-Fair, Overall-Poor, Fair-Good, Fair-Poor and Variable) were defined according to the percentage of sites, or years if the

time series were considered, being in the fair, good and poor category. The attribution of the correct aggregated performance category is based on the distribution of these percentages and is further explained in Figure 3.b. The Root Mean Squared Error (RMSE) and the relative bias for the selected metrics were also estimated (details are provided in Appendix A). Only performances at validation sites are presented for all characteristics.

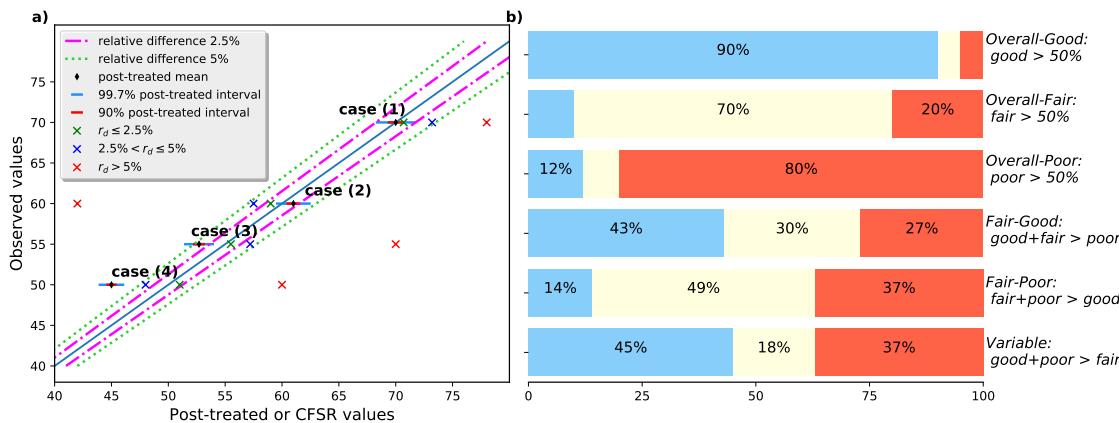


Figure 3 – a) Four possible cases when comparing CFSR (crosses) or post-processed (confidence intervals) climate indices or characteristics to those observed: case (1) “good” performances (90% simulated intervals); cases (2) and (3) “fair” performance; and case (4) “poor” performances. CFSR performances (crosses) for the four cases were considered “good”, “fair” or “poor” if the relative differences (r_d) with the observations were $\geq 2.5\%$, $> 2.5\%$ and $\leq 5\%$, or $> 5\%$, respectively; b) method to construct the six categories of aggregated performances (percentage below 10% are not showed) (adapted from Bennett *et al.*, 2018)

5.3.3 Daily spatial structure evaluation in a k -CV framework

This evaluation, conducted separately, aimed to establish if the meta-Gaussian latent field model calibrated with subsamples was able to represent the spatial structure of the daily precipitation across the whole domain. First, spatial covariance functions were fitted separately for each of the subsamples identified (see above) in the k -CV folds ($k=10$) and for the four seasons, leading to 4×10 functions. Second, 100 random simulations were generated across the domain and for each of the spatial covariance functions combined with the at-site daily precipitation mixed distributions (Local model). Finally, the spatial correlations of the resulting 100×10 daily sequences were analyzed. To ease visualization, spatial correlations were smoothed with Lowess functions (Cleveland, 1979) and only the simulated 90% probability intervals (corresponding to the good category of the CASE) were illustrated for each of the 10 covariance functions.

6 Results and discussion

6.1 Selection of spatial covariates

The spatial covariates employed for the kriging and VGAM/GAM models are classically applied in precipitation spatial modeling (Blanchet & Lehning, 2010; Van de Vyver, 2012; Panthou, 2012) and are defined in Table 1. Geographical co-

ordinates such as the latitude (Lat), the longitude (Lon) and the elevation (Elev) have a known impact on precipitation processes. The distance from water bodies (DistWat), computed as the shortest distance between the CFRS grid-cell center and the water bodies boundaries of the GLakes region, was also considered given the numerous lakes and their impact on precipitation (e.g., snow-lake effect, Lucas-Picher et al., 2017). Mean annual precipitation (MAP), estimated from CFSR precipitation datasets, was considered in this study, as suggested in the literature (Panthou, 2012). The covariates were intentionally observation-independent so as to propose precipitation estimates at sites with no observed precipitation.

With regards to kriging, the integration of spatial covariates was conducted during the analysis of the stationarity of the mean fields (hypothesis to be verified for ordinary kriging) to be interpolated. If the stationarity is not verified, the universal kriging, also known as kriging with an external drift (Goovaerts, 1997), is more adapted than ordinary kriging. To identify potential drifts, linear regressions between the occurrence (α_k , $k \in [0, 3]$; equation 4) coefficients and the spatial covariates of Table 1 were computed. The significance at the 95% confidence level of the slope of linear regression coefficients (not shown for conciseness) helped assess the consistency of the drifts. Results showed that the occurrence model coefficients (not shown for conciseness) did not display drifts along the selected spa-

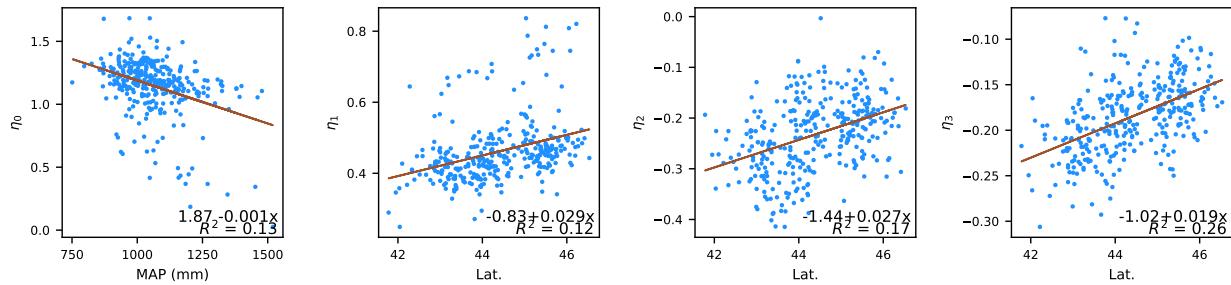


Figure 4 – At-site estimates of $\{\eta_0, \eta_1, \eta_2, \eta_3\}$ coefficients from the Local intensity model (equation 4) versus the mean annual precipitation (MAP) and the latitude (Lat.). The linear regression equation between the two variables are displayed at the bottom right sides.

tial covariates. The OK was then more suitable for interpolations. However, as illustrated in Figure 4, gradients along the latitudes were observed for the following intensity coefficients $\{\eta_1, \eta_2, \eta_3\}$, while the intercept η_0 displayed a significant trend along the averaged annual amount (MAP). The UK was then applied with the appropriate covariate to interpolate these coefficients. As for the occurrence model, the OK was employed to interpolate the two coefficients defining the shape parameter $\{\beta_0, \beta_1\}$ of the Gamma distribution (equation 4), as they did not display significant drifts along the spatial covariates.

The identification of the explanatory spatial covariates was also required to enable the smooth

spatial modeling of the occurrence (GAM) and intensity (VGAM) processes. To do so, several GAM and VGAM models (equation 8) were tested with different spatial covariates (Table 1) integrated through penalized of third order spline functions (Fessler, 1991). Among these models, the one with the lowest TIC value was selected for the analysis. The TIC values obtained for each of these models are illustrated in ascending order in Figure 5. The model with latitude outperformed the other models for the occurrence process (Figure 5.a) and was selected for the GAM model in the following analyses. The mean annual amount (MAP) better explained the intensity model (Figure 5.b) and was chosen as a covariate for both position and shape parameters of the VGAM.

6.2 Daily characteristics performances in validation mode

We evaluated the predictive capacities of the two spatial modeling approaches to provide daily statistics across the GLakes region using the RMSE

and the relative bias (Table 3). Results indicated that the KG and VGAM models outperformed CFSR for almost all attributes (bold figures in Table 3), except for the daily precipitation standard deviation (std) and $p_{wet}^{(2)}$. Absolute relative bias ranged from 4% to 136.3% for CFSR datasets (std

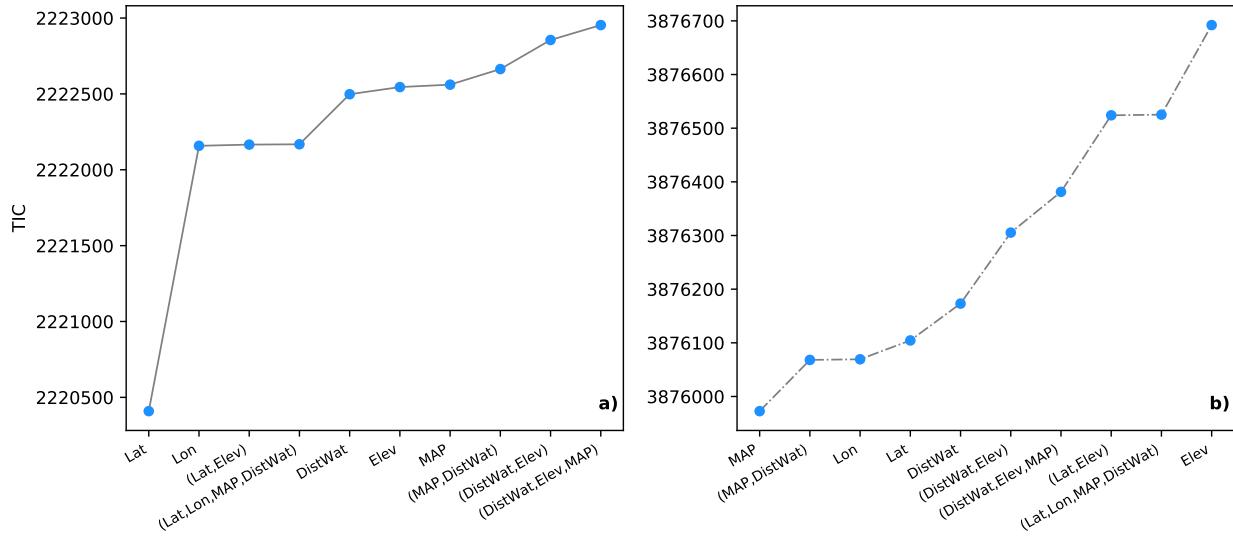


Figure 5 – TIC values obtained with different spatial covariates (x-axis) for a) the occurrence and b) for the intensity VGAM models. TIC values are ordered in ascending order, the x-axis are thus different in a) and b).

and $p_{wet}^{(2)}$ excluded), while it ranged from 0.4% to 7.4% for, indistinguishably, KG and VGAM datasets. As expected, the Local model provided the lowest RMSE and relative bias (below 2% for the majority of the characteristics), demonstrating that the post-processing adequately corrects the biases.

The VGAM, KG and Local models produced similar performances regarding transition probabilities and probabilities of wet/dry events over different durations, with VGAM (KG) outperforming KG (VGAM) on probabilities of wet/dry events over different durations (transition probabilities). These characteristics, mainly driven by the lag-1 autocorrelation in the meta-Gaussian latent field and defined similarly in the three models, explained the obtained results. Differences were more substantial for characteristics that described intensity and the number of wet days, whereas the expected Local

model outperformed KG, VGAM, and CFSR. These characteristics are directly influenced by the at-site mixed daily precipitation distribution, whose parameters were estimated either by KG or by VGAM. In this respect, the lower performances of the KG and VGAM models compared to the Local model were not surprising. However, both KG and VGAM approaches displayed low relative biases (< 10%) and RMSE.

The CASE framework applied to these daily characteristics led to the same results. Almost all of the studied characteristics for the Local model were attributed to the Overall-Good category (third column, dominant blue color in Figure 6). The CFSR precipitation series (Figure 6, last column to the right), without post-processing, displayed Overall-Poor performances for most characteristics, except for $p95$, the std and the $p_{wet}^{(2)}$ dis-

playing Variable performances. A similar ranking of models was obtained at the seasonal scale (not shown for conciseness). The KG and VGAM approaches displayed Overall-Poor performances for the mean daily precipitation. The seasonal analysis of the mean precipitation (see Figure S1 in the supplementary material) suggested that this performance was mainly due to variable performances during winter (DJF), while Overall-Good performances were observed during the other seasons. The transition probabilities showed Variable to Fair-Good performances within the KG and VGAM ap-

proaches, with slightly more sites in the good category with the KG than with the VGAM, and were consistent with the results of Table 3. Here again, winter (DJF) followed by spring (MAM) did not perform as well (Variable category) as the summer (JJA) and autumn (SON) (Overall-Good category). The probabilities of wet and dry events of varying durations (third and fourth lines in Figure 6) were generally the best represented characteristics with Overall-Good and Fair-Good performances for both KG and VGAM, except short duration wet events that showed Variable performances.

Table 3 – RMSE and relative bias for different daily characteristics (lines) estimated between observed and estimated from four daily precipitation datasets (columns) on validation sites. Bold figures indicate the lowest RMSE and absolute relative bias among the KG, VGAM and CFSR, while italic figures correspond to the Local model performances.

	RMSE				Relative Bias			
	KG	VGAM	CFSR	Local	KG	VGAM	CFSR	Local
Mean	0,21	0,25	0,48	<i>0,03</i>	0,8%	1,9%	14,5%	<i>0,8%</i>
Mean wet day	0,54	0,46	1,49	<i>0,16</i>	1,8%	2,3%	-17,4%	<i>1,8%</i>
std	0,60	0,54	0,50	<i>0,18</i>	4,2%	5,1%	-2,8%	<i>1,9%</i>
p95	1,06	1,04	1,36	<i>0,35</i>	-1,6%	-0,4%	0,8%	<i>-1,2%</i>
Number of wet days	192	198	2821	<i>28</i>	-1,4%	-0,9%	107,5%	<i>-0,9%</i>
p_{01}	0,030	0,031	0,138	<i>0,016</i>	2,0%	1,8%	-23,3%	<i>1,9%</i>
p_{11}	0,030	0,031	0,138	<i>0,016</i>	-2,7%	-2,5%	31,2%	<i>-2,5%</i>
p_{00}	0,018	0,019	0,088	<i>0,006</i>	-0,3%	-0,5%	-11,8%	<i>-0,2%</i>
p_{10}	0,018	0,019	0,088	<i>0,006</i>	0,7%	1,4%	30,7%	<i>0,5%</i>
$p_{wet}^{(1)}$	0,041	0,041	0,141	<i>0,033</i>	5,0%	4,8%	-24,5%	<i>5,0%</i>
$p_{wet}^{(2)}$	0,025	0,025	0,018	<i>0,025</i>	-7,4%	-7,2%	1,9%	<i>-7,8%</i>
$p_{wet}^{(3)}$	0,013	0,013	0,035	<i>0,010</i>	-6,4%	-5,7%	30,8%	<i>-6,1%</i>
$p_{wet}^{(4)}$	0,008	0,008	0,036	<i>0,005</i>	-2,3%	-1,5%	83,0%	<i>-1,6%</i>
$p_{wet}^{(5)}$	0,005	0,005	0,024	<i>0,003</i>	-0,7%	-0,2%	136,3%	<i>0,9%</i>
$p_{dry}^{(1)}$	0,023	0,025	0,103	<i>0,013</i>	1,1%	1,7%	35,5%	<i>1,3%</i>
$p_{dry}^{(2)}$	0,013	0,014	0,030	<i>0,011</i>	-1,8%	-1,4%	11,5%	<i>-2,1%</i>
$p_{dry}^{(3)}$	0,011	0,011	0,015	<i>0,011</i>	-0,5%	-0,2%	-4,0%	<i>-0,7%</i>
$p_{dry}^{(4)}$	0,008	0,008	0,021	<i>0,008</i>	1,7%	1,8%	-18,1%	<i>1,6%</i>
$p_{dry}^{(5)}$	0,008	0,008	0,021	<i>0,007</i>	0,6%	0,4%	-26,8%	<i>-0,2%</i>

6.3 Assessment of the spatial structure of the daily precipitation

Results for the spatial correlations of the daily precipitation as a function of the distance are summarized in Figure 7. For each season, the 90% confidence interval of the 100 realizations of the correlations differed only slightly across the 10 folds, as illustrated by the almost indistinguishable blue curves in Figure 7. In other words, for the studied region, calibration subsamples with 10% of the sta-

tions were enough to capture the spatial structure of the daily precipitation across the whole region.

Moreover, the correlation estimated from subsamples constituted “good” estimates, using the term of the CASE framework, of the observed spatial correlation (red curve in Figure 7). Except during winter, the observed spatial correlation fell in the 90th post-processed interval for a high range of distances. Overestimated correlations at short and long distances observed during winter may be explained by the hypothesis of isotropy in the meta-

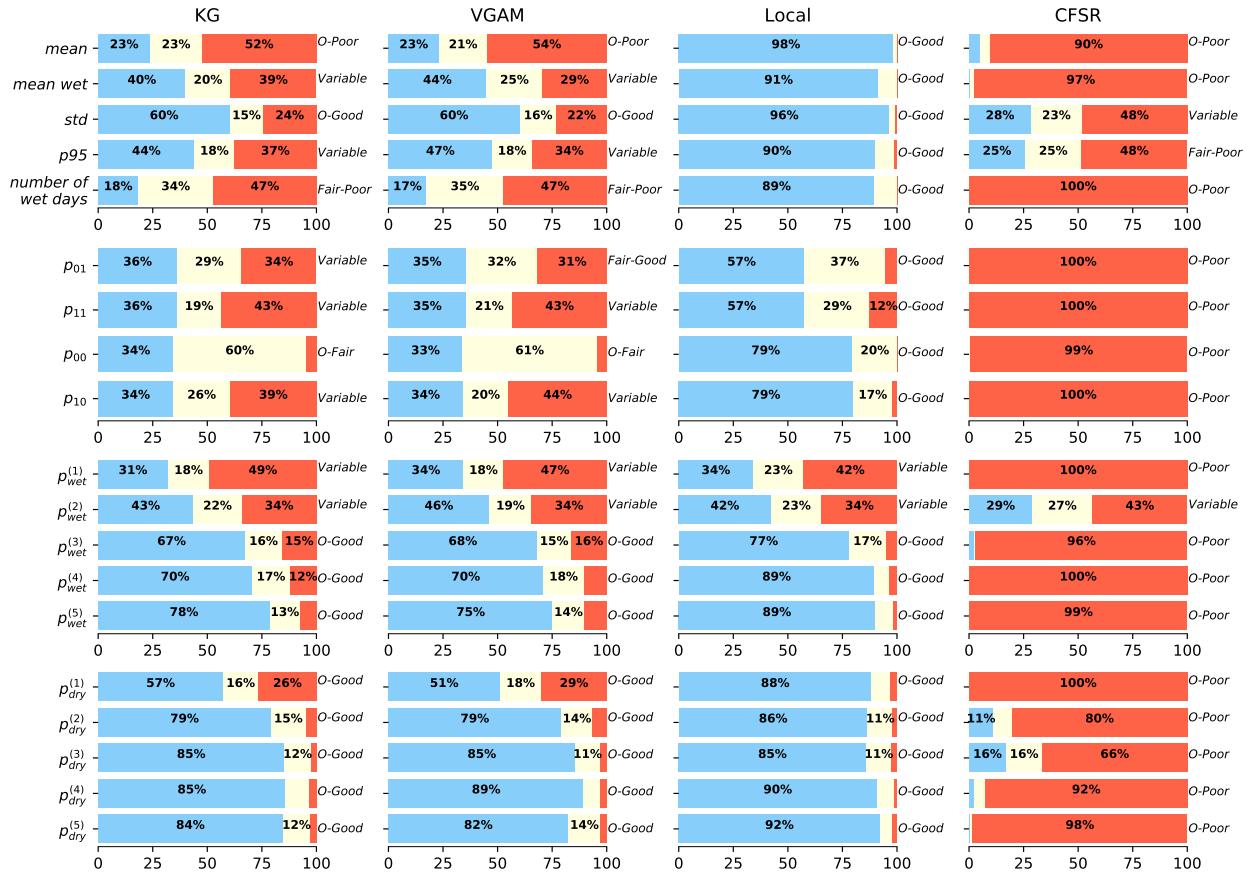


Figure 6 – Daily characteristics performances for KG, VGAM and Local models, and CFSR. The blue, pale yellow and red colors represent respectively the percentage of sites being in the “good”, “fair” or “poor” category across the GLakes region. The aggregated performances are indicated in italic at the right side of each characteristic.

Gaussian definition (Section 4). In fact, considering the very particular spatial distribution of the snow (snowbelts around the Great Lakes, Lucas-Picher et al., 2017) during this time of the year, a more complex spatial correlation function would have

been more adapted. However, the post-processed precipitation series provided better daily spatial consistency than CFSR, which largely overestimated the observed spatial correlations during all seasons.

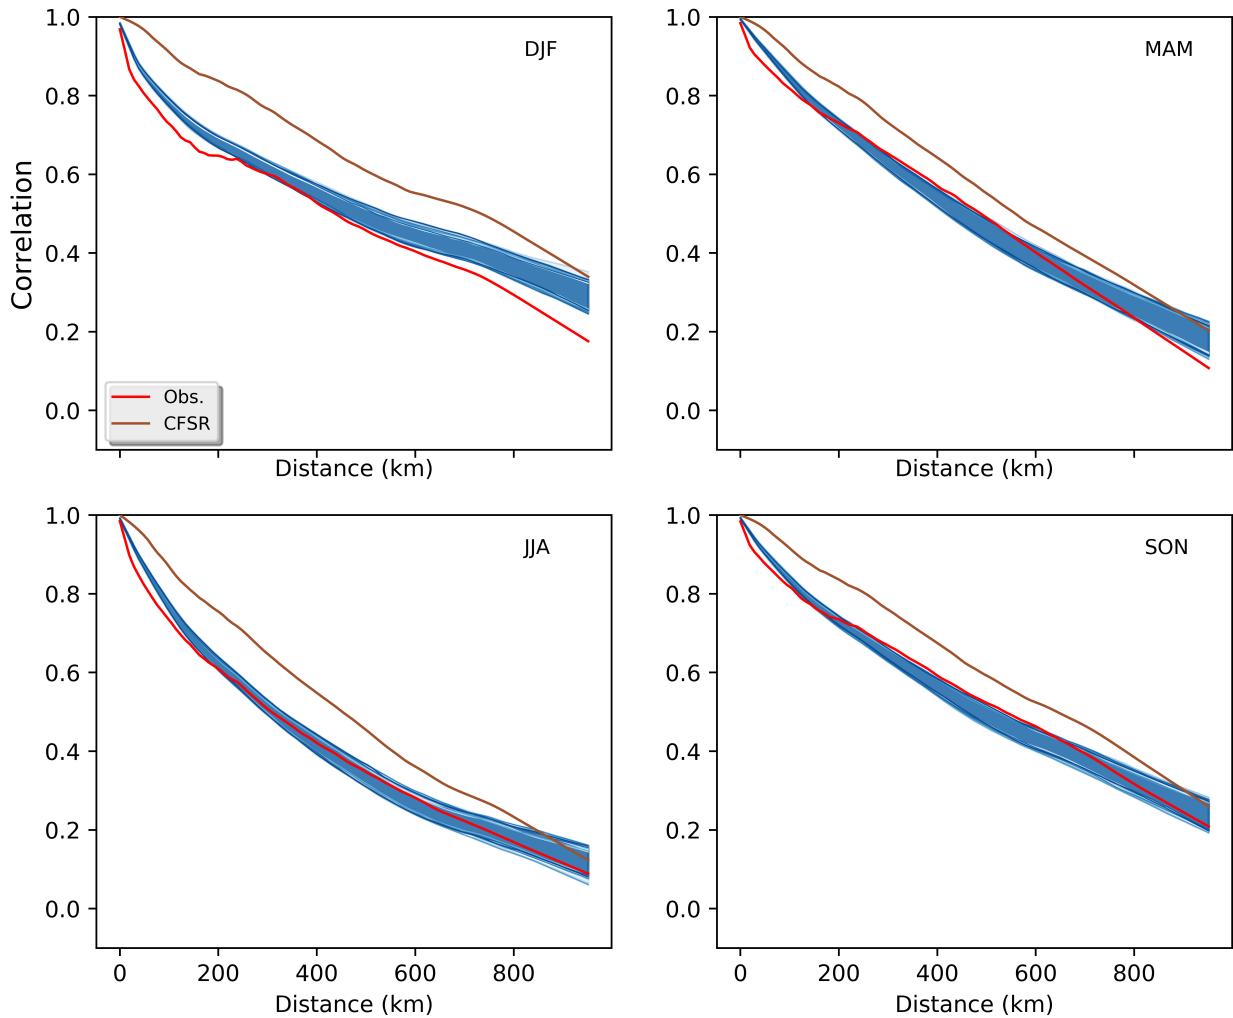


Figure 7 – Spatial correlations of the daily precipitation series during the DJF, MAM, JJA, and SON seasons for observed (red) and CFSR (brown) datasets. The blues lines correspond the 90% (“good”) confidence intervals of the spatial correlation obtained from the post-processed series with 10 different covariances functions.

6.4 ETCCDI indices at validation sites

Figure 8 summarizes the performances of the Local and spatial models in validation of the selected annual climate indices. More precisely, it presents the proportion of years of annual index series that were classified in the “good” category over the various sites. From this figure, it is also possible to

visualize the global performances as defined in Figure 3.b. Overall-Good performances were observed for the majority of sites. More than 90% of the sites had more than 50% of their annual series attributed to the “good” category regardless of the selected model. Similar results were observed at the seasonal scale (not shown here) in terms of aggregated performances. However, JJA followed by DJF were the less well-simulated seasons. Among the climate in-

dices, model performance differences, between the Local and the two spatial models, were greater for R10mm and PRCPTOT, than for the other indices (Figure 8).

As previously mentioned for the daily characteristic analysis, the Local model (Figure 8, pink curve) systematically outperformed the two spatial models with a higher percentage of years classified in the good category. The boxplots within each panel of Figure 8 compare the relative performances of the three models with CFSR. Once again, the Local and the two spatial models outperformed CFSR; on average 90% of the cases in which the performances were “good” for one of the three models, CFSR had a worse performance category (either “fair” or “poor”). At the annual and seasonal time scales (not shown here), CFSR displayed (for almost all indices except Rx1day and Rx5day) the highest relative bias, while the KG approach performed slightly better than VGAM.

The biases of the selected indices relative to the observations, shown in Figure 9, were particularly low for PRCPTOT and R10mm indices, among others. These results may seem counterintuitive when compared to those presented in Figure 8, especially for PRCPTOT. However, it appeared that for this index the simulated climate index intervals

were very small, resulting in decreased probabilities that the observations would be placed in the “good” category, regardless of the model. Once again, DJF had the lowest performance with a relatively high spatial spread in the relative bias values compared to the other seasons (Figure 10). The biases for the annual maximum duration of wet and dry events (CDW and CDD) were significantly smaller for KG, VGAM and the Local model compared to CFSR. In fact, the median values estimated across the region declined from around -22% and 50% for, respectively, CDD and CDW, to below 3% for KG and VGAM. The spatial modeling approaches, especially the VGAM, produced even lower bias values for indices describing the annual frequency of moderate (R10mm) and more extreme events (R20mm), with regional median varying, respectively, around 0.23% and -4%. The annual maximum intensity for one and five-day events (Rx1day and Rx5day) were generally overestimated, to different extents according to the models, with more spatially dispersed relative biases for KG model. As expected from a gridded precipitation product, CFSR underestimated extreme indices, especially those occurring during summer (see gray boxplots in Figure 10). The RMSE results led to similar conclusions (see Figure S2 in the supplementary material).

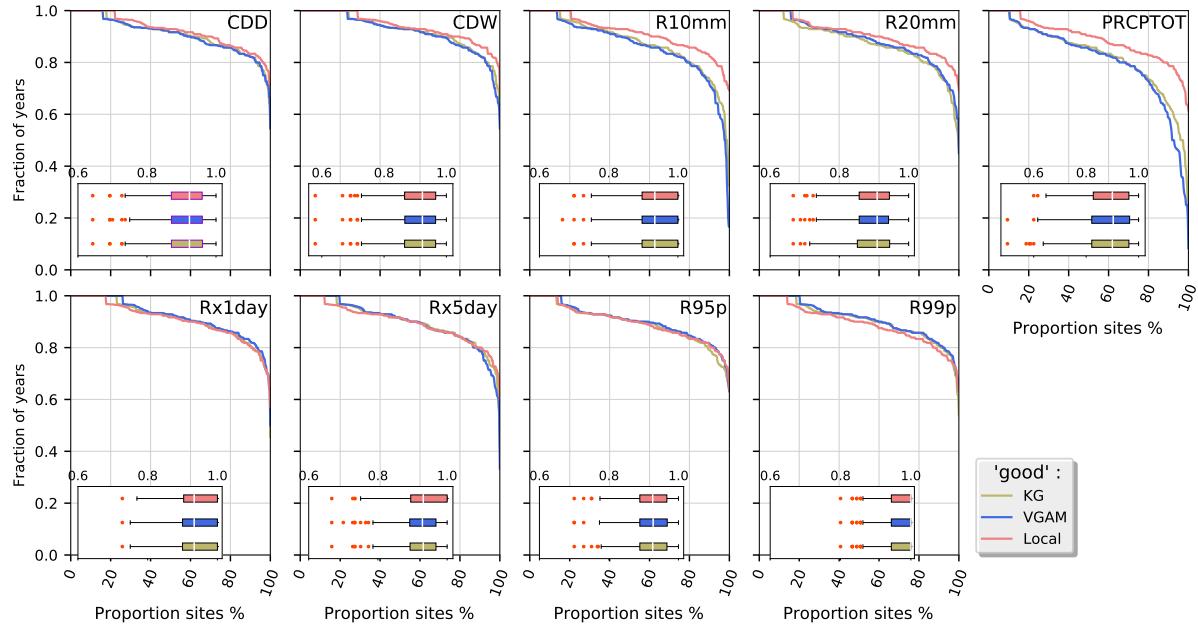


Figure 8 – Proportion of years for the corresponding annual indices series (indicated in the top right of each panel) displaying good performances for the three models: KG (purple), VGAM (black) and Local (blue). Proportions for each site (x -axis) are ordered in decreasing order. Boxplots in each panel illustrate the distribution of the proportion of years with post-processed “good” performance which have similar performance to CFSR or outperformed CFSR. Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the mean value, while the whiskers lower and upper limits correspond, respectively, to $q_{25}-1.5 \times \text{IQR}$ and $q_{75}+1.5 \times \text{IQR}$. Outliers are indicated by orange circles.

7 Conclusions

Reanalyses are generated from numerical weather prediction models that assimilate, at each given time step (e.g., 6h), past observations over relatively long periods. They represent an interesting option for regions with low station density. However, reanalyses, especially for a variable such as precipitation, may be biased and representativeness issues may also be of concern for local scale applications (e.g., hydrological modeling of small watersheds). The work presented in this paper intended to post-process gridded CFSR precipitation, across a continuous spatial domain, to overcome these limitations and generate daily precipitation

sequences at ungauged sites. The present study therefore proposed a spatio-temporal modeling of daily precipitation that takes advantage of the CFSR dataset to generate information at sites without observations.

A two-step approach was developed to reach this objective. First, stochastic post-processing using CFSR precipitation as a covariate combined with a meta-Gaussian random field was implemented and calibrated using at-site observations (Serrinaldi & Kilsby, 2014). The stochastic approach, inspired by downscaling methods, was defined in a similar way to the study by Wong *et al.* (2014). This approach applied probabilistic regression tools

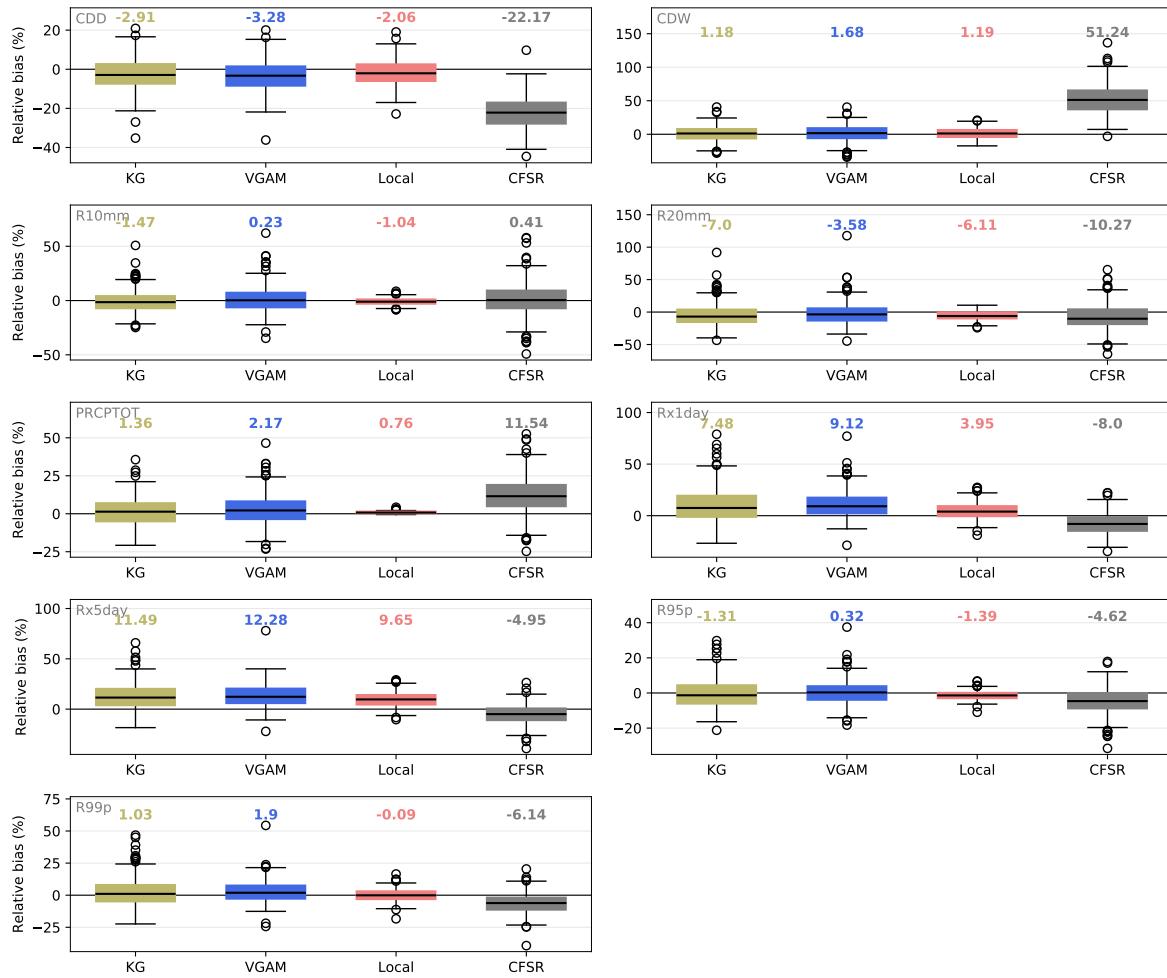


Figure 9 – Boxplots of the relative bias (%) between observed and KG, VGAM, Local and CFSR climate indices (top left panel). Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the median value, while the whiskers lower and upper limits correspond, respectively, to $q_{25}-1.5\times\text{IQR}$ and $q_{75}+1.5\times\text{IQR}$. The median value is written at the top of each boxplot with its corresponding color. The *y*-axis limits are different in the subplots.

to provide the at-site mixed daily precipitation distributions. The generated series from these distributions allow for unexplained local scale variability of the precipitation unlike other bias correction tools (e.g., quantile mapping, Maraun *et al.*, 2010). The meta-Gaussian field was applied in a latent way to ensure daily spatio-temporal consistency in the random simulations from the mixed daily precipitation distribution (Serinaldi & Kilsby, 2014).

The second major step consisted of the extension of these models, defined and calibrated using station records, at CFSR grid cells without records. In order to do this, two spatial-modeling methods were tested. The kriging (KG) method was used to interpolate the mixed daily precipitation distribution coefficients. The second is an integrated method (more parsimonious) based on the assessment of stochastic regional post-processing models in a

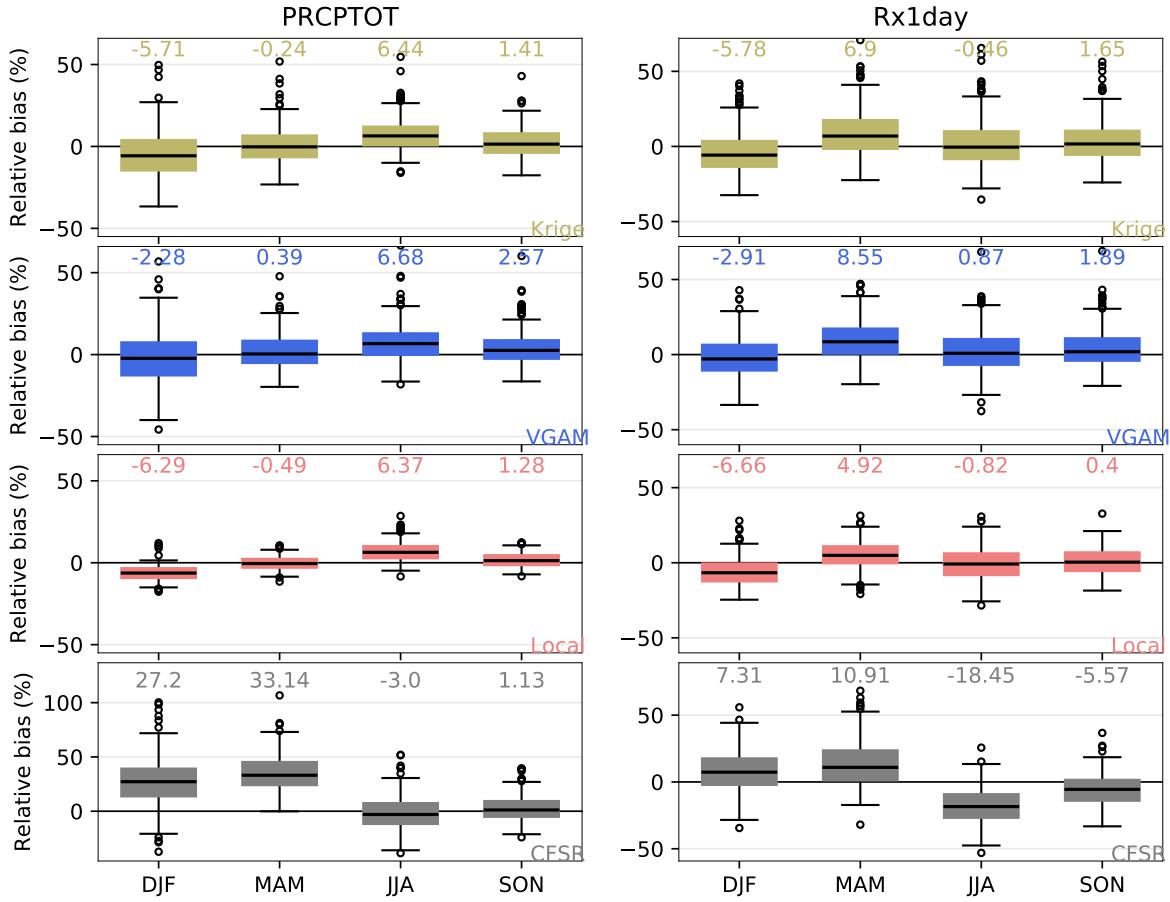


Figure 10 – Boxplots of the relative bias (%) between observed and KG, VGAM, Local and CFSR PRCPTOT (left panels) and Rx1day (right panels) indices at the season time scale (DJF, MAM, JJA, SON) (x -axis). Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the median value, while the whiskers lower and upper limits correspond, respectively, to $q_{25} - 1.5 \times \text{IQR}$ and $q_{75} + 1.5 \times \text{IQR}$. The median value is written at the top of each boxplot with its corresponding color. The y -axis limits are different in the subplots.

VGAM framework, which showed similarities with the smooth maximum likelihood estimation found in the extreme modeling studies of Blanchet & Lehning (2010) and Panthou (2012). One hundred precipitation sequences were randomly generated from the mixed daily precipitation distribution with parameters that were: 1) local estimates (Local model), 2) interpolated with KG, and 3) estimated with VGAM models.

The methodology was applied to an ensemble of 331 station records covering the 1979–2009 period across the Canadian part of the Great Lakes region (Plummer *et al.*, 2006). The assessment aimed to investigate how the two spatial models (KG, VGAM) compared to the Local model and to the observations. The added value of these three models (Local and spatial) versus CFSR without any post-processing was also evaluated. Daily characteristics and selected climate indices from the

ETCCDI list, depicting different aspects of the daily precipitation, were analyzed in a k -fold cross-validation framework with results that were investigated at validation sites. The CASE evaluation framework developed by Bennett *et al.* (2018) was considered, as it allows a simple and intuitive framework for the comparisons of observed, CFSR and post-processed performances. Three categories including “good”, “fair” and “poor” were defined within the CASE framework and are based on how confidence intervals of randomly generated characteristics/indices or CFSR compared with the corresponding observation.

Results indicated that the stochastic approach had a high potential for providing reliable precipitation series. In fact, the randomly generated series presented very low bias with a very high fraction of the sites classified in the “good” category for the majority of studied characteristics. Results of spatial modeling at validation sites showed that the KG approach slightly outperformed the VGAM for several climate characteristics. These results differ from those reported in Panthou (2012) for the spatial modeling of extreme precipitation in West Africa and those produced in Blanchet & Lehning (2010) for the snow mapping in Switzerland, where both studies demonstrated better performances using smooth spatial functions than kriging. The number of studied sites, the type of precipitation (extremes in their case) and the spatial domain are different factors that may explain these differences.

Generally, the climate characteristics and indices estimated from the spatial models displayed too low spatial variabilities. The uncertainties, possibly linked to short records, may explain these shortcomings even if the at-site mixed distribution coefficients were consistent spatially (as opposed to random), it also appeared that at neighboring sites some coefficients led to different estimated parameters. This was especially the case for coefficients defining the shape parameters in the Gamma distribution. This local effect is then difficult to represent with the kriging and VGAM models, which by construction attribute similar parameter estimates at sites sharing similar geographical conditions. The characteristics defining the temporal persistence (e.g., transition probabilities) and the spatial correlations of the daily precipitation generally performed well. These characteristics were indeed linked to the meta-Gaussian field, which demonstrated that even if calibration was carried out using regional subsamples, results were representative of the whole region. Despite the large differences between the KG and VGAM approaches in terms of the number of parameters, it is worth noting that similar biases, RMSE values and performance categories were obtained with these two approaches. Moreover, even when evaluating the predictive abilities of the models (validation sites), KG and VGAM still displayed significant improvement of the metric estimation compared to those of CFSR without post-processing. This demonstrates that for annual climate series such as the annual

or monthly precipitation series over the 1979-2009 period, post-processed series combined with KG or VGAM clearly outperformed CFSR.

Using a different partition of the cross-validation samples with k equal to 5 (results not shown) did not change the performances ranking among the models and the performance categories for characteristics and indices. Slight differences were obtained on the RMSE and the relative bias with generally higher values for $k = 5$ than $k = 10$. These latter results were expected as larger calibration subsamples ($k = 10$) are more likely to give better predictions. However, differences were very small and highlighted the low performance sensitivity when using either $k = 10$ or $k = 5$.

From a methodological point of view, several avenues of research could be investigated to improve the modeling approach proposed in this study. First, a multi-site approach would add robustness to the parameter estimates, especially for the intensity parameters, possibly leading to improved interpolation. Second, the VGAM approach could be generalized by implementing Bayesian spatial modeling (Cooley & Sain, 2010) to explicitly model the spatial structure of the distribution parameters, especially concerning the intensity distribution. Olson & Kleiber (2017) addressed this issue, but only for the daily precipitation occurrences. The proposed approach could also be used to downscale and bias-correct regional climate model precipitation (Asong *et al.*, 2016b; Volosciuk *et al.*, 2017).

Appendix A

Let $\mathbf{m}_s = \{m_{1,s}, m_{2,s}, \dots, m_{100,s}\}$, $m_s^{(obs)}$, and $m_s^{(cfsr)}$ be the vector of climate characteristics (e.g., mean) or ETCCDI indices (e.g., mean of the annual CDW), estimated across the 100 post-processed daily precipitation series at the site s , the observed and the CFSR estimates of the same quantity, the RMSE presented in this study corresponds to:

$$\text{RMSE}(obs, pst) = \sqrt{\frac{1}{S} \sum_{i=1}^S (m_i^{(obs)} - \bar{m}_i)^2} \quad (9)$$

$$\text{RMSE}(obs, cfsr) = \sqrt{\frac{1}{S} \sum_{i=1}^S (m_i^{(obs)} - m_i^{(cfsr)})^2}$$

where S is the total number of sites across the domain, and \bar{m}_i the averaged characteristic or index across the 100 simulations at the site i . The pst subscript refers to the post-processed values.

The relative bias expresses as:

$$\text{Rbias}(obs, pst) = \frac{1}{S} \sum_{i=1}^S \left(\frac{\bar{m}_i - m_i^{(obs)}}{m_i^{(obs)}} \right) \quad (11)$$

$$\text{Rbias}(obs, cfsr) = \frac{1}{S} \sum_{i=1}^S \left(\frac{m_i^{(cfsr)} - m_i^{(obs)}}{m_i^{(obs)}} \right) \quad (12)$$

References

- Akaike H (1974). A new look at the statistical model identification. *IEEE Trans. Autom. Control*, 19:716–723.
- Allard M & Lemay M (2012). Nunavik and Nu-

- natsiavut: From science to policy. An Integrated Regional Impact Study (IRIS) of climate change and modernization. ArcticNet Inc. 303 pages.
- Ambrosino C, Chandler RE & Todd MC (2014). Rainfall-derived growing season characteristics for agricultural impact assessments in South Africa. *Theor. Appl. Climatol.*, 115(3-4):411–426. DOI:10.1007/s00704-013-0896-y.
- Asong ZE, , Khaliq MN, & Wheater HS (2016a). Multisite multivariate modeling of daily precipitation and temperature in the Canadian Prairie Provinces using generalized linear models. *Clim. Dyn.*, pages 1–21. DOI:10.1007/s00382-016-3004-z.
- Asong ZE, Khaliq MN & Wheater HS (2016b). Projected changes in precipitation and temperature over the Canadian Prairie Provinces using the Generalized Linear Model statistical downscaling approach . *Journal of Hydrology*, pages 429 – 446. DOI:10.1016/j.jhydrol.2016.05.044.
- Baxevani A & Lennartsson J (2015). A spatiotemporal precipitation generator based on a censored latent Gaussian field. *Water Resources Research*, 51(6):4338–4358. DOI:10.1002/2014WR016455.
- Bengtsson L & Shukla J (1988). Integration of Space and In Situ Observations to Study Global Climate Change. *Bulletin of the American Meteorological Society*, 69:1130–1143. DOI:10.1175/1520-0477(1988)069<1130:IOSAIS>2.0.CO;2.
- Bennett B, Thyer M, Leonard M, Lambert M & Bates B (2018). A comprehensive and systematic evaluation framework for a parsimonious daily rainfall field model (in press). *Journal of Hydrology*. DOI:10.1016/j.jhydrol.2016.12.043.
- Blanchet J & Lehning M (2010). Mapping snow depth return levels: smooth spatial modeling versus station interpolation. *Hydrology and Earth System Sciences*, 14(12):2527.
- Bromwich DH, Nicolas JP & Monaghan AJ (2011). An Assessment of Precipitation Changes over Antarctica and the Southern Ocean since 1989 in Contemporary Global Reanalyses *. *Journal of Climate*, 24(16):4189–4209. DOI:10.1175/2011JCLI4074.1.
- Buishand TA, Shabalova MV & Brandsma T (2004). On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation. *Journal of Climate*, 17(9):1816–1827. DOI:10.1175/1520-0442(2004)017<1816:OTCOTT>2.0.CO;2.
- Chandler R (2002). GLIMCLIM: generalized linear modelling for daily climate time series (software and user guide). Department of Statistical Science, University College London.
- Chandler RE & Wheater HS (2002). Analysis of rainfall variability using generalized linear models: A case study from the west of Ireland.

- Water Resources Research*, 38(10):10–1–10–11. DOI:10.1029/2001WR000906. 1192.
- Cleveland WS (1979). Robust locally weighted regression and smoothing scatterplots. *Journal of the American Statistical Association*, 74(368):829–836. DOI:10.1080/01621459.1979.10481038.
- Coe R & Stern R (1982). Fitting Models to Daily RainfallData. *J. Appl. Meteorol.*, 21(7):1024–1031. DOI:10.1175/1520-0450(1982)021<1024:FMTDRD>2.0.CO;2.
- Cooley D & Sain SR (2010). Spatial hierarchical modeling of precipitation extremes from a regional climate model. *Journal of Agricultural, Biological, and Environmental Statistics*, 15(3):381–402. DOI:10.1007/s13253-010-0023-9.
- Cressie N & Huang HC (1999). Classes of Nonseparable, Spatio-Temporal Stationary Covariance Functions. *J. Am. Stat. Assoc.*, 94(448):1330. DOI:10.2307/2669946.
- Cressie NAC (1993). *Statistics for Spatial Data*. John Wiley & Sons, Inc., pages 1–26.
- Dai A (2006). Precipitation Characteristics in Eighteen Coupled Climate Models. *Journal of Climate*, 19(18):4605–4630. DOI:10.1175/JCLI3884.1.
- Deutsch C & Journel A (1992). *GSLIB: Geostatistical Software Library and User's Guide*. Applied geostatistical series. Oxford University Press.
- Devine KA & Mekis E (2008). Field accuracy of Canadian rain measurements. *Atmosphere-Ocean*, 46(2):213–227. DOI:10.3137/ao.460202.
- Diggle PJ, Tawn JA & Moyeed RA (1998). Model-based geostatistics. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 47(3):299–350. DOI:10.1111/j.1467-9876.00113.
- Eden JM, Widmann M, Maraun D & Vrac M (2014). Comparison of GCM- and RCM-simulated precipitation following stochastic postprocessing. *Journal of Geophysical Research: Atmospheres*, 119(19):11,040–11,053. DOI:10.1002/2014JD021732.
- Environment and Climate Change Canada (2013). *Adjusted Precipitation and Homogenized Canadian Climate Data (AHCCD)*. <http://ec.gc.ca/dccha-ahccd/default.asp?lang=En&n=9AA530BE-1>. 2014-10-27.
- Eum HI, Dibike Y, Prowse T & Bonsal B (2014). Inter-comparison of high-resolution gridded climate data sets and their implication on hydrological model simulation over the Athabasca Watershed, Canada. *Hydrol. Process.*, 28(14):4250–4271. DOI:10.1002/hyp.10236.
- Evin G, A.-C. F & B. H (2017). Stochastic generation of multi-site daily precipitation for the assessment of extreme floods in switzerland. *Hydrol. Earth Syst. Sci. Discuss.*, pages n/a–n/a. DOI:10.5194/hess-2017-226.

- Fessler JA (1991). Nonparametric fixed-interval smoothing with vector splines. *IEEE Transactions on Signal Processing*, 39(4):852–859.
- Goovaerts P (1997). *Geostatistics for Natural Resources Evaluation*. Applied geostatistics series. Oxford University Press.
- Gräler B, Pebesma E & Heuvelink G (2016). Spatio-temporal interpolation using gstat. *The R Journal*, 8:204–218.
- 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.
- Hastie T & Tibshirani R (1990). *Generalized Additive Models*. Chapman and Hall/CRC, 352 pages.
- Hopkinson RF, Mckenney DW, Milewska EJ, Hutchinson MF, Papadopol P & Vincent LA (2011). Impact of aligning climatological day on gridding daily maximum-minimum temperature and precipitation over Canada. *J. Appl. Meteorol. Climatol.*, 50(8):1654–1665. DOI:10.1175/2011JAMC2684.1.
- Katz RW (1977). Precipitation as a Chain-Dependent Process. *Journal of Applied Meteorology*, 16(7):671–676.
- Kendall MG (1962). *Rank correlation methods*. London : Charles Griffin & Co. Ltd, 3rd ed edition. Previous ed.(B55-8618) 1955.
- Khedhaouiria, D., A. Mailhot, and A.-C. Favre, 2018a: Daily precipitation fields modeling across the Great Lakes region (Canada) by using the CFSR reanalysis.
- Khedhaouiria D, Mailhot A & Favre AC (2018a). Daily precipitation fields modeling across the Great Lakes region (Canada) by using the CFSR reanalysis (submitted)
- Khedhaouiria D, Mailhot A & Favre AC (2018a). Stochastic Post-Processing of CFSR Daily Precipitation across Canada. *Atmosphere-Ocean*, 1–13. DOI:10.1080/07055900.2018.1434122
- Kidd C, Becker A, Huffman GJ, Muller CL, Joe P, Skofronick-Jackson G, Kirschbaum DB, Kidd C, Becker A, Huffman GJ, Muller CL, Joe P, Skofronick-Jackson G & Kirschbaum DB (2017). So, How Much of the Earth's Surface Is Covered by Rain Gauges? *Bull. Am. Meteorol. Soc.*, 98(1):69–78. DOI:10.1175/BAMS-D-14-00283.1.
- Kleiber W, Katz RW & Rajagopalan B (2012). Daily spatiotemporal precipitation simulation using latent and transformed Gaussian processes. *Water Resources Research*, 48(1): W01523. DOI:10.1029/2011WR011105.
- Lamb R, Faulkner D, Wass P & Cameron D (2016). Have applications of continuous rainfall-runoff simulation realized the vision for process-based flood frequency analy-

- sis? *Hydrological Processes*, 30(14):2463–2481. DOI:10.1002/hyp.10882.
- Lin A & Wang XL (2011). An algorithm for blending multiple satellite precipitation estimates with in situ precipitation measurements in canada. *Journal of Geophysical Research: Atmospheres*, 116(D21):n/a–n/a. DOI:10.1029/2011JD016359. D21111.
- Lucas-Picher P, Laprise R & Winger K (2017). Evidence of added value in North American regional climate model hindcast simulations using ever-increasing horizontal resolutions. *Clim. Dyn.*, 48(7-8):2611–2633. DOI:10.1007/s00382-016-3227-z.
- Maraun D, Wetterhall F, Ireson AM, Chandler RE, Kendon EJ, Widmann M, Brienen S, Rust HW, Sauter T, Themeßl M, Venema VKC, Chun KP, Goodess CM, Jones RG, Onof C, Vrac M & Thiele-Eich I (2010). Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, 48(3):n/a–n/a. DOI:10.1029/2009RG000314.
- McCullag P & Nelder JA (1989). *Generalized linear models*. Chapman and Hall, New York, 2nd edition edition, 532 pages.
- Mekis E (2005). Adjustments for trace measurements in Canada. *15th Conference on Applied Climatology*, Savannah, Georgia, USA.
- Mekis E & Vincent LA (2011). An Overview of the Second Generation Adjusted Daily Precipitation Dataset for Trend Analysis in Canada. *Atmosphere-Ocean*, 49(2):163–177. DOI:10.1080/07055900.2011.583910.
- Mesinger F, DiMego G, Kalnay E, Mitchell K, Shafran PC, Ebisuzaki W, Jović D, Woollen J, Rogers E, Berbery EH, Ek MB, Fan Y, Grumbine R, Higgins W, Li H, Lin Y, Manikin G, Parrish D & Shi W (2006). North American Regional Reanalysis. *Bulletin of the American Meteorological Society*, 87(3):343–360.
- Newlands N, Davidson A, Howard A & Hill H (2011). Validation and inter-comparison of three methodologies for interpolating daily precipitation and temperature across Canada. *Environmetrics*, 22(2):205–223. DOI:10.1002/env.1044.
- Olson B & Kleiber W (2017). Approximate bayesian computation methods for daily spatiotemporal precipitation occurrence simulation. *Water Resources Research*, 53(4):3352–3372. DOI:10.1002/2016WR019741.
- Panthou G, Vischel T, Lebel T, Blanchet J, Quantin G & Ali A (2012). Extreme rainfall in West Africa: A regional modeling. *Water Resources Research*, 48(8):1–19. DOI:10.1029/2012WR012052.
- Plummer DA, Caya D, Frigon A, Côté H, Giguère M, Paquin D, Biner S, Harvey R & de Elia R (2006). Climate and climate change over

- North America as simulated by the Canadian RCM. *Journal of Climate*, 19(13):3112–3132. DOI:10.1175/JCLI3769.1.
- Podgórski K & Wegener J (2012). Velocities of a spatial-temporal stochastic field with embedded dynamics. *Environmetrics*, 23(3):238–252. DOI:10.1002/env.2135.
- Rusticucci M, Zazulie N & Raga GB (2014). Regional winter climate of the southern central Andes: Assessing the performance of ERA-Interim for climate studies. *J. Geophys. Res. Atmos.*, 119(14): 8568–8582. DOI:10.1002/2013JD021167.
- Saha S, Moorthi S, Pan HL, Wu X, Wang J, Nadiga S, Tripp P, Kistler R, Woollen J, Behringer D, Liu H, Stokes D, Grumbine R, Gayno G, Hou YT, Chuang HY, Juang HMH, Sela J, Iredell M, Treadon R, Kleist D, Van Delst P, Keyser D, Derber J, Ek M, Meng J, Wei H, Yang R, Lord S, Van Den Dool H, Kumar A, Wang W, Long C, Chelliah M, Xue Y, Huang B, Schemm JK, Ebisuzaki W, Lin R, Xie P, Chen M, Zhou S, Higgins W, Zou CZ, Liu Q, Chen Y, Han Y, Cucurull L, Reynolds RW, Rutledge G & Goldberg M (2010). The NCEP Climate Forecast System Reanalysis. *Bulletin of the American Meteorological Society*, 91(8):1015–1057. DOI:10.1175/2010BAMS3001.1.
- Schlather M, Malinowski A, Oesting M, Boecker D, Strokorb K, Engelke S, Martini J, Ballani F, Moreva O, Auel J, Menck PJ, Gross S, Ober U, Christoph Berreth, Burmeister K, Manitz J, Ribiero P, Singleton R, Pfaff B & R Core Team (2017). *RandomFields: Simulation and Analysis of Random Fields*. R package version 3.1.50.
- Schmidli J, Frei C & Vidale PL (2006). Downscaling from GCM precipitation: a benchmark for dynamical and statistical downscaling methods. *International Journal of Climatology*, 26(5):679–689. DOI:10.1002/joc.1287.
- Serinaldi F & Kilsby CG (2014). Simulating daily rainfall fields over large areas for collective risk estimation. *J. Hydrol.*, 512:285–302. DOI:10.1016/j.jhydrol.2014.02.043.
- Stern RD & Coe R (1984). A Model Fitting Analysis of Daily Rainfall Data. *Journal of the Royal Statistical Society. Series A (General)*, 147(1):1–34. DOI:10.2307/2981736.
- Stone M (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *J. R. Stat. Soc. Ser. B*, 36(2):111–147.
- Sun Y, Solomon S, Dai A & Portmann RW (2006). How often does it rain? *Journal of Climate*, 19(6):916–934. DOI:10.1175/JCLI3672.1.
- Takeuchi K (1976). *Distribution of informational statistics and a criterion of model fitting*. *Suri-Kagaku (Mathematical Sciences)* 153 12-18.
- Tapiador F, Navarro A, Levizzani V, García-Ortega E, Huffman G, Kidd C, Kucera P, Kummerow C, Masunaga H, Petersen W, Roca

- R, Sánchez JL, Tao WK & Turk F (2017). Global precipitation measurements for validating climate models. *Atmos. Res.*, 197:1–20. DOI:10.1016/J.ATMOSRES.2017.06.021.
- Tustison B, Harris D & Foufoula-Georgiou E (2001). Scale issues in verification of precipitation forecasts. *J. Geophys. Res.*, 106(D11): 11775–11784. DOI:10.1029/2001JD900066.
- Van de Vyver H (2012). Spatial regression models for extreme precipitation in belgium. *Water Resources Research*, 48(9):n/a–n/a. DOI:10.1029/2011WR011707.
- Volosciuk C, Maraun D, Vrac M & Widmann M (2017). A combined statistical bias correction and stochastic downscaling method for precipitation. *Hydrology and Earth System Sciences*, 21(3):1693–1719. DOI:10.5194/hess-21-1693-2017.
- Wijngaard JB, Klein Tank AMG & Könen GP (2003). Homogeneity of 20th century European daily temperature and precipitation series. *International Journal of Climatology*, 23(6):679–692. DOI:10.1002/joc.906.
- Wong G, Maraun D, Vrac M, Widmann M, Eden JM & Kent T (2014). Stochastic model output statistics for bias correcting and downscaling precipitation including extremes. *Journal of Climate*, 27(18):6940–6959. DOI:10.1175/JCLI-D-13-00604.1.
- Yee TW (2016). *VGAM: Vector Generalized Linear and Additive Models*. R package version 1.0-3.
- Yee TW & Wild CJ (1996). Vector Generalized Additive Models. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(3):481–493. DOI:10.2307/2345888.
- Zamani S, Gobin A, Van de Vyver H & Gerlo J (2016). Atmospheric drought in belgium – statistical analysis of precipitation deficit. *International Journal of Climatology*, 36(8):3056–3071. DOI:10.1002/joc.4536.

CONCLUSIONS ET PERSPECTIVES

Sommaire

1	Principaux résultats	158
2	Perspectives	159
2.1	Perspectives méthodologiques	159
2.2	Perspectives applicatives	161

Comme pour beaucoup d'autres pays, le Canada, et particulièrement ses régions nordiques, dispose d'historiques de précipitations courts, voire inexistant, avec, en moyenne une station tous les 2000 km² (environ quatre fois la superficie de l'agglomération de Montréal). L'utilité de ces historiques n'est plus à prouver tant pour les projets de développement et l'analyse de leurs impacts sur l'environnement, que pour la gestion des ressources en eau. Les précipitations possèdent une forte variabilité spatio-temporelle et nécessitent par conséquent de disposer d'un réseau dense avec une haute fréquence d'archivage afin de capturer cette variabilité.

Des solutions alternatives aux données des stations pluviométriques sont maintenant disponibles. Les données satellitaires et de radars sont, certes, issues de l'observation (indirecte), mais doivent composer avec certaines limitations qui empêchent leur utilisation. Parmi ces limitations, on note :

- des historiques relativement courts ;
- une couverture spatiale insuffisante (surtout pour les radars) ;
- une calibration empirique des valeurs issues de ces équipements à partir des stations de mesure qui demeure toujours incertaine ;

— ou encore de faibles performances constatées aux endroits à la topologie marquée (Tableau 3 dans Tapiador *et al.*, 2017).

Les données sur grilles issues de l'interpolation statistique (p. ex., NRCan) constituent un autre exemple de données disponibles. Ces dernières couvrent le territoire canadien, mais ne s'appuient cependant que sur des observations aux sites et sur certains critères géographiques, rendant ainsi les estimations peu fiables pour les régions aux faibles densités de stations (Gervais *et al.*, 2014b). Enfin, les données issues de la modélisation météorologique sont également disponibles. Les réanalyses constituent une alternative intéressante, car elles sont caractérisées par l'assimilation à des pas de temps réguliers d'une très grande quantité d'observations sur une longue période. Le but des réanalyses vise en effet à reconstruire l'état passé de l'atmosphère avec une couverture spatiale continue. On comprend alors le potentiel des réanalyses et la motivation à utiliser ce type de données.

L'utilisation directe des précipitations issues de réanalyses pour des applications nécessitant des données locales demeure cependant discutable. La présence de biais et les erreurs de représentativité (*representativeness errors*; Hutchinson *et al.*, 2009) dues à la résolution horizontale finie des réanalyses, constituent les principales raisons empêchant une utilisation de ces séries brutes. Les travaux de recherche développés dans le cadre de cette thèse visent à corriger ces erreurs sur une réanalyse en particulier, CFSR, afin de proposer des séries de précipitations locales aux sites non instrumentés. Pour ce faire, les trois étapes suivantes ont été complétées :

1. Développer une approche stochastique de post-traitement basée sur des modèles de régression prenant la précipitation de CFSR comme prédicteur et les observations comme prédictand. L'occurrence et l'intensité des précipitations journalières ont été modélisées séparément pour tenir compte de la nature intermittente des précipitations. Le pouvoir prédictif des modèles de post-traitement est d'abord comparé à un système de prédiction de référence, ici la climatologie, pour l'occurrence et l'intensité sur la période d'étude (analyse climatique des distributions statistiques). Ensuite, les séries aux sites sont générées aléatoirement à partir des modèles et évaluées en fonction de divers indices climatiques.
2. Améliorer l'approche ponctuelle développée à l'étape précédente afin de tenir compte de la persistance et de la cohérence spatiale des précipitations à l'échelle journalière. Les champs métgaussiens latents sont alors conjointement appliqués aux modèles de régression de l'étape 1 pour répondre à cette problématique. Les précipitations sont générées aléatoirement aux sites d'obser-

vation sur la région des Grands Lacs et sont analysées par le biais de divers indices climatiques dans le cadre du CASE (Bennett *et al.*, 2018).

3. Estimer les séries de précipitations locales aux sites non observés. Deux méthodes de modélisation spatiale de complexité différente sont développées et mises en œuvre. La première méthode consiste à interpoler, par des approches de type krigage, les paramètres ponctuels des modèles de post-traitement identifiés aux étapes 1 et 2. La seconde approche vise à appliquer deux modèles spatiaux de régression, l'un pour l'occurrence et l'autre pour l'intensité. Cette approche possède l'avantage de ne considérer qu'un seul modèle pour l'ensemble du domaine, avec des variations locales (des distributions de précipitations) incluses par une covariable spatiale en plus de la réanalyse CFSR. Pour les deux approches méthodologiques, les séries aléatoires seront générées et comparées à la réanalyse CFSR sans post-traitement selon une méthode de validation croisée.

La présente thèse apporte plusieurs contributions originales. D'un point de vue méthodologique, l'application de ces approches est généralement réservée à la descente d'échelle spatiale des sorties de modèles climatiques (Volosciuk *et al.*, 2017; Wong *et al.*, 2014). La génération des précipitations sur la période historique constitue un autre domaine qui présente des objectifs similaires à ceux de ces travaux de recherche. Dans ce dernier cas, les prédicteurs peuvent être, certes, issus de la réanalyse, mais doivent être exogènes à la variable précipitation. Les résultats obtenus sont intéressants (Asong *et al.*, 2016a), mais nécessitent un travail important en amont sur la sélection des covariables et peuvent conduire à des modèles complexes comportant un nombre conséquent de paramètres, contrairement aux modèles parcimonieux proposés dans le cadre de la présente thèse. L'utilisation de la précipitation issue de réanalyses comme prédicteur de la précipitation locale n'a pas, à notre connaissance, été encore étudiée dans la littérature. La possibilité de générer des champs de précipitations aux caractéristiques locales en incluant l'information donnée par une réanalyse constitue un autre point novateur de ces travaux de recherche. Enfin, le domaine étudié représente un défi applicatif tant par le manque de données que par les différences climatiques fortement marquées entre les régions.

Les principaux résultats des trois différentes étapes sont résumés à la prochaine section. Les pistes d'améliorations sont détaillées à la Section 2 de ce chapitre.

1 Principaux résultats

Les résultats obtenus, en accord avec les travaux de Wong *et al.* (2014) et de Eden *et al.* (2014), montrent que les modèles de régression permettent d'obtenir de meilleures prédictions probabilistes (*i.e.* probabilité qu'il pleuve une certaine quantité de précipitations à l'échelle locale) que la climatologie observée. Les modèles ont également montré de grandes aptitudes à représenter les distributions marginales (occurrence et intensité) pour un très grand nombre de sites.

L'analyse des indices climatiques annuels obtenus à partir des séries générées aléatoirement a montré de meilleures performances que la réanalyse CFSR, en termes de biais moyen et de variabilité interannuelle sur la période d'étude. Il est important de relever ici l'intérêt d'analyser ces indices, ces derniers n'étant pas explicitement modélisés par l'approche de post-traitement (contrairement, par exemple, à l'intensité moyenne sur la période durant les jours avec pluie). Ils permettent ainsi d'évaluer la robustesse de l'approche de post-traitement à représenter divers aspects du processus de précipitation. L'intégration des champs spatio-temporels méta-gaussien latents a conduit à une meilleure estimation des indices caractérisant la durée des événements de précipitation et la structure spatiale des précipitations journalières. L'analyse des séries annuelles des indices, réalisée lors de la deuxième étape de ce travail de thèse, a mis en lumière la valeur ajoutée du post-traitement stochastique pour la majorité des indices. Les séries présentaient en effet de meilleures estimations que celles obtenues à partir de la réanalyse et, dans une moindre mesure, pour les indices caractérisant les extrêmes. À l'échelle saisonnière, l'été et l'hiver ont été moins bien reproduits dans les séries post-traitées comparativement aux autres saisons. La nature convective des événements de précipitations (durée courte et forte intensité), qui domine durant l'été, pourrait expliquer en partie ces moins bonnes performances pendant la saison estivale. La modélisation numérique ne permet pas la résolution explicite de la convection à l'échelle spatiale simulée par CFSR. En hiver, par contre, les événements sont stratiformes et plus aisément simulés par les modèles numériques. Cependant, la présence des Grands Lacs (*snow-lake effect*) possède un impact particulier sur la répartition des précipitations et peut représenter un défi de taille pour la modélisation, ce qui pourrait expliquer la moins bonne performance constatée pour cette saison. Les résultats demeurent tout de même généralement très encourageants. En effet, le post-traitement n'affecte pas les performances aux points de grilles de CFSR possédant initialement de bonnes concordances avec les observations tout en permettant des améliorations très significatives aux autres sites.

Les modèles spatiaux mis en œuvre ont permis d'expérimenter une approche originale pour proposer des séries de précipitations journalières locales. La performance, en validation croisée, des modèles spatiaux se basant sur les approches d'interpolation est légèrement supérieure à la seconde approche. Malgré la différence du nombre de paramètres définissant les deux modèles spatiaux (beaucoup plus important dans les modèles d'interpolation), les résultats obtenus par ces deux approches montrent des différences très faibles lorsqu'on s'intéresse à la climatologie des précipitations journalières et un peu plus marquées sur les indices climatiques. Il est intéressant de noter que, dans les deux cas, les modèles spatiaux ont permis de générer des séries de précipitations, en validation, plus proches des observations que celles obtenues par la réanalyse CFSR.

2 Perspectives

Les perspectives de ce projet de doctorat sont de deux ordres. Premièrement, des améliorations peuvent être apportées à la méthodologie de façon à proposer de meilleures estimations des précipitations journalières locales. Deuxièmement, les modèles présentés dans cette thèse pourraient être utilisés dans un contexte applicatif différent.

2.1 Perspectives méthodologiques

Les modèles stochastiques construits à partir des GLM et des VGLM ont permis de dériver les distributions de probabilité de la précipitation journalière conditionnellement à la précipitation journalière issue de CFSR. Dans le cadre de la présente thèse, les paramètres de ces modèles sont estimés de façon indépendante d'un site à l'autre. L'inférence de ces paramètres pourrait être améliorée en intégrant les sites voisins dans le cadre d'une approche multi-sites. Les travaux initiés par Chandler & Wheater (2002) et récemment appliqués à certaines provinces canadiennes par Asong *et al.* (2016a), pourraient constituer une source d'inspiration dans ce contexte. Une idée serait d'utiliser comme covariable supplémentaire, pour une station donnée avec sa tuile associée, une pondération des précipitations journalières aux tuiles voisines donnant plus de poids à la tuile la plus proche du site étudié (Ambrosino *et al.*, 2014). La définition des limites du voisinage à considérer, et donc la définition de régions homogènes selon certaines caractéristiques des précipitations, serait une étape préliminaire cruciale pour l'approche multi-sites (Asong *et al.*, 2015). Il est important de rappeler que les délimitations régionales, employées dans

cette thèse, sont fondées sur des considérations climatiques générales (Plummer *et al.*, 2006) et pourraient être affinées afin d'être plus représentatives des régimes de précipitation. L'objectif viserait l'amélioration de l'estimation des paramètres locaux, surtout ceux caractérisant l'intensité des précipitations, assurant ainsi une meilleure robustesse dans la modélisation spatiale de ces derniers.

Les VGLM appliqués pour modéliser l'intensité considèrent une loi Gamma à deux paramètres (position et forme). La flexibilité des VGLM (paramètre de forme variant linéairement selon la précipitation CFSR) a conduit à des séquences avec une variabilité intéressante à diverses échelles temporelles et à une meilleure représentation de certains quantiles relativement élevés, contrairement à d'autres études se basant sur un paramètre de forme constant (Asong *et al.*, 2016a; Chandler & Wheater, 2002). Une meilleure représentation des extrêmes de précipitation est possible par l'inclusion d'autres distributions à queues plus lourdes, telles la loi mixte exponentielle (trois paramètres), la loi de Pareto généralisée (seuil à 0 mm, Serinaldi & Kilsby, 2014), la loi mixte Gamma-Pareto (Vrac & Naveau, 2007; Wong *et al.*, 2014), ou encore la loi EGPD (Naveau *et al.*, 2016). Ces améliorations pourraient être profitables pour certaines régions comme les Plaines canadiennes qui sont caractérisées par des événements peu fréquents, mais intenses durant la période estivale. Une première analyse avec la loi de Pareto généralisée serait ici pertinente. Les modèles développés par Vrac & Naveau (2007) pour la loi mixte Gamma-Pareto sont certes plus élégants, mais sont plus difficiles (optimisation numérique et temps de calcul) à mettre en place, comme le montre le nombre restreint de sites déployés dans les études appliquant ces modèles (Vrac & Naveau, 2007; Wong *et al.*, 2014)

Par ailleurs, l'ensemble des travaux de cette thèse a été réalisé en ne considérant qu'une seule variable météorologique, la précipitation. Or, la cohérence spatiale, temporelle et entre différentes variables physiques, revêt une grande importance pour plusieurs applications. La gestion du gel des routes (conditions de températures et précipitations particulières, Berrocal *et al.*, 2010) ou encore la gestion des énergies renouvelables (Schefzik, 2016) constituent des exemples où le cadre multivarié est pertinent. Les séries générées dans cette thèse ne tiennent pas compte de cette cohérence entre les variables physiques, le cadre multivarié apporterait certaines pistes d'améliorations à cet égard. Tout récemment, des approches utilisant des outils statistiques tels que le *quantile mapping* (Cannon, 2017) ou les copules (Bevacqua *et al.*, 2017; Schefzik, 2017) ont montré des exemples d'utilisation du cadre multivarié et seraient des pistes à explorer.

Enfin, un autre point d'amélioration méthodologique consisterait à intégrer une approche bayésienne pour l'estimation spatiale des paramètres de la distribution mixte des précipitations journalières. Les paramètres seraient toujours fonction de la précipitation CFSR, mais intégreraient en plus la structure spatiale (une fonction de covariance) de ces derniers. L'objectif vise à générer en deux modèles (occurrence et intensité) des champs spatiaux des paramètres de la distribution mixte, et, par la même, à définir les précipitations sur tout le domaine. Les modèles VGAM, appliqués au Chapitre 6, reposent sur une philosophie similaire dans le sens où un seul modèle est développé pour l'occurrence et l'intensité pour générer ces champs de paramètres. La variation spatiale des paramètres, fonction d'une variable géographique et de la réanalyse CFSR, gagnerait à être représentée de façon explicite par l'approche bayésienne. En plus de présenter une démarche novatrice dans ce domaine, car très peu d'études se sont penchées sur ce sujet (Olson & Kleiber, 2017), l'approche bayésienne pourrait amener une valeur ajoutée.

2.2 Perspectives applicatives

Des travaux visant à comparer soit divers modèles de descente d'échelle, soit différents jeux de données, seraient pertinents et intéressants. Une comparaison de l'approche utilisée dans cette thèse à d'autres outils statistiques de descente d'échelle (Vaittinada Ayar *et al.*, 2015) pourrait d'abord être réalisée. Un portrait des performances des diverses méthodes existantes à représenter les caractéristiques des précipitations pourrait ainsi être dressé. Une seconde étude comparative servirait à analyser les réanalyses. L'idée serait ici d'appliquer les mêmes modèles que ceux exposés dans les Chapitres 4 à 6, à d'autres réanalyses. L'objectif serait d'identifier la réanalyse qui permet de mieux représenter les précipitations au Canada, en appliquant éventuellement des réanalyses différentes selon les régions. Plusieurs usagers des réanalyses pourraient alors disposer d'un outil pour effectuer un choix éclairé quant à la réanalyse à privilégier selon les régions. Une dernière analyse consisterait à comparer les modèles de descente d'échelle de la précipitation d'une réanalyse (sujet de cette thèse) aux modèles stochastiques de génération des précipitations utilisant des variables exogènes (i.e. différente de la précipitation) de la même réanalyse. En effet, la littérature suggère (Chapitre 3, Section 4) que les covariables de grandes échelles (p. ex., pression au niveau de la mer) constituent de bons prédicteurs de la précipitation locale dans les modèles stochastiques, car elles sont bien simulées par les réanalyses. Or, aucune étude, à notre connaissance, n'a montré la supériorité ou l'équivalence des modèles utilisant plusieurs covariables spatiales exogènes versus une seule covariable: la précipitation de la réanalyse. En plus de clarifier ce

point, ce travail permettrait, dans l'éventualité où il n'existerait pas de valeur ajoutée à utiliser plusieurs covariables exogènes, d'identifier les modèles les plus parcimonieux.

L'évolution des précipitations sous un climat changeant constitue également un domaine qui pourrait profiter des modèles développés dans cette thèse. Les projections effectuées à partir des modèles climatiques globaux et régionaux sont des outils indispensables pour identifier les mesures d'adaptation les plus adéquates. Or, souvent, une information locale est nécessaire. Les modèles climatiques, en raison de leur résolution spatiale et des processus simulés, ne permettent toujours pas de travailler directement sur cette échelle. Les approches de post-traitement développées ici pourraient être calibrées sur des simulations de précipitations sur une période de référence, pour être ensuite déployées sur une période future. Les simulations sur la période de référence devront cependant être pilotées par des réanalyses (Eden *et al.*, 2014; Volosciuk *et al.*, 2017; Wong *et al.*, 2014) pour assurer une correspondance temporelle entre les observations et les simulations et ainsi pouvoir appliquer les outils de régression. Dans ce cadre, on prend comme hypothèse que les coefficients définissant les paramètres des distributions des précipitations seront les mêmes pour les deux périodes de temps. La flexibilité de l'approche apporterait tout de même des résultats intéressants, car ces paramètres sont des fonctions linéaires des précipitations des modèles climatiques. La linéarité de ce lien est discutable et mériterait plus de recherche pour évaluer la dépendance entre prédicteurs et prédictand et éventuellement opter pour un cadre plus flexible (VGAM). L'issue de ce travail permettrait d'obtenir les distributions des précipitations « futures » avec lesquelles il serait possible de générer des séquences avec des valeurs potentiellement non observées dans le passé, contrairement à d'autres approches (p. ex., méthode des analogues).

Toutes ces perspectives montrent à quel point le domaine étudié dans cette thèse est porteur et mettent en évidence un petit aperçu des possibilités d'amélioration des connaissances des précipitations historiques.

Bibliographie

- Ailliot P, Allard D, Monbet V & Naveau P (2015). Stochastic weather generators: an overview of weather type models. *J. la Société Française Stat.*, 156(1):101–113.
- Akaike H (1974). A new look at the statistical model identification. *IEEE Trans. Autom. Control*, 19:716–723.
- Alexandersson H (1986). A homogeneity test applied to precipitation data. *J. Climatol.*, 6(6):661–675. DOI:10.1002/joc.3370060607.
- Allard M & Lemay M (2012). Nunavik and Nunatsiavut: From Science to Policy, An Integrated Regional Impact Study (IRIS) of Climate Change and Modernization. ArcticNet Inc. Québec, 303 pages.
- Allcroft DJ & Glasbey CA (2003). A latent Gaussian Markov random-field model for spatiotemporal rainfall disaggregation. *J. R. Stat. Soc. Ser. C (Applied Stat.)*, 52(4):487–498. DOI:10.1111/1467-9876.00419.
- Ambrosino C, Chandler RE & Todd MC (2014). Rainfall-derived growing season characteristics for agricultural impact assessments in South Africa. *Theor. Appl. Climatol.*, 115(3-4):411–426. DOI:10.1007/s00704-013-0896-y.
- Asong ZE, Khaliq MN, & Wheater HS (2016a). Multisite multivariate modeling of daily precipitation and temperature in the Canadian Prairie Provinces using generalized linear models. *Climate Dynamics*, pages 1–21. DOI:10.1007/s00382-016-3004-z.
- Asong ZE, Khaliq MN & Wheater HS (2015). Regionalization of precipitation characteristics in the Canadian Prairie Provinces using large-scale atmospheric covariates and geophysical attributes. *Stochastic Environmental Research and Risk Assessment*, 29(3):875–89. DOI:10.1007/s00477-014-0918-z.
- Asong ZE, Khaliq MN & Wheater HS (2016b). Projected changes in precipitation and temperature over the Canadian Prairie Provinces using the Generalized Linear Model statistical downscaling approach . *Journal of Hydrology*, pages 429 – 446. DOI:10.1016/j.jhydrol.2016.05.044.
- Bárdossy A & Pegram G (2009). Copula-based geostatistical models for groundwater quality parameters. *Hydrol. Earth Syst. Sci.*, 13(12):2299–2314. DOI:10.1029/2005WR004754.
- Bardossy A & Plate EJ (1992). Space-time model for daily rainfall using atmospheric circulation patterns. *Water Resour. Res.*, 28(5):1247–1259. DOI:10.1029/91WR02589.

Bathurst J & Bovolo C (2004). *Development of Guidelines for Sustainable Land Management in the Agri and Cobres Target Basins, Deliverable 28 of the EU funded MEDACTION project, 37 pp.*

Baxevani A & Lennartsson J (2015). A spatiotemporal precipitation generator based on a censored latent Gaussian field. *Water Resources Research*, 51(6):4338–4358. DOI:10.1002/2014WR016455.

Beaulieu C (2009). *Homogénéisation des séries de précipitations : identification des techniques les plus prometteuses et nouveaux développements*. Thèse de doctorat, INRS-ETE.

Beaulieu C, Ouarda TBMJ & Seidou O (2007). Synthèse des techniques d'homogénéisation des séries climatiques et analyse d'applicabilité aux séries de précipitations. *Hydrol. Sci. J.*, 52(1):18–37. DOI:10.1623/hysj.52.1.18.

Beaulieu C, Seidou O, Ouarda TBMJ, Zhang X, Boulet G & Yagouti A (2008). Intercomparison of homogenization techniques for precipitation data. *Water Resources Research*, 44(2):n/a–n/a. DOI:10.1029/2006WR005615. W02425.

Beck HE, van Dijk AIJM, Levizzani V, Schellekens J, Miralles DG, Martens B & de Roo A (2017). Mswepl: 3-hourly 0.25 deg global gridded precipitation (1979–2015) by merging gauge, satellite, and reanalysis data. *Hydrology and Earth System Sciences*, 21(1):589–615. DOI:10.5194/hess-21-589-2017.

Bengtsson L & Shukla J (1988). Integration of Space and In Situ Observations to Study Global Climate Change. *Bulletin of the American Meteorological Society*, 69:1130–1143. DOI:10.1175/1520-0477(1988)069<1130:IOSAIS>2.0.CO;2.

Bennett B, Thyer M, Leonard M, Lambert M & Bates B (2018). A comprehensive and systematic evaluation framework for a parsimonious daily rainfall field model. *Journal of Hydrology*. DOI:10.1016/j.jhydrol.2016.12.043.

Bentzien S & Friederichs P (2014). Decomposition and graphical portrayal of the quantile score. *Quarterly Journal of the Royal Meteorological Society*, 140(683):1924–1934. DOI:10.1002/qj.2284.

Berrocal VJ, Raftery AE, Gneiting T & Steed RC (2010). Probabilistic weather forecasting for winter road maintenance. *Journal of the American Statistical Association*, 105(490):522–537. DOI:10.1198/jasa.2009.ap07184.

Betts AK, Zhao M, Dirmeyer PA & Beljaars ACM (2006). Comparison of ERA40 and NCEP/DOE near-surface data sets with other ISLSCP-II data sets. *J. Geophys. Res.*, 111(D22):D22S04. DOI:10.1029/2006JD007174.

- Bevacqua E, Maraun D, Hobæk Haff I, Widmann M & Vrac M (2017). Multivariate statistical modelling of compound events via pair-copula constructions: analysis of floods in ravenna (italy). *Hydrology and Earth System Sciences*, 21(6):2701–2723. DOI:10.5194/hess-21-2701-2017.
- Blanchet J, Ceresetti D, Molinié G & Creutin JD (2016). A regional GEV scale-invariant framework for Intensity–Duration–Frequency analysis. *J. Hydrol.*, 540:82–95. DOI:10.1016/j.jhydrol.2016.06.007.
- Blanchet J & Lehning M (2010). Mapping snow depth return levels: smooth spatial modeling versus station interpolation. *Hydrology and Earth System Sciences*, 14(12):2527.
- Boé J, Terray L, Habets F & Martin E (2006). A simple statistical-dynamical downscaling scheme based on weather types and conditional resampling. *J. Geophys. Res. Atmos.*, 111(D23):n/a–n/a. DOI:10.1029/2005JD006889.
- Bosilovich MG, Chen J, Robertson FR & Adler RF (2008). Evaluation of Global Precipitation in Reanalyses. *J. Appl. Meteorol. Climatol.*, 47(9):2279–2299. DOI:10.1175/2008JAMC1921.1.
- Bromwich DH, Nicolas JP & Monaghan AJ (2011). An Assessment of Precipitation Changes over Antarctica and the Southern Ocean since 1989 in Contemporary Global Reanalyses *. *Journal of Climate*, 24(16):4189–4209. DOI:10.1175/2011JCLI4074.1.
- Buishand T (1982). Some methods for testing the homogeneity of rainfall records. *J. Hydrol.*, 58(1-2):11–27. DOI:10.1016/0022-1694(82)90066-X.
- Buishand TA & Brandsma T (2001). Multisite simulation of daily precipitation and temperature in the Rhine Basin by nearest-neighbor resampling. *Water Resour. Res.*, 37(11):2761–2776. DOI:10.1029/2001WR000291.
- Buishand TA, Shabalova MV & Brandsma T (2004). On the Choice of the Temporal Aggregation Level for Statistical Downscaling of Precipitation. *Journal of Climate*, 17(9):1816–1827. DOI:10.1175/1520-0442(2004)017<1816:OTCOTT>2.0.CO;2.
- Burton A, Kilsby C, Fowler H, Cowpertwait P & O'Connell P (2008). Rainsim: A spatial–temporal stochastic rainfall modelling system. *Environmental Modelling & Software*, 23(12):1356 – 1369. DOI:<http://dx.doi.org/10.1016/j.envsoft.2008.04.003>.
- Canadian Standards Association (2012). Technical guide. Development, interpretation, and use of rainfall intensity-duration-frequency (IDF) information: Guideline for Canadian water resources practitioners. 214 pages.

Cannon AJ (2017). Multivariate quantile mapping bias correction: an N-dimensional probability density function transform for climate model simulations of multiple variables. *Clim. Dyn.*, pages 1–19. DOI:10.1007/s00382-017-3580-6.

Chandler R (2002). GLIMCLIM: generalized linear modelling for daily climate time series (software and user guide). Department of Statistical Science, University College London.

Chandler RE & Wheater HS (2002). Analysis of rainfall variability using generalized linear models: A case study from the west of Ireland. *Water Resources Research*, 38(10):10–1–10–11. DOI:10.1029/2001WR000906. 1192.

Chardon J (2014). *Interests of the analog method for the generation of precipitation scenarios for the French territory : Spatial consistency and adaptability of the scale relation*. Theses, Université de Grenoble.

Chen CT & Knutson T (2008). On the Verification and Comparison of Extreme Rainfall Indices from Climate Models. *J. Clim.*, 21(7):1605–1621. DOI:10.1175/2007JCLI1494.1.

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.

Coe R & Stern R (1982). Fitting Models to Daily RainfallData. *Journal of Applied Meteorology*, 21(7):1024–1031. DOI:10.1175/1520-0450(1982)021<1024:FMTDRD>2.0.CO;2.

Conover W (1999). *Practical Nonparametric Statistics*. John Wiley & Sons, New York, third edition, 592 pages.

Contractor S, Alexander LV, Donat MG & Herold N (2015). How Well Do Gridded Data-sets of Observed Daily Precipitation Compare over Australia? *Advances in Meteorology*, 2015. DOI:10.1155/2015/325718.

Cressie N & Wikle C (2011). *Statistics for Spatio-Temporal Data*. Wiley.

Cressie NAC (1993). *Statistics for Spatial Data*. John Wiley & Sons, Inc., pages 1–26.

Dai A (2006). Precipitation Characteristics in Eighteen Coupled Climate Models. *Journal of Climate*, 19(18):4605–4630. DOI:10.1175/JCLI3884.1.

- Daly C (2006). Guidelines for assessing the suitability of spatial climate data sets. *Int. J. Climatol.*, 26(6):707–721. DOI:10.1002/joc.1322.
- Devine KA & Mekis E (2008). Field accuracy of Canadian rain measurements. *Atmosphere-Ocean*, 46(2):213–227. DOI:10.3137/ao.460202.
- Dobson A (2010). *An Introduction to Generalized Linear Models, Second Edition*. Chapman & Hall/CRC Texts in Statistical Science. Taylor & Francis.
- Donat MG, Sillmann J, Wild S, Alexander LV, Lippmann T & Zwier FW (2014). Consistency of Temperature and Precipitation Extremes across Various Global Gridded In Situ and Reanalysis Datasets. *Journal of Climate*, 27:5019–5035. DOI:10.1175/JCLI-D-13-00405.1.
- Eden JM, Widmann M, Maraun D & Vrac M (2014). Comparison of GCM- and RCM-simulated precipitation following stochastic postprocessing. *Journal of Geophysical Research: Atmospheres*, 119(19):11,040–11,053. DOI:10.1002/2014JD021732.
- Emery X & Arnaud M (2000). *Estimation et interpolation spatiales*. Hermès.
- Environment and Climate Change Canada (2013). *Adjusted Precipitation and Homogenized Canadian Climate Data (AHCCD)*. <http://ec.gc.ca/dccha-ahccd/default.asp?lang=En&n=9AA530BE-1>. 2014-10-27.
- Eum HI, Dibike Y, Prowse T & Bonsal B (2014). Inter-comparison of high-resolution gridded climate data sets and their implication on hydrological model simulation over the Athabasca Watershed, Canada. *Hydrol. Process.*, 28(14):4250–4271. DOI:10.1002/hyp.10236.
- Fowler H, Blenkinsop S & Tebaldi C (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12):1547–1578. DOI:10.1002/joc.1556.
- Fowler H, Ekström M, Kilsby C & Jones P (2005). New estimates of future changes in extreme rainfall across the UK using regional climate model integrations. 1. Assessment of control climate. *J. Hydrol.*, 300(1-4):212–233. DOI:10.1016/j.jhydrol.2004.06.017.
- Frei C, Schöll R, Fukutome S, Schmidli J & Vidale PL (2006). Future change of precipitation extremes in Europe: Intercomparison of scenarios from regional climate models. *J. Geophys. Res.*, 111(D6):D06105. DOI:10.1029/2005JD005965.

Friederichs P & Thorarinsdottir TL (2012). Forecast verification for extreme value distributions with an application to probabilistic peak wind prediction. *Environmetrics*, 23(7):579–594. DOI:10.1002/env.2176.

Gervais M, Gyakum J, Atallah E, Tremblay LB & Neale RB (2014a). How Well Are the Distribution and Extreme Values of Daily Precipitation over North America Represented in the Community Climate System Model? A Comparison to Reanalysis, Satellite, and Gridded Station Data. *Journal of Climate*, 27(14):5219–5239. DOI:10.1175/JCLI-D-13-00320.1.

Gervais M, Tremblay LB, Gyakum JR & Atallah E (2014b). Representing Extremes in a Daily Gridded Precipitation Analysis over the United States: Impacts of Station Density, Resolution, and Gridding Methods. *J. Clim.*, 27(14):5201–5218. DOI:10.1175/JCLI-D-13-00319.1.

Giorgi F, Jones C & Asrar GR (2009). Addressing climate information needs at the regional level: the CORDEX framework. *Bull. - World Meteorol. Organ.*, 58(3):175–183.

Giorgi F & Marinucci MR (1996). A Investigation of the Sensitivity of Simulated Precipitation to Model Resolution and Its Implications for Climate Studies. *Mon. Weather Rev.*, 124(1):148–166. DOI:10.1175/1520-0493(1996)124<0148:AIOTSO>2.0.CO;2.

Guillot G (1999). Approximation of Sahelian rainfall fields with meta-Gaussian random functions. *Stoch. Environ. Res. Risk Assess.*, 13(1-2):100–112. DOI:10.1007/s004770050034.

Haberlandt U, Hundecha Y, Pahlow M & Schumann AH (2011). Rainfall Generators for Application in Flood Studies. *Flood Risk Assess. Manag. How to Specify Hydrol. Loads, Their Consequences Uncertainties*. Schumann AH, éditeur, Springer Netherlands, pages 117–147.

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.

Hall A (2014). Predicting climate change. Vital details of global warming are eluding forecasters. *Science* (80-.), 346(6212):1461–1462. DOI:10.1126/science.334.6053.173.

Hastie T & Tibshirani R (1990). *Generalized Additive Models*. Chapman and Hall/CRC, 352 pages.

Hersbach H (2000). Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. *Weather and Forecasting*, 15(5):559–570. DOI:10.1175/1520-0434(2000)015<0559:DOTCRP>2.0.CO;2.

- Hewitson B & Crane R (1996). Climate downscaling: techniques and application. *Clim. Res.*, 7(2):85–95. DOI:10.3354/cr007085.
- Hewitt CD (2004). Ensembles-based predictions of climate changes and their impacts. *Eos, Trans. Am. Geophys. Union*, 85(52):566–566. DOI:10.1029/2004EO520005.
- Higgins RW, Kousky VE, Silva VBS, Becker E & Xie P (2010). Intercomparison of Daily Precipitation Statistics over the United States in Observations and in NCEP Reanalysis Products. *Journal of Climate*, 23(17):4637–4650. DOI:10.1175/2010JCLI3638.1.
- Hipel K & McLeod A (1994). *Time Series Modelling of Water Resources and Environmental Systems*. Developments in Water Science. Elsevier Science.
- 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.
- Hopkinson RF, Mckenney DW, Milewska EJ, Hutchinson MF, Papadopol P & Vincent LA (2011). Impact of aligning climatological day on gridding daily maximum-minimum temperature and precipitation over Canada. *Journal of Applied Meteorology and Climatology*, 50(8):1654–1665. DOI:10.1175/2011JAMC2684.1.
- Huffman GJ, Bolvin DT, Nelkin EJ, Wolff DB, Adler RF, Gu G, Hong Y, Bowman KP & Stocker EF (2007). The trmm multisatellite precipitation analysis (tmpa): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1):38–55. DOI:10.1175/JHM560.1.
- Hutchinson MF, McKenney DW, Lawrence K, Pedlar JH, Hopkinson RF, Milewska E & Papadopol P (2009). Development and Testing of Canada-Wide Interpolated Spatial Models of Daily Minimum–Maximum Temperature and Precipitation for 1961–2003. *J. Appl. Meteorol. Climatol.*, 48(4):725–741. DOI:10.1175/2008JAMC1979.1.
- Janowiak J, Gruber A, Kondragunta C, Livezey R & Huffman, G J (1998). A Comparison of the NCEP – NCAR Reanalysis Precipitation and the GPCP Rain Gauge – Satellite Combined Dataset with Observational Error Considerations. *J. Clim.*, 11(11):2960–2979.

Jha SK, Mariethoz G, Evans J, McCabe MF & Sharma A (2015). A space and time scale-dependent nonlinear geostatistical approach for downscaling daily precipitation and temperature. *Water Resources Research*, 51(8):6244–6261. DOI:10.1002/2014WR016729.

Kalnay E, Kanamitsu M, Kistler R, Collins W, Deaven D, Gandin L, Iredell M, Saha S, White G, Woollen J, Zhu Y, Leetmaa A, Reynolds R, Chelliah M, Ebisuzaki W, Higgins W, Janowiak J, Mo KC, Ropelewski C, Wang J, Jenne R & Joseph D (1996). The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77(3):437–471. DOI:10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2.

Katz RW (1977). Precipitation as a Chain-Dependent Process. *Journal of Applied Meteorology*, 16(7): 671–676. DOI:10.1175/1520-0450(1977)016<0671:PAACDP>2.0.CO;2.

Kelly KS & Krzysztofowicz R (1997). A bivariate meta-Gaussian density for use in hydrology. *Stoch. Hydrol. Hydraul.*, 11(1):17–31. DOI:10.1007/BF02428423.

Kendall MG (1962). *Rank correlation methods*. London : Charles Griffin & Co. Ltd, 3rd ed edition, 160 pages. Previous ed.(B55-8618) 1955.

Kleiber W, Katz RW & Rajagopalan B (2012). Daily spatiotemporal precipitation simulation using latent and transformed Gaussian processes. *Water Resour. Res.*, 48(1):W01523. DOI:10.1029/2011WR011105.

Klein WH, Lewis BM & Enger I (1959). Objective prediction of five-day mean temperatures during winter. *Journal of Meteorology*, 16(6):672–682. DOI:10.1175/1520-0469(1959)016<0672:OPOFDM>2.0.CO;2.

Krige DG (1951). A statistical approach to some basic mine valuation problems on the witwatersrand. *Journal of the Southern African Institute of Mining and Metallurgy*, 52(6):119–139.

Langousis A & Kaleris V (2014). Statistical framework to simulate daily rainfall series conditional on upper-air predictor variables. *Water Resour. Res.*, 50(5):3907–3932. DOI:10.1002/2013WR014936.

Langousis A, Mamalakis A, Deidda R & Marrocu M (2016). Assessing the relative effectiveness of statistical downscaling and distribution mapping in reproducing rainfall statistics based on climate model results. *Water Resour. Res.*, 52(1):471–494. DOI:10.1002/2015WR017556.

- Laprise R, de Elía R, Caya D, Biner S, Lucas-Picher P, Diaconescu E, Leduc M, Alexandru A, Separovic L, & Diagnostics CNfRCM (2008). Challenging some tenets of Regional Climate Modelling. *Meteorol. Atmos. Phys.*, 100(1-4):3–22. DOI:10.1007/s00703-008-0292-9.
- Leander R & Buishand TA (2007). Resampling of regional climate model output for the simulation of extreme river flows. *J. Hydrol.*, 332(3):487–496. DOI:10.1016/j.jhydrol.2006.08.006.
- Leblois E & Creutin JD (2013). Space-time simulation of intermittent rainfall with prescribed advection field: Adaptation of the turning band method. *Water Resources Research*, 49(6):3375–3387. DOI:10.1002/wrcr.20190.
- Lee Y & Nelder JA (1998). Generalized linear models for the analysis of quality-improvement experiments. *Canadian Journal of Statistics*, 26(1):95–105. DOI:10.2307/3315676.
- Lin A & Wang XL (2011). An algorithm for blending multiple satellite precipitation estimates with in situ precipitation measurements in canada. *Journal of Geophysical Research: Atmospheres*, 116(D21):n/a–n/a. DOI:10.1029/2011JD016359. D21111.
- Lindstedt D, Lind P, Kjellstrom E & Jones C (2015). A new regional climate model operating at the meso-gamma scale: Performance over Europe. *Tellus A Dyn. Meteorol. Oceanogr.*, 67(1). DOI:10.3402/tellusa.v67.24138.
- Lombardo F, Volpi E, Koutsoyiannis D & Serinaldi F (2017). A theoretically consistent stochastic cascade for temporal disaggregation of intermittent rainfall. *Water Resources Research*, pages n/a–n/a. DOI:10.1002/2017WR020529.
- Lorente-Plazas R & Hacker JP (2017). Observation and Model Bias Estimation in the Presence of Either or Both Sources of Error. *Mon. Weather Rev.*, 145(7):2683–2696. DOI:10.1175/MWR-D-16-0273.1.
- Lorenz EN (1969). Atmospheric Predictability as Revealed by Naturally Occurring Analogues. *J. Atmos. Sci.*, 26(4):636–646. DOI:10.1175/1520-0469(1969)26<636:APARBN>2.0.CO;2.
- Lubes-Niel H, Masson J, Paturel J & Servat E (1998). Variabilité climatique et statistiques. Etude par simulation de la puissance et de la robustesse de quelques tests utilisés pour vérifier l'homogénéité de chroniques. *Rev. des Sci. l'eau*, 11(3):383–408.
- Lucas-Picher P, Laprise R & Winger K (2017). Evidence of added value in North American regional climate model hindcast simulations using ever-increasing horizontal resolutions. *Clim. Dyn.*, 48(7-8):2611–2633. DOI:10.1007/s00382-016-3227-z.

- MacKay D (2003). *Information Theory, Inference and Learning Algorithms*. Cambridge University Press.
- Mailhot A, Beauregard I, Talbot G, Caya D & Biner S (2011). Future changes in intense precipitation over Canada assessed from multi-model NARCCAP ensemble simulations. *Int. J. Climatol.*, 1163(May 2011):n/a–n/a. DOI:10.1002/joc.2343.
- Maraun D (2013). Bias Correction, Quantile Mapping, and Downscaling: Revisiting the Inflation Issue. *Journal of Climate*, 26(6):2137–2143. DOI:10.1175/JCLI-D-12-00821.1.
- Maraun D (2016). Bias Correcting Climate Change Simulations - a Critical Review. *Curr. Clim. Chang. Reports*, 2(4):211–220. DOI:10.1007/s40641-016-0050-x.
- Maraun D, Wetterhall F, Ireson AM, Chandler RE, Kendon EJ, Widmann M, Brienen S, Rust HW, Sauter T, Themeßl M, Venema VKC, Chun KP, Goodess CM, Jones RG, Onof C, Vrac M & Thiele-Eich I (2010). Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Rev. Geophys.*, 48(3):RG3003. DOI:10.1029/2009RG000314.
- Maraun D, Widmann M, Gutiérrez JM, Kotlarski S, Chandler RE, Hertig E, Wibig J, Huth R & Wilcke RA (2015). VALUE: A framework to validate downscaling approaches for climate change studies. *Earth's Future*, 3(1):1–14. DOI:10.1002/2014EF000259.
- Matheron G (1971). *The theory of regionalized variables and its applications*. École national supérieure des mines, Paris, 211 pages.
- McCullag P & Nelder JA (1989). *Generalized linear models*. Chapman and Hall, New York, 2nd edition edition, 532 pages.
- Mekis E (2005). Adjustments for trace measurements in Canada. *15th Conference on Applied Climatology*, Savannah, Georgia, USA.
- Mekis E & Hogg WD (1999). Rehabilitation and analysis of Canadian daily precipitation time series. *Atmosphere-Ocean*, 37(1):53–85. DOI:10.1080/07055900.1999.9649621.
- Mekis E & Vincent LA (2011). An Overview of the Second Generation Adjusted Daily Precipitation Dataset for Trend Analysis in Canada. *Atmosphere-Ocean*, 49(2):163–177. DOI:10.1080/07055900.2011.583910.

- Mesinger F, DiMego G, Kalnay E, Mitchell K, Shafran PC, Ebisuzaki W, Jović D, Woollen J, Rogers E, Berbery EH, Ek MB, Fan Y, Grumbine R, Higgins W, Li H, Lin Y, Manikin G, Parrish D & Shi W (2006). North American Regional Reanalysis. *Bull. Am. Meteorol. Soc.*, 87(3):343–360.
- Metcalfe J, Routledge B & Devine K (1997). Rainfall Measurement in Canada : Changing Observational Methods and Archive Adjustment Procedures. *J. Clim.*, 10(1):92–101. DOI:10.1175/1520-0442(1997)010<0092:RMICCO>2.0.CO;2.
- Naveau P, Huser R, Ribereau P & Hannart A (2016). Modeling jointly low, moderate, and heavy rainfall intensities without a threshold selection. *Water Resources Research*, 52(4):2753–2769. DOI:10.1002/2015WR018552.
- Nelder JA & Wedderburn RWM (1972). Generalized linear models. *J. R. Stat. Soc. Ser. A*, 135(3):370–384.
- Neter J, Kutner MH, Nachtsheim CJ & Wasserman W (1996). *Applied Linear Statistical Models*. Irwin, Chicago.
- Newlands N, Davidson A, Howard A & Hill H (2011). Validation and inter-comparison of three methodologies for interpolating daily precipitation and temperature across Canada. *Environmetrics*, 22(2):205–223. DOI:10.1002/env.1044.
- Neykov NM, Neytchev PN & Zucchini W (2014). Stochastic daily precipitation model with a heavy-tailed component. *Natural Hazards and Earth System Science*, 14(9):2321–2335. DOI:10.5194/nhess-14-2321-2014.
- Nolan BT, Dubus IG, Surdyk N, Fowler HJ, Burton A, Hollis JM, Reichenberger S & Jarvis NJ (2008). Identification of key climatic factors regulating the transport of pesticides in leaching and to tile drains. *Pest Manag. Sci.*, 64(9):933–944. DOI:10.1002/ps.1587.
- Olson B & Kleiber W (2017). Approximate Bayesian computation methods for daily spatiotemporal precipitation occurrence simulation. *Water Resour. Res.* DOI:10.1002/2016WR019741.
- Olsson J, Uvo C & Jinno K (2001). Statistical atmospheric downscaling of short-term extreme rainfall by neural networks. *Phys. Chem. Earth, Part B Hydrol. Ocean. Atmos.*, 26(9):695–700. DOI:10.1016/S1464-1909(01)00071-5.

- Onof C, Chandler RE, Kakou A, Northrop P, Wheater HS & Isham V (2000). Rainfall modelling using Poisson-cluster processes: a review of developments. *Stoch. Environ. Res. Risk Assess.*, 14:0384–0411.
- Panthou G (2012). *Analyse des extrêmes pluviométriques en Afrique de l'Ouest et de leur évolution au cours des 60 dernières années*. Thèse de doctorat, Université de Grenoble.
- Pegram Gm & Clothier A (2001). High resolution space?time modelling of rainfall: the "String of Beads" model. *J. Hydrol.*, 241(1-2):26–41. DOI:10.1016/S0022-1694(00)00373-5.
- Pellarin T, Delrieu G, Saulnier GM, Andrieu H, Vignal B & Creutin JD (2002). Hydrologic visibility of weather radar systems operating in mountainous regions: Case study for the ardèche catchment (france). *Journal of Hydrometeorology*, 3(5):539–555. DOI:10.1175/1525-7541(2002)003<0539:HVOWRS>2.0.CO;2.
- Peterson TC, Folland C, Gruza G, Hogg W, Mokssit A & Plummer N (2001). Report on the Activities of the Working Group on Climate Change Detection and Related Rapporteurs 1998-2001. WMO. Geneve, 143 pages.
- Pettitt A (1979). A Non-parametric Approach to the Change-Point Problem. *J. Appl. Stat.*, 28(2):126–135.
- Phillips D (1990). *The Climates of Canada*. Canadian Government Publishing Center, Ottawa, Canada, 176 pages.
- Piani C, Haerter JO & Coppola E (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. *Theor. Appl. Climatol.*, 99(1-2):187–192. DOI:10.1007/s00704-009-0134-9.
- Plummer DA, Caya D, Frigon A, Côté H, Giguère M, Paquin D, Biner S, Harvey R & de Elia R (2006). Climate and climate change over North America as simulated by the Canadian RCM. *J. Clim.*, 19(13):3112–3132. DOI:10.1175/JCLI3769.1.
- Podgórski K & Wegener J (2012). Velocities of a spatial-temporal stochastic field with embedded dynamics. *Environmetrics*, 23(3):238–252. DOI:10.1002/env.2135.
- Raynaud D, Hingray B, Zin I, Anquetin S, Debionne S & Vautard R (2017). Atmospheric analogues for physically consistent scenarios of surface weather in Europe and Maghreb. *Int. J. Climatol.*, 37(4):2160–2176. DOI:10.1002/joc.4844.

- Richardson CW (1981). Stochastic simulation of daily precipitation, temperature, and solar radiation. *Water Resour. Res.*, 17(1):182–190. DOI:10.1029/WR017i001p00182.
- Rummukainen M (2010). State-of-the-art with regional climate models. *Wiley Interdiscip. Rev. Clim. Chang.*, 1(1):82–96. DOI:10.1002/wcc.8.
- Rummukainen M (2016). Added value in regional climate modeling. *Wiley Interdiscip. Rev. Clim. Chang.*, 7(1):145–159. DOI:10.1002/wcc.378.
- Rusticucci M, Zazulie N & Raga GB (2014). Regional winter climate of the southern central Andes: Assessing the performance of ERA-Interim for climate studies. *Journal of Geophysical Research: Atmosphere*, 119(14):8568–8582. DOI:10.1002/2013JD021167.
- Saha S, Moorthi S, Pan HL, Wu X, Wang J, Nadiga S, Tripp P, Kistler R, Woollen J, Behringer D, Liu H, Stokes D, Grumbine R, Gayno G, Hou YT, Chuang HY, Juang HMH, Sela J, Iredell M, Treadon R, Kleist D, Van Delst P, Keyser D, Derber J, Ek M, Meng J, Wei H, Yang R, Lord S, Van Den Dool H, Kumar A, Wang W, Long C, Chelliah M, Xue Y, Huang B, Schemm JK, Ebisuzaki W, Lin R, Xie P, Chen M, Zhou S, Higgins W, Zou CZ, Liu Q, Chen Y, Han Y, Cucurull L, Reynolds RW, Rutledge G & Goldberg M (2010). The NCEP Climate Forecast System Reanalysis. *Bull. Am. Meteorol. Soc.*, 91(8):1015–1057. DOI:10.1175/2010BAMS3001.1.
- Saha S, Nadiga S, Thiaw C & Wang J (2006). The NCEP Climate Forecast System. *J. Clim.*, 19(15): 3483–3517. DOI:10.1175/JCLI3812.1.
- Schefzik R (2016). A similarity-based implementation of the schaake shuffle. *Monthly Weather Review*, 144(5):1909–1921. DOI:10.1175/MWR-D-15-0227.1.
- Schefzik R (2017). Ensemble calibration with preserved correlations: unifying and comparing ensemble copula coupling and member-by-member postprocessing. *Q. J. R. Meteorol. Soc.*, 143(703):999–1008. DOI:10.1002/qj.2984.
- Schlather M, Malinowski A, Oesting M, Boecker D, Strokorb K, Engelke S, Martini J, Ballani F, Moreva O, Auel J, Menck PJ, Gross S, Ober U, Christoph Berreth, Burmeister K, Manitz J, Ribeiro P, Singleton R, Pfaff B & R Core Team (2017). *RandomFields: Simulation and Analysis of Random Fields*. R package version 3.1.50.

Schmidli J, Frei C & Vidale PL (2006). Downscaling from GCM precipitation: a benchmark for dynamical and statistical downscaling methods. *International Journal of Climatology*, 26(5):679–689. DOI:10.1002/joc.1287.

Schwarz G (1978). Estimating the Dimension of a Model. *Ann. Stat.*, 6(2):461–464. DOI:10.1214/aos/1176344136.

Serinaldi F (2008). Analysis of inter-gauge dependence by Kendall's τ_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.

Serinaldi F & Kilsby CG (2014). Simulating daily rainfall fields over large areas for collective risk estimation. *Journal of Hydrology*, 512:285–302. DOI:10.1016/j.jhydrol.2014.02.043.

Stein ML (1999). *Interpolation of Spatial Data: Some Theory for Kriging*. Springer-Verlag, New York, 249 pages.

Stern RD & Coe R (1984). A Model Fitting Analysis of Daily Rainfall Data. *Journal of the Royal Statistical Society. Series A (General)*, 147(1):1–34. DOI:10.2307/2981736.

Stone M (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society. Series B (Methodological)*, 36(2):111–147. DOI:10.2307/2984809.

Sun Y, Solomon S, Dai A & Portmann RW (2006). How often does it rain? *Journal of Climate*, 19(6):916–934. DOI:10.1175/JCLI3672.1.

Tapiador F, Navarro A, Levizzani V, García-Ortega E, Huffman G, Kidd C, Kucera P, Kummerow C, Masunaga H, Petersen W, Roca R, Sánchez JL, Tao WK & Turk F (2017). Global precipitation measurements for validating climate models. *Atmospheric Research*, 197(Supplement C):1 – 20. DOI:<https://doi.org/10.1016/j.atmosres.2017.06.021>.

Tustison B, Harris D & Foufoula-Georgiou E (2001). Scale issues in verification of precipitation forecasts. *J. Geophys. Res.*, 106(D11):11775–11784. DOI:10.1029/2001JD900066.

Vaittinada Ayar P, Vrac M, Bastin S, Carreau J, Déqué M & Gallardo C (2015). Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework: present climate evaluations. *Clim. Dyn.* DOI:10.1007/s00382-015-2647-5.

- Verdin A, Rajagopalan B, Kleiber W, Podestá G & Bert F (2015). A conditional stochastic weather generator for seasonal to multi-decadal simulations. *Journal of Hydrology*. DOI:10.1016/j.jhydrol.2015.12.036.
- Villarini G, Smith JA, Ntelekos AA & Schwarz U (2011). Annual maximum and peaks-over-threshold analyses of daily rainfall accumulations for austria. *Journal of Geophysical Research: Atmospheres*, 116(D5):n/a–n/a. DOI:10.1029/2010JD015038.
- Vischel T & Lebel T (2007). Assessing the water balance in the Sahel: Impact of small scale rainfall variability on runoff. Part 2: Idealized modeling of runoff sensitivity. *J. Hydrol.*, 333(2-4):340–355. DOI:10.1016/J.JHYDROL.2006.09.007.
- Vischel T, Lebel T, Massuel S & Cappelaere B (2009). Conditional simulation schemes of rain fields and their application to rainfall–runoff modeling studies in the sahel. *Journal of Hydrology*, 375(1):273 – 286. DOI:<http://dx.doi.org/10.1016/j.jhydrol.2009.02.028>. Surface processes and water cycle in West Africa, studied from the AMMA-CATCH observing system.
- Volosciuk C, Maraun D, Semenov VA, Park W, Volosciuk C, Maraun D, Semenov VA & Park W (2015). Extreme Precipitation in an Atmosphere General Circulation Model: Impact of Horizontal and Vertical Model Resolutions. *J. Clim.*, 28(3):1184–1205. DOI:10.1175/JCLI-D-14-00337.1.
- Volosciuk C, Maraun D, Vrac M & Widmann M (2017). A combined statistical bias correction and stochastic downscaling method for precipitation. *Hydrol. Earth Syst. Sci.*, 21(3):1693–1719. DOI:10.5194/hess-21-1693-2017.
- von Neumann J (1941). Distribution of the Ratio of the Mean Square Successive Difference to the Variance. *Ann. Math. Stat.*, 12(4):367–395. DOI:10.1214/aoms/1177731677.
- von Storch H (1999). On the Use of “Inflation” in Statistical Downscaling. *J. Clim.*, 12(12):3505–3506. DOI:10.1175/1520-0442(1999)012<3505:OTUOII>2.0.CO;2.
- Vrac M & Naveau P (2007). Stochastic downscaling of precipitation: From dry events to heavy rainfalls. *Water Resources Research*, 43(7). DOI:10.1029/2006WR005308.
- Wan H, Zhang X & Barrow EM (2005). Stochastic modelling of daily precipitation for Canada. *Atmosphere-Ocean*, 43(1):23–32. DOI:Doi 10.3137/Ao.430102.

Way RG, Oliva F & Viau AE (2016). Underestimated warming of northern Canada in the Berkeley Earth temperature product. *International Journal of Climatology*. DOI:10.1002/joc.4808.

Wijngaard JB, Klein Tank AMG & Können GP (2003). Homogeneity of 20th century European daily temperature and precipitation series. *Int. J. Climatol.*, 23(6):679–692. DOI:10.1002/joc.906.

Wilby R & Wigley T (1997). Downscaling general circulation model output: a review of methods and limitations. *Progress in Physical Geography*, 21(4):530–548. DOI:10.1177/030913339702100403.

Wilks D (1998). Multisite generalization of a daily stochastic precipitation generation model. *J. Hydrol.*, 210(1):178–191. DOI:10.1016/S0022-1694(98)00186-3.

Wilks D (2011). *Statistical Methods in the Atmospheric Sciences*. Academic Press, New York, USA, 3rd edition edition, 676 pages.

Wilks DS (2010). Use of stochastic weather generators for precipitation downscaling. *Wiley Interdiscip. Rev. Clim. Chang.*, 1(6):898–907. DOI:10.1002/wcc.85.

Wong G, Maraun D, Vrac M, Widmann M, Eden JM & Kent T (2014). Stochastic model output statistics for bias correcting and downscaling precipitation including extremes. *Journal of Climate*, 27(18):6940–6959. DOI:10.1175/JCLI-D-13-00604.1.

Xie P & Arkin PA (1997). Global Precipitation: A 17-Year Monthly Analysis Based on Gauge Observations, Satellite Estimates, and Numerical Model Outputs. *Bull. Am. Meteorol. Soc.*, 78(11):2539–2558. DOI:10.1175/1520-0477(1997)078<2539:GPAYMA>2.0.CO;2.

Xue Y, Janjic Z, Dudhia J, Vasic R & De Sales F (2014). A review on regional dynamical downscaling in intraseasonal to seasonal simulation/prediction and major factors that affect downscaling ability. *Atmos. Res.*, 147:68–85. DOI:10.1016/j.atmosres.2014.05.001.

Yang C, Chandler RE, Isham VS & Wheater HS (2005). Spatial-temporal rainfall simulation using generalized linear models. *Water Resour. Res.*, 41:1–13. DOI:10.1029/2004WR003739.

Yee TW (2015). *Vector Generalized Linear and Additive Models: With an Implementation in R*. Springer, New York, USA.

Yee TW (2016a). *Vector Generalized Linear and Additive Models : with an implementation in R*. Springer-Verlag, New-York, 589 pages.

- Yee TW (2016b). *VGAM: Vector Generalized Linear and Additive Models*. R package version 1.0-3.
- Yee TW & Wild CJ (1996). Vector Generalized Additive Models. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(3):481–493. DOI:10.2307/2345888.
- Yiou P, Salameh T, Drobinski P, Menut L, Vautard R & Vrac M (2013). Ensemble reconstruction of the atmospheric column from surface pressure using analogues. *Climate Dynamics*, 41(5):1333–1344. DOI:10.1007/s00382-012-1626-3.
- Zhang Q, Körnich H & Holmgren K (2013). How well do reanalyses represent the southern African precipitation? *Climate Dynamics*, 40(3-4):951–962. DOI:10.1007/s00382-012-1423-z.
- Zhang X, Alexander L, Hegerl GC, Jones P, Tank AK, Peterson TC, Trewin B & Zwiers FW (2011). Indices for monitoring changes in extremes based on daily temperature and precipitation data. *Wiley Interdiscip. Rev. Clim. Chang.*, 2(6):851–870. DOI:10.1002/wcc.147.

A

ESTIMATION DES COEFFICIENTS DES GLM ET VGLM PAR MAXIMUM DE VRAISEMBLANCE

On prends dans cette annexe les notations suivantes:

- $O_{s,t}$ est une variable binaire caractérisant l'occurrence observée au jour t au site s ;
- $Y_{s,t}$ est la variable des précipitations observées positives non nulles au jour t au site s ;
- $X_{s,t}$ est la variable des précipitations CFSR au jour t au site s ;
- $R_{s,t}$ est la variable des précipitations locales au jour t au site s ;
- (c_t, s_t) correspondent respectivement à $\cos(2\pi t/T)$ et $\sin(2\pi t/T)$, où T est la période moyenne (365,25 jours).

1 Occurrence

On souhaite expliquer la variable $O_{s,t}$ à l'aide la précipitation journalière de CFSR ($X_{s,t}$) et des saisons (c_t, s_t), lorsque $O_{s,t}$ prends la valeur à 0 (échec) ou à 1 (succès). On cherche alors à modéliser : $\mathbb{P}(O_{s,t} = 1|X_{s,t} = x_{s,t})$. On prend pour hypothèse que l'occurrence suit un loi de binomiale de paramètre π . On travaille en terme d'espérance (cadre des GLM) et afin que $\mathbb{E}(O_{s,t}) = 0$ ou 1, on utilise la fonction

logistique:

$$f(x) = \frac{\exp(x)}{1 + \exp(x)}, \quad f(x) \in [0, 1], \quad (1)$$

donnant ainsi dans le cadre de la modélisation de l'occurrence des précipitations:

$$\pi(x_{s,t}, \boldsymbol{\alpha}) = \frac{\exp(\alpha_0 + \alpha_1 \log(x_{s,t}) + \alpha_2 c_t + \alpha_3 s_t)}{1 + \exp(\alpha_0 + \alpha_1 \log(x_{s,t}) + \alpha_2 c_t + \alpha_3 s_t)} \quad (2)$$

On note pour simplifier les notations par la suite $A = \alpha_0 + \alpha_1 \log(x_{s,t}) + \alpha_2 c_t + \alpha_3 s_t$ et $\boldsymbol{\alpha} = \{\alpha_0, \alpha_1, \alpha_2, \alpha_3\}$.

L'estimation des coefficients $\boldsymbol{\alpha}$ est réalisée par la méthode du maximum de vraisemblance. En supposant que l'échantillon des n occurrences observées soit i.i.d et suit une loi binomiale de paramètre π alors la fonction de vraisemblance \mathcal{L} s'écrit comme suit :

$$\mathcal{L}(\boldsymbol{\alpha}) = \prod_t^n \pi^{o_{s,t}} (1 - \pi)^{1 - o_{s,t}}, \quad (3)$$

Il est équivalent et souvent plus simple de maximiser la fonction de log-vraisemblance ℓ , qui s'écrit :

$$\ell(\boldsymbol{\alpha}) = \sum_t^n o_{s,t} \log \pi + (1 - o_{s,t}) \log (1 - \pi), \quad (4)$$

en développant et simplifiant, on peut écrire que :

$$\ell(\boldsymbol{\alpha}) = \sum_t^n -\log(1 + \exp(A)) + \sum_t^n o_{s,t} A \quad (5)$$

Enfin, classiquement pour trouver les paramètres qui maximise la fonction ℓ , on dérive l'équation 5 par rapport aux coefficients $\boldsymbol{\alpha}$ et on cherche la solution aux équations suivante :

$$\frac{\partial \ell}{\partial \alpha_i} = 0, \quad i \in [0, 3] \quad (6)$$

L'équation transcendante 6 n'ayant pas de solution analytique, on se tourne vers les solutions numériques. Dans ce travail de recherche thèse, on utilise l'algorithme de Newton-Raphson.

2 Intensité

On souhaite expliquer, dans un espace probabiliste, l'intensité des précipitations non nulles en fonction des précipitations issues de CFSR, c'est à dire: $F(r) = \mathbb{P}(R_{s,t} < r | X_{s,t} = x_{s,t})$. On prend pour hypothèse que les précipitations journalières non nulles sont distribuées selon une loi gamma dont la densité est donnée par :

$$f_{\mu,\gamma}(r) = \frac{\gamma}{\mu \Gamma(\gamma)} \left(\frac{\gamma r}{\mu} \right)^{\gamma-1} e^{-\gamma r/\mu}, \forall r > 0, \quad (7)$$

où μ est la moyenne et γ le paramètre de forme. La fonction F est ainsi complètement définie par ces derniers coefficients. Le cadre des VGLM permet de prédire les paramètres de la distribution pour chaque pas de temps t et, ici, pour chaque site s de façon indépendante. Pour la modélisation des intensités de précipitations, le système suivant illustre le VGLM utilisé :

$$\begin{aligned} h(\mu_{s,t}) &= \eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 c_s + \eta_3 s_s, \\ h(\gamma_{s,t}) &= \beta_0 + \beta_1 \log(x_{s,t} + 1), \end{aligned} \quad (8)$$

avec $h(\cdot)$, la fonction lien, ici la fonction $\log(\cdot)$. On peut également écrire que :

$$\begin{aligned} \mu_{s,t} &= \exp [\eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 c_s + \eta_3 s_s], \\ \gamma_{s,t} &= \exp [\beta_0 + \beta_1 \log(x_{s,t} + 1)], \end{aligned} \quad (9)$$

. La valeur des paramètres $(\mu_{s,t}, \gamma_{s,t})$ passe par l'estimation des coefficients $\boldsymbol{\eta} = \{\eta_0, \eta_1, \eta_2, \eta_3\}$ et $\boldsymbol{\beta} = \{\beta_0, \beta_1\}$ calculé selon la méthode du maximum de vraisemblance et en utilisant l'ensemble des observations $y_{s,t}$.

Ainsi si l'on pose la fonction de vraisemblance, \mathcal{L} , définie par :

$$\begin{aligned} \mathcal{L}(\boldsymbol{\eta}, \boldsymbol{\beta}) &= \prod_t^n f_{\mu,\gamma}(y_{s,t}) \\ &= \prod_t^n \frac{\gamma_{s,t}}{\mu_{s,t} \Gamma(\gamma_{s,t})} \left(\frac{\gamma_{s,t} y_{s,t}}{\mu_{s,t}} \right)^{\gamma_{s,t}-1} e^{-\gamma_{s,t} y_{s,t}/\mu_{s,t}} \end{aligned} \quad (10)$$

Comme précédemment on s'intéresse à maximiser la fonction de log-vraisemblance, et en considérant les développements de l'équation 9 :

$$\begin{aligned}
 \ell(\mu_{s,t}, \gamma_{s,t}) = & \sum_t^n [\beta_0 + \beta_1 \log(x_{s,t} + 1)] \\
 & - [\eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 c_s + \eta_3 s_s] \\
 & - \log(\Gamma(\exp[\beta_0 + \beta_1 \log(x_{s,t} + 1)])) \\
 & + (\exp[\beta_0 + \beta_1 \log(x_{s,t} + 1)] - 1) \times \\
 & (\log(y_{s,t}) + \beta_0 + \beta_1 \log(x_{s,t} + 1)) \\
 & - \eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 c_s + \eta_3 s_s \\
 & - \frac{y_{s,t} \exp[\beta_0 + \beta_1 \log(x_{s,t} + 1)]}{\exp[\eta_0 + \eta_1 \log(x_{s,t} + 1) + \eta_2 c_s + \eta_3 s_s]}
 \end{aligned} \tag{11}$$

Par la suite, comme précédemment on cherche les maximum à l'équation en estimant les solutions au système d'équations aux dérivées partielles, *i.e.* dériver la $\ell(\mu_{s,t}, \gamma_{s,t})$ selon chaqu'un des six coefficients. Encore une fois, on se tourne vers une solution numérique dans l'impossibilité de trouver une solution analytique.



SUPPLEMENTARY MATERIAL

On trouve dans ce chapitre l'ensemble des figures supplémentaires relatives à chacun des trois articles des Chapitre 4 à 6.

1 Article 1

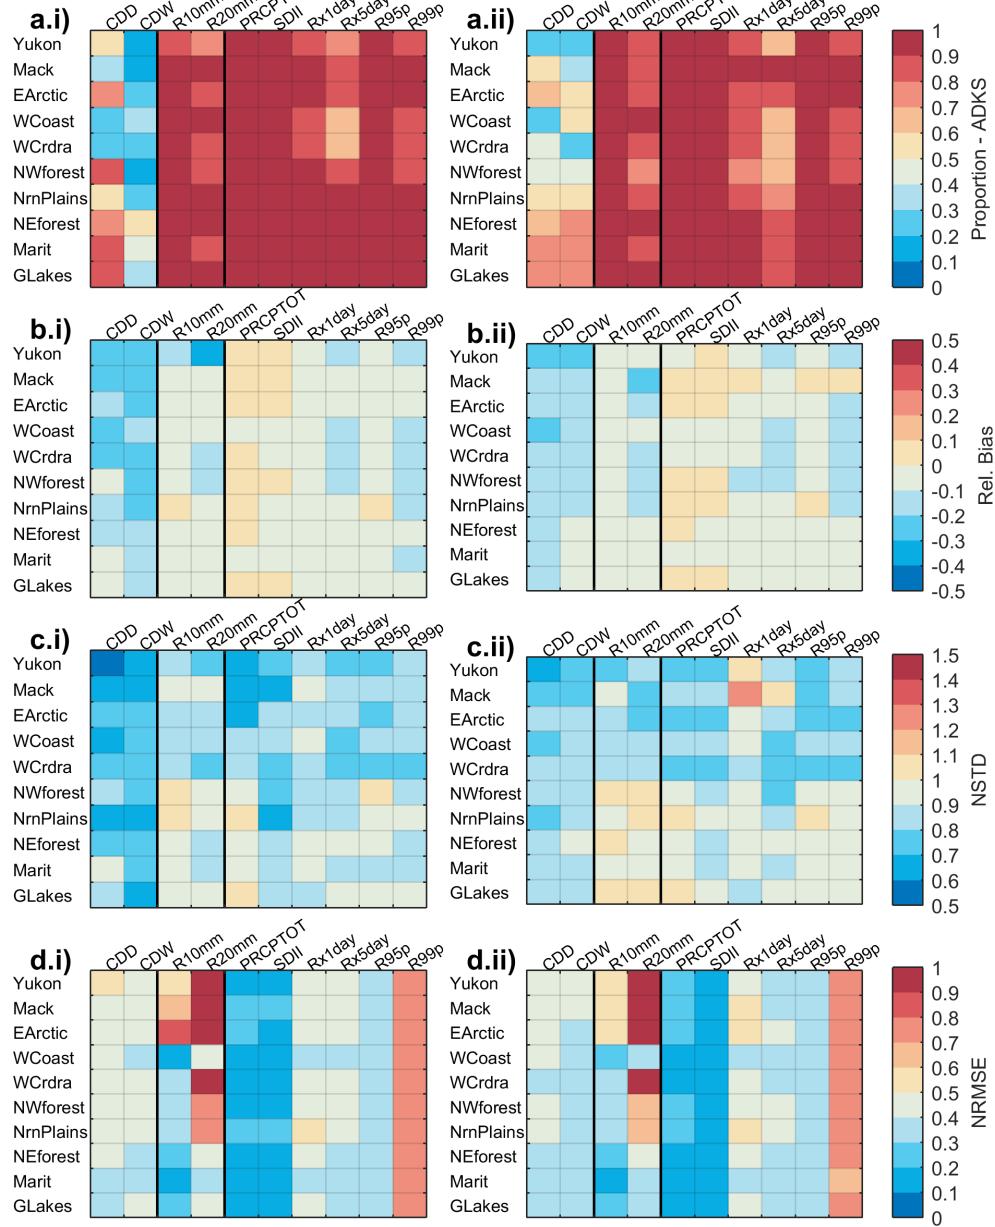


Figure S1 – Regional average of the: a) proportion of post-treated index distribution being different from observed ones at the 95% c.l. according to the ADKS tests; b) relative bias between the post-treated and observed index series; c) NSTD; and d) NRMSE. Left panels (a.i, b.i, c.i, d.i) refer to sites where observed and CFSR distributions of annual indices were not significantly different at the 95% c.l. according to the ADKS test (Figure 3), while the right panels (a.ii, b.ii, c.ii, d.ii) refer to sites where observed and CFSR distributions of annual indices were significantly different at the 95% c.l.

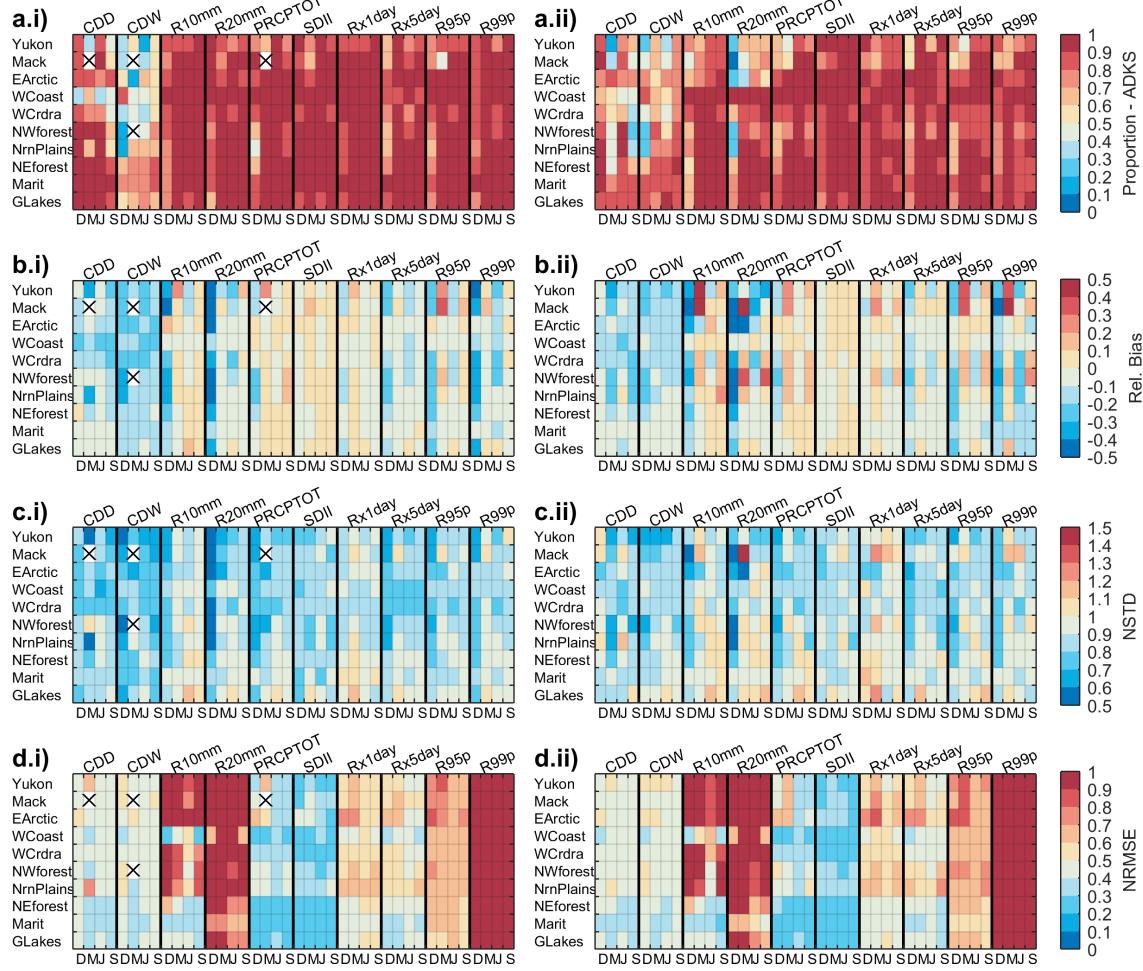


Figure S2 – Regional average of the: a) relative bias; b) NSTD; and c) NRMSE between post-treated CFSR and observed seasonal index series. Left panels (a.i, b.i, c.i) refer to sites where observed and CFSR distributions of seasonal indices were not significantly different at the 95% c.l. according to the ADKS test (Figure 3), while the right panels (a.ii, b.ii, c.ii) refer to sites where observed and CFSR distributions of annual indices were significantly different at the 95% c.l. Boxes marked with an 'X' indicate that, for the corresponding region and index, no site displayed similar observed and CFSR index distributions. For clarity, D, M, J and S refer to DJF, MAM, JJA and SON.

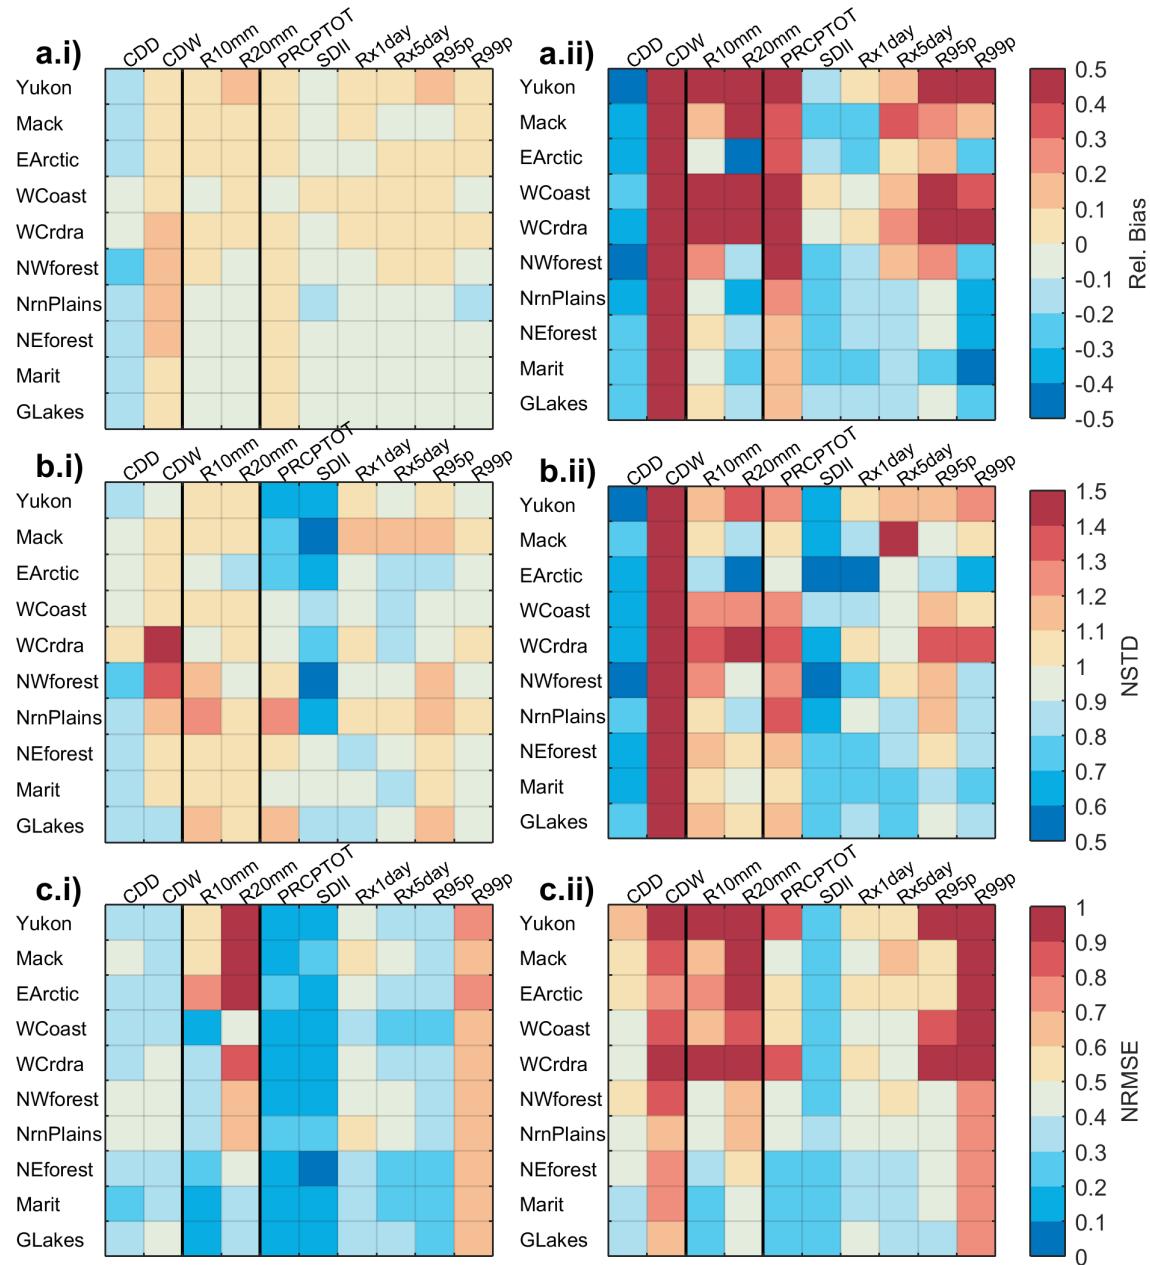


Figure S3 – Regional average of the: a) relative bias; b) NSTD and c) NRMSE between CFSR and observed annual index series. Left panels (a.i, b.i, c.i) refer to sites where observed and CFSR distributions of annual indices were not significantly different at the 95% c.l. according to the ADKS test, while the right panels (a.ii, b.ii, c.ii) refer to sites where observed and CFSR distributions of annual indices were significantly different at the 95% c.l.

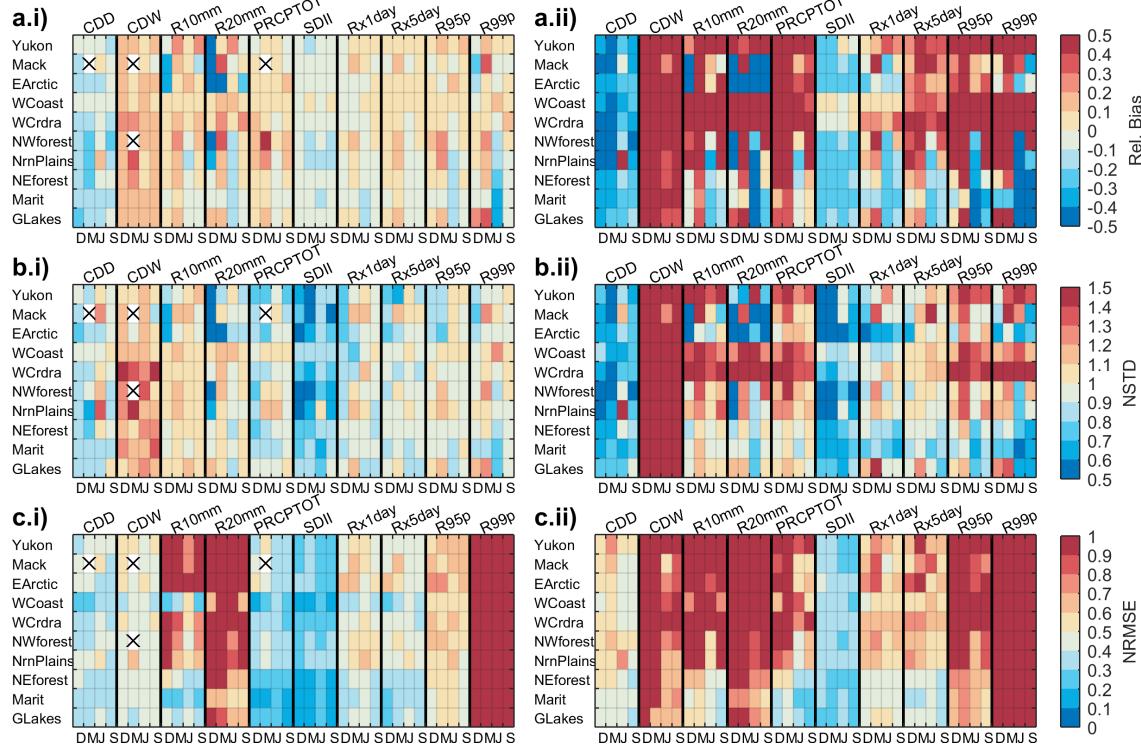


Figure S4 – Regional average of the: a) relative bias; b) NSTD; and c) NRMSE between CFSR and observed seasonal index series. Left panels (a.i, b.i, c.i) refer to sites where observed and CFSR distributions of seasonal indices were not significantly different at the 95% c.l. according to the ADKS test, while the right panels (a.ii, b.ii, c.ii) refer to sites where observed and CFSR distributions of seasonal indices were significantly different at the 95% c.l. Boxes marked with an 'X' indicate that, for the corresponding region and index, no site displayed similar observed and CFSR index distributions. For clarity, D, M, J and S refer to DJF, MAM, JJA and SON.

2 Article 2

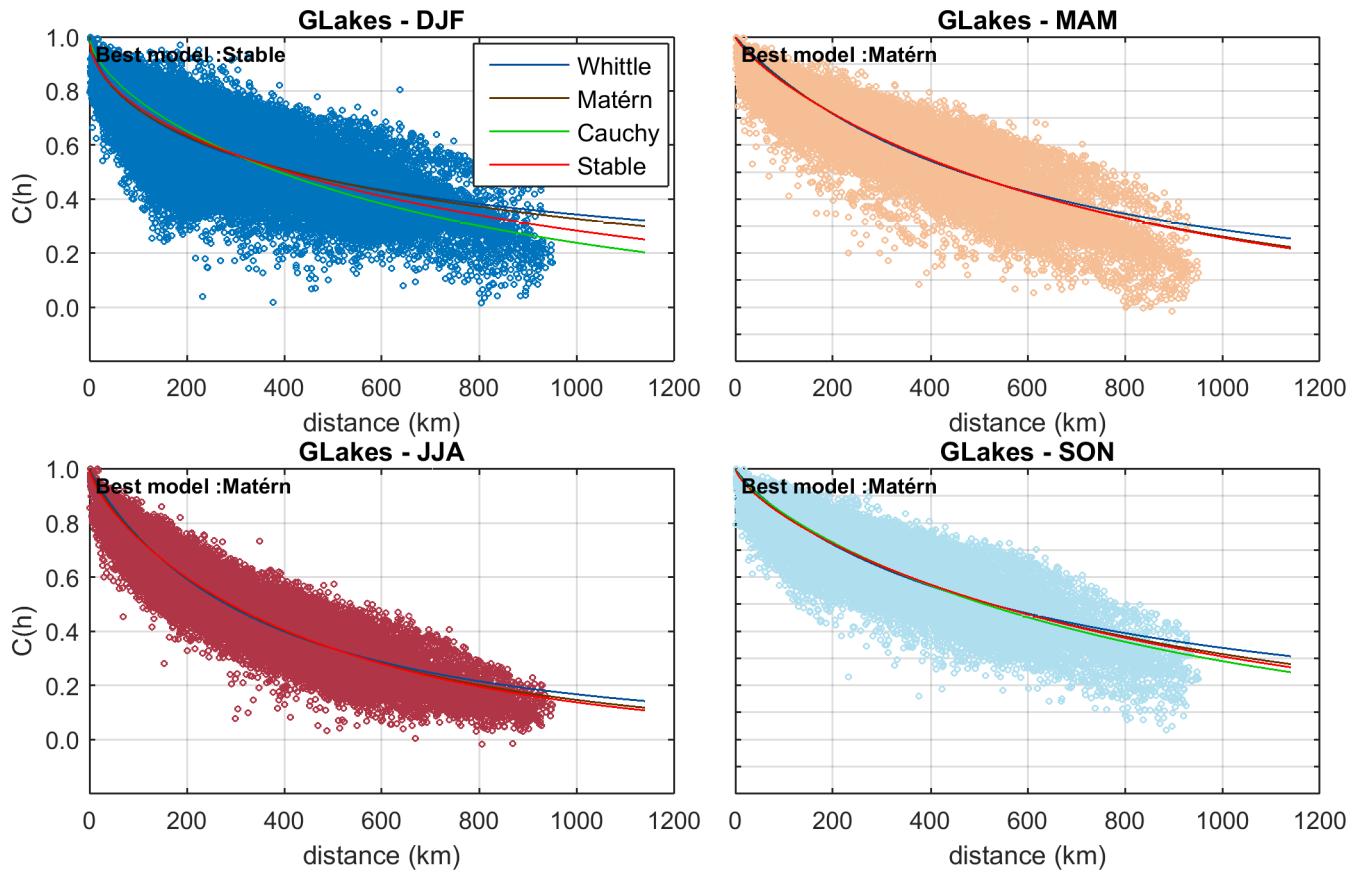


Figure S1 – Adjustement of the empirical covariogram (dotted blue points) to the Exponential, Stable, Whittle and Matérn model for the DJF, MAM, JJA and SON seasons. The selected model according to the IRLS is shown in the left corner of the figures.

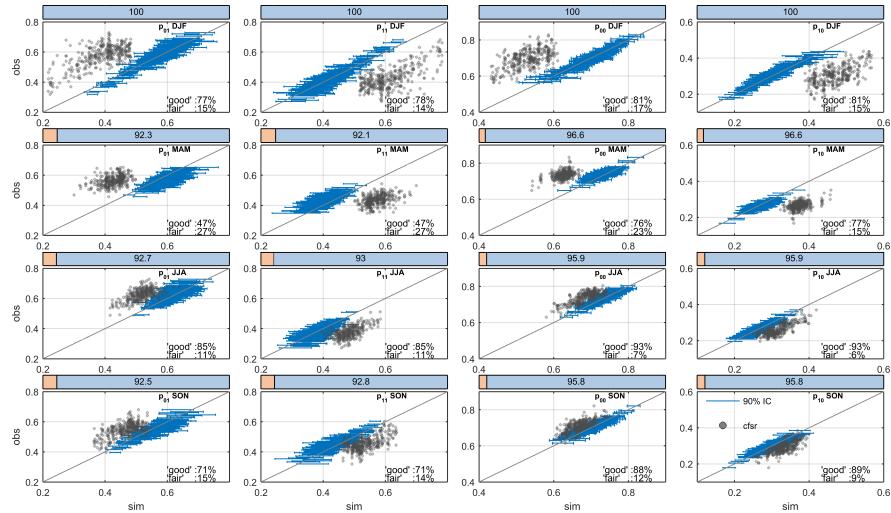


Figure S2 – At-site two-state transition probabilities p_{01} , p_{11} , p_{00} and p_{10} (dry:0; wet:1) estimated from the observed series as a function of the corresponding values estimated from the post-treated (90% confidence interval) or CFSR daily time series (gray points). Proportion of sites with “good” and “fair” performances are indicated in the lower right corner of each panel. Each line correspond to a season, from the top: DJF, MAM, JJA and SON. The scale above each panel indicates the percentage of sites with “good” or “fair” performances after post-treatment that that displayed higher (pale blue), similar (pale brown) or smaller (dark brown) performances compared to CFSR (percentages are not indicated when below 20%).

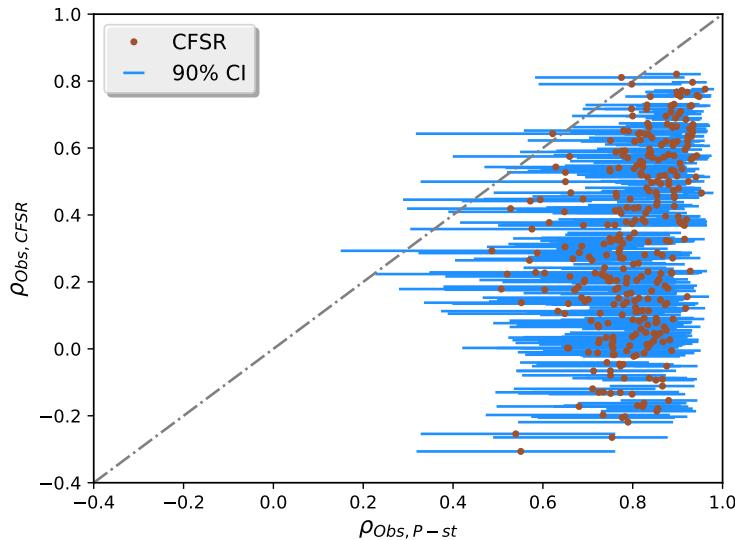


Figure S3 – Pearson correlations (ρ) of the annual precipitation cycles between observed and CFSR (y-axis, brown dots) or post-treated series (90% confidence interval). Annual cycles were estimated by averaging precipitation over each month of the 1979–2009 period.

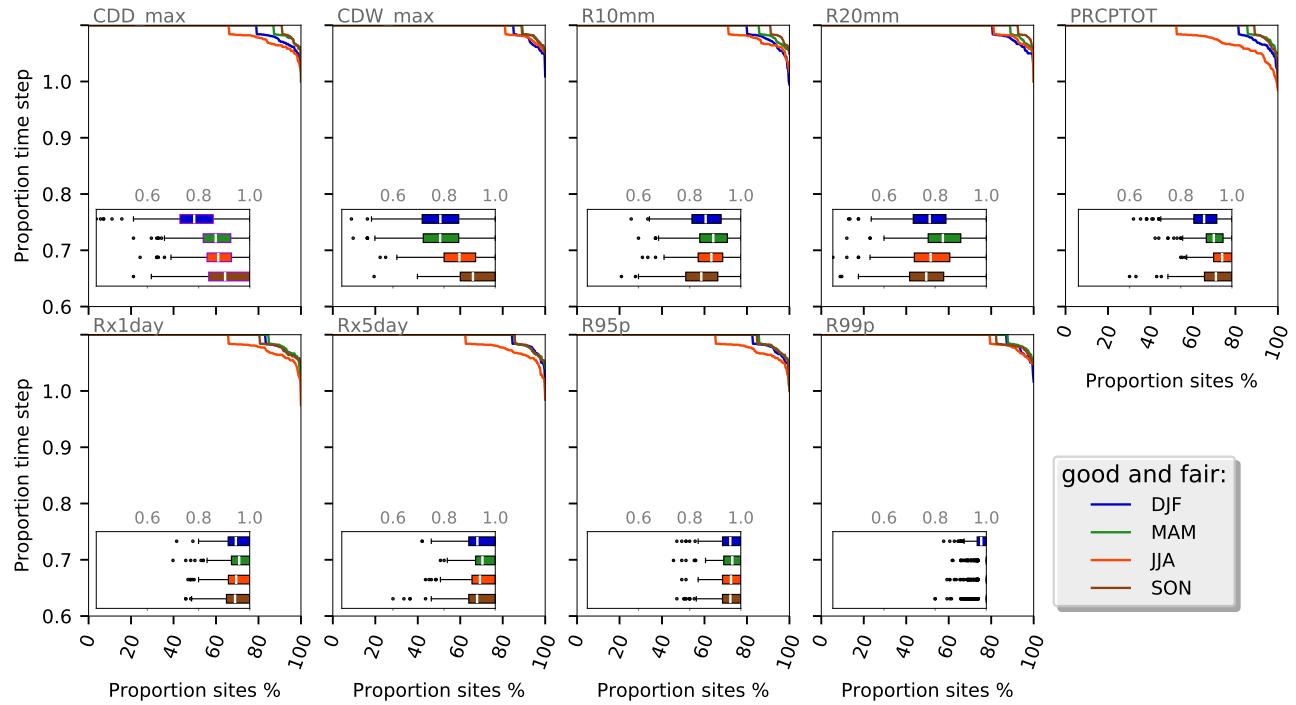


Figure S4 – At-site (*x*-axis) years proportions (*y*-axis) being in the “good” or “fair” category for the ETCDII indices indicated in the upper right of the figures. The inside boxplots illustrates the distribution of the fraction of years with post-treated “good” that were similar or outperformed CFSR. Boxes delineate the interquartile range (IQR, $[q_{25} - q_{75}]$), vertical line defines the mean value, while the whiskers lower and upper limits correspond, respectively, to $q_{25} - 1.5 \times IQR$ and $q_{75} + 1.5 \times IQR$. Outliers are marked by black circles.

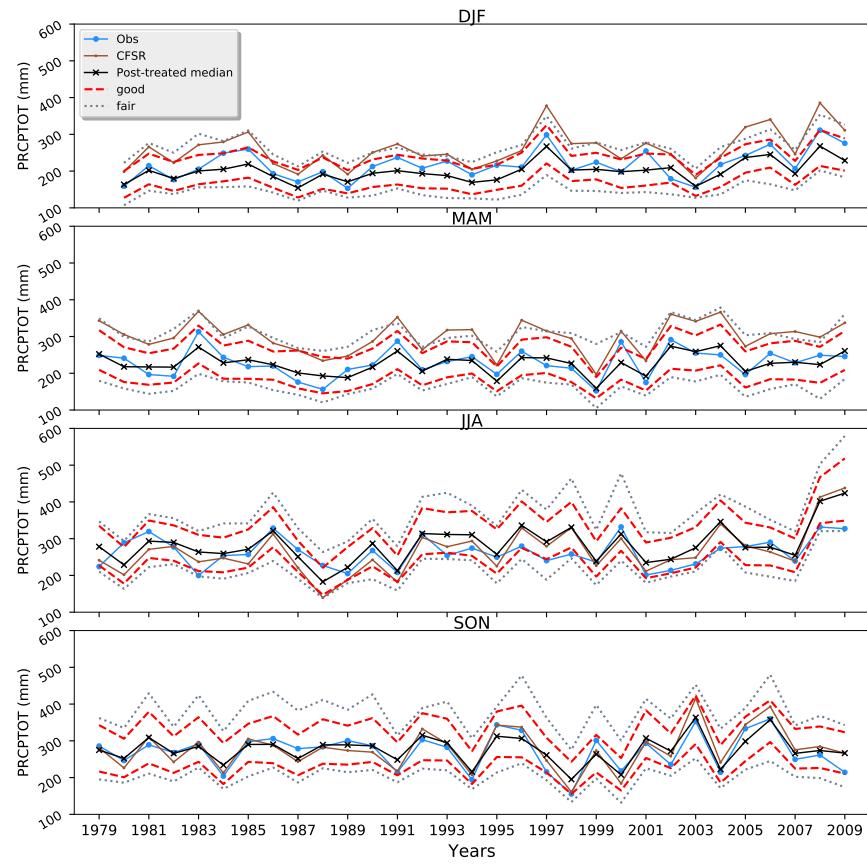


Figure S5 – Annual amount (PRCPTOT) estimated at the domain scale from the observed (blue), the cfsr (brown) datasets during DJF, MAM, JJA and SON. The 100 post-treated (p-st) series are illustrated with the median values (black line with crosses), the 90 % (dashed red line, “good”) and 99.7 % (dotted gray lines, “fair”) confidence intervals.

3 Article 3

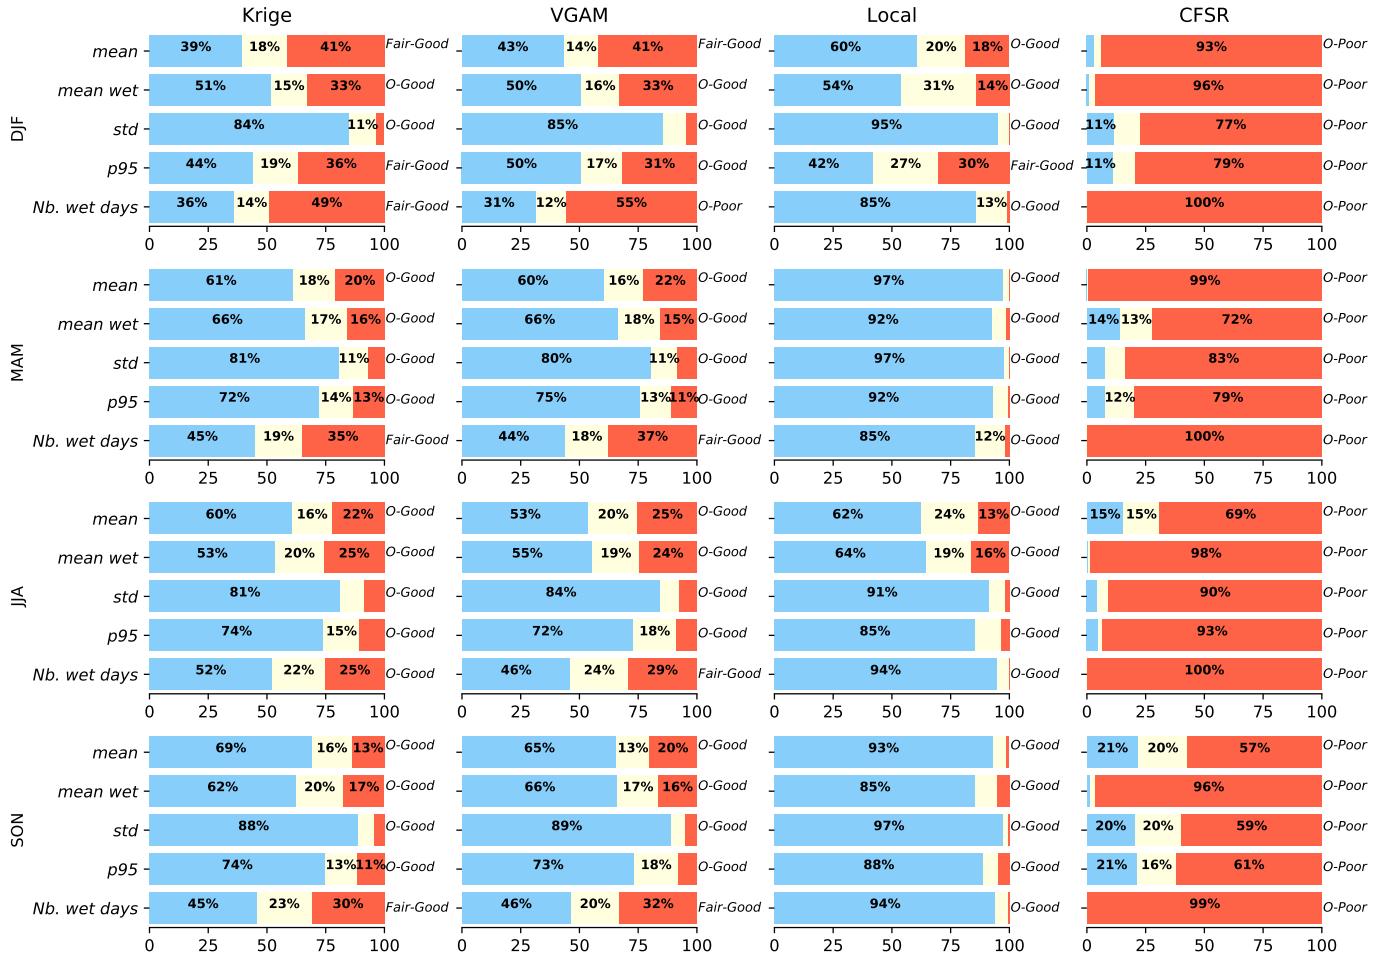


Figure S1 – Daily characteristic performances across the DJF, MAM, JJA and SON seasons (lines) for Kriging, VGAM and Local models, and CFSR (columns). The blue, pale yellow and red colors represent respectively the percentage of sites being in the good, fair category across the GLakes region. The aggregated performances are indicated in italic at the right side of each statistic for the DJF, MAM, JJA and SON seasons.

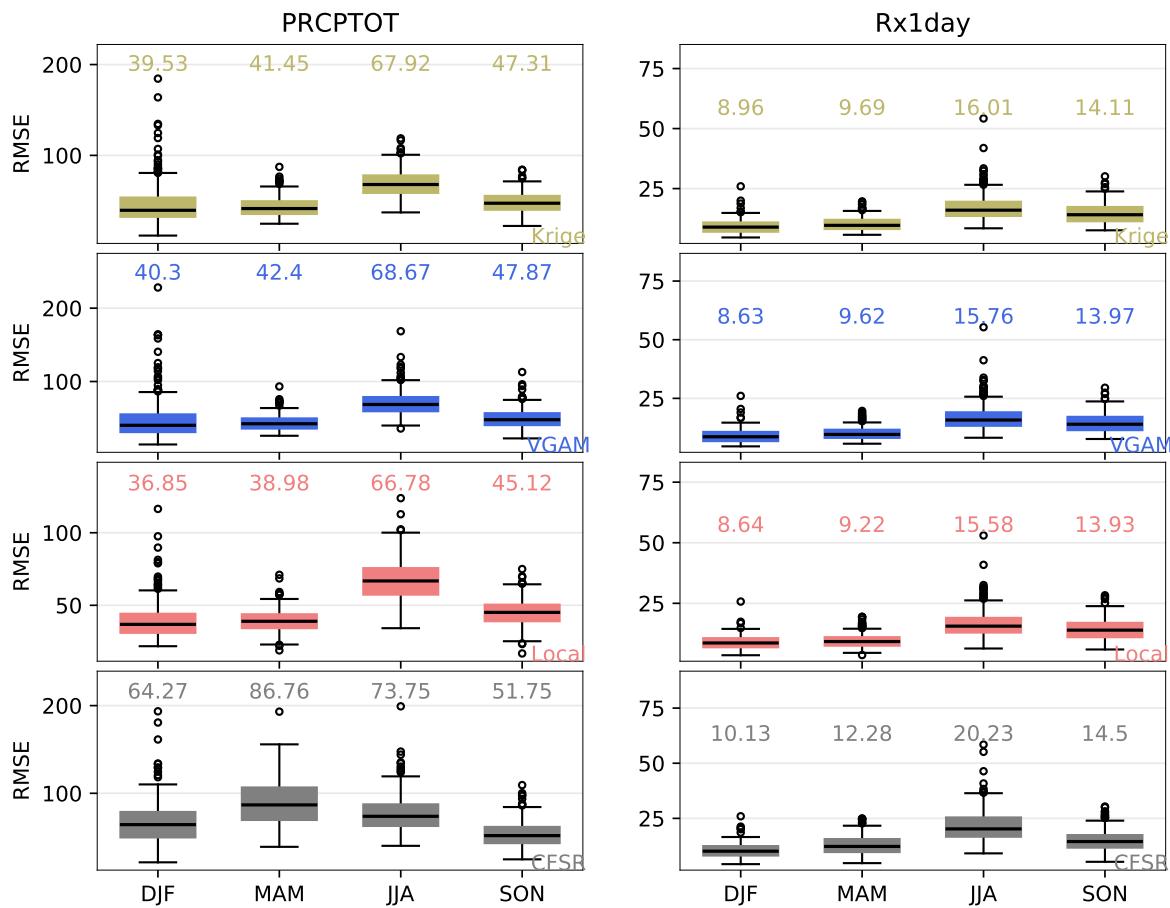


Figure S2 – Boxplots of the RMSE between observed and Krige, VGAM, Local and CFSR PRCPTOT (left panels) and Rx1day (right panels) indices at the season time scale (DJF, MAM, JJA, SON) (*x*-axis). Boxes delineate the interquartile range (IQR, [q₂₅ - q₇₅]), vertical line defines the mean value, while the whiskers lower and upper limits correspond, respectively, to q₂₅-1.5×IQR and q₇₅+1.5×IQR. The median value is written at the top of each boxplot with its corresponding color, *y*-axis limits are different in the subplots.

