HAL
open science

Intérêt de la méthode des analogues pour la génération de scénarios de précipitations à l'échelle de la France métropolitaine. Cohérence spatiale et adaptabilité du lien d'échelle.

Jérémy Chardon

To cite this version:

Jérémy Chardon. Intérêt de la méthode des analogues pour la génération de scénarios de précipitations à l'échelle de la France métropolitaine. Cohérence spatiale et adaptabilité du lien d'échelle.. Météorologie. Université Grenoble Alpes, 2014. Français. NNT : . tel-01100759

HAL Id: tel-01100759

https://theses.hal.science/tel-01100759v1

Submitted on 7 Jan 2015

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

UNIVERSITÉ DE GRENOBLE

THÈSE

Pour obtenir le grade de

DOCTEUR DE L'UNIVERSITÉ DE GRENOBLE

Spécialité : **Océan, Atmosphère, Hydrologie**

Arrêté ministériel : 7 août 2006

Présentée par

Jérémy Chardon

Thèse co-dirigée par **Anne-Catherine FAVRE**
et par **Benoît HINGRAY**

préparée au sein du **Laboratoire d'étude des Transferts en Hydrologie et Environnement (LTHE, UMR 5564, CNRS - Grenoble INP - IRD - UJF)**
dans l'Ecole Doctorale **Terre Univers Environnement**

Intérêt de la méthode des analogues pour la génération de scénarios de précipitations à l'échelle de la France métropolitaine. Cohérence spatiale et adaptabilité du lien d'échelle.

Thèse soutenue publiquement le **11 décembre 2014**,
devant le jury composé de :

Clémentine PRIEUR
Professeure, Université Joseph Fourier, Laboratoire Jean Kuntzmann, Grenoble, Présidente

Michel DÉQUÉ
Chercheur, Météo-France/CNRM, CNRS/GAME, Toulouse, Rapporteur

Pierre CAMBERLIN
Professeur, Université de Bourgogne, directeur adjoint UMR Biogéosciences, Dijon, Rapporteur

Jean-Philippe VIDAL
Chargé de Recherche, Irstea, Unité de Recherche Hydrologie-Hydraulique, Examinateur

Anne-Catherine FAVRE
Professeure, ENSE^3-GINP, LTHE, Grenoble, Co-Directrice de thèse

Benoît HINGRAY
Chargé de Recherche, CNRS, LTHE, Grenoble, Co-Directeur de thèse

Joël GAILHARD
Ingénieur Expert, EDF/DTG, Grenoble, Invité

Remerciements

Rendre hommage à l'ensemble des personnes qui ont constitué un appui scientifique et/ou moral certain est très important pour moi, pour la simple raison que ce travail de thèse et ce document écrit n'auraient pu être effectués sans ces dernières. Plus spécialement, je tiens à remercier toutes ces personnes pour la raison qu'elles m'ont permis de me construire et de me développer tant sur le plan professionnel que sur le plan personnel, et c'est avec une grande émotion que je tiens à leur adresser ces quelques mots.

Parmi elles, je commencerais tout d'abord par remercier une équipe de direction de choc représentée par Mme Anne-Catherine Favre et M. Benoît Hingray. D'un point de vue scientifique, ce fut pour moi un vrai plaisir de travailler avec de telles personnes très complémentaires. Les nombreux échanges que nous avons eus représentent un précieux enseignement. Sur le plan humain, j'estime avoir eu une réelle chance d'avoir pu collaborer avec eux : ils ont toujours su se rendre disponibles lorsque c'était nécessaire. Ils ont été à l'écoute de mes attentes, compréhensifs et respectueux de mes idées et m'ont laissé mener plusieurs activités connexes à mon projet de recherche.

En second lieu, mes remerciements s'adressent aux membres du jury, M. Pierre Camberlin, M. Michel Déqué, M. Jean-Philippe Vidal, Mme Clémentine Prieur et M. Joël Gailhard, pour avoir pris le temps de relire et d'évaluer mon travail avec intérêt. C'est un honneur pour moi que mon travail ait été reconnu par de tels experts scientifiques.

Je souhaite de plus remercier certains acteurs nationaux de la méthode des analogues, à savoir au LTHE, M. Charles Obled pour les longues discussions échangées, ainsi que Mme Isabella Zin avec laquelle j'ai eu le plaisir de partager la gestion des prévisions opérationnelles et ses nombreux rebondissements. A EDF, M. Joël Gailhard et M. Rémy Garçon pour leurs éclairages pertinents et avisés. A IRSTEA, M. Jean-Philippe Vidal et sa doctorante Mlle Sabine Radanovics pour les discussions que nous avions échangées pendant nos thèses respectives, et enfin M. Renaud Marty et

M. Alain Gautheron du SCHAPI ainsi que M. Guillaume Bontron et M. Aurélien Ben Daoud de la CNR.

Ce travail de thèse n'est pas seulement le fruit d'une collaboration de directeurs/doctorant : plusieurs étudiants de qualité y ont contribué. Je tiens particulièrement à remercier M. Philémon Autin, Mlle Angèle Nahat, Mlle Laïla Sfeir et Mlle Marion Francelle avec lesquelles ce fut un plaisir de travailler.

Certaines personnes ont contribué ponctuellement de près ou de loin à la réalisation de ces travaux. Je remercie fortement l'ensemble de l'équipe du centre de calcul à haute performance CIMENT, et particulièrement M. Bruno Bzeznik, Romain Caravagna et Pierre Girard pour leur soutien informatique irréprochable, leur réactivité et leur aide à la bonne réalisation des calculs. Mes remerciements s'adresse aussi à M. Samuel Debionne pour son amabilité, sa disponibilité et son aide pour la résolution de certaines questions informatiques. Certains aspects d'ordre météorologiques n'auraient pu être considérés sans la concertation de plusieurs personnes. Je remercie ainsi Mme Sandrine Anquetin, M. Gilles Molinié et M. Damien Raynaud. Mme Juliette Blanchet pour son aide concernant l'écriture du générateur stochastique. M. Nicolas Merlet pour l'acquisition de données ERA40 supplémentaires. M. François Bonnel et M. Thierry Bouillon pour leur aide logistique lors de la soutenance de thèse. M. Matthieu Lafaysse et M. Abdelkader Mezghani pour les conseils pertinents qu'ils m'ont transmis lors de mon arrivée au sein de l'équipe HMCI. Enfin, M. Thibault Mathevet, M. Matthieu Le-Lay et M. Jean-Marie Lepioufle pour avoir suscité en moi un intérêt à la recherche en hydro-météorologie.

Parallèlement à mes travaux de thèse, j'ai encadré ou enseigné à de nombreux étudiants au travers d'une mission de Doctorant Contractuel Enseignant effectuée au sein de l'école ENSE^3 de Grenoble INP. Je remercie ici l'ensemble des enseignants avec lesquels j'ai collaboré, dont Mme Christine Faury, M. Eric Barthélémy, Mme Céline Bourgeois, M. Julien Chauchat et plus particulièrement Mme Isabella Zin, M. Philippe Séchet et Mme Anne-Catherine Favre pour leur soutien infaillible dans mes initiatives. Depuis plus de cinq ans, ces personnes ont d'abord participé à ma formation d'ingénieur, puis m'ont accueilli en tant que collègue. Je tiens donc à les remercier pour leurs enseignements, leur intégration au sein du corps enseignant et enfin, pour la chance et le plaisir d'avoir pu collaborer avec eux. Je remercie de plus M. Yvan Renou pour son intérêt à mes interventions au sein de la licence professionnelle de l'UPMF à Valence.

Le bon déroulement d'une thèse ne serait certainement pas le même s'il n'y avait pas un groupe de doctorants soudés et une ambiance conviviale. Que ce soit technique, scientifique ou moral, il est toujours possible de trouver un soutien. Parmi eux, certains sont déjà partis, d'autres sont arrivés, certains sont mêmes revenus. Merci beaucoup à Gé, Joris, Baptiste, Moussa, Olivier, Aloïs, Osse, les ThomasSSS, Solène, Antoine, Benoît, Steph, Camille, Annette, Lise, Saïf, Damien, Aurélien, Galatïa & Thanos, Rafaël, Julien, Guillaume, Audrey, Gildas, Cuam, Sammy et plus particulièrement, ceux avec lesquels nous nous sommes serrés les coudes dans la dernière ligne droite, Max et Val.

Je remercie de plus l'ensemble des personnels du LTHE, plus précisément l'équipe HMCI pour son accueil chaleureux, ainsi que les pôles administratif et informatique du laboratoire.

Le moment est maintenant venu de remercier les personnes avec lesquelles j'ai partagé de très bons moments en dehors du cadre de la thèse. En premier lieu, les colocs du P'tit Bulletin : Eric le Hippie, Guillaume El Conquistador, Lucas El Che, Victor Mi Amor, Simon Bolivar. Les itinérants du P'tit Bulletin : Andréa, Bastoun & Masha, MarieC, Ramouch, Val, Yoyo, Le Père & Chloé. Les poules du P'tit Bulletin : Poule & The Gang, Poule-Vord et Poule-Izère. A ces amis se joignent d'autres personnes : Sylou & Zouï, Mariette & Ben & Manouch, Ouin-Ouin & Riri, Polo & Anouk, Camouille & Fridouille, Jul', Maxi Bûchette, Marion Mouth, MouthMouth, Marie & Norbert, Princesse Manon, Fab, Antoine Sasat, Georgi Boy, Sandra, le Festiv'Arts, la Mixture, les FQCG, la team-basket du CAESUG, l'ESMUG, ainsi que tout ceux que j'ai eu le plaisir de côtoyer au long de ces trois années et quelques de thèse. Je remercie vivement ces superbes amis car ils ont constitué une réelle bouffée d'oxygène dans le nuage épais que peut parfois représenter une thèse.

Mes remerciements s'adressent enfin à ma famille pour le soutien et la confiance inébranlable qu'elle m'accorde depuis plusieurs années dans les différents projets que j'entreprends.

A travers ces premières pages – qui sont paradoxalement les dernières que j'écris – c'est avec une grande émotion que je remercie une dernière fois l'ensemble de ces personnes qui ont, de près comme de loin, contribué à la réalisation de ce projet de thèse et avec lesquelles j'ai partagé de très bons moments.

Table des matières

Remerciements — iii

Sommaire — vi

Liste des symboles — x

Partie I Génération de scénarios de précipitations spatialement cohérents sur la France — 1

I. Génération de scénarios météorologiques cohérents pour les études d'impact — 3

1. L'approche dynamique — 4
2. L'approche statistique — 5
   - 2.1. Les générateurs de temps — 5
   - 2.2. Les fonctions de transfert — 6
   - 2.3. Les méthodes analogiques — 6
   - 2.4. La sélection des prédicteurs — 7
3. Quelques questions associées à l'utilisation des MDES — 8

II. Modèles & Données — 13

1. Les descentes d'échelle statistiques retenues — 13
   - 1.1. La MDES Analog — 13
   - 1.2. La MDES d2gen — 16
2. Données — 17
   - 2.1. Les ré-analyses ERA-40 — 17
   - 2.2. Les ré-analyses Safran — 17
     - 2.2.1. Climatologie des précipitations Safran — 18
     - 2.2.2. Climatologie saisonnière — 20
     - 2.2.3. Climatologie par type de temps — 20

Partie II Intérêt du modèle Analog 27

III. Le modèle Analog de référence 31

1. Adaptation du modèle Analog à la France 31
2. Stratégie d'évaluation 35
   2.1. Les évaluations déterministes 35
   2.2. Une évaluation probabiliste 36
      2.2.1. Evaluation de l'occurrence de précipitation 37
      2.2.2. Evaluation de la quantité de précipitation 38
   2.3. Evaluation du biais moyen 42
   2.4. Comparaison de performances 43
3. Evaluation du modèle Analog 43
   3.1. Evaluation globale du modèle Analog 43
   3.2. Evaluation saisonnière 46
   3.3. Evaluation par type de temps 48

IV. Transposabilité spatiale des dates analogues 53

1. Résumé étendu 54
2. Publication dans Journal of Climate 56
3. Compléments d'étude 81
   3.1. Sensibilité à la longueur d'archive 81
   3.2. Sensibilité selon différents filtres temporels 83
      3.2.1. Evaluation saisonnière 84
      3.2.2. Evaluation selon les types de temps 86

V. Prédiction d'une précipitation spatiale moyenne : sensibilité de la performance à l'échelle d'agrégation 89

1. Modèle & données 91
2. Sensibilité des performances à l'agrégation spatiale 92
3. Influence de la corrélation spatiale 95
   3.1. Analyse expérimentale 95
   3.2. Analyse simulatoire 96
      3.2.1. Définition du cadre simulatoire 97
         3.2.1.a. Modélisation du predictand 97
         3.2.1.b. Le générateur de prédictions spatio-temporelles 98
      3.2.2. Sensibilité aux paramètres régionaux 100
      3.2.3. Influences de l'agrégation et de la corrélation spatiale 102
4. Considération de deux régions hétérogènes 103

Synthèse 108

Partie III Adaptabilité du lien d'échelle par la combinaison d'un modèle analogique et d'un modèle de régression. 111

VI. Un modèle adaptatif sur la base des dates analogues 115

1. De la nécessité de s'adapter – Motivations 115

2. Modélisation des précipitations par les GLM 116
2.1. Théorie des GLM 116
2.2. Application aux précipitations 117
2.3. Détermination d'un modèle GLM approprié 118
2.3.1. La méthode d'inclusion 119
2.3.2. La méthode d'exclusion 119
2.3.3. Combinaison des méthodes d'inclusion et d'exclusion 119
3. Mise en œuvre d'un GLM sur la base des dates analogues 120
3.1. L'extraction 120
3.2. Détermination d'un modèle d'occurrence et de quantité 121
3.3. La phase d'assemblage 122

VII. Constitution d'un jeu de prédicteurs 125

1. Caractérisation des précipitations 125
1.1. Précipitation de type stratiforme 125
1.2. Précipitation de type orographique 126
1.3. Précipitation de type convective 126
2. Composition d'un jeu de prédicteurs 126
2.1. Typologie des prédicteurs 127
2.1.1. Les prédicteurs dynamiques 127
2.1.2. Les prédicteurs d'humidité 127
2.1.3. Les prédicteurs thermiques 127
2.1.4. Les prédicteurs de mouvements verticaux 128
2.1.5. Les prédicteurs de persistance 128
2.1.6. Les prédicteurs d'instabilité thermo-dynamique 128
2.2. Prédicteurs composites & autres variables 129
2.2.1. Produit de l'humidité relative par l'équivalent en eau 129
2.2.2. Flux d'humidité 129
2.2.3. Différence de températures potentielles 129
2.2.4. La vorticité potentielle 130
2.2.5. Divergence du flux d'humidité en basse couche 133
2.2.6. L'hélicité 133
3. Etude des corrélations entre prédicteurs 133

VIII. Détermination d'un modèle régressif unique d'occurrence des précipitations 139

1. Pouvoir prédictif de chacun des prédicteurs 140
2. Optimisation du modèle d'occurrence 144
3. Etude du modèle unique d'occurrence 147
3.1. Adaptation dans le temps 147
3.1.1. Fréquence d'échantillonnage des structures régressives 149
3.1.2. Variation de l'échantillonnage dans le temps 152
3.2. Cohérence spatiale des structures régressives 156
3.2.1. Cohérence spatiale et temporelle des structures régressives 156
3.2.2. Sensibilité spatiale des coefficients 156

IX. Détermination d'un modèle régressif unique de quantité des précipitations 161

1. Pouvoir prédictif de chacun des prédicteurs 161
2. Optimisation du modèle de quantité 165

3. Etude du modèle de quantité unique 167
3.1. Adaptation dans le temps 167
3.1.1. Fréquence d'échantillonnage des structures régressives 167
3.1.2. Variation de l'échantillonnage dans le temps 171
3.2. Cohérence spatiale des structures régressives 175
3.2.1. Cohérence spatiale de l'échantillonnage des structures 175
3.2.2. Cohérence spatiale des coefficients de la régression 175

X. Intérêt des mises à jour de l'occurrence et de la quantité : combinaison et contribution 179

1. Caractérisation des quatre assemblages 180
2. Contribution à l'augmentation du gain de performance 186

Synthèse 188

Conclusion & Perspectives **191**

Références Bibliographiques **199**

Annexes **211**

A. Le modèle Analog de référence 213

1. Nombre optimal de dates analogues 213
2. Sensibilité de l'optimisation de la fenêtre d'analogie à une transformation de la variable d'intérêt 214

B. Transposabilité des dates analogues en fonctions des types de temps 217

C. Simulation d'une MDES 227

1. Performance en CRPS moyen lorsque les dispersions de l'erreur et des scénarios régionaux sont égales à celle du signal régional du predictand 227
2. Expression du CRPS dans le cas d'un système de prédiction fiable 228

D. Compléments d'évaluation sur le modèle combiné 231

1. Influence de la multi-colinéarité des prédicteurs sur l'estimation des coefficients de la régression 231
2. Modèle d'occurrence 232
2.1. Pouvoir prédictif des prédicteurs 232
2.2. Illustration de la multi-colinéarité des prédicteurs 233
2.3. Fréquence d'échantillonnage des structures régressives 235
3. Modèle de quantité 243
3.1. Erreur du modèle de quantité en fonction de la complexité de la structure régressive 243
3.2. Echantillonnage des structures régressives 243
4. Mise en place d'un nouvel algorithme de sélection des structures régressives 253

Liste des symboles

β_k Coefficient du prédicteur k d'une régression, page 116

$\boldsymbol{\beta^o}$ Vecteur des coefficients de l'occurrence, page 118

$\boldsymbol{\beta^q}$ Vecteur des coefficients de la quantité, page 118

$\boldsymbol{\beta}$ Vecteur des coefficients de la régression, page 116

$\Delta\theta$ Variation de température potentielle entre les niveaux 925 et 700 hPa, page 129

Δ_Z Différence de hauteurs de géopotentiel entre 700 et 1000 hPa, page 129

η Prédicteur linéaire d'une régression, page 117

$\mathbf{X^o}$ Vecteur des prédicteurs de l'occurrence, page 118

$\mathbf{X^q}$ Vecteur des prédicteurs de la quantité, page 118

$\mathbf{X}$ Vecteur de prédicteurs, page 116

$\mathcal{P}$ Générateur spatio-temporel de prédictions gaussiennes, page 96

μ Moyenne de la quantité de précipitation, page 118

∇FR Divergence du flux d'humidité de basse couche à 850 hPa, page 133

ν Paramètre de forme d'une loi Gamma, page 118

π Probabilité qu'il précipite, page 117

σ^2 Variance de la variable quantité de précipitation, page 121

θ Température potentielle, page 130

$\widehat{\pi}_{\mathrm{MA}_{25}}$ Probabilité estimée qu'il précipite à partir du modèle MA_{25}, page 122

$\widehat{F}_{\mathrm{MA}_{25}}$ Distributions cumulées estimées des précipitations analogues, page 122

$\widehat{F}_{q,\mathrm{MA}_{25}}$ Distributions cumulées estimées des précipitations positives analogues, page 122

$\widetilde{K}_o$ Nombre de prédicteurs potentiels du modèle d'occurrence, page 121

$\widetilde{K}_q$ Nombre de prédicteurs potentiels du modèle de quantité quantité, page 121

$\widetilde{N}_d$ Nombre de dates analogues humides pour une prédiction donnée, page 120

B Baroclinicité à 700 hPa, page 129

F Résultante du vent à 700 hPa, page 129

f_0 Fréquence des pluies nulles, page 117

F_Q Distribution cumulée des précipitations positives, page 117

F_Y Distribution cumulée des précipitations, page 117

FR Flux d'humidité à 700 hPa, page 129

g Fonction lien d'un GLM, page 117

K Nombre de variables explicatives, page 116

K_o Nombre de prédicteurs de la régression logistique déterminée pour une prédiction donnée, page 121

K_q Nombre de prédicteurs de la régression logarithmique déterminée pour une prédiction donnée, page 121

O Occurrence de précipitation, page 117

Q Quantité de précipitation, page 117

R_1 Humidité relative à 850 hPa, page 129

R_2 Humidité relative à 700 hPa, page 129

R_3 Humidité relative à 500 hPa, page 129

$RTCW$ Produit de R_1 par TCW, page 129

TCW Equivalent en eau dans la colonne d'atmosphère, page 133

U Vitesse du vent zonal à 700 hPa, page 129

UR Flux d'humidité méridional à 700 hPa, page 129

V Vitesse du vent méridien à 700 hPa, page 129

VR Flux d'humidité zonal à 700 hPa, page 129

W Vitesse du vent vertical à 700 hPa, page 129

X_k k^{ème} variable explicative (ou prédicteur), page 116

Y Variable à expliquer (ou prédictand), page 116

Z_1 Hauteur de géopotentiel à 1000 hPa, page 129

Z_2 Hauteur de géopotentiel à 700 hPa, page 129

ANN Réseau de Neurones Artificiel, page 6

BIC Critère d'Information Bayésien, page 118

BS Score de Brier, page 37

CCA Analyse Canonique des Corrélations, page 8

CRPS Continuous Ranked Probability Score, page 38

CRPSS Continuous Ranked Probability Skill Score, page 42

EDF Electricité de France, page 13

EOF Fonctions Orthogonales Empiriques, page 8

GAM Modèle Additif Généralisé, page 6

GCM Modèle de Climat Global, page 3

GLM Generalized Linear Model, page 116

H Hélicité calculée entre les niveaux 1000 et 500 hPa, page 133

IRLS Iterative Re-weighted Least Squares, page 118

LAM Modèle à Aire Limitée, page 4

MCA Analyse du Maximum de Covariance, page 8

MDE Méthodes de Descente d'Echelle, page 4

MDES Méthode de Descente d'Echelle Statistique, page 5

NWP Modèle de Prévision Numérique du Temps, page 3

OHMCV Observatoire Hydro-météorologique Méditerranéen Cévennes-Vivarais, page 14

PCA Analyses en Composantes Principales, page 7

PV Vorticité potentielle à 400 hPa, page 130

RCM Modèle de Climat Régional, page 4

SAL Niveau d'Agrégation Spatial, page 92

T Température à 700 hPa, page 129

VIF Critère d'Inflation de Variance (ou Variance Inflation Factor), page 233

WG Weather Generator, page 5

Occ-1 Occurrence de précipitation de la veille, page 129

Première partie

GÉNÉRATION DE SCÉNARIOS DE PRÉCIPITATIONS SPATIALEMENT COHÉRENTS SUR LA FRANCE

Chapitre *I*

Génération de scénarios météorologiques cohérents pour les études d'impact

Les scénarios hydrologiques nécessaires aux études d'impact sont classiquement obtenus par simulation à l'aide de modèles hydrologiques sur la base de scénarios météorologiques spatiaux à haute résolution. Par exemple, dans un contexte de changement climatique, ces scénarios météorologiques correspondent à un scénario hypothétique du climat futur issu d'un modèle climatique global (ou Global Climate Model – GCM) dont le forçage représente une potentielle évolution future des gaz à effet de serre [Moss et al., 2010]. Un autre exemple peut être trouvé dans le domaine des prévisions hydro-météorologiques où les scénarios météorologiques locaux correspondent dans ce cas à l'évolution du temps pour plusieurs échéances prévues par un modèle de prévision numérique du temps (ou Numerical Weather Prediction – NWP).

De par la forte variabilité à la fois spatiale et temporelle de certaines variables locales (*e.g.* les précipitations), les champs météorologiques générés à haute résolution doivent être adaptés aux échelles spatiales et temporelles des hydro-systèmes considérés. Dans ce contexte, l'utilisation de sorties météorologiques brutes issues d'un GCM ou d'un NWP est inappropriée. Ces modèles sont basés sur des représentations simplifiées de la réalité induites non seulement par la connaissance imparfaite des processus océaniques et atmosphériques mais aussi par la nécessité de simplifier la description du milieu et des phénomènes météorologiques [Giorgi & Mearns, 1991 ; Frei et al., 2003]. Ceci implique par exemple des biais importants sur des variables importantes pour l'hydrologie telles que les précipitations dont les distributions spatiales et la variabilité restent très souvent simulées de façon irréaliste [Salathe, 2003 ; Burger & Chen, 2005]. Qui plus est, la résolution spatiale de ces modèles (variant de 200 km pour un GCM à 25 km pour un NWP) est trop souvent grossière au regard de la taille des bassins versants considérés. Les reliefs sont finalement très mal représentés dans ces modèles alors qu'ils contribuent fortement au régime des précipitations par le biais des phéno-

mènes orographiques. De façon à pallier ce problème, il est nécessaire de recourir à l'utilisation d'une Méthode de Descente d'Echelle (MDE). Ces méthodes permettent d'adapter les sorties des modèles climatiques aux échelles spatiales requises pour les études d'impacts. Elles reposent sur le fait que les conditions de grande échelle influent fortement sur les variables météorologiques locales. En pratique, deux approches sont couramment utilisées : une approche dynamique ou une approche statistique.

1. L'approche dynamique

L'approche dynamique consiste à forcer les conditions aux limites d'un modèle météorologique à aire limitée (ou Limited Area Model – LAM) par un modèle climatique global ou un modèle de prévision numérique (GCM ou NWP tournant à l'échelle du globe). Le LAM peut être représenté par un NWP dans le cas de la prévision du temps à diverses échéances ou par un modèle climatique régional (ou Regional Climate Model – RCM) dans le contexte du changement climatique. La résolution spatiale plus fine permet à ces modèles de décrire avec une plus grande précision les processus atmosphériques, la topographie et les contrastes de surface (*e.g.* terre/mer). La résolution spatiale peut atteindre 12 km dans le cas d'un RCM [*e.g.* Jacob et al., 2014] et jusqu'à 2,5 km pour le modèle français Arome [*e.g.* Seity et al., 2011] dans le cadre d'une prévision numérique du temps. Dans ces modèles, la représentation des variables repose sur des lois physiques qui permettent de respecter à la fois la cohérence temporelle, la cohérence spatiale et la cohérence physique entre variables atmosphériques. Ces trois atouts représentent les principaux avantages de ces modèles pour l'alimentation des modèles d'impacts hydrologiques. Toutefois, pour la plupart d'entre eux, certains processus sous-maille comme la formation des précipitations convectives sont représentés par des paramétrisations simplifiées.

D'autres problèmes sont rencontrés lorsque cette approche est mise en œuvre pour les études d'impacts hydrologiques, par exemple :

- Etant donné la représentation simplifiée des processus sous-mailles, les scénarios météorologiques produits se retrouvent biaisés, dont une partie du biais peut être expliquée par le forçage aux limites par le GCM ou le NWP. Il est souvent déconseillé de les utiliser directement dans le cas où la réponse au forçage est non linéaire, ce qui est souvent le cas pour les modèles d'impacts hydrologiques. Toutefois, il est possible d'adapter par des méthodes statistiques ces sorties météorologiques à des fins de modélisation hydrologique.
- De part leur résolution importante, la mise en œuvre des modèles météorologiques requiert de disposer de moyens de calculs très importants. Seuls de grands projets internationaux [*e.g.* Christensen & Christensen, 2007 ; van der Linden & Mitchell, 2009 ; Jacob et al., 2014] ou des services de prévisions météorologiques d'Etat peuvent se permettre de développer et d'améliorer si besoin les modèles pour une région spécifique.
- Même si la résolution spatiale la plus fine peut être inférieure à une dizaine de kilomètres, certains hydro-systèmes considérés couvrent une superficie inférieure à celle de la maille d'un RCM et l'utilisation des champs en sortie du modèle régional ne permet pas de représenter aussi finement la variabilité spatiale des précipitations sur le bassin versant.

2. L'approche statistique

Les Méthodes de Descente d'Echelle dite Statistique (MDES) font l'hypothèse que les variables météorologiques de surface sont fortement influencées par l'état de l'atmosphère à grande échelle, pour lequel les variables atmosphériques sont mieux simulées par les GCM (ou NWP tournant à l'échelle du globe). Plus précisément, sur la base d'un ensemble de situations passées, elles identifient dans un premier temps les liens d'échelle statistiques entre les variables de grande échelle, appelées "*prédicteurs*", et les variables météorologiques locales, appelées "*prédictands*" [1]. Dans un second temps, pour chaque jour de prédiction, l'application des liens statistiques déterminés permettent de produire des scénarios météorologiques locaux d'un prédictand donné sur la base des variables atmosphériques de grande échelle obtenues en sortie des GCM (ou des NWP). Pour les études d'impacts hydrologiques, le prédictand peut être représenté par une variable météorologique de surface en un site donné ou par une valeur agrégée de cette variable à l'échelle d'un territoire (*e.g.* un bassin versant).

De nombreuses MDES sont décrites dans la littérature. Pour une revue détaillée de ces différentes méthodes, le lecteur se référera à Fowler et al. [2007], Hingray et al. [2009, chap. 12, pour une revue en français] et plus récemment dans Maraun et al. [2010]. Selon les auteurs, ces MDES peuvent être classifiées de diverses manières. Dans cette section, nous présentons trois types de MDES : les générateurs de temps (section 2.1), les méthodes analogiques (section 2.3) et les fonctions de transfert (section 2.2). Les méthodes analogiques et les fonctions de transfert sont souvent qualifiées de "Perfect Prog" car elles visent la reproduction des variations temporelles des variables météorologiques locales sur la base des variations temporelles des prédicteurs de grande échelle.

2.1. Les générateurs de temps

Les générateurs de temps (ou Weather Generator – WG) permettent de générer des séquences temporelles à partir de l'estimation des caractéristiques des variables météorologiques locales (typiquement les premiers moments statistiques). L'estimation de ces caractéristiques est souvent conditionnée à la circulation atmosphérique par l'utilisation d'une classification en type de temps définie au préalable. Pour une prédiction, les paramètres utilisés dans le WG dépendent alors des fréquences d'occurrence des types de temps lorsque l'on considère un ensemble de prédictions. Les variations du prédictand sont alors guidées par les variations de la fréquence d'échantillonnage des types de temps.

Il existe dans la littérature de nombreux générateurs de temps. Une revue détaillée de cette approche peut être trouvée dans Wilks & Wilby [1999] et plus récemment dans Maraun et al. [2010] et Ailliot et al. [2014]. Richardson [1981] et Dubrovský [1997] développent par exemple un générateur paramétrique et prédisent les précipitations pour un site donnée selon deux étapes :

- L'occurrence est simulée par une variable aléatoire uniforme qui est ensuite comparée à la probabilité d'obtenir un jour pluvieux. Cette dernière est souvent conditionnée par l'occurrence du jour précédent.
- Un cumul de précipitation est généré à partir d'une distribution définie *a priori* pour les jours où une occurrence de précipitation est effectivement prédite.

1. Les termes de *prédicteurs* et *prédictands* sont des anglicismes. Nous devrions plutôt parler de *variables explicatives* et de *variables à expliquer*.

D'autres générateurs de temps peuvent être utilisés, comme par exemple les générateurs paramétriques à pulses rectangulaires [Evin & Favre, 2013]. Pour la génération de précipitations multi-sites, la génération de variables aléatoires pilotes multi-variées et multi-corrélées permet de garder une certaine cohérence spatiale des champs générés entre les sites [*e.g.* Keller et al., 2014]. Toutefois, la génération de champs spatiaux réalistes par le WGs n'est pas assurée [Wilks, 2012]. Finalement, un inconvénient majeur de ces méthodes est qu'elles sous-estiment la variabilité inter-annuelle observée [Wilks & Wilby, 1999].

2.2. Les fonctions de transfert

Les méthodes basées sur l'utilisation d'une fonction de transfert constituent une seconde façon de générer des séquences temporelles d'une variable de surface. Leur principe consiste à identifier puis exploiter une relation statistique entre les prédicteurs de grande échelle et le prédictand. Cette relation statistique peut se modéliser sous différentes formes : une régression linéaire [*e.g.* Karl et al., 1990], un modèle linéaire généralisé [ou Generalized Linear Model – GLM, Abaurrea & Asn, 2005 ; Frost et al., 2011], un modèle additif généralisé [ou Generalized Additive Model – GAM, Vrac et al., 2007] ou un modèle de régression non-linéaire tel qu'un réseau de neurones artificiel [ou Artificial Neural Network – ANN, Hewitson & Crane, 1996 ; Olsson et al., 2001]. Les méthodes de régression permettent d'obtenir de bonnes corrélations entre les variables reconstituées et observées. Toutefois, de nombreuses études ajoutent une perturbation stochastique à la variable simulée de façon à éviter de sous-estimer la variance temporelle de cette dernière [*e.g.* von Storch, 1999]. Tout comme les méthodes basées sur des générateurs de temps, les questions de cohérence spatiale et physique entre variables sont difficiles à gérer avec cette approche [*e.g.* Mezghani & Hingray, 2009].

2.3. Les méthodes analogiques

Les méthodes basées sur la recherche de situations analogues s'appuient sur le principe d'analogie introduit par Lorenz [1969]. Ce principe fait l'hypothèse que deux situations atmosphériques similaires donnent lieu à des situations météorologiques locales similaires. Pour une situation cible caractérisée par un ensemble de prédicteurs de grande échelle décrivant l'état et la circulation de l'atmosphère, une ou plusieurs situations analogues peuvent être retenues sur la base d'un critère d'analogie appliqué à ce jeu de prédicteurs. Pour ces situations analogues, l'extraction du prédictand dans une archive météorologique passée permet de prédire la variable météorologique de surface. Pour la constitution de séries temporelles, la valeur prédite peut alors prendre plusieurs formes : elle peut correspondre (i) à la valeur observée de la situation analogue la plus proche, (ii) à la valeur moyenne ou à une pondération des valeurs correspondant aux k-plus proches situations analogues [*e.g.* Fernandez & Saenz, 2003], (iii) à la valeur correspondant à une situation analogue sélectionnée aléatoirement parmi les k-plus proches analogues [*e.g.* Lall & Sharma, 1996 ; Lafaysse et al., 2014]. Une autre approche, issue de l'adaptation statistique des NWP, consiste à émettre une prédiction probabiliste dont la distribution est estimée empiriquement sur la base des k-plus proches situations analogues [*e.g.* pour la prévision quantitative probabiliste des précipitations, Obled et al., 2003 ; Gangopadhyay et al., 2005 ; Ben Daoud et al., 2011 ; Marty et al., 2012]. L'intérêt d'une méthode analogique est triple : (i) Aucune hypothèse n'est posée sur la distribution statistique de la

variable d'intérêt. (ii) Pour une situation cible, si une même situation analogue est appliquée pour la prédiction en plusieurs sites d'une variable de surface, le champ prédit est réaliste et la cohérence spatiale du scénario est automatiquement respectée puisqu'elle a déjà été observée. (iii) Si une même situation analogue est utilisée pour prédire en un site plusieurs variables de surface, la cohérence physique est aussi conservée [*e.g.* Bedia et al., 2013]. Cependant, l'inconvénient principal de cette méthode est qu'elle ne peut que ré-échantillonner des situations déjà observées, n'étant donc pas en mesure d'extrapoler en dehors de la gamme de valeurs observées.

2.4. La sélection des prédicteurs

Pour chacune des MDES exposées, la sélection des prédicteurs constitue une étape cruciale pour la calibration de ces dernières. Dans une majorité d'étude, ces prédicteurs sont retenus car ils possèdent un pouvoir d'information significatif [aussi appelé parfois pouvoir prédictif, Cavazos & Hewiston, 2005 ; Mezghani et al., 2012] et parce qu'ils sont corrélés avec le prédictand [*e.g.* Wilby et al., 1999 ; Abdellatif et al., 2012]. De plus, il est préférable que chaque prédicteur soit porteur d'une information différente, car la présence d'information redondante en entrée d'une MDES peut conduire à une sur-calibration de cette dernière. C'est pourquoi certains travaux ajoutent une étude de la matrice des corrélations entre prédicteurs de façon à retenir uniquement ceux qui sont le moins corrélés entre eux. Par exemple, Mezghani & Hingray [2009] se contraignent à considérer des prédicteurs qui ont une corrélation inférieure à 0,6.

Ensuite, un raffinement du jeu de prédicteurs peut être effectué à l'aide de procédures itératives de sélection. Le gain de performance apporté par l'ajout ou le retrait d'un prédicteur permet de converger vers un jeu de prédicteurs final [*e.g.* Bontron, 2004 ; Mezghani & Hingray, 2009 ; Ben Daoud, 2010]. Le choix des prédicteurs est censé dépendre de la région pour laquelle une prédiction doit être effectuée et de la saison [Cavazos & Hewiston, 2005 ; Timbal et al., 2009]. Les prédicteurs doivent être ré-optimisés pour tout nouveau site de prédiction et beaucoup d'études optimisent les prédicteurs par saisons. Idéalement, il faudrait optimiser l'ensemble des paramètres de la MDES de façon simultanée [*i.e.* ses prédicteurs et sa structure de modèle, *e.g.* Horton, 2012]. Cependant, l'exploration des différents jeux de prédicteurs possibles est généralement fastidieuse. Elle se limite par conséquent souvent à quelques jeux de prédicteurs indépendants issus d'études antérieures ou similaires.

Les prédicteurs directement issus des sorties de GCM ou de NWP sont généralement des champs grillés de grande dimension. Comme certaines variables de grande échelle sont spatialement corrélées entre elles, divers auteurs décident de transformer ces prédicteurs en un nombre réduit de variables décorrélées. Pour ce faire, une méthode largement utilisée est l'analyse en composantes principales [ou Principal Components Analysis – PCA, Preisendorfer & Mobley, 1988 ; Hannachi et al., 2007]. Cette approche permet d'exprimer une large part de la variabilité des prédicteurs selon un nombre réduit de vecteurs orthogonaux [1]. Cependant, la signification physique des prédicteurs synthétiques résultants est souvent difficile à appréhender. De plus, cette méthode ne permet pas de tenir compte du prédictand et ne conduit pas forcément à l'obtention d'un résultat optimale. Une analyse cano-

1. Ces vecteurs sont aussi dénommés fonctions orthogonales empiriques (ou Empirical Orthogonal Functions – EOF) ou encore composantes principales.

nique des corrélations (ou Canonical Correlation Analysis – CCA) ou une analyse du maximum de covariance (ou Maximum Covariance Analyse – MCA) permettent d'y remédier [Huth, 1999 ; von Storch & Zwiers, 2001].

3. Quelques questions associées à l'utilisation des MDES

Les MDES constituent des méthodes intéressantes pour pallier les biais issus d'une chaîne de modèles météorologiques ou climatologiques emboîtés (*i.e.* GCM → RCM ou NWP → LAM). Cependant, elles ne satisfont pas forcément toutes les contraintes liées à la génération de scénarios météorologiques pertinents pour l'alimentation de modèles d'impacts hydrologiques. L'une de ces contraintes majeures pour les applications hydrologiques est le respect de la cohérence spatiale des champs générés.

Comme mentionné dans la section 2, seule une MDES basée sur un ré-échantillonnage des situations analogues permet de satisfaire aisément cette contrainte. Cependant, la cohérence spatiale n'est assurée que si un même jeu de situations analogues – et donc une même paramétrisation du modèle – est considéré pour la prédiction des précipitations en plusieurs sites. Lorsque l'on considère des régions réparties sur plusieurs continents et pour lesquelles les processus atmosphériques à l'origine des précipitations diffèrent, on comprend facilement que les paramètres (*e.g.* en termes de prédicteurs et de domaines d'analogie) d'une même méthode analogique diffèrent. Lorsque deux stations pluviométriques sont relativement proches (*e.g.* distantes de quelques kilomètres), on peut à l'inverse facilement imaginer qu'un même jeu de paramètres puisse être optimal pour la prédiction de ces deux stations. La question est moins évidente lorsque l'on considère des stations réparties à l'échelle d'une région ou d'un pays, les paramètres pouvant *a priori* être relativement différents selon l'endroit géographique considéré [*e.g.* Timbal & McAvaney, 2001 ; Wetterhall et al., 2006]. A l'échelle d'un pays comme la France, par exemple, les travaux récents de Radanovics et al. [2013] suggèrent qu'une unique méthode analogique est fortement sous-optimale pour la prédiction des précipitations locales. C'est potentiellement aussi vrai à l'échelle d'une sous-région. Par exemple, Bontron [2004] montre que le domaine optimal d'analogie d'un prédicteur varie entre deux sites situés dans le Sud-Est de la France.

Pour limiter la perte de performance liée à l'utilisation d'un modèle analogique unique, il est possible de réduire l'étendue du territoire sur lequel appliquer le modèle. Le territoire peut être identifié de sorte que les prédicteurs et les domaines d'analogie optimaux pour la prédiction monosite soient les mêmes pour l'ensemble des sites contenus dans ce territoire. Ainsi, Radanovics et al. [2013] suggèrent d'identifier des zones homogènes en termes de prédicteurs et de prédictands pour la France. Toutefois, même lorsque les prédicteurs choisis correspondent aux mêmes variables atmosphériques, les domaines d'analogie optimaux obtenus pour deux sites voisins peuvent légèrement différer. L'identification de régions homogènes en termes de domaines d'analogie est donc une tâche difficile. La difficulté est accentuée du fait que les domaines sont identifiés sur la base de produits grillés issus de ré-analyses ou de GCM. De par la discontinuité de ces données dans l'espace, le domaine optimisé pour la prédiction d'une variable locale a en fait peu de chance d'être le domaine optimal réel. Différents domaines d'analogie peuvent conduire à des performances équivalentes, par ailleurs

proches de la performance optimale. On fait donc face à un problème classique d'équifinalité [Beven, 2006], tel que montré par exemple par Radanovics et al. [2013]. Par conséquent, l'optimisation du domaine d'analogie pour un site donné conduit souvent à l'identification d'un domaine qui n'est que quasi-optimal et qui peut être par conséquent différent du domaine quasi-optimal identifié pour un site voisin. Avec ces contraintes, l'identification de régions homogènes en termes de prédicteurs et de domaines d'analogie est donc potentiellement difficile.

Une autre façon d'aborder la question de la cohérence spatiale consiste à évaluer la perte de performance obtenue par un modèle analogique dont les paramètres sont optimisés pour un ensemble de stations par rapport à la performance obtenue par le modèle optimal de chaque station. Comme l'a exposé Bontron [2004, pp. 142] dans son manuscrit de thèse, il peut être envisagé de *"déterminer la distance pour laquelle il est raisonnable d'utiliser un domaine commun pour rechercher des situations analogues pour deux stations"*. De ses résultats, il suggère qu'un même domaine d'analogie peut être considéré dès lors que :

- L'inter-distance entre deux stations est inférieure à 250 km.
- Aucune barrière climatique telle que les Alpes ne se situe entre ces deux stations.

Dans cette thèse, nous proposons une approche légèrement différente de celle exposée par Bontron [2004]. Elle consiste à évaluer la transposabilité spatiale d'un modèle analogique en évaluant la capacité d'un modèle optimisé pour un site donné à être appliqué en un autre site. Similairement à Bontron [2004], l'évaluation de la transposabilité spatiale d'un modèle donné en un site est effectuée par l'évaluation de la perte de performance qui résulte de l'application d'un modèle optimisé pour un site distant au lieu du modèle optimisé pour le site cible. Cette approche, qui a été appliquée pour une méthode Analog précédemment développée au LTHE par Bontron [2004], nous permettra dans un premier temps de répondre aux questions suivantes :

Sur quelle étendue spatiale est-il possible de générer des scénarios performants et spatialement cohérents ? En d'autres termes, une MDES analogique développée spécifiquement pour une région donnée peut-elle être facilement transposable pour la prédiction en des sites voisins ? Si oui, jusqu'à quelle distance la transposition spatiale est-elle raisonnable ?

Comme mentionné précédemment, la génération de scénarios cohérents sur un territoire donné constitue une nécessité pour les applications hydro-météorologiques régionales et les analyses hydrologiques en particulier. Elle peut, sous certaines conditions, être effectuée à l'aide de méthode analogique. La possibilité de prédire correctement la moyenne spatiale de la variable considérée sur le territoire visé est aussi fortement souhaitée dès lors que l'on s'intéresse à des questions relatives à la ressource en eau ou aux crues à l'échelle d'un bassin versant.

On pourrait penser que la performance de prédiction est dépendante du niveau d'agrégation de la variable considérée. L'effet de lissage lié au processus d'agrégation réduisant la variabilité de la variable à prédire, on peut s'attendre à ce que la performance de prédiction soit plus importante pour une précipitation agrégée que pour une précipitation locale. Ce résultat est par exemple exposé

par Mezghani & Hingray [2009] qui ont comparé les performances de prédiction des précipitations obtenues à l'échelle de la station, à l'échelle du bassin versant du Rhône à l'amont du Léman et à l'échelle de ses six sous-bassins versants. Ce résultat a déjà été mis en lumière par Gangopadhyay et al. [2004] avec toutefois quelques nuances, dues au nombre de stations utilisées pour la construction d'une précipitation agrégée.

A notre connaissance, peu d'analyses traitent de ce sujet. Les études exposées par Gangopadhyay et al. [2004] et Mezghani & Hingray [2009] laissent penser que les performances de prédiction augmentent continûment avec l'échelle d'agrégation spatiale. Cependant, on peut se demander s'il existe une échelle d'agrégation spatiale pour laquelle un optimum de prédiction pourrait être obtenu, en particulier lorsque les précipitations régionales moyennes à prédire résultent d'un mixte très hétérogène de situations météorologiques locales.

Pour répondre à ces questions, nous utiliserons un modèle Analog optimisé pour la France. Nous considérerons en particulier les questions suivantes :

Quelle est la performance de la prédiction lorsque celle-ci vise une précipitation moyenne à l'échelle d'un territoire donné ? Comment cette performance évolue-elle lorsque le territoire considéré est de plus en plus vaste ?

Dans ce cas, l'utilisation d'un jeu de données telle qu'une ré-analyse météorologique de surface pour laquelle le prédictand est réparti selon un maillage régulier et homogène dans l'espace constitue alors un réel avantage par opposition aux limites atteintes par l'hétérogénéité rencontrée au travers d'un découpage spatial effectué sur la base de critères hydrologiques [*e.g.* Gangopadhyay et al., 2004 ; Mezghani & Hingray, 2009].

Comme suggéré précédemment, l'utilisation d'une unique approche analogique pour un territoire donné permet *a priori* de prédire des scénarios spatialement cohérents à l'échelle du territoire. Cela conduit aussi potentiellement à une prédiction très sous-optimale par rapport à l'utilisation d'un modèle optimisé localement pour chaque site. Si l'on veut assurer la cohérence spatiale sur un territoire donné, il est donc nécessaire de trouver un compromis entre sa taille et la perte de performance subie en chacun de ses sites. Ce compromis est imposé du fait que la prédiction est effectuée à l'aide d'un unique modèle d'analogie. Dans la dernière partie de cette thèse, nous explorons l'intérêt d'une stratégie alternative qui permet de relaxer cette contrainte. Nous tentons en particulier d'apporter des éléments de réponse à la question suivante :

Lorsqu'une MDES analogique est utilisée pour la prédiction en plusieurs sites, est-il possible d'améliorer la performance de prédiction par l'utilisation de prédicteurs additionnels en chacun des sites tout en conservant sa cohérence spatiale sur un large territoire ?

Nous explorons à cet effet le potentiel d'un modèle de prédiction hybride où la prédiction obtenue à l'aide d'un modèle analogique simple est affinée à l'aide d'un modèle de régression, basé sur les

situations analogues retenues pour chaque prédiction. Le modèle de régression, exploitant divers prédicteurs atmosphériques additionnels, s'inspire du modèle d2gen développé à l'EPFL dans le cadre des travaux de thèse de Mezghani [2009] puis au LTHE dans le contexte du projet RIWER2030 [*cf.* Mezghani & Hingray, 2009 ; Hingray et al., 2013 ; Lafaysse et al., 2014].

Chapitre II

Modèles & Données

Dans ce chapitre, nous présentons dans une première section (section 1) le modèle Analog [Bontron, 2004] sur laquelle l'ensemble de nos travaux sont basés. Nous exposons aussi le modèle d2gen [Mezghani & Hingray, 2009] considéré pour la mise en place d'un modèle de régression dans la partie III de cette thèse. La deuxième section de ce chapitre (section 2.2) présente et décrit les caractéristiques des précipitations de la ré-analyse Safran à l'échelle de la France. La description de ce jeu de données est effectuée par saison et pour une classification en types de temps.

1. Les descentes d'échelle statistiques retenues

1.1. La MDES Analog

Le modèle Analog appliquée dans cette thèse a été à l'origine développée pour la prévision quantitative journalière des précipitations en France. Les travaux ont été initiés à EDF (Electricité De France) par Duband [1970] pour la gestion de la ressource en eau liée à la production hydroélectrique et l'anticipation du risque d'inondation lié aux crues rapides. Il s'agissait alors d'une méthode statistique dont l'analogie était effectuée sur les champs de pression observés du jour à prédire. Comme les NWP devenaient de plus en plus performants dans les années 1980, l'approche est devenue une méthode d'adaptation statistique [1]. Guilbaud [1997] dans ces travaux de thèse a amélioré la méthode par la détermination d'un critère d'analogie mieux adapté. Ensuite, Bontron [2004] a déterminé de meilleures variables d'analogie (*i.e.* leurs niveaux et leurs fenêtres temporelles) permettant d'augmenter les performances de la méthode par l'ajout d'un second niveau d'analogie appliqué sur la base d'une information d'humidité extraite des situations analogues en terme de hauteurs de géopo-

1. Un lecteur intéressé trouvera un historique de l'évolution de cette méthode pour la période 1970–1995 dans Guilbaud [1997, pp. 23–34].

tentiel [1]. Ben Daoud [2010] a étendu la méthode à de grands bassins versants que sont ceux de la Seine à Paris et de la Saône à Lyon alors qu'elle était initialement développée pour des précipitations sur des bassins majoritairement situés dans le Sud-Est de la France. La présélection de situations analogues – auparavant déterminée par une fenêtre saisonnière centrée sur la situation cible – a été améliorée par une analogie sur les températures. De plus, un troisième niveau d'analogie basé sur la vitesse verticale a permis d'améliorer les performances du modèle Analog sur les bassins considérés. Marty [2010] a quant à lui ajouté une étape de post-traitement de façon à corriger les biais de la méthode et à désagréger les précipitations à l'échelle infra-journalière pour la prévision probabiliste des débits de bassins à crues rapides.

Un point commun de ces études est qu'elles se situent toutes dans un contexte de prévision. La prédiction des précipitations émise sous la forme d'une distribution empirique [2] est effectuée pour la situation cible mais aussi pour plusieurs échéances à venir [3] (*e.g.* jusqu'à J+6). De plus, la variable à prédire était une précipitation homogène sur une surface donnée issue d'une pondération de précipitations mesurées à l'aide de pluviographes. Dans cette thèse, le contexte est élargi à celui de la génération de scénarios météorologiques, pour les études d'impacts hydrologiques, qui soient adaptés spatialement à la surface considérée. La prédiction ne concerne plus une valeur agrégée représentative de la précipitation à l'échelle du bassin mais plutôt la prédiction d'un champ de précipitations locales à l'échelle d'un territoire donné. Toutefois, certains des résultats montrés dans cette étude peuvent être également appliqués pour la prévision des précipitations.

Comme il a été mentionné à la section 2.3, un des intérêts des approches par recherche d'analogues concerne la reproduction de la cohérence spatiale : pour un modèle Analog, les situations analogues retenues permettent d'extraire les valeurs de précipitation correspondantes en tout site sur le territoire. Les champs prédits par la méthode sont des champs réalistes car ils ont été auparavant déjà observés (*cf.* figure II.1). En pratique, ces situations analogues sont référencées par un indice par rapport à une origine temporelle et un pas de temps donné. Par exemple, si la date du 25-01-1958 est choisie comme situation analogue, que l'origine temporelle correspond au 01-01-1958 et le pas de temps est journalier, alors l'indice temporel est égal à 24, car le nombre de jours entre ces deux dates est égal à 24. Si la date du 02-02-1959 est retenue, l'indice temporel sera alors égal à 397. Comme nous venons de le voir, ces indices réfèrent à des dates, qui elles-mêmes correspondent à des situations observées. Dans la suite de ce document, nous nous référons souvent aux situations analogues par le terme de *"dates analogues"*, faisant référence à ce système d'indices. Le nombre de dates analogues retenues par un modèle Analog pour la prédiction en un jour cible donné est noté N_d.

Comme nous avons pu le constater, plusieurs versions d'une approche analogique issues des différents développements historiques sont disponibles. Dans notre thèse, nous utilisons un seul modèle Analog à un niveau d'analogie dérivé des travaux de Bontron [2004]. Les paramètres du modèle sont les suivants :

1. Une démonstration de l'application de cette méthode pour la prévision des précipitations sur des bassins du Sud-Est de la France est illustrée sur le site de l'OHMCV [Observatoire Hydro-météorologique Méditerranéen Cévennes-Vivarais – `www.ohmcv.fr`, Marty et al., 2012]

2. Excepté pour la période entre 1970 et 1990 où les prévisions étaient alors émises par l'intermédiaire de trois quantiles : les quantiles 20, 60 et 90%.

3. Une étude de sensibilité des performances en fonction de l'échéance de prédiction a par ailleurs été menée par Thévenot [2004].

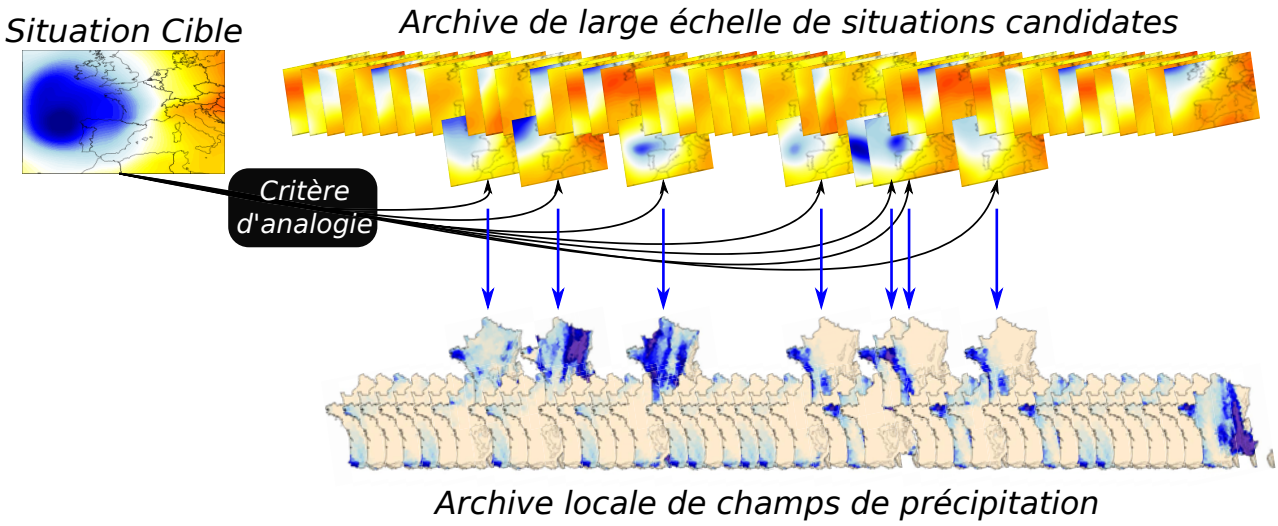

FIGURE II.1 – Illustration schématique de la sélection de situations analogues pour une situation cible donnée.

- L'analogie correspond à **une analogie de circulation atmosphérique** car elle porte sur les hauteurs des géopotentiels Z_{1000} +12h et Z_{500} +24h. Les échéances temporelles +12h et +24h permettent d'encadrer le pas de temps journalier sur lequel les précipitations sont cumulées (ici de 06h00 UTC J à 06h00 UTC J+1).
- Les dates analogues sont retenues à l'aide d'une **analogie de forme** appliquée sur la circulation atmosphérique. GUILBAUD [1997] a montré qu'une analogie de forme à l'aide du critère TWS [TEWELESS & WOBUS, 1954] appliqué directement sur les hauteurs de géopotentiel permettait d'obtenir de meilleures performances de prédiction qu'une analogie basée sur la distance Euclidienne appliquée sur les composantes principales, préalablement dérivées des prédicteurs.
- Un **filtre saisonnier** permet de pré-sélectionner les dates analogues dans une fenêtre calendaire de ± 2 mois centrée autour du jour cible. Ce filtre permet, par exemple, pour une situation cible d'été, de ne pas conserver de situations d'hiver qui pourraient toutefois être analogues selon les hauteurs de géopotentiels, mais qui ne conduiraient pas aux mêmes effets locaux. Les jours correspondant à l'année du jour cible sont retirés de l'archive des jours analogues.
- Le **domaine d'analogie** dépend de la localisation de la précipitation à prédire. Un même domaine d'analogie est toutefois considéré pour les géopotentiels Z_{1000} +12h et Z_{500} +24h.

Les principales raisons qui nous ont conduites à retenir cette version du modèle Analog sont les suivantes :

i. Les différentes versions du modèle Analog ont été optimisées pour le Sud-Est de la France ou certains grands bassins comme la Seine ou la Saône. Dans cette thèse, la prédiction des précipitations est effectuée sur l'ensemble du territoire français. Dans ce cas, un modèle très optimisé pour une région donnée (*i.e.* que ce soit le modèle Analog à deux niveaux d'analogie de BONTRON [2004], ou celui optimisé par BEN DAOUD [2010] pour les bassins de la Seine et de la Saône) n'est peut-être pas adapté pour la prédiction des précipitations en d'autres endroits (comme par exemple dans le Nord de la France où la Bretagne). Par conséquent, nous avons décidé de retenir un modèle Analog seulement basé sur les géopotentiels car nous supposons *a priori* qu'ils sont déjà explicatifs d'une partie importante de la variabilité des précipitations sur l'ensemble du territoire français.

ii. L'utilisation d'un modèle Analog simple nous permet de le considérer comme un modèle de référence pour la génération de scénarios météorologiques spatialement cohérents.

Dans la suite de ce document, le modèle Analog à un seul niveau d'analogie basé sur les hauteurs de géopotentiel est noté MA. L'adaptation de ce modèle à notre contexte est décrite au chapitre III.

1.2. La MDES d2gen

La MDES d2gen a été initialement développée pour la génération de champs de précipitation et de température sur le bassin du Rhône à l'amont du Léman en Valais (Suisse). [Mezghani & Hingray, 2009]. Cette méthode a ensuite été adaptée au LTHE dans le cadre du projet RIWER2030 [1] [Hingray et al., 2013] pour la génération de séries temporelles de précipitations et de températures sur le bassin de la Durance. Ces séries ont par suite été évaluées et comparées à celles issues de deux autres MDES dans la thèse de Lafaysse [2011]. La MDES d2gen est illustrée à la figure II.2 et se décompose en trois parties :

1. Pour un territoire donné (*e.g.* un bassin versant), la précipitation moyenne est modélisée en deux étapes : la première concerne la probabilité d'occurrence de précipitation, la seconde la quantité de précipitation. La probabilité d'occurrence et la quantité de précipitation sont modélisées à l'aide d'un modèle linéaire généralisé (ou Generalized Linear Model – GLM). Dans le projet RIWER2030 [Hingray et al., 2013], plusieurs jeux de prédicteurs ont été testés pour chacun de ces deux modèles. Ils regroupent des indices de circulation atmosphérique tels que la pression réduite au niveau de la mer, les composantes zonales et méridiennes des vents géostrophiques à 700 hPa ainsi que des prédicteurs thermodynamiques tels que l'humidité relative, l'humidité spécifique et le flux d'humidité spécifique à 700 hPa. De plus, un prédicteur de persistance correspondant à l'occurrence de précipitation le jour précédent la journée cible permet de tenir compte de l'auto-corrélation temporelle des précipitations. Les prédicteurs considérés ne varient pas selon les saisons, alors que les paramètres des modèles GLM dépendent de la saison.
2. Pour un jeu de prédicteurs, les régressions établies à l'étape 1 permettent d'estimer pour un jour cible donné les espérances de l'occurrence (autrement dit la probabilité qu'il précipite) et de la quantité de précipitation. Les résidus des deux modèles GLM pour l'occurrence et la quantité de précipitation permettent de générer différents scénarios locaux.
3. Dans le but de prédire les champs de précipitation pour le bassin versant considéré, une étape de désagrégation spatiale est effectuée. A partir du scénario régional généré à l'étape 2, k plus proches journées analogues sont retenues selon une distance euclidienne appliquée à la précipitation moyenne. Au travers d'un tirage aléatoire dont la probabilité de tirage est inversement proportionnelle à la distance euclidienne d'analogie, une situation analogue est échantillonnée et permet de rejouer une structure spatiale observée de champs de précipitation. L'intérêt de l'approche analogique utilisée ici est de générer des structures spatiales de précipitations et de températures connues et par conséquent de respecter la cohérence spatiale et physique de ces variables.

Dans ces travaux de thèse, nous explorerons l'intérêt de combiner cette approche à la méthode analogique présentée à la section 1.1. Nous ne considérerons que les deux seules premières étapes

1. http://www.lthe.fr/RIWER2030/

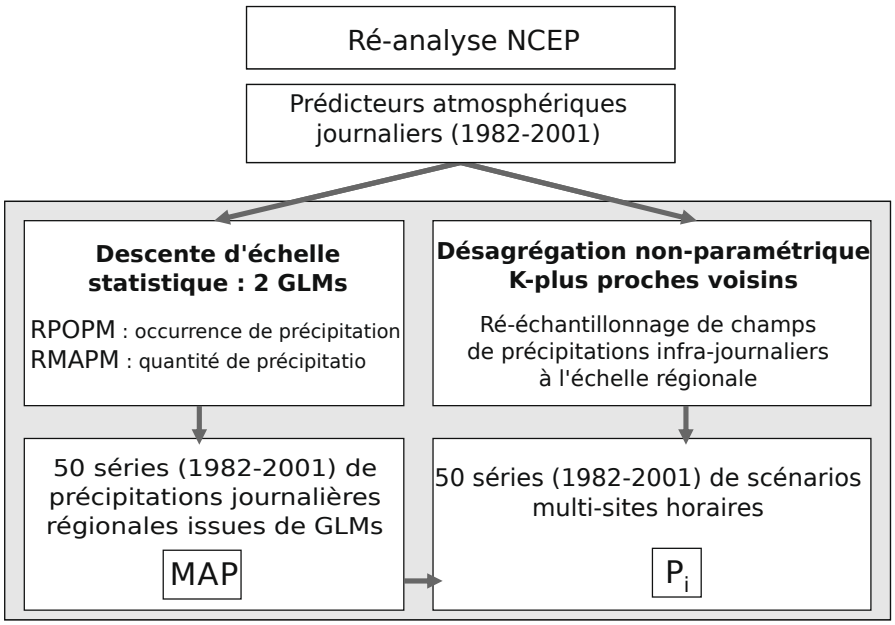

FIGURE II.2 – Schéma du modèle d2gen, adapté de MEZGHANI & HINGRAY [2009].

de la génération proposées dans d2gen, visant respectivement la détermination des régressions et l'estimation de la distribution des précipitations à partir de la variance des résidus.

2. Données

2.1. Les ré-analyses ERA-40

Les variables atmosphériques retenues comme prédicteurs de grande échelle sont extraites des ré-analyses ERA-40 [UPPALA et al., 2005] à une résolution spatiale égale à 1,125×1,125° de longitude/latitude et une résolution temporelle de 06h00. A l'origine, le modèle Analog a été développé par BONTRON [2004] sur la base des ré-analyses NCEP/NCAR [KALNAY et al., 1996], disposant alors d'une résolution spatiale de 2,5×2,5° de longitude/latitude et d'une résolution temporelle égale à 12h00. Par la suite, BEN DAOUD et al. [2009] ont montré que les ré-analyses ERA-40 à une résolution de 2,5×2,5 ° permettaient d'obtenir légèrement de meilleures performances comparé à l'utilisation des ré-analyses NCEP/NCAR. Dans ses travaux de thèse, BEN DAOUD [2010] a montré que la considération d'une résolution spatiale égale à 1,125×1,125° de l'archive ERA-40 menait seulement à un léger gain de performance par rapport à l'utilisation de cette même archive à la résolution 2,5×2,5°. Nous avons décidé de retenir la résolution 1,125×1,125° car elle permet de limiter les problèmes de discontinuité liés à la recherche d'un domaine spatial d'analogie entre deux mailles voisines (comparativement à la résolution de 2,5×2,5°).

2.2. Les ré-analyses Safran

Dans cette thèse, la précipitation utilisée est issue du système de ré-analyse Safran/France développé pour le territoire français [QUINTANA-SEGUI et al., 2008 ; DURAND et al., 2009 ; VIDAL et al.,

2010] [1]. Pour cette ré-analyse, la France est découpée en zones *Symposium* supposées homogènes en terme de fonctionnement météorologique. De telles zones sont utilisées pour la prévision météorologique à courte échéance à Météo-France. Au sein d'une zone, la précipitation ne dépend que de l'altitude et de l'exposition. Une première ébauche est d'abord établie quotidiennement à 06h00 UTC par la constitution d'un champ climatologique constant obtenu pour le type de temps auquel appartient la journée cible. Elle est par la suite affinée grâce aux observations disponibles par la méthode d'interpolation optimale [Gandin, 1965]. La résolution verticale de cette analyse est de 300 mètres. Les valeurs analysées sont ensuite interpolées au pas de temps horaire.

Les ré-analyses Safran/France sont initialement délivrées pour un ensemble de 608 zones couvrant le territoire français. La ré-analyse est toutefois disponible sous un format grillé où les données ont été interpolées à partir des zones sur un ensemble de 8 981 mailles d'une résolution de 8×8 km^2 en fonction de l'altitude de chaque maille. Les données du format grillé n'ont *a priori* pas de valeur ajoutée par rapport à celles du format en zones Symposium. Toutefois, *a contrario* d'une discrétisation en zones, un support grillé nous permet une meilleure estimation de certaines échelles spatiales qui seront évaluées par la suite. Cela nous permettra en particulier d'explorer de façon systématique l'évolution de la performance de prédiction en fonction de l'échelle d'agrégation spatiale du prédictand.

Par suite, les ré-analyses Safran/France sont dénommées simplement par le terme de ré-analyses Safran. Elles contiennent également d'autres variables météorologiques, à savoir la température, l'humidité relative, la vitesse du vent, les rayonnements de courtes et grandes longueurs d'ondes et la nébulosité. Ces variables ne sont pas utilisées dans cette thèse. Pour une description plus exhaustive des ré-analyses Safran, le lecteur est invité à lire Durand & Brun [1993], Quintana-Segui et al. [2008], Durand et al. [2009] et Vidal et al. [2010].

Dans cette étude, le prédictand considéré est représenté par la précipitation totale (pluie et neige) journalière en chaque maille Safran. Comme de nombreuses observations de précipitations assimilées dans les ré-analyses sont des précipitations journalières correspondant aux cumuls entre 06h00 UTC à J et 06h00 UTC à J+1, les précipitations journalières considérées dans cette thèse sont issues d'une agrégation appliquée sur la même fenêtre temporelle. Dans la suite de cette section, une évaluation globale (section 2.2.1), saisonnière (section 2.2.2) et selon une classification en type de temps (section 2.2.3) des précipitations journalières Safran est effectuée sur la France pour la période 1982–2001.

2.2.1. Climatologie des précipitations Safran

Dans cette section, nous montrons les résultats d'une évaluation climatologique des précipitations Safran pour la période allant du 01-08-1982 au 31-07-2001. La figure II.3 représente le cumul moyen journalier obtenu en chacune des mailles Safran. La précipitation journalière moyenne est la plus importante sur les reliefs, car ces derniers constituent des obstacles aux différents flux principalement originaires de l'Atlantique ou de la Méditerranée. Ils regroupent le Nord des Alpes, l'Ouest du Massif Central, les massifs des Cévènnes et du Vivarais, les Vosges ainsi que les Pyrénées où les valeurs rencontrées peuvent être supérieures à 4 mm (*i.e.* ce qui correspond à un cumul annuel moyen supérieur à 1460 mm). En plaine, les précipitations sont plus faibles et varient entre 1,5 et 2 mm par jour (respectivement 547 et 730 mm de cumul annuel). Les valeurs les plus faibles sont observées le

1. Une version similaire de cette ré-analyse – nommée Safran/Alpes – a initialement été développée spécifiquement pour le massif Alpin dans un contexte de prévision du risque d'avalanches [Durand & Brun, 1993].

long de la côte méditerranéenne relativement bien protégée des flux d'Ouest par le Massif Central. Le long de la côte Atlantique, les valeurs de précipitations journalières moyennes sont légèrement plus importantes. Elles se situent aux environs de 2,5 mm par jour (soit 913 mm de cumul annuel moyen).

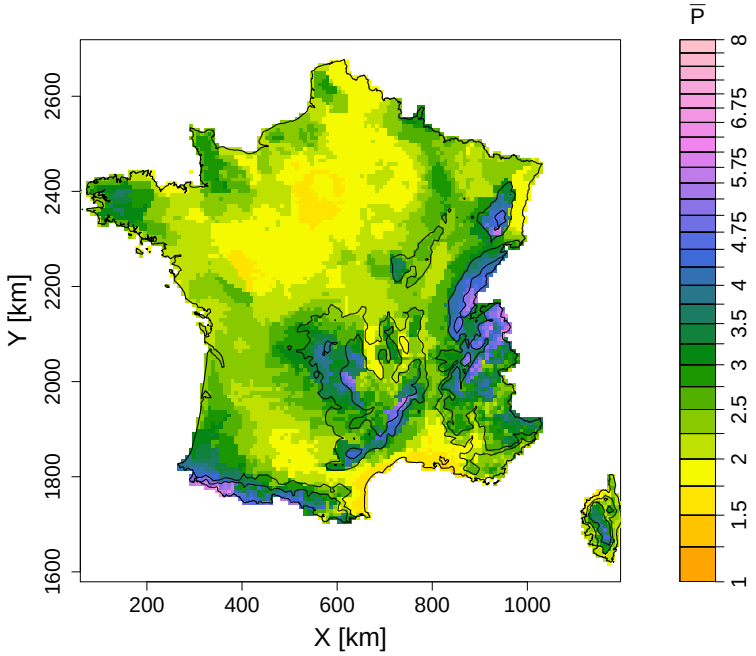

FIGURE II.3 – Moyenne [mm] des précipitations Safran calculée sur la période allant du 01-08-1982 au 31-07-2001. Les lignes de reliefs à 400 et 800 mètres d'altitude sont tracées en noir. Elles seront utilisées dans de nombreuses figures par la suite.

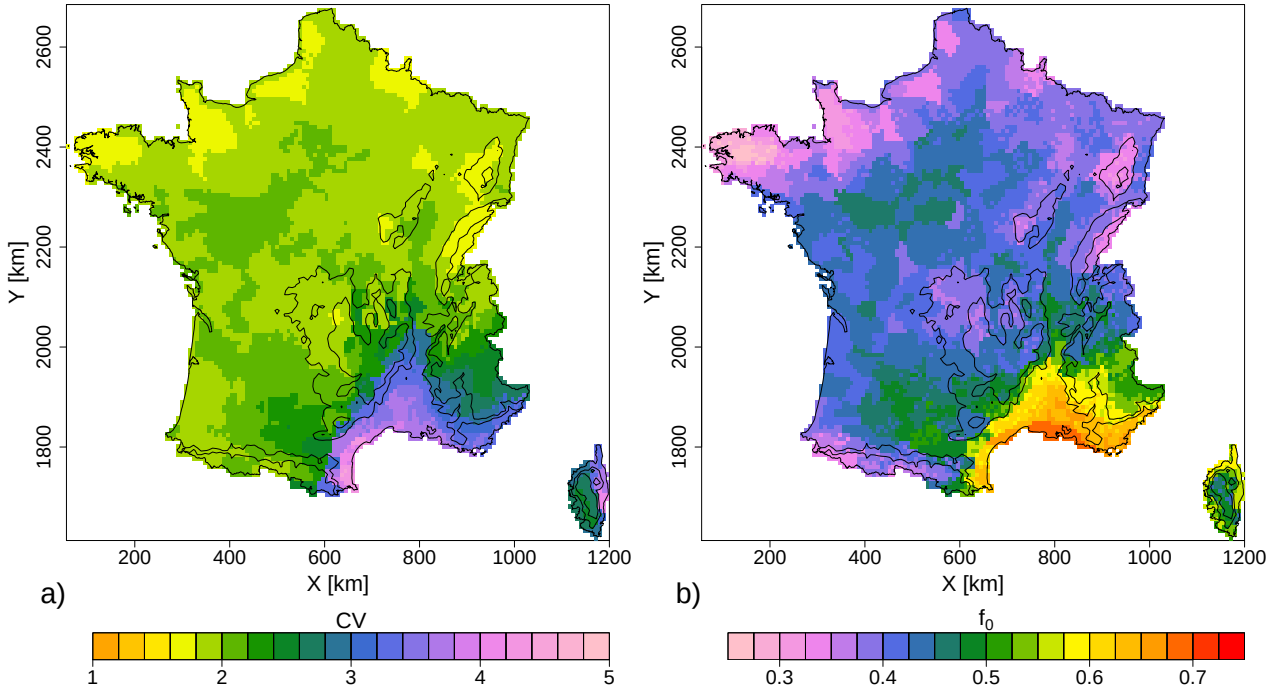

FIGURE II.4 – a) Coefficient de variation CV et b) Fréquence des jours secs f_0 des précipitations Safran calculés sur la période allant du 01-08-1982 au 31-07-2001.

La figure II.4.a) représente le coefficient de variation des précipitations journalières sur l'ensemble du territoire français. Il est en moyenne inférieur à 3 pour une large majorité de la France. Seule la région du Sud-Est de la France obtient un coefficient de variation supérieur à cette valeur. Il s'explique par la présence d'orages locaux pouvant s'accompagner de forts cumuls parfois à l'origine de crues rapides. La figure II.4.b) représente le pourcentage de jours secs (*i.e.* les jours pour lesquels la précipitation observée est inférieure à 0,1 mm), noté f_0. La Bretagne, les Vosges, le Jura et l'Ouest du Massif Central correspondent aux régions pour lesquelles la fréquence des jours secs est la plus faible (entre 30% et 35% de jours secs). En plaine, cette fréquence varie en moyenne entre 40 et 50%, excepté dans le Sud-Est de la France où elle varie entre 55 et 75%.

2.2.2. Climatologie saisonnière

Similairement à la figure II.3, il est possible de calculer les valeurs de précipitations journalières moyennes pour chaque saison. De façon à déterminer si une saison est à tendance plus humide ou plus sèche, le cumul saisonnier moyen est comparé au cumul journalier moyen par le biais d'un quotient. Si ce quotient est supérieur à 1, la saison considérée est plutôt humide par rapport à la moyenne globale. Dans le cas inverse, elle est considérée plutôt sèche.

La figure II.5 représente le quotient des précipitations journalières moyennes de chaque saison par rapport à la précipitation moyenne annuelle. Les saisons les plus humides sont l'hiver, l'automne et le printemps. La précipitation moyenne pour ces trois saisons est du même ordre que la précipitation moyenne annuelle. Toutefois, en hiver, la précipitation moyenne est plus faible pour les vallées du Rhône, de la Loire et de l'Allier. En automne, les précipitations observées dans le Sud-Est de la France sont presque deux fois plus importantes en cette région, dû aux évènements précipitants d'origine convective. La saison d'été correspond, quant à elle, à la saison sèche. Quasiment l'ensemble des mailles Safran obtient un quotient de précipitations moyennes inférieur à 1.

2.2.3. Climatologie par type de temps

La section 2.2.2 a montré que seule la saison estivale se démarquait des autres saisons avec des cumuls faibles sur l'ensemble de la France, les autres saisons étant considérées comme humides. En une maille donnée, les précipitations moyennes diffèrent aussi suivant les types de temps considérés. Dans cette section, nous évaluons les précipitations Safran selon une classification en type de temps définie par Garavaglia et al. [2010]. Une approche *"bottom-up"* combinant un algorithme de classification hiérarchique ascendante appliquée à la forme des champs journaliers de précipitations et une méthode analogique a permis de déterminer huit types de circulations atmosphériques contrastées pour la France (tableau II.1).

Sur la figure II.6, le géopotentiel moyen à 1000 hPa à 00h00 UTC permet d'avoir un aperçu des circulations moyennes correspondant à ces types de temps (TT) pour la période allant du 01-08-1982 au 31-07-2001. Les flèches noires indiquent la direction des flux atmosphériques de basse couche. Similairement à la figure II.5, la figure II.7 représente le quotient de la précipitation journalière moyenne pour un type de temps considéré par rapport à la précipitation moyenne annuelle représentée à la figure II.3. La figure II.8 représente la fréquence des jours secs pour chaque type de temps.

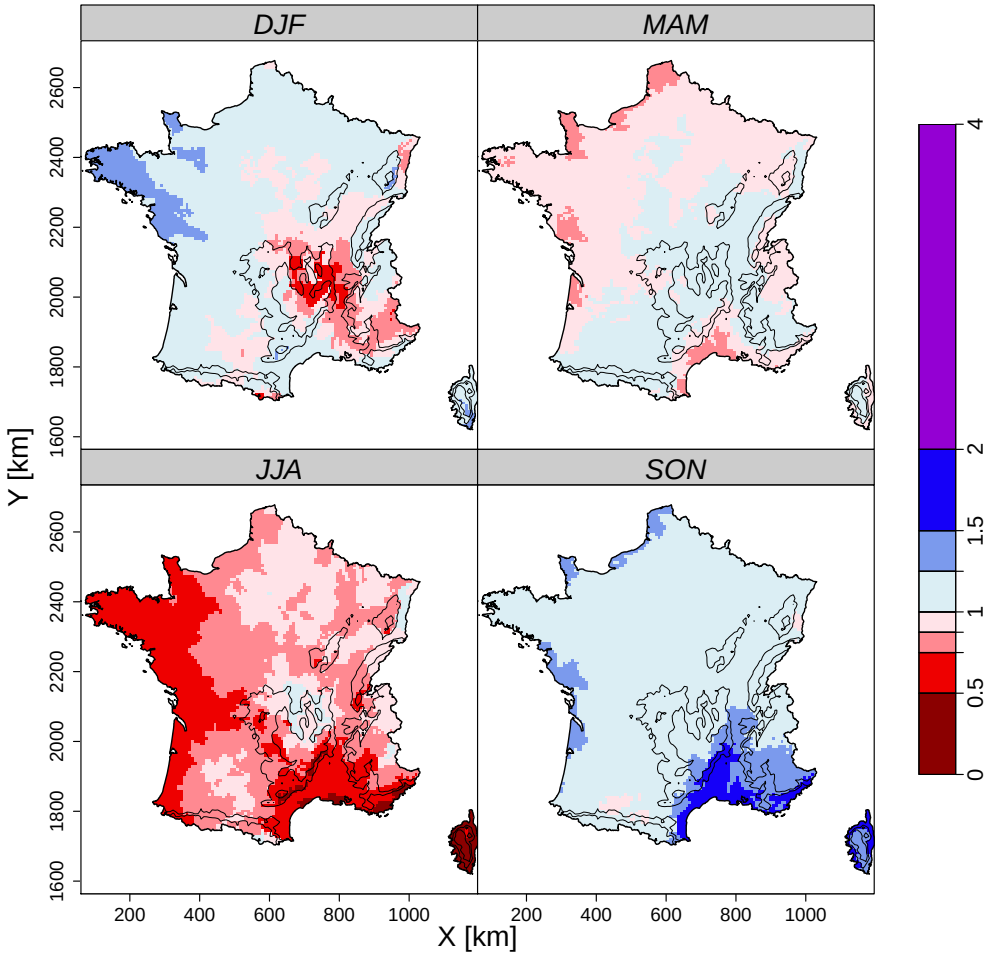

FIGURE II.5 – Ratio de la précipitation moyenne saisonnière par rapport à la précipitation moyenne annuelle globale.

Tableau II.1 – Fréquence des types de temps pour la période s'étendant du 01-08-1982 au 31-07-2001. Adapté de GARAVAGLIA et al. [2010].

Classe	Nom du TT	Global	Hiver	Printemps	Eté	Automne
TT1	Onde Atlantique	8%	10%	8%	8%	7%
TT2	Océanique Stationnaire	22%	34%	26%	12%	23%
TT3	Circulation de Sud-Ouest	8%	5%	7%	13%	7%
TT4	Circulation de Sud	17%	16%	17%	13%	24%
TT5	Circulation de Nord-Est	6%	7%	7%	7%	5%
TT6	Retour d'Est	6%	5%	7%	6%	4%
TT7	Dépression Centrale	4%	3%	4%	3%	4%
TT8	Situation Anticyclonique	29%	20%	24%	38%	26%

Dans cette classification, les TT2, TT1 et TT3 correspondent à des circulations synoptiques provenant de l'Atlantique. Les précipitations moyennes associées à ces types de temps sont retrouvées sur l'ensemble du territoire français, excepté dans le Sud-Est de la France pour le TT2 pour lequel la fréquence des jours secs est proche de 75% (figure II.8). Les TT7, TT4 et TT6 correspondent à des circulations synoptiques d'origine méditerranéenne. Le TT7 impacte l'ensemble du territoire avec une précipitation moyenne pouvant être plus de quatre fois supérieure à la moyenne annuelle en certains endroits. Le TT6 conduit, quant à lui, à des précipitations localisées dans le Sud de la France. Le

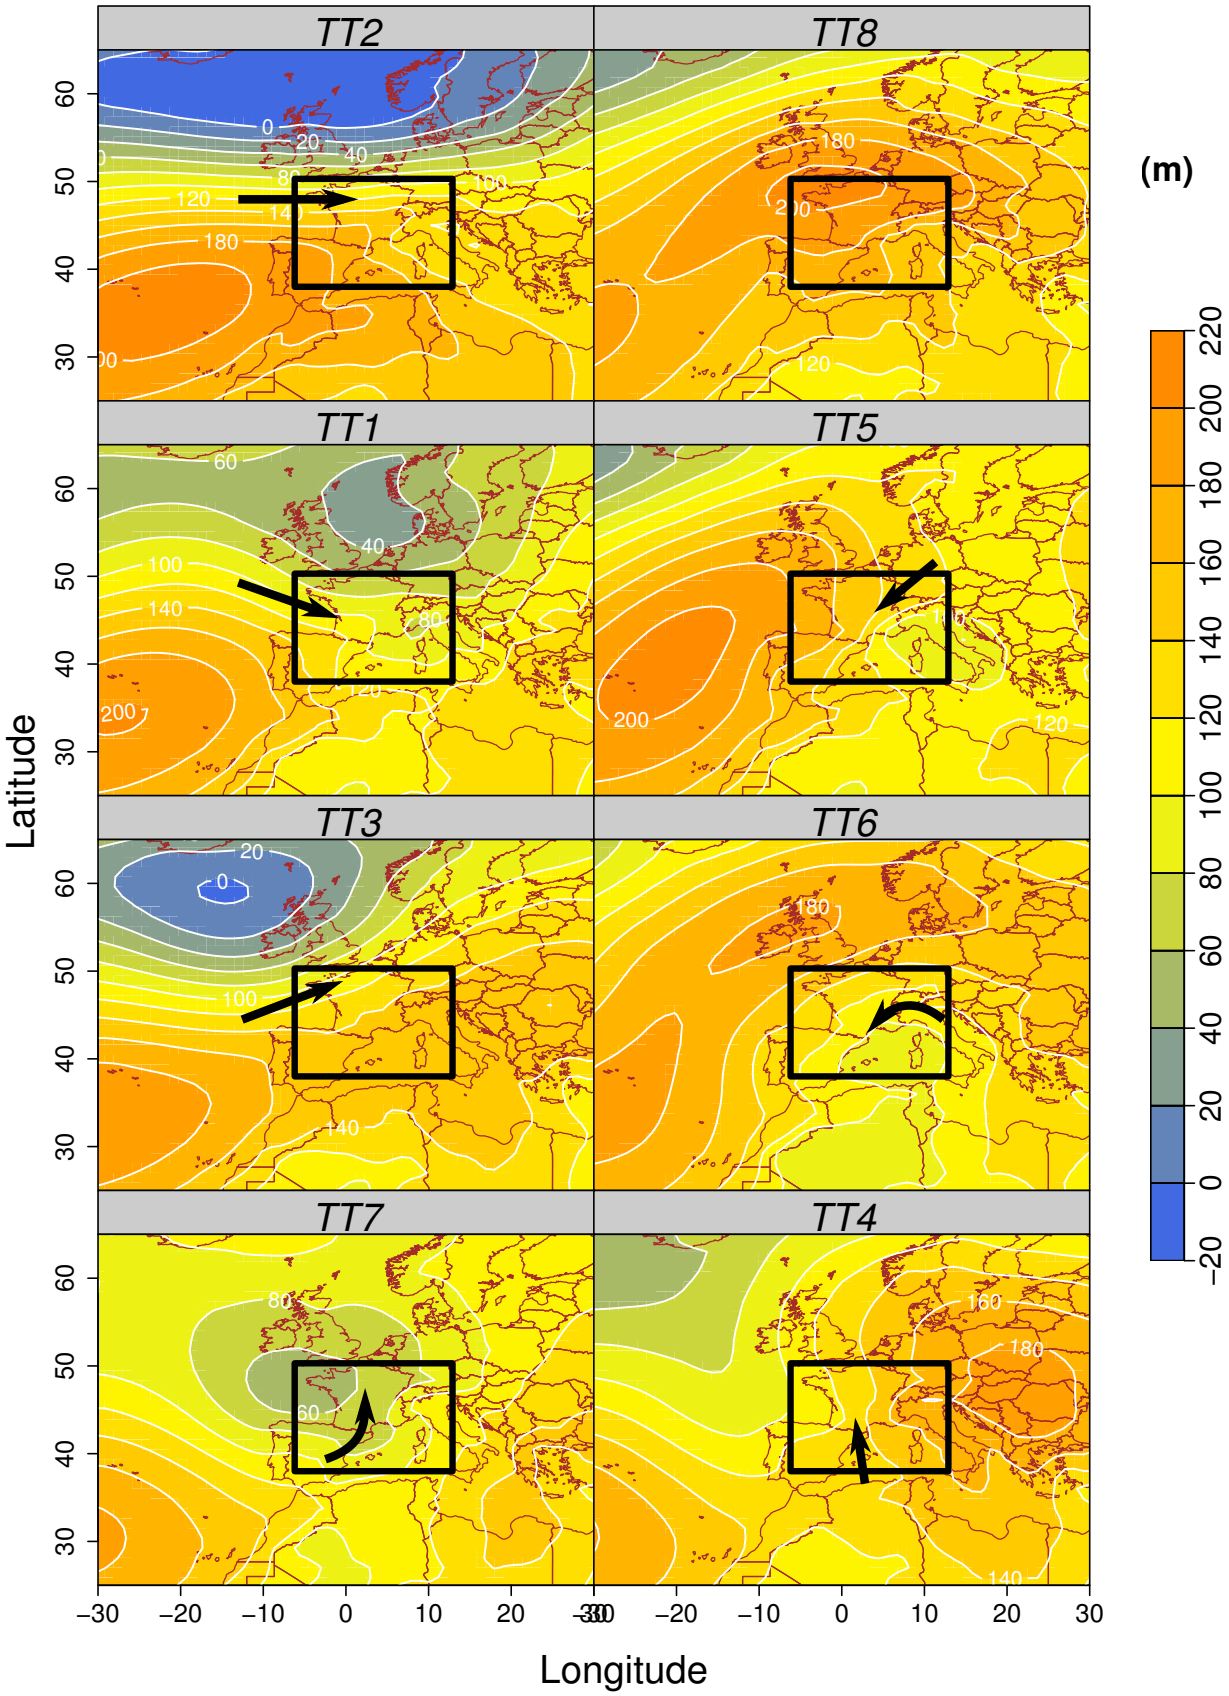

FIGURE II.6 – Hauteur moyenne du géopotentiel 1000 hPa des types de temps définis par GARAVAGLIA et al. [2010]. Les flèches noires représentent la direction des flux atmosphériques de basses couches. Le cadre noir représente quant à lui le domaine d'analogie utilisé pour la répartition des jours dans cette classification. Figure adaptée de GARAVAGLIA et al. [2010].

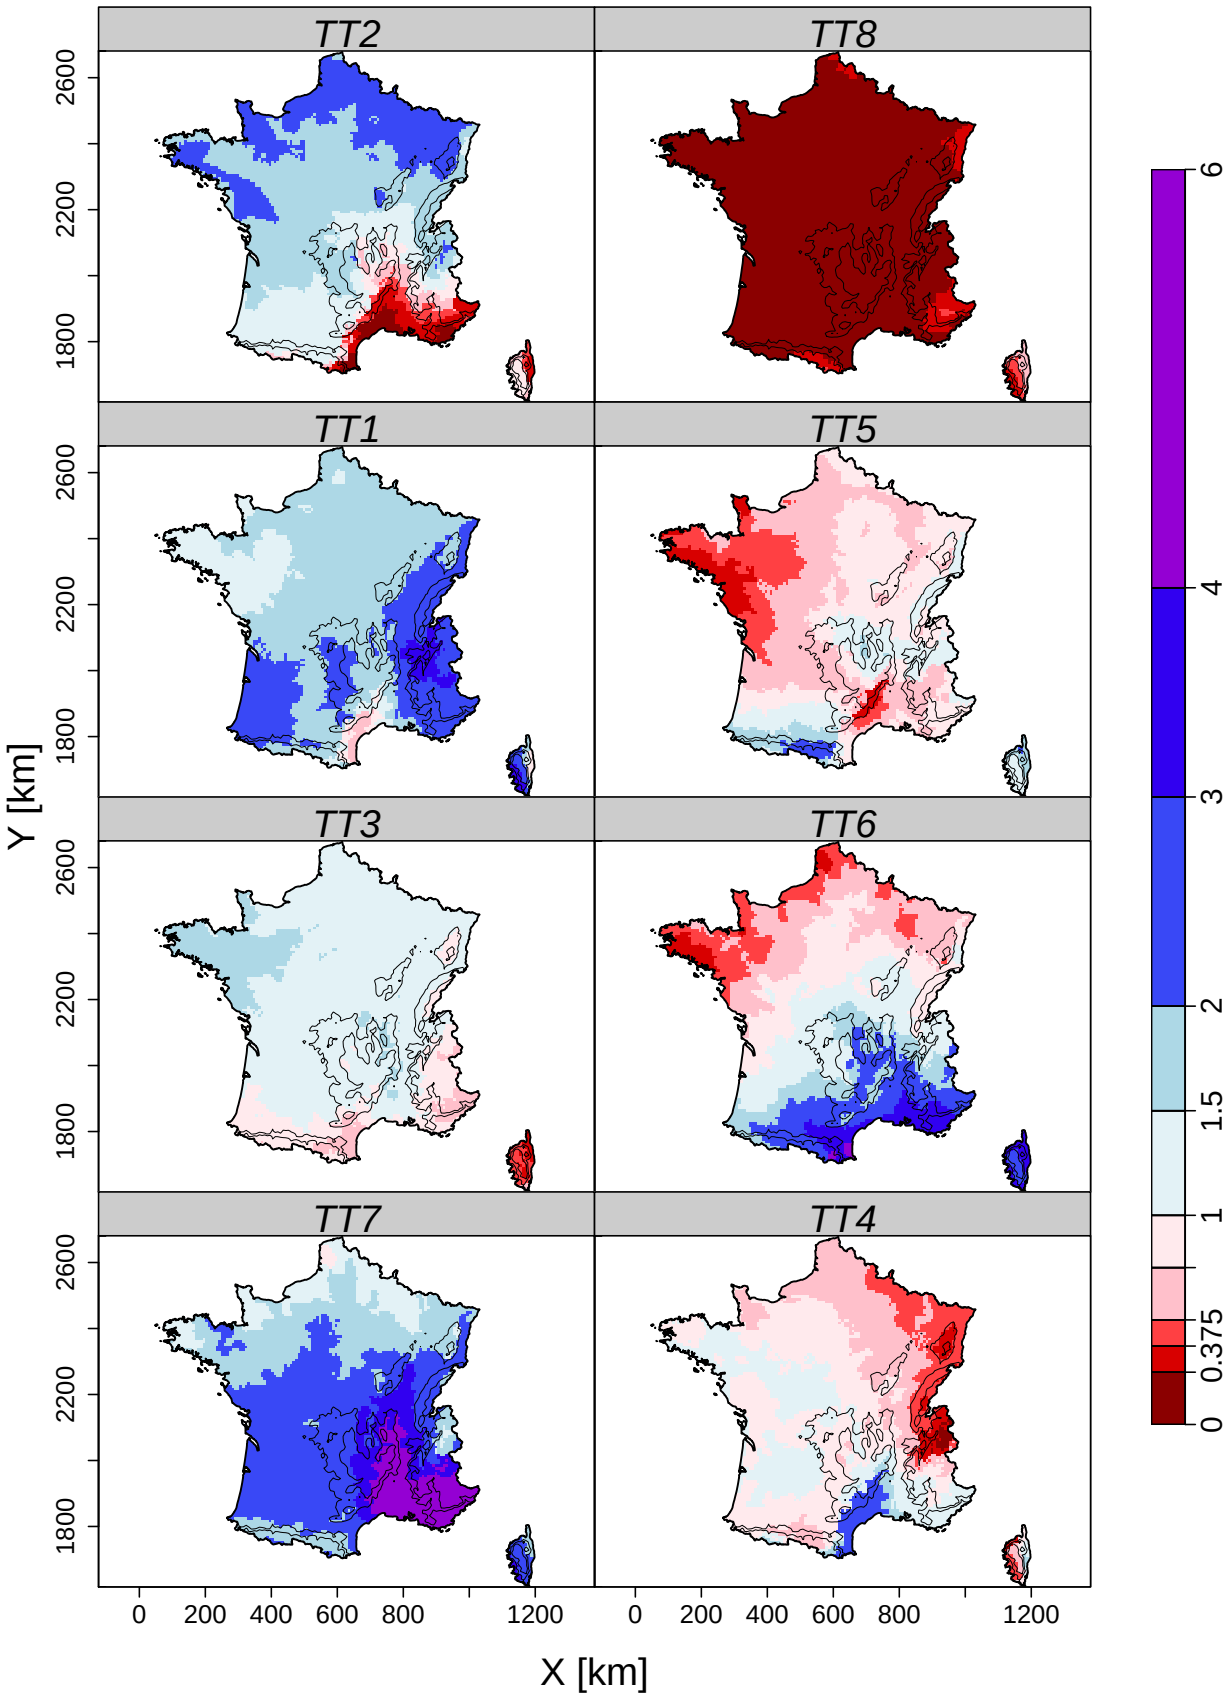

FIGURE II.7 – Ratio des précipitations journalières moyenne de chaque type de temps par rapport à la précipitation journalière moyenne annuelle. Adapté de GARAVAGLIA et al. [2010].

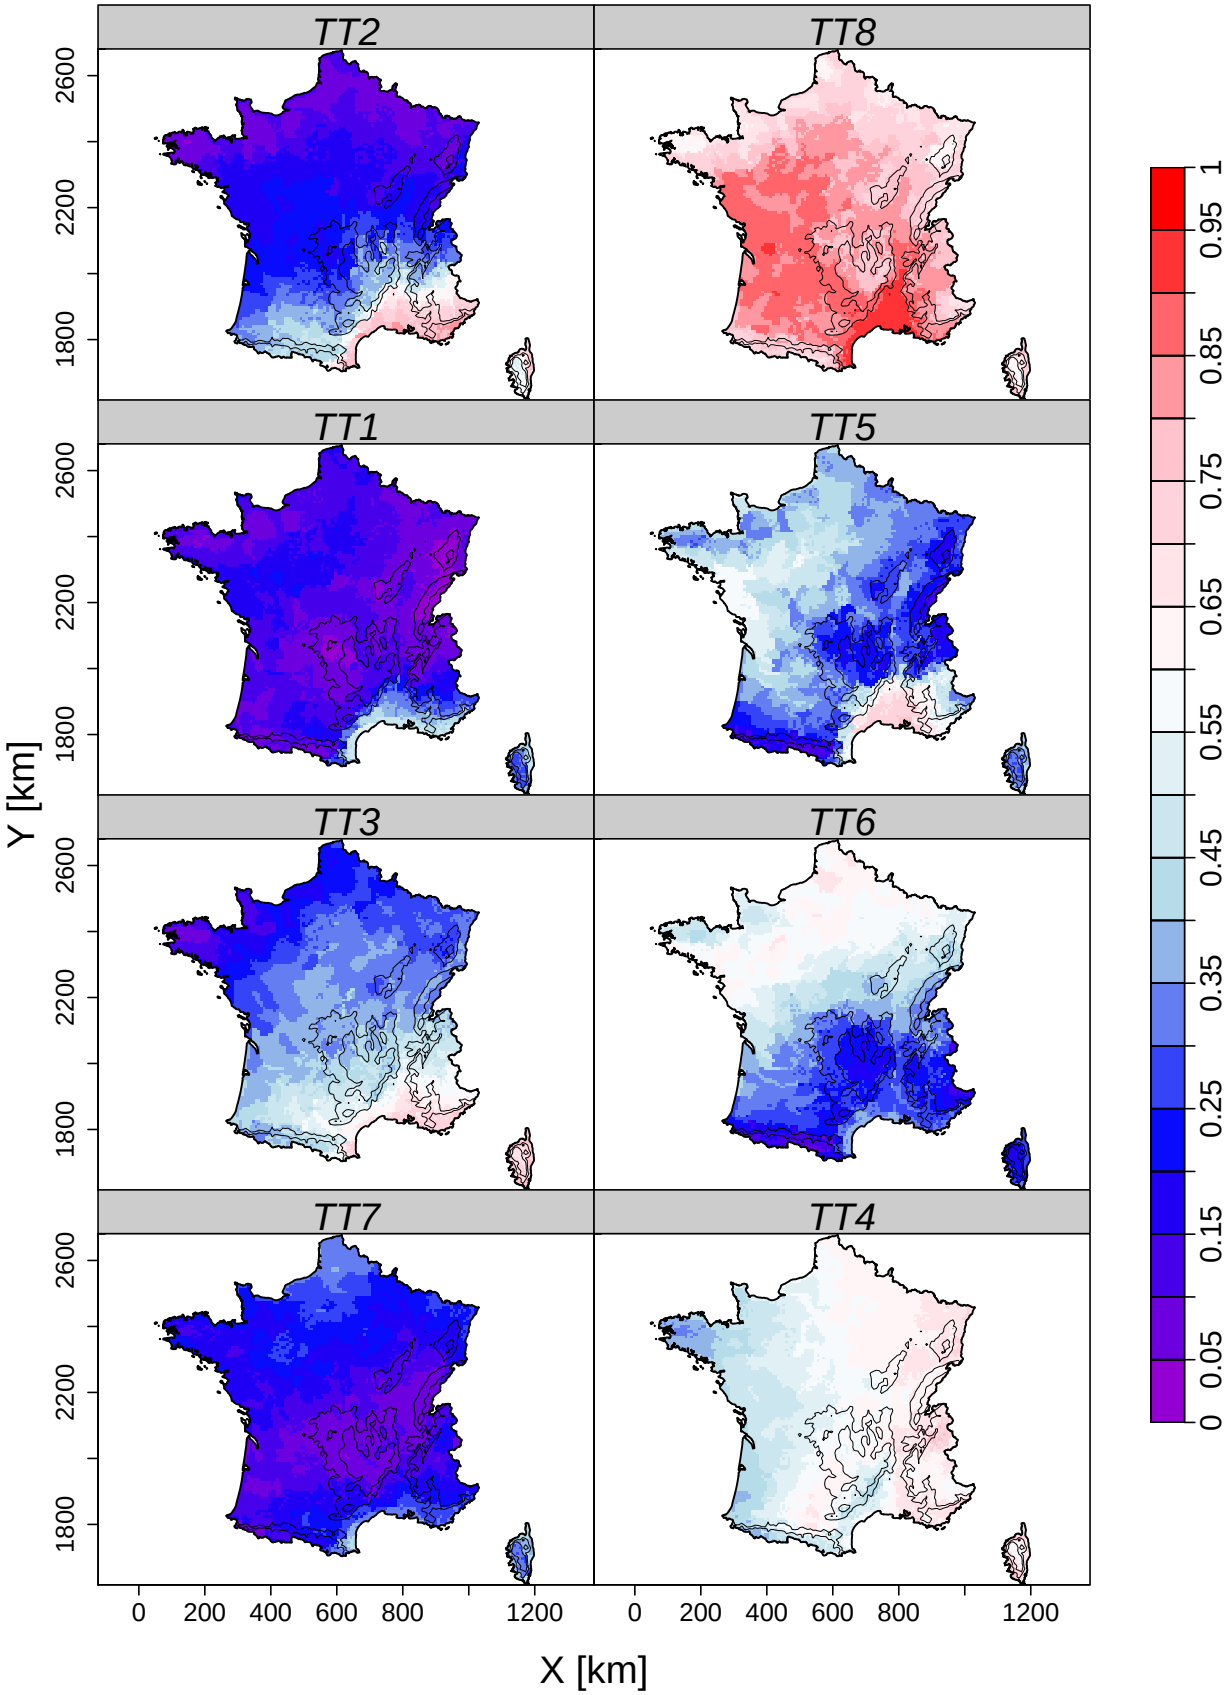

FIGURE II.8 – Fréquence des jours secs en fonction des types de temps.

TT5 est une circulation continentale alors que le TT8 correspond aux cas où aucune circulation n'a pas été clairement identifiée. Il est toutefois dénommé par Garavaglia et al. [2010] sous le terme de "Situation Anticyclonique". Ce type de temps correspond à des journées relativement sèches car la précipitation moyenne observée est proche de 0 et le pourcentage de jours secs est le plus important (environ égal à 85%).

Pour la période 1982-2001, le tableau II.1 fournit les fréquences d'échantillonnage annuelles et saisonnières de ces types de temps. La figure II.9 représente, quant à elle, l'évolution mensuelle de cet échantillonnage. Sur l'ensemble de la période, les types de temps les plus échantillonnés correspondent aux TT8 (29%), au TT2 (22%) et au TT4 (17%). D'après la figure II.9 et le tableau II.1, la saison pour laquelle le TT2 est le plus échantillonné (supérieur à 30%) correspond à l'hiver. Ce type de temps est cependant aussi majoritaire ou quasiment majoritaire au printemps et en automne. Concernant le TT4, son échantillonnage est le plus important en automne. Enfin, la saison pour laquelle les situations anticycloniques (TT8) sont les plus rencontrées est l'été.

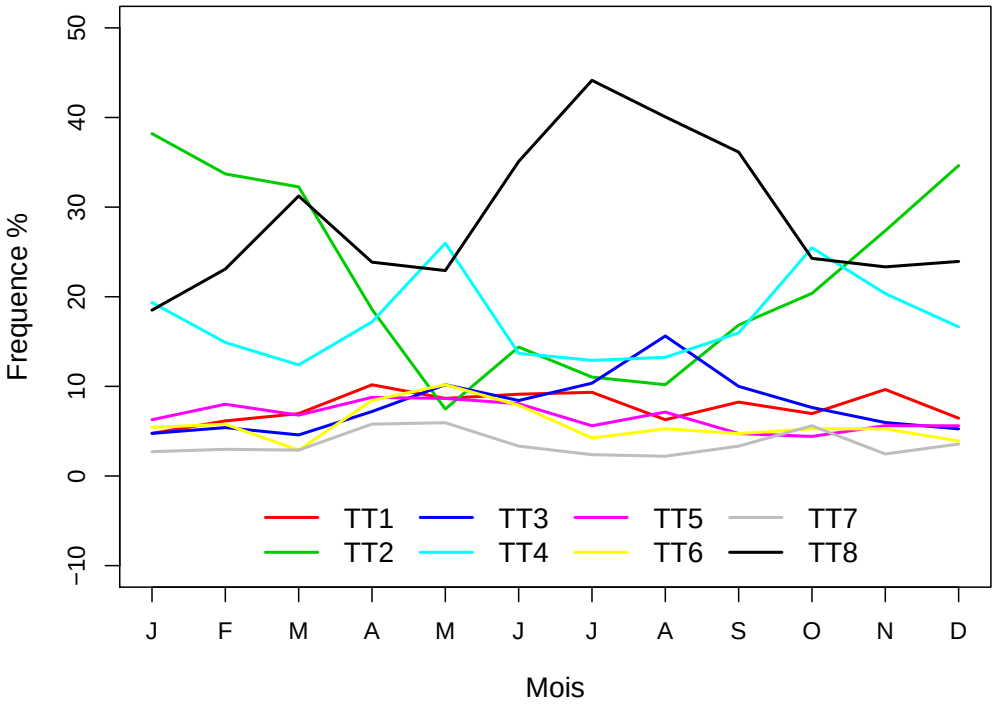

Figure II.9 – Fréquence mensuelle des types de temps pour la période s'étendant du 01-08-1982 au 31-07-2001.

Dans la suite de cette thèse, plusieurs évaluations sont effectuées en fonction de cette discrétisation en type de temps. De façon à éviter les allers/retours entre les chapitres suivants et cette section, le lecteur dispose d'un marque page sur lequel les figures II.6 et II.7 sont représentées.

Deuxième partie

INTÉRÊT DU MODÈLE ANALOG

Cette première partie du manuscript est composé de trois chapitres :

- Après avoir exposé la stratégie d'évaluation, nous évaluons dans un premier chapitre les performances obtenues par un modèle Analog optimisé pour la prédiction des précipitations Safran à l'échelle de la France. Pour ce faire, le modèle Analog a été optimisé pour chacune des mailles p, menant à un ensemble de 8 981 modèles qui sont par la suite respectivement appliqués à la maille Safran p considérée. A la suite d'une caractérisation des performances en termes de fiabilité et résolution, une évaluation en fonction des saisons et des types de temps permet de déterminer les endroits et les situations pour lesquelles de bonnes performances de la méthode sont obtenues.
- Le second chapitre évalue la capacité de transposition du modèle Analog. Pour un modèle Analog donné issu de l'ensemble de modèles Analog précédemment optimisés, la perte de performance obtenue par ce modèle par rapport aux modèles optimaux locaux permet d'estimer la transposabilité spatiale du modèle Analog. Un article publié [Chardon et al., 2014] expose les résultats de cette étude. La sensibilité de la transposabilité spatiale des dates analogues est évaluée en fonction des paramètres du modèle Analog, des saisons et des types de temps.
- Enfin, le troisième chapitre expose l'évaluation des performances de prédiction d'une précipitation agrégée sur des territoires de plus en plus vastes. Dans un premier temps, un modèle Analog optimisé pour la France entière et appliqué pour la prédiction de précipitations agrégées sur la France permet d'évaluer les performances en fonction de l'agrégation spatiale. Ensuite, une expérience simulatoire permet d'expliquer le comportement observé. Finalement, l'utilisation d'un modèle optimisé pour une région donnée permet d'évaluer la performance de prédiction d'une précipitation agrégée issue de deux régions hétérogènes.

Chapitre *III*

Le modèle Analog de référence

Dans cette thèse, le modèle Analog retenu est celui décrit à la section 1.1 du chapitre I. Dans ses travaux de thèse, Bontron [2004] a optimisé les prédicteurs de grande échelle – incluant les niveaux et les fenêtres temporelles correspondantes – pour un ensemble de précipitations de bassins localisées dans le quart Sud-Est de la France. En cette région, les performances de ce modèle sont déjà connues et décrites dans la littérature [*e.g.* Bontron & Obled, 2005 ; Ben Daoud et al., 2009]. Une amélioration de cette méthode a été notamment proposée par Ben Daoud et al. [2011] pour la prédiction des précipitations des bassins de la Seine et de la Saône. Une présentation des performances de cette méthode améliorée à l'échelle de la France est exposée dans Radanovics et al. [2013].

Dans une première section (section 1), nous adaptons à notre étude le modèle Analog présenté à la section 1.1 du chapitre II. Ce modèle servira de modèle de référence pour l'évaluation d'approches de prédiction plus complexes. Après avoir exposé la stratégie d'évaluation utilisée dans cette thèse (section 2), nous présentons la performance de prédiction de ce modèle de référence (section 3). L'évaluation est effectuée selon plusieurs filtres temporels constitués des saisons et des types de temps [Garavaglia et al., 2010].

1. Adaptation du modèle Analog à la France

Le modèle Analog issu des travaux de Bontron [2004] ayant été seulement optimisé pour le Sud-Est de la France, certains de ses paramètres doivent être ré-optimisés pour l'application du modèle sur la France. Cette section possède pour but l'adaptation de la paramétrisation du modèle Analog à notre objet d'étude, *i.e.* les précipitations Safran France.

La version optimisée par Bontron [2004, pp. 171] possède les paramètres suivants :

- **Filtre saisonnier** : Les jours sont sélectionnés selon un filtre calendaire de ± 2 mois centré autour du jour cible. Les jours correspondant à l'année du jour cible sont retirés de l'archive des jours analogues.
- **Variables d'analogie** : hauteurs des géopotentiels Z_{1000} +12h et Z_{500} +24h.
- **Fenêtre d'analogie** : fenêtre optimale dépendante de la localisation de la précipitation à prédire. La fenêtre d'analogie est la même pour les géopotentiels Z_{1000} +12h et Z_{500} +24h.
- **Critère d'analogie** : le TWS [Teweless & Wobus, 1954] dont l'équation est :

$$\mathrm{TWS} = 100 \cdot \frac{\sum_{i=1}^{I-1}\sum_{j=1}^{J}\left|\Delta_{i,j}^{i,cible} - \Delta_{i,j}^{i,candidate}\right| + \sum_{i=1}^{I}\sum_{j=1}^{J-1}\left|\Delta_{i,j}^{j,cible} - \Delta_{i,j}^{j,candidate}\right|}{\sum_{i=1}^{I-1}\sum_{j=1}^{J} max\left(\left|\Delta_{i,j}^{i,cible}\right|, \left|\Delta_{i,j}^{i,candidate}\right|\right) + \sum_{i=1}^{I}\sum_{j=1}^{J-1} max\left(\left|\Delta_{i,j}^{j,cible}\right|, \left|\Delta_{i,j}^{j,candidate}\right|\right)} \quad \text{(III.1)}$$

Où $\Delta_{i,j}^{i,cible} = Z_{i+1,j}^{cible} - Z_{i,j}^{cible}$ est le gradient de géopotentiels selon une direction ouest-est à partir du point (i, j) pour le géopotentiel cible et $\Delta_{i,j}^{j,cible} = Z_{i,j+1}^{cible} - Z_{i,j}^{cible}$ est le gradient de géopotentiels selon une direction sud-nord à partir du point (i, j) pour le géopotentiel cible. Les gradients de géopotentiels $\Delta_{i,j}^{i,candidate}$ et $\Delta_{i,j}^{j,candidate}$ correspondant aux situations candidates sont construits de la même manière.

Bontron [2004, pp. 187] montre que dans cette configuration, une valeur optimale du nombre N_d de dates analogues à retenir se situe entre 30 et 35. Le seul paramètre dépendant de la localisation de la précipitation considérée est la fenêtre d'analogie.

Il est *a priori* supposé que les paramètres de la MDES Analog – *i.e.* les variables, le critère et le domaine d'analogie – varient en fonction de la localisation de la précipitation considérée. Comme Horton [2012] le préconise, ces paramètres devraient être optimisés tous ensemble. Cependant, ne disposant pas d'un outil informatique permettant une telle optimisation, nous avons décidé de nous baser sur certains paramètres issus de l'optimisation faite par Bontron [2004]. Les hauteurs de géopotentiels Z_{1000} +12h et Z_{500} +24h ont été retenues comme variables d'analogie. Ces variables renseignent sur la circulation atmosphérique de grande échelle et permettent de décrire les masses d'air advectées sur le territoire. Le critère TWS étant le mieux adapté pour une analogie basée sur les hauteurs de géopotentiels [Guilbaud, 1997 ; Wetterhall et al., 2005], nous avons décidé de le conserver. Concernant le filtre temporel, nous avons décidé de le réduire à ± un mois : dans le cas d'une génération multivariée de variables météorologiques (comme par exemple pour la modélisation hydrologique), il est préférable de disposer d'un filtre saisonnier plus discriminant pour la génération de certaines variables ayant un cycle journalier fortement saisonnier tel que le rayonnement solaire.

Bontron [2004, pp. 147] a montré qu'une fenêtre d'analogie adaptée à chaque site permettait d'obtenir de meilleures performances. De même, nous optimiserons le domaine d'analogie pour chaque précipitation issue d'une maille Safran. Le jeu de données Safran étant composé de 8 981 mailles, nous obtiendrons alors un jeu de 8 981 modèles Analog. Pour chaque maille Safran, la procédure d'optimisation du domaine d'analogie est similaire à celle définie par Bontron [2004] :

1. La maille élémentaire ERA-40 centrée sur la maille cible Safran considérée est choisie comme domaine d'analogie initial.
2. Pour chacune des quatre directions (Nord, Sud, Est et Ouest), quatre domaines d'analogie alternatifs – obtenus par l'extension d'une maille ERA-40 – basés sur le domaine initial sont testés

comme domaine d'analogie. Le domaine d'analogie alternatif obtenant la meilleure performance (en terme de CRPSS) est alors retenu.

3. L'étape 2 est répétée en considérant le domaine d'analogie alternatif retenu à l'étape 2 comme domaine d'analogie initial jusqu'à ce que la performance ne puisse plus être améliorée. Le domaine d'analogie final obtenu par cette procédure itérative est celui pour lequel la performance est optimale. Aucun critère de tolérance n'est appliqué ici.

Un exemple de cette procédure est représenté à la figure III.1 pour une maille située au Nord de la France. La période de calibration considérée s'étend du 01-08-1982 au 31-07-2001. Nous avons remarqué que cette procédure d'optimisation du domaine d'analogie ne permettait pas d'explorer l'ensemble des domaines possibles car elle est conditionnée par le choix de la maille élémentaire ERA-40 initiale. Par suite, elle peut conduire à l'obtention d'un domaine d'analogie ne correspondant pas au domaine optimal [1].

Pour cette optimisation, un nombre N_d de dates analogues égal à 50 a dans un premier temps été fixé. Pour les fenêtres d'analogie identifiées, une étude de sensibilité des performances de prédiction par rapport à N_d a été développée. Elle a mis en évidence qu'un nombre N_d égal à 25 permettait d'obtenir la meilleure performance moyenne en CRPSS sur l'ensemble des mailles Safran (*cf.* annexe A).

Comme la période de calibration est de courte durée, nous avons décidé d'exclure seulement les jours appartenant à une fenêtre temporelle de ± 5 jours centrée autour de notre jour cible parmi les jours candidats au lieu d'exclure l'année entière comme le faisait Bontron [2004]. Nous faisons ici l'hypothèse que les géopotentiels sont peu corrélés entre eux lorsqu'ils sont espacés de 6 jours.

Finalement, la configuration de notre modèle Analog est donc la suivante :

- **Filtre saisonnier** : ± 1 mois. Les jours appartenant à une fenêtre temporelle de ± 5 jours centrée sur le jour cible sont retirés de l'archive des jours analogues.
- **Variables d'analogie** : Z_{1000} +12h et Z_{500} +24h.
- **Fenêtre d'analogie** : fenêtre optimale dépendante de la localisation de la précipitation Safran à prédire.
- **Critère d'analogie** : le TWS [Teweless & Wobus, 1954].
- **Nombre N_d de dates analogues à retenir** : 25.

Par la suite, un modèle Analog optimisé pour la prédiction des précipitations en la maille p est noté MA_p. L'évaluation de ce modèle est effectuée à l'aide de scores de performance définis à la section 2 suivante.

1. Dans l'étude de la transposabilité qui suit, plusieurs modèles Analog sont testés pour la prédiction des précipitations à l'échelle de la France. Or, pour quelques mailles, il est arrivé qu'un modèle testé obtienne légèrement une meilleure performance que le modèle Analog déduit de la procédure itérative d'accroissement de domaines. Dans ce cas, le modèle remplace le modèle initialement déduit.

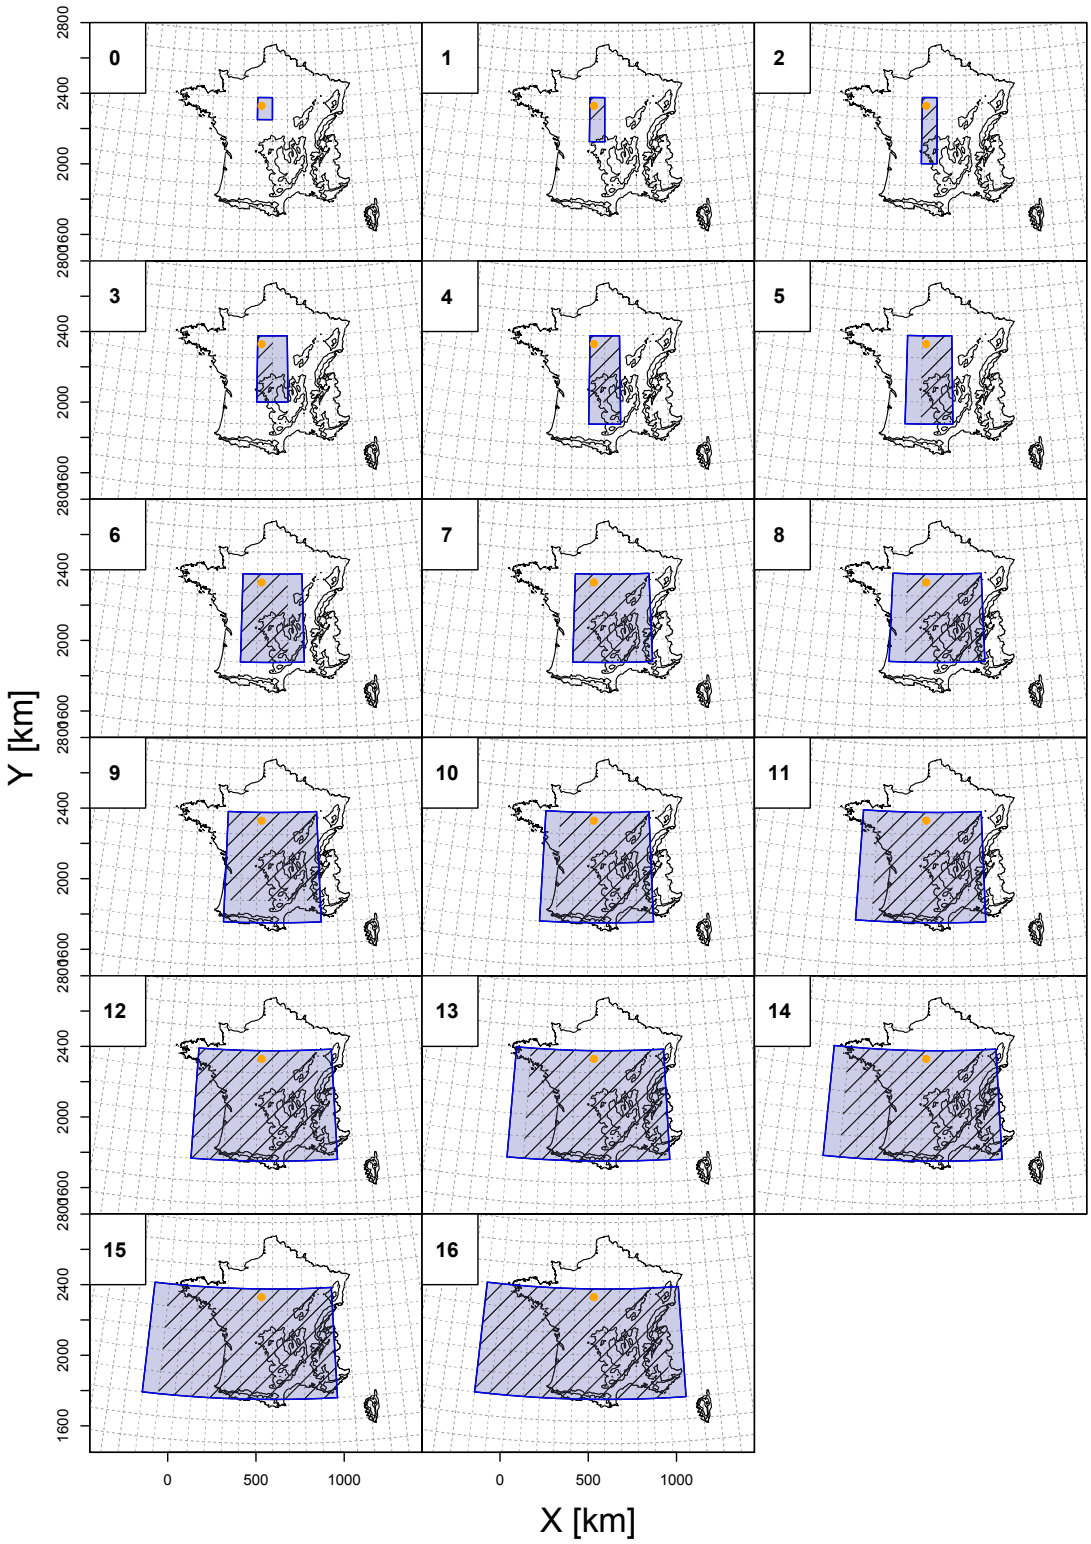

FIGURE III.1 – Procédure itérative d'optimisation de la fenêtre d'analogie pour la maille Safran représentée en orange. Pour chaque itération successive repérée par son numéro, la fenêtre d'analogie retenue est représentée par la surface bleue. Pour une itération donnée, la surface hachurée représente le domaine d'analogie de l'itération précédente. L'itération 0 correspond à l'analogie effectuée sur la maille élémentaire centrée ERA-40 correspondant à l'étape 1 de l'algorithme. La 16ème itération fournit ici la fenêtre d'analogie finale pour la maille Safran donnée. Sur cette figure, le maillage ERA-40 est représenté par les lignes discontinues noires. Ce quadrillage est utilisé dans de nombreuses figures par la suite.

2. Stratégie d'évaluation

2.1. Les évaluations déterministes

Dans cette section, nous décrivons la méthode que nous avons mise en œuvre pour évaluer les MDES retenues à la section 1 du chapitre II. Avant cela, nous exposons les raisons qui nous ont menées à cette stratégie d'évaluation. Elles découlent des travaux de Lafaysse [2011] qui a comparé les performances de prédiction de trois MDES [1] pour la génération de scénarios météorologiques pour le bassin de la Durance à Serre-Ponçon. Dans sa thèse, Lafaysse [2011] distingue quatre évaluations :

- L'**évaluation climatologique** : il s'agit de vérifier si le modèle utilisé arrive à reproduire la distribution statistique de différentes caractéristiques dérivées de la variable d'intérêt (*e.g.* précipitations journalières ou agrégées sur différents pas de temps, durées de temps sec ou humide). Cela peut être effectué de manière graphique [*e.g.* Imbert & Benestad, 2005] ou à l'aide des moments clés de la variable aléatoire associée : la comparaison des moyennes observée et estimée qui s'exprime par le calcul du biais, la capacité à reproduire la variation des valeurs observées en calculant le quotient de l'écart-type de la variable estimée et celui de la variable observée. Dans la plupart des cas, cette évaluation est menée par saison.
- L'**évaluation chronologique** : il s'agit de tester la capacité du modèle à reproduire les variations observées de la variable d'intérêt, résultant des changements observées dans les situations atmosphériques de grande échelle sur une période de temps donnée. Pour évaluer l'occurrence des précipitations, certains critères comme la probabilité de détection (POD), le taux de fausse alarme (FAR), le taux de fausse détection (POFD) et le *True Skill* Score peuvent être utilisés. Pour les hauteurs précipitées, les critères calculés incluent par exemple la corrélation de Pearson ou le score de Nash-Sutcliffe.
- L'**évaluation ensembliste** : dans les travaux de Lafaysse [2011], les MDES utilisées possèdent toutes une part de stochasticité, induite par le tirage aléatoire dans une distribution choisie ou par la sélection d'une précipitation issue d'une situation analogue retenue. Par conséquent, une même paramétrisation d'une MDES peut conduire à l'obtention de différentes séries temporelles de précipitations. Pour chaque série temporelle générée, une évaluation climatologique et chronologique peut par ailleurs être effectuée. Par exemple, une représentation synthétique des performances climatologique et chronologique peut être donnée par le diagramme de Taylor [Taylor, 2001]. Un exemple de ce diagramme est représenté à la figure III.2 pour une des MDES mise en œuvre dans les travaux de Lafaysse [2011]. Sur ce graphique, les axes des abscisses et des ordonnées correspondent au rapport de variance entre la précipitation estimée et la précipitation observée. Le coefficient de corrélation de Pearson entre la variable observée et la variable simulée est représenté sur le quart de cercle extérieur. Les demi-cercles intérieurs illustrent, quant à eux, la racine de l'erreur quadratique moyenne. Le point noté REF correspond à une série temporelle qui obtiendrait des performances optimales (*i.e.* un coefficient de corrélation et un rapport de variance égal à 1 ainsi qu'une erreur moyenne nulle). Sur ce graphique, les performances de cent séries temporelles issues d'une même MDES sont représentées. Chaque

1. Les trois MDES évaluées dans les travaux de Lafaysse [2011] correspondaient à une méthode analogique similaire à celle présentée à la section 1.1, au modèle d2gen ainsi qu'au modèle DSCLIM [Boé & Terray, 2008 ; Page et al., 2009].

point noir indique les performances obtenues par une des cent générations. On remarque alors que pour une même MDES, la série temporelle générée peut obtenir un coefficient de corrélation variant entre 0,4 et 0,7 ainsi qu'un rapport de variance s'étendant de 0,75 à 1,25. Une évaluation robuste ne peut donc pas être obtenue par la caractérisation des performances résultant d'une seule chronique générée. Elle nécessite alors de considérer plusieurs réalisations [Lafaysse et al., 2014 ; Hingray & Saïd, 2014].

L'évaluation ensembliste considérée par Lafaysse [2011] n'est ainsi pas optimale. Elle permet en particulier difficilement de comparer les performances obtenues soient par deux MDES différentes, soient pour deux sites voisins pour lesquels une même MDES est appliquée. Dans le contexte de ces travaux de thèse, nous devons être capables d'évaluer les performances de prédiction d'une MDES en tout site pour lequel des précipitations doivent être prédites. Comme le nombre de mailles dans les ré-analyses Safran est de 8 981, un critère numérique synthétique unique permettant de donner une appréciation globale pour l'ensemble des scénarios s'est avéré nécessaire. Un moyen de satisfaire ces contraintes consiste à se placer dans un contexte de prédiction probabiliste et d'utiliser les critères d'évaluation correspondants.

2.2. Une évaluation probabiliste

Pour chaque prédiction i donnée, il est possible d'estimer une distribution cumulative empirique $\widehat{F}_{Y,i}(y)$ de la variable Y aléatoire représentant la précipitation sur la base d'un ensemble de N valeurs y de précipitations prédites par une MDES. Par exemple, dans le cas d'un modèle MA, les N valeurs correspondent aux N_d valeurs de précipitations extraites à partir des N_d situations analogues les plus proches de la situation cible. Dans le cas d'un modèle de régression, les N valeurs de précipitations sont issus de la distribution statistique estimée par le modèle GLM. Les valeurs de probabilités au non-dépassement de ces N valeurs de précipitations sont distribuées de façon uniforme dans l'intervalle $[0; 1]$.

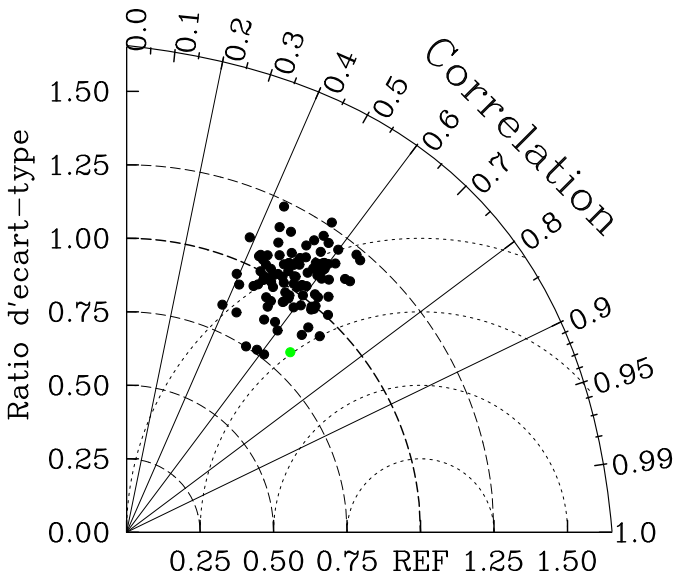

Figure III.2 – Diagramme de Taylor obtenu pour une configuration de la méthode DSCLIM utilisée dans les travaux de Lafaysse [2011, pp. 141].

Par suite, la prédiction des précipitations est délivrée sous forme d'une distribution cumulative empirique. L'évaluation de cette dernière peut être effectuée sur l'ensemble de la distribution ou seulement sur la probabilité d'occurrence des précipitations à l'aide de scores propres [Gneiting & Raftery, 2007 ; Bröcker & Smith, 2007]. Dans cette thèse, nous avons privilégié l'évaluation de l'ensemble de la distribution émise au travers du *Continuous Ranked Probability Score* (CRPS) défini à la section 2.2.2. Cependant, dans certains cas, nous effectuerons une évaluation de la probabilité d'occurrence des précipitations à l'aide du score de Brier. Ce dernier est présenté à la section 2.2.1.

2.2.1. Evaluation de l'occurrence de précipitation

Considérons pour un jour i de prédiction donné un ensemble de N valeurs de précipitations $y_{i,n}$, $n \in \{1, 2, \ldots, N\}$ émises par un système de prédiction $\mathcal{P}$. Ces valeurs permettent d'estimer la probabilité d'occurrence $\widehat{\pi}_i$ de précipitation pour ce jour i. Elle est définie comme :

$$\widehat{\pi}_i = \frac{1}{N} \sum_{n=1}^{N} H(y_{i,n} - y_s) \tag{III.2}$$

où y_s correspond à un seuil fixé pour lequel il est considéré que le jour est pluvieux. Dans notre cas, nous avons choisis y_s égal à 0,1 mm. $H(\cdot)$ correspond à la fonction d'Heaviside définie comme :

$$H(x) = \begin{cases} 0 \text{ si } x < 0 \\ 1 \text{ si } x \geq 0 \end{cases} \tag{III.3}$$

Pour évaluer la performance d'un système $\mathcal{P}$ pour la prédiction de l'occurrence de précipitation, nous avons retenu le score de Brier [BS, Brier, 1950 ; Murphy, 1973]. Il est défini comme la moyenne, sur l'ensemble des M jours de prédictions, de l'écart quadratique entre la probabilité d'occurrence $\widehat{\pi}_i$ émise et l'occurrence effective de précipitation o_i observée *a posteriori* :

$$\begin{aligned} \overline{\mathrm{BS}} &= \frac{1}{M} \sum_{i=1}^{M} \mathrm{BS}_i \\ &= \frac{1}{M} \sum_{i=1}^{M} [\widehat{\pi}_i - o_i]^2 \end{aligned} \tag{III.4}$$

où BS_i est le score de Brier journalier et M correspond au nombre de prédictions à partir desquelles $\overline{\mathrm{BS}}$ est estimé. o_i représente l'occurrence effective pour la prédiction i : o_i est égal à 1 si l'évènement est survenu (*i.e.* le jour est considéré comme pluvieux car la précipitation observée est supérieure à 0,1 mm). Autrement, o_i est égal à 0 (*i.e.* le jour est considéré comme sec). Le $\overline{\mathrm{BS}}$ est compris entre 0 et 1 et est un score orienté négativement car il s'agit d'un écart quadratique : plus le $\overline{\mathrm{BS}}$ est proche de 0, meilleur est le système de prédiction $\mathcal{P}$.

De façon à comparer les performances de prédiction obtenues entre deux sites, on utilise généralement le *Brier Skill Score* (BSS) qui compare la performance obtenue par le système $\mathcal{P}$ d'intérêt avec un système de référence. En pratique, cette référence est souvent un système de prédiction climatologique $\mathcal{P}_\varphi$ qui prédit une probabilité d'occurrence égale à la fréquence empirique des précipitations.

Le BSS est alors défini comme :

$$\mathrm{BSS} = 1 - \frac{\overline{\mathrm{BS}}}{\overline{\mathrm{BS}}_{\varphi}} \tag{III.5}$$

où $\overline{\mathrm{BS}}_{\varphi}$ est le score de Brier obtenu par le système $\mathcal{P}_{\varphi}$. Le BSS est compris entre $-\infty$ et 1 et est orienté positivement, *i.e.* plus sa valeur est proche de 1, meilleure est la performance de $\mathcal{P}$. Une valeur de BSS égale à 1 indique que le modèle $\mathcal{P}$ est un système de prédiction parfait. Si la valeur du BSS est inférieure à 0, le système $\mathcal{P}$ obtient alors une performance moins bonne qu'un modèle $\mathcal{P}_{\varphi}$ basé sur la climatologie φ.

Dans la suite de ce manuscrit, le score de Brier est parfois appliqué pour évaluer la prédiction de l'occurrence des précipitations.

2.2.2. Evaluation de la quantité de précipitation

Le *Continuous Ranked Probability Score* [CRPS, Brown, 1974 ; Matheson & Winkler, 1976] est un critère numérique classiquement utilisé pour l'évaluation d'un système de prédiction probabiliste $\mathcal{P}$ car il possède les avantages suivants :

- Il évalue l'ensemble de la distribution probabiliste émise.
- Il s'agit d'un score propre [Gneiting & Raftery, 2007 ; Bröcker & Smith, 2007].
- Il peut être interprété comme l'intégrale du score de Brier sur l'ensemble des valeurs prises par le prédictand.
- Il est égal à l'erreur absolue moyenne (ou Mean Absolute Error – MAE) dans le cas d'une prédiction déterministe.

Ce score est défini comme :

$$\begin{aligned}\overline{\mathrm{CRPS}} &= \frac{1}{M}\sum_{i=1}^{M}\mathrm{CRPS}_i \\ &= \frac{1}{M}\sum_{i=1}^{M}\int_{-\infty}^{+\infty}\left[\widehat{F}_{Y,i}(y) - H(y-y_i)\right]^2 dy\end{aligned} \tag{III.6}$$

où CRPS_i correspond au CRPS journalier, $\widehat{F}_{Y,i}(y)$ est la distribution empirique émise par $\mathcal{P}$. La fonction d'Heaviside $H(y-y_i)$ représente la distribution cumulative de l'observation y_i pour la prédiction i. L'unité du $\overline{\mathrm{CRPS}}$ correspond à l'unité de la variable Y considérée.

Pour une prédiction i donnée, le CRPS_i peut être interprété comme égal à l'aire comprise entre les distributions $\widehat{F}_{Y,i}(y)$ et $H(y-y_i)$ comme illustré à la figure III.3. Comme $H(y-y_i)$ est égal à 0 lorsque $y \in \,]-\infty, y_i\,[$ et égal à 1 dans le cas inverse, sa formulation mathématique définie à l'équation III.6 peut être divisée en deux intégrales comme :

$$\begin{aligned}\mathrm{CRPS}_i &= \int_{-\infty}^{+\infty}\left[\widehat{F}_Y(y) - H(y-y_i)\right]^2 dy \\ &= \int_{-\infty}^{y_i}\widehat{F}_Y^2(y)dy + \int_{y_i}^{+\infty}\left[\widehat{F}_Y(y) - 1\right]^2 dy\end{aligned} \tag{III.7}$$

En ajoutant et en soustrayant 1 à l'intégrale de droite de l'équation III.7, le CRPS_i peut être ré-écrit comme :

$$\text{CRPS}_i = \int_{-\infty}^{y_i} F_Y^2(y)dy + \int_{y_i}^{+\infty} 1 - \left\{1 - [1 - F_Y(y)]^2\right\}dy \tag{III.8}$$

L'intégrale de gauche de l'équation III.8 correspond à la surface orange située à gauche de l'observation y_i sur la figure III.3 tandis que l'intégrale de droite correspond à la surface orange située à droite de l'observation y_i. Le CRPS_i correspond alors à l'intégrale des différences quadratiques entre les distributions cumulatives $\widehat{F}_{Y,i}(y)$ et $H(y - y_i)$.

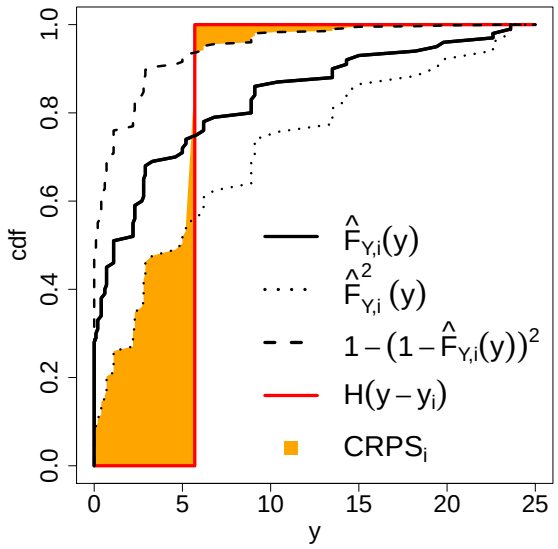

FIGURE III.3 – Illustration du CRPS pour une prédiction i donnée. L'intégrale de l'équation III.6 correspond à la somme des aires oranges ; les aires sont égales à la différence quadratique entre la distribution cumulative émise (représentée en noir) et observée (représentée en rouge) intégrée sur l'ensemble des valeurs de précipitations.

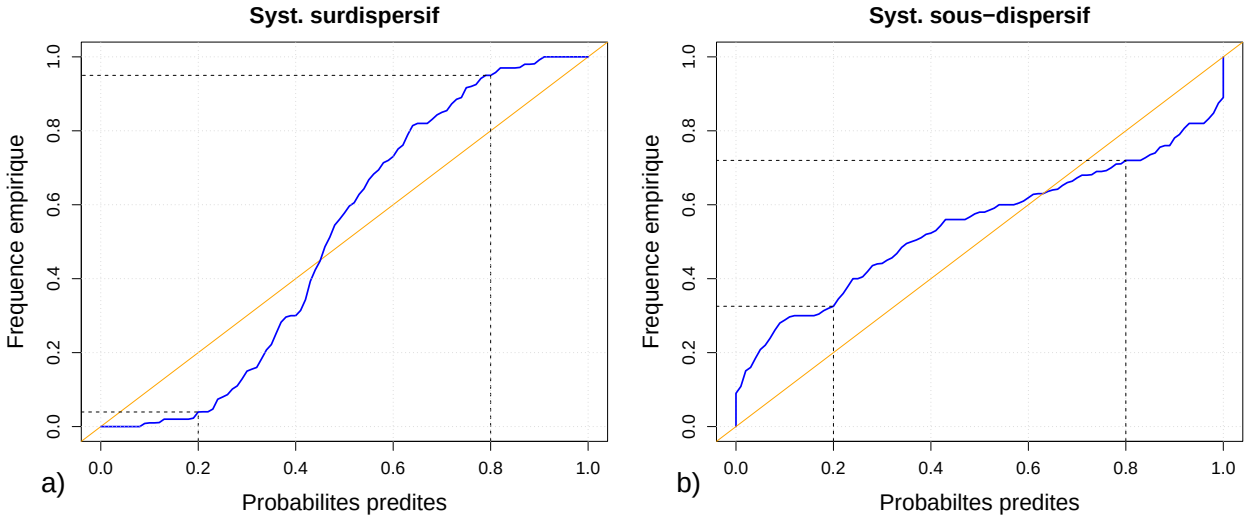

FIGURE III.4 – Illustration de la fiabilité pour a) un système de prédiction surdispersif (qui sous-estime les faibles probabilités et surestime les fortes probabilités) et b) un système de prédiction sous-dispersif (qui surestime les faibles probabilités et sous-estime les fortes probabilités).

Le $\overline{\text{CRPS}}$ est par nature très synthétique et englobe en un score unique différentes propriétés d'un système $\mathcal{P}$. Pour mieux caractériser $\mathcal{P}$, plusieurs auteurs ont proposé de décomposer le score en différents attributs [*e.g.* Hersbach, 2000 ; Bontron, 2004 ; Candille & Talagrand, 2005]. Une décomposition particulièrement intéressante est celle proposée par Hersbach [2000] en terme de *fiabilité* et de *résolution* :

- la *fiabilité* : il s'agit d'évaluer la distance entre la prédictive émise et les observations conditionnées par cette prédictive. En pratique, cela consiste à vérifier *a posteriori* sur un nombre importants de M prédictions, que le quantile à $x\%$ de la prédictive n'est effectivement pas dépassé dans $x\%$ des cas. Pour chaque valeur de probabilité prise dans la distribution émise par un système $\mathcal{P}$, la fréquence empirique des cas où le quantile correspondant à la probabilité émise n'a effectivement pas été dépassé peut être représentée en fonction de la probabilité émise. Afin de mieux comprendre la fiabilité, deux exemples sont illustrés à la figure III.4 pour deux systèmes de prédiction.
  - Dans le premier cas (figure III.4.a), on remarque que le quantile correspondant à une probabilité de non-dépassement de 0,2 n'est en moyenne pas dépassé pour environ seulement 5% des cas. Plus généralement, on peut dire que le système de prédiction considéré sous-estime les probabilités comprises entre 0 et 0,5. A l'inverse, le quantile correspondant à une probabilité de non-dépassement de 0,8 n'est pas dépassé dans environ 95% des cas. Dans ce cas, le système surestime les fortes probabilités (de 0,55 à 1). Le système de prédiction est dit *non-fiable*, ce comportement étant caractéristique de la surdispersion du système $\mathcal{P}$.
  - Un second système de prédiction est considéré à la figure III.4.b). Cette fois, les faibles probabilités sont surestimées tandis que les fortes probabilités sont sous-estimées. Ce système de prédiction est qualifié de sous-dispersif.
  - Sur la figure III.4, une bonne fiabilité peut être assimilée à la première bissectrice, *i.e.* les probabilités émises sont égales aux fréquences empiriques. C'est par exemple le cas pour un système $\mathcal{P}_\varphi$ basé sur la climatologie. Par construction, la fiabilité d'un système de prédiction peut être corrigée *a posteriori* .
- la *résolution* : la résolution correspond à la capacité d'un système de prédiction à distinguer les valeurs observées *a posteriori* par rapport à un modèle $\mathcal{P}_\varphi$ basé sur la climatologie. Pour illustrer notre propos, un exemple est montré à la figure III.5. La figure III.5.a) montre l'enveloppe de prédiction d'une variable Y mensuelle émise par un modèle $\mathcal{P}_\varphi$ basé sur la climatologie φ de la variable Y (*i.e.* pour un mois donné, la distribution émise correspond à la distribution empirique estimée par l'ensemble des valeurs observées de la variable y pour le mois considéré) pour trois années de prédiction. La figure III.5.b) représente, pour la même période, l'enveloppe de prédiction délivrée par un système de prédiction $\mathcal{P}$ dont la résolution est plus importante. On remarque alors que la variation des valeurs de quantiles varient plus fortement dans le cas du système $\mathcal{P}$ par rapport à un système $\mathcal{P}_\varphi$ basé sur la climatologie. De plus, l'enveloppe émise par un système $\mathcal{P}_\varphi$ est la même pour les trois années considérées, tandis que celle émise par $\mathcal{P}$ tient compte de l'évolution temporelle du prédictand. En effet, l'enveloppe de prédiction émise par $\mathcal{P}$ varie autour de la valeur observée avec le temps. $\mathcal{P}$ possède alors un pouvoir de discrimination des évènements plus important.

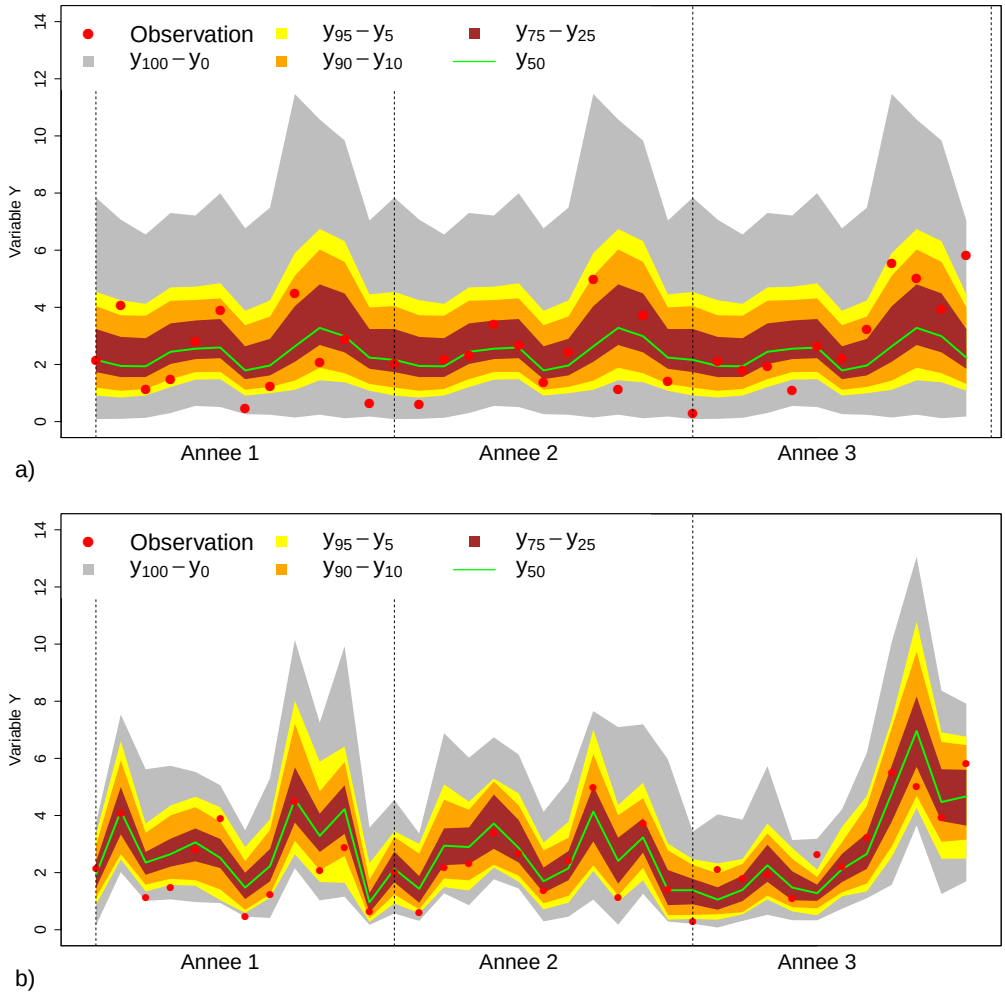

FIGURE III.5 – Illustration de la résolution pour la prédiction mensuelle d'une variable Y pour a) un système de prédiction $\mathcal{P}_\varphi$ prédisant la distribution empirique de Y pour chaque mois et b) un système de prédiction $\mathcal{P}$ pour lequel la capacité à distinguer les évènements est plus importante. Les plages de couleurs représentent la différence min-max (gris), l'inter-quantile $y_{95} - y_5$ (jaune), l'inter-décile (orange) et l'inter-quartile (rouge foncé). Le quantile médian est représenté en vert.

HERSBACH [2000] a proposé une décomposition empirique du $\overline{\text{CRPS}}$ en fonction d'un terme de fiabilité $\overline{\text{Rel}}$ et d'un terme de résolution $\overline{\text{Res}}$, tel que :

$$\overline{\text{CRPS}} = \overline{\text{Rel}} - \overline{\text{Res}} + \overline{\text{U}} \tag{III.9}$$

Le terme de fiabilité $\overline{\text{Rel}}$ est orienté négativement : plus $\overline{\text{Rel}}$ est faible, meilleure est la fiabilité du système de prédiction $\mathcal{P}$. Graphiquement, la valeur prise par $\overline{\text{Rel}}$ peut être reliée à la différence entre les courbes bleue et orange sur la figure III.4. On remarque alors que si le terme $\overline{\text{Rel}}$ est nul (correspondant alors à une surface entre les deux courbes nulle), le système de prédiction $\mathcal{P}$ est dit fiable.

Le terme de résolution $\overline{\text{Res}}$ est, quant à lui, orienté positivement. Plus il est important, plus la capacité du système $\mathcal{P}$ à discriminer les évènements est importante et meilleur est le système $\mathcal{P}$. Selon HERSBACH [2000], ce terme est très sensible aux observations qui se situent en dehors de la

gamme de valeurs couverte par les distributions émises, rendant par ailleurs le $\overline{\text{CRPS}}$ très sensible à de telles situations.

Enfin, un terme $\overline{\text{U}}$ appelé *incertitude* apparaît dans cette décomposition : il correspond à la performance moyenne en CRPS obtenue par un système $\mathcal{P}_\varphi$ basé sur la climatologie φ. Ce terme dépend seulement de la variable d'intérêt et est indépendant du système de prédiction. Pour une description plus mathématique de ces termes, le lecteur peut se référer aux travaux d'Hersbach [2000] [1].

En pratique, disposer d'une bonne fiabilité est souvent le premier attribut recherché pour un système de prédiction [*e.g.* Zalachori et al., 2012]. Par suite, une amélioration des autres caractéristiques d'un système de prédiction peut être effectuée.

Similairement au BSS, la comparaison de la performance de prédiction obtenue entre deux sites peut être effectuée en calculant le *Continuous Ranked Probability Skill Score* (CRPSS). Le CRPSS compare la performance du système $\mathcal{P}$ avec celle d'un système de prédiction de référence. En pratique, ce système de référence correspond souvent à un système $\mathcal{P}_\varphi$ qui prédit une distribution climatologique empirique. Le CRPSS est alors défini comme :

$$\text{CRPSS} = 1 - \frac{\overline{\text{CRPS}}}{\overline{\text{CRPS}}_\varphi} \tag{III.10}$$

où $\overline{\text{CRPS}}_\varphi$ correspond au CRPS moyen obtenu par le système $\mathcal{P}_\varphi$. Si le CRPSS est égal à 1, alors le système $\mathcal{P}$ est considéré comme parfait. Si sa valeur est inférieure à 0, alors il vaut mieux utiliser un système de prédiction $\mathcal{P}_\varphi$ basé sur la climatologie φ. Dans ces travaux de thèse, la distribution climatologique est estimée à partir de l'ensemble des précipitations observées dans une fenêtre saisonnière de $\pm$ 30 jours centrée sur le jour à prédire. Nous considérons donc une climatologie calendaire.

2.3. Evaluation du biais moyen

Le CRPSS et le BSS constituent les principaux critères d'évaluation mis en œuvre dans cette thèse. Dans certains cas, une évaluation de la capacité d'une MDES à reproduire la quantité de précipitation moyenne observée – ce qui représente une caractéristique souvent recherchée pour une MDES – a aussi été effectuée. Pour ce faire, nous avons utilisé un critère déterministe portant sur le scénario moyen.

Pour chaque prédiction i, la moyenne empirique $\widehat{\mu}_i$ de la distribution $\widehat{F}_{Y,i}(y)$ peut être estimée à partir des N valeurs y de précipitations. La série temporelle regroupant les valeurs de $\widehat{\mu}_i$ peut alors être considérée comme le scénario moyen prédit par le système $\mathcal{P}$. Le biais relatif b du scénario moyen est alors défini comme :

$$b = \frac{1}{\overline{y}} \cdot \left[\frac{1}{M} \sum_{i=1}^{M} \widehat{\mu}_i - \overline{y} \right] \tag{III.11}$$

où $\overline{y}$ note la valeur moyenne des précipitations observées.

1. Cette décomposition en termes de fiabilité, résolution et d'incertitude se base sur une décomposition similaire du score de Brier $\overline{\text{BS}}$ [Murphy, 1973 ; Murphy, 1986]. Comme nous ne l'avons pas utilisée dans cette thèse, elle n'est pas présentée ici.

2.4. Comparaison de performances

Dans ces travaux de recherche, les performances de prédiction définies aux sections 2.2.1, 2.2.2 et 2.3 sont évaluées pour plusieurs versions de la MDES Analog et pour le développement d'une MDES combinant un modèle MA et un modèle de régression. Dans de nombreux cas, la performance obtenue lorsqu'une version d'une MDES est testée est souvent comparée à la performance d'une MDES de référence. La variation de performance est alors définie comme :

$$\Delta \mathrm{S} = \mathrm{S}_T - \mathrm{S}_R \tag{III.12}$$

où S_T et S_R sont respectivement les performances selon le score S obtenues pour la MDES à tester et la MDES de référence. Dans cette thèse, le score S est souvent représenté par le BSS ou le CRPSS. Dans ce cas, un ΔS positif indiquera un gain de performance tandis qu'un ΔS négatif montrera une perte.

3. Evaluation du modèle Analog

Dans cette section, nous cherchons à établir les performances lorsqu'un modèle MA_p est appliqué pour la prédiction des précipitations sur la maille p pour laquelle le modèle MA_p a été optimisé. Dans ce cas, la période d'évaluation est la même que la période de calibration, *i.e.* du 01-08-1982 au 31-07-2001.

3.1. Evaluation globale du modèle Analog

La figure III.6.a) représente la distribution spatiale des performances en CRPSS de chaque modèle MA_p appliqué à la précipitation Safran p correspondante. Le CRPSS est le plus élevé le long de la côte Atlantique, sur la partie Ouest du Massif Central ainsi que sur le Nord des Alpes et le Jura où il atteint des valeurs supérieures à 0,35. Ces régions sont fortement exposées aux systèmes dépressionnaires de large-échelle provenant de l'Atlantique pour lesquels des précipitations sont souvent observées en ces mailles. Pour les massifs montagneux mentionnés, une part importante des précipitations observées est aussi d'origine orographique résultant des masses d'air humides associées aux vents d'Ouest. Par suite, l'analogie effectuée sur les géopotentiels, informant sur l'origine des flux et/ou l'activité dépressionnaire, permet d'expliquer une bonne partie des précipitations. Ceci n'est pas le cas pour d'autres régions en France où ces configurations atmosphériques influencent moins le régime. Par exemple dans le Sud-Est, une part plus importante d'entre elles sont d'origine convective. L'analogie sur les géopotentiels étant peu informative des précipitations convectives, de faibles valeurs de CRPSS atteignant 0,17 sont retrouvées dans le Sud-Est de la France et sur la Corse. La distribution des performances représentées à la figure III.6.a) est similaire à celle obtenue par Radanovics et al. [2013] avec un modèle Analog à l'origine optimisé pour les bassins de la Seine et de la Saône [Ben Daoud et al., 2011].

Les figures III.6.b) à III.6.d) représentent les termes de la décomposition du $\overline{\mathrm{CRPS}}$ selon Hersbach [2000]. Comme les termes de $\overline{\mathrm{Res}}$, $\overline{\mathrm{Rel}}$ et $\overline{\mathrm{U}}$ intervenant dans cette décomposition sont exprimés

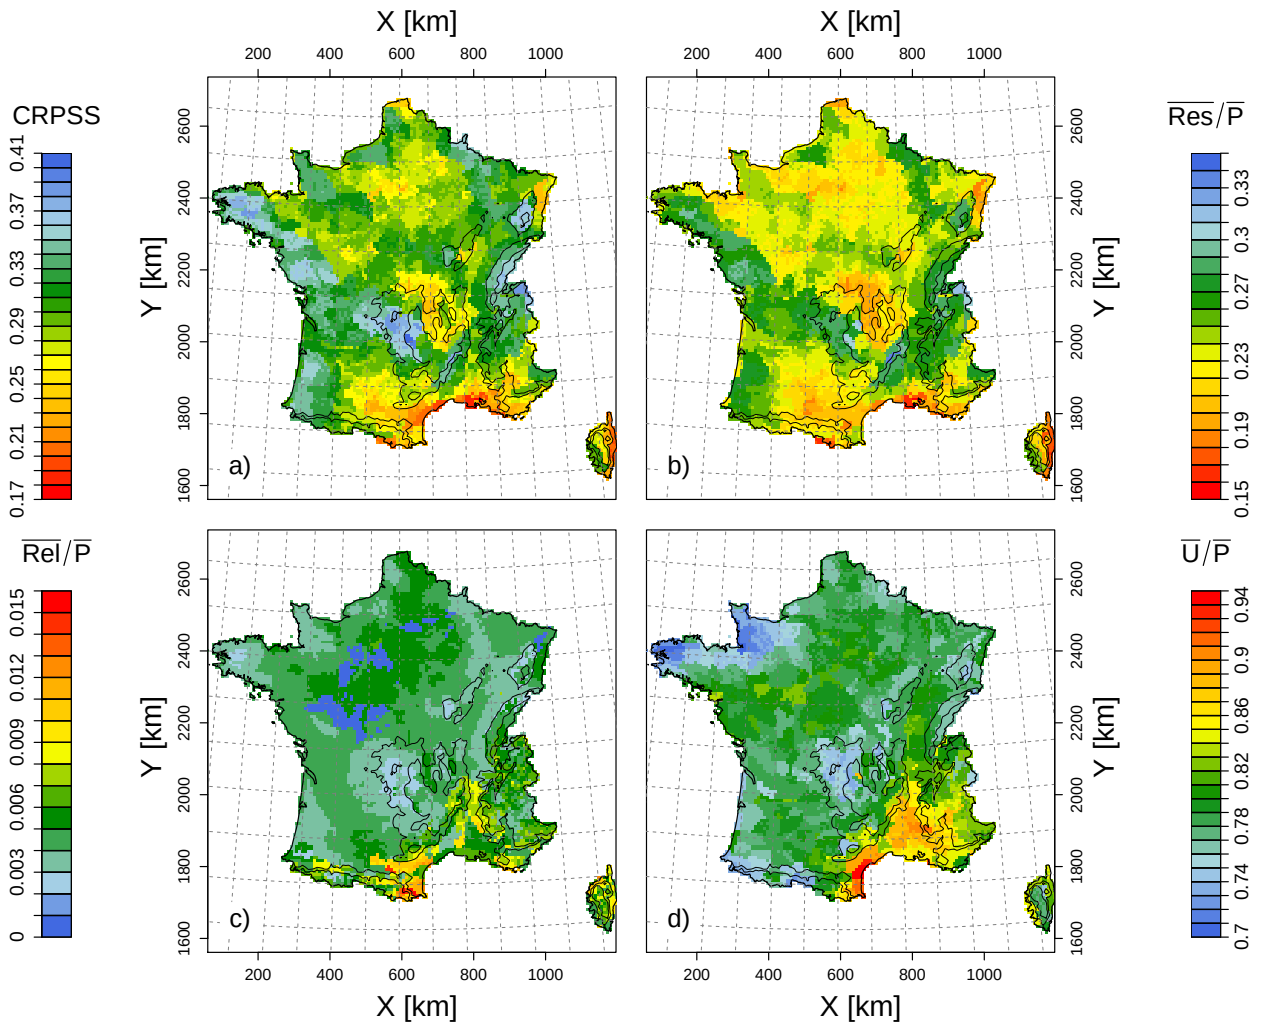

FIGURE III.6 – Distribution a) du CRPSS obtenu par le modèle MA_p appliqué à la maille p, b) de la résolution $\overline{\mathrm{Res}}/\overline{P}$, c) de la fiabilité $\overline{\mathrm{Rel}}/\overline{P}$ et d) de l'incertitude $\overline{\mathrm{U}}/\overline{P}$.

dans l'unité du predictand (*i.e.* des millimètres dans notre cas), nous avons décidé de les normaliser par la précipitation moyenne obtenue en chaque maille Safran et représentée à la figure II.3 de façon à pouvoir comparer spatialement les termes entre deux régions données. Concernant le terme normalisé de fiabilité $\overline{\mathrm{Rel}}$ (figure III.6.c), une majorité du territoire obtient une valeur inférieure à 0,005. Seulement quelques mailles Safran localisées dans le Sud-Est de la France obtiennent une valeur de fiabilité proche de 0,01. Cette région est caractérisée par une forte variabilité attestée par le coefficient de variation des précipitations qui est supérieur à 2,5 tandis qu'il est proche de 2 pour le reste des mailles Safran (figure III.7.a). La figure III.7.b) représente le quotient du terme de fiabilité $\overline{\mathrm{Rel}}$ sur le $\overline{\mathrm{CRPS}}$. Autrement dit, il s'agit de la part de l'erreur en $\overline{\mathrm{CRPS}}$ qui est due au terme de fiabilité $\overline{\mathrm{Rel}}$. Sur le territoire français, cette erreur représente au maximum 2,5 % du $\overline{\mathrm{CRPS}}$. Pour une majorité des mailles Safran, cette part est vraiment infime car elle est même comprise entre 0 et 1 % du $\overline{\mathrm{CRPS}}$. Par conséquent, le terme de fiabilité est négligeable par rapport aux autres termes de la décomposition du $\overline{\mathrm{CRPS}}$ de HERSBACH [2000]. De ce fait, le modèle MA peut être considéré comme un modèle de prédiction fiable. Par ailleurs, le CRPSS peut être approximé par le ratio du terme de

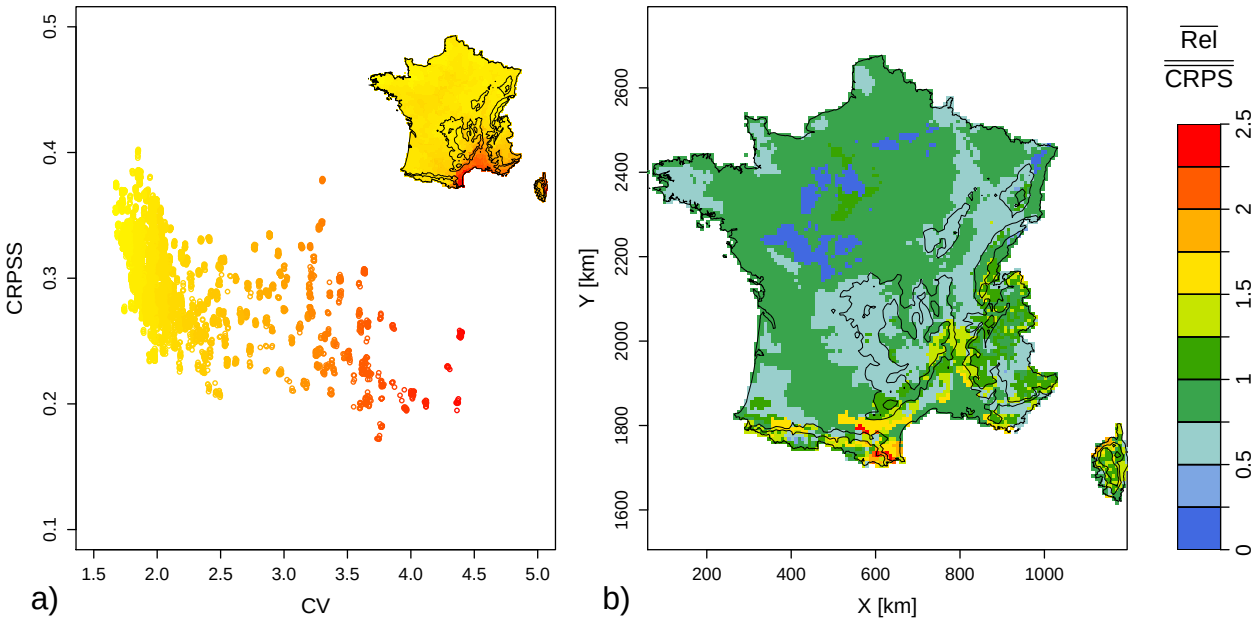

FIGURE III.7 – a) CRPSS obtenu par le modèle MA_p appliqué à la précipitation Safran p en fonction de son coefficient de variation. La distribution spatiale du coefficient de variation est représentée dans le coin supérieur droit. b) Quotient du terme de fiabilité $\overline{\mathrm{Rel}}$ et du $\overline{\mathrm{CRPS}}$ exprimé en pourcentage.

résolution par le terme d'incertitude (équation III.13).

$$\begin{aligned} \mathrm{CRPSS} &= 1 - \frac{\overline{\mathrm{Rel}} - \overline{\mathrm{Res}} + \overline{\mathrm{U}}}{\overline{\mathrm{U}}} \\ \mathrm{CRPSS} &= \frac{\overline{\mathrm{Res}} - \overline{\mathrm{Rel}}}{\overline{\mathrm{U}}} \\ \mathrm{CRPSS} &\simeq \frac{\overline{\mathrm{Res}}}{\overline{\mathrm{U}}} \end{aligned} \tag{III.13}$$

La distribution du terme normalisé de résolution est représentée sur la figure III.6.b). On remarque qu'elle semble corrélée à celle du CRPSS (figure III.6.a) : les régions pour lesquelles une forte valeur normalisée de $\overline{\mathrm{Res}}$ est observée correspondent à celles pour lesquelles de fortes valeurs de CRPSS sont obtenues, comme par exemple dans le Nord des Alpes, l'Ouest du Massif Central et la côte Atlantique. De même, les régions situées dans le Sud de la France sont celles dont le terme normalisé de résolution $\overline{\mathrm{Res}}$ et le CRPSS sont les plus faibles. Le CRPSS est donc fortement déterminé par la valeur obtenue par le terme de résolution $\overline{\mathrm{Res}}$. Le rapport entre les deux termes est néanmoins modulé par le terme d'incertitude $\overline{\mathrm{U}}$ (équation III.13). La valeur normalisée de ce dernier est relativement constante sur l'ensemble du territoire avec une valeur moyenne de 0,8 (figure III.6.d). Les valeurs plus faibles rencontrées (jusqu'à 0,7) sur l'Ouest du Massif Central, la Bretagne et la Normandie tendent à augmenter les valeurs de CRPSS rencontrées en ces régions. A l'inverse, des valeurs plus importantes sont obtenues dans le Sud-Est de la France, menant alors à diminuer les performances en CRPSS.

Finalement, la figure III.8 représente le biais relatif (*cf.* équation III.11) observé pour la reconstitution des précipitations annuelles moyennes par le modèle MA. La majorité des mailles Safran obtient un biais relatif absolu inférieur à 5%. Un biais négatif est observé dans le Sud de la France,

plus particulièrement sur les régions du Languedoc-Roussillon et des Midi-Pyrénées avec des biais inférieurs à -0,10. Un biais positif compris entre 0,05 et 0,10 est observé sur le Nord des Alpes et le massif du Jura.

3.2. Evaluation saisonnière

La figure III.9 représente les performances en CRPSS en fonction de chaque saison. Pour le calcul du CRPSS d'une saison donnée, l'incertitude $\overline{U}$ – calculée à partir d'un système basé sur la climatologie – est déterminée à partir des prédictions émises pour les jours appartenant à la saison considérée. Les distributions spatiales des saisons d'hiver, d'automne et de printemps se comportent de la même façon que les performances globales illustrées sur la figure III.6.a) : les performances les plus importantes se situent sur le pourtour Atlantique, sur les reliefs du Massif Central, des Vosges et des Alpes. Pour ces saisons (plus particulièrement pour l'hiver et l'automne), les précipitations retrouvées sur ces trois massifs sont dans une plus large mesure de type orographique comparées à celles de l'évaluation globale effectuée à l'échelle annuelle. Une bonne partie de ces précipitations est bien expliquée par l'analogie réalisée sur les géopotentiels, menant à une bonne capacité de prédiction. En plaine et dans les vallées, de plus faibles performances sont constatées. Les CRPSS les plus faibles se retrouvent le long de la côte méditerranéenne. Cependant, les performances en CRPSS sont meilleures pour les saisons d'hiver et d'automne (*i.e.* correspondant aux saisons les plus humides *cf.* figure II.3) et enfin au printemps. En comparant ces trois saisons, les meilleures performances varient entre 0,48 (sur le Massif Central en hiver) et 0,36 (sur la côte Atlantique au printemps). En plaine, le CRPSS est compris entre 0,36 et 0,26. Sur le pourtour méditerranéen, les performances se situent entre 0,26 et 0,2.

La saison d'été se distingue des autres par l'obtention de performances plus faibles et plus homogènes sur le territoire. La performance moyenne en CRPSS est de 0,26. Seul le Nord des Alpes

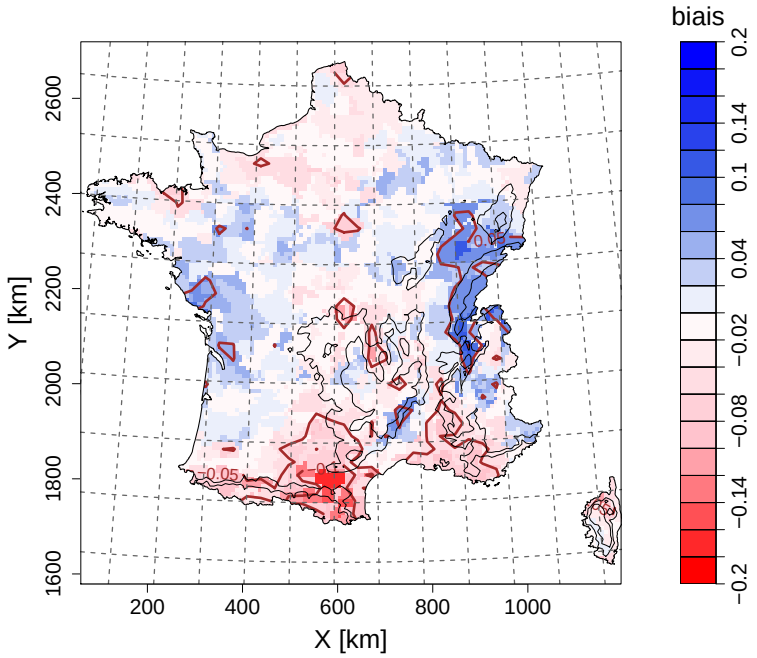

FIGURE III.8 – Biais relatif obtenu par le modèle MA. Les lignes de contour correspondent à des biais relatifs de ± 0,05 et ± 0,10.

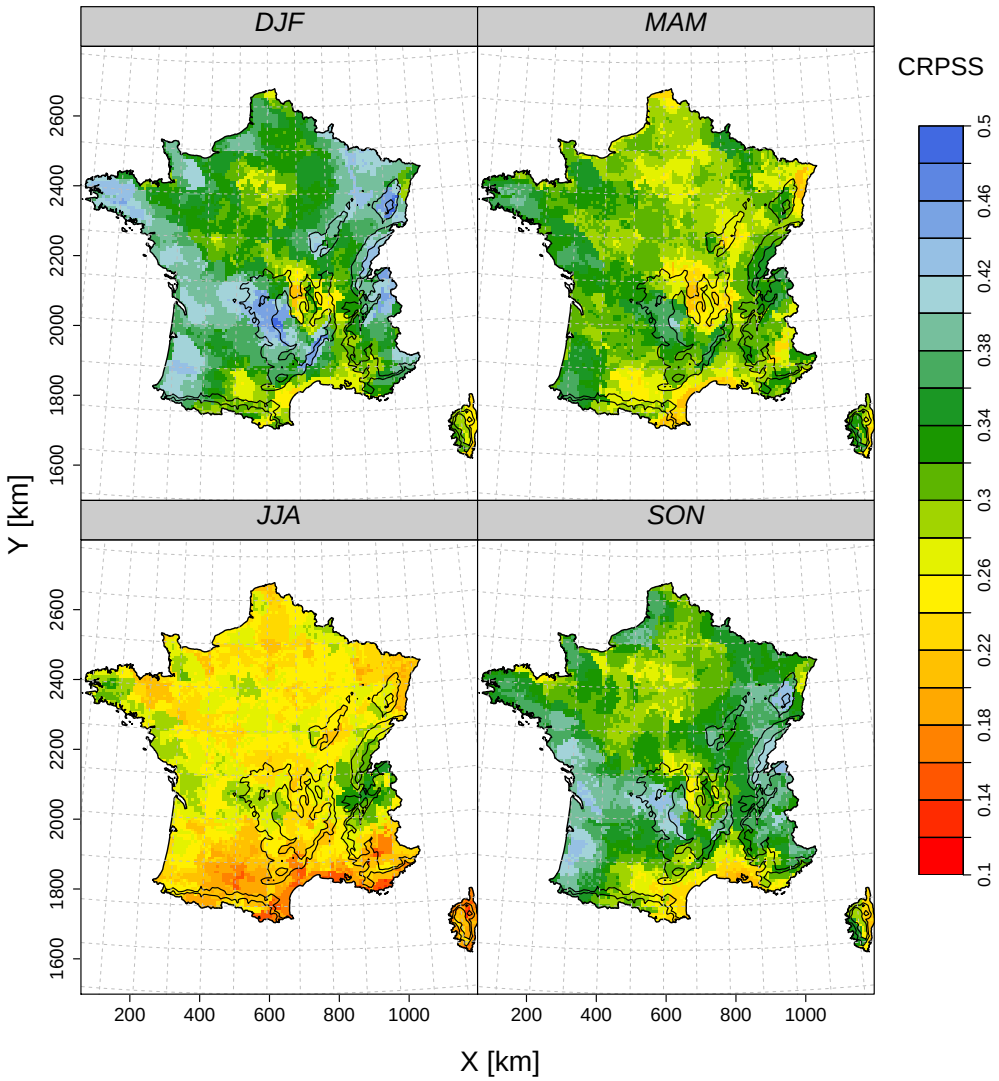

FIGURE III.9 – Performance en CRPSS lorsque le modèle MA_p est appliqué à la maille p en fonction des saisons.

se démarque par une performance plus importante environ égale à 0,32. Les performances les moins bonnes se situent le long de la côte méditerranéenne où elles peuvent atteindre 0,12 en certaines mailles. Cette baisse de performance est due à la plus forte proportion de précipitations d'origine convective.

La figure III.10 représente les biais relatifs obtenus par le modèle MA en fonction des saisons. Par rapport à l'évaluation globale illustrée à la figure III.8, le biais présente ici une variabilité plus importante. Les saisons pour lesquelles les biais relatifs absolus sont proches de 0 sont les saisons de transition à savoir le printemps et l'automne. Plus particulièrement, le biais relatif observé en automne s'avère très proche du biais relatif global où un biais négatif inférieur à -0,05 est constaté pour les régions du Languedoc-Roussillon et des Midi-Pyrénées, et un biais positif supérieur à 0,05 sur le Nord des Alpes et le Jura. Au printemps, la variation spatiale du biais est légèrement plus importante qu'à l'automne. Le biais négatif s'étend sur le pourtour méditerranéen et le Sud des Alpes et un biais positif est trouvé le long de la côte Atlantique allant de la Vendée aux Landes. Les saisons d'été et d'hiver possèdent quant à elles des biais très marqués. En hiver, des biais humides se retrouvent sur

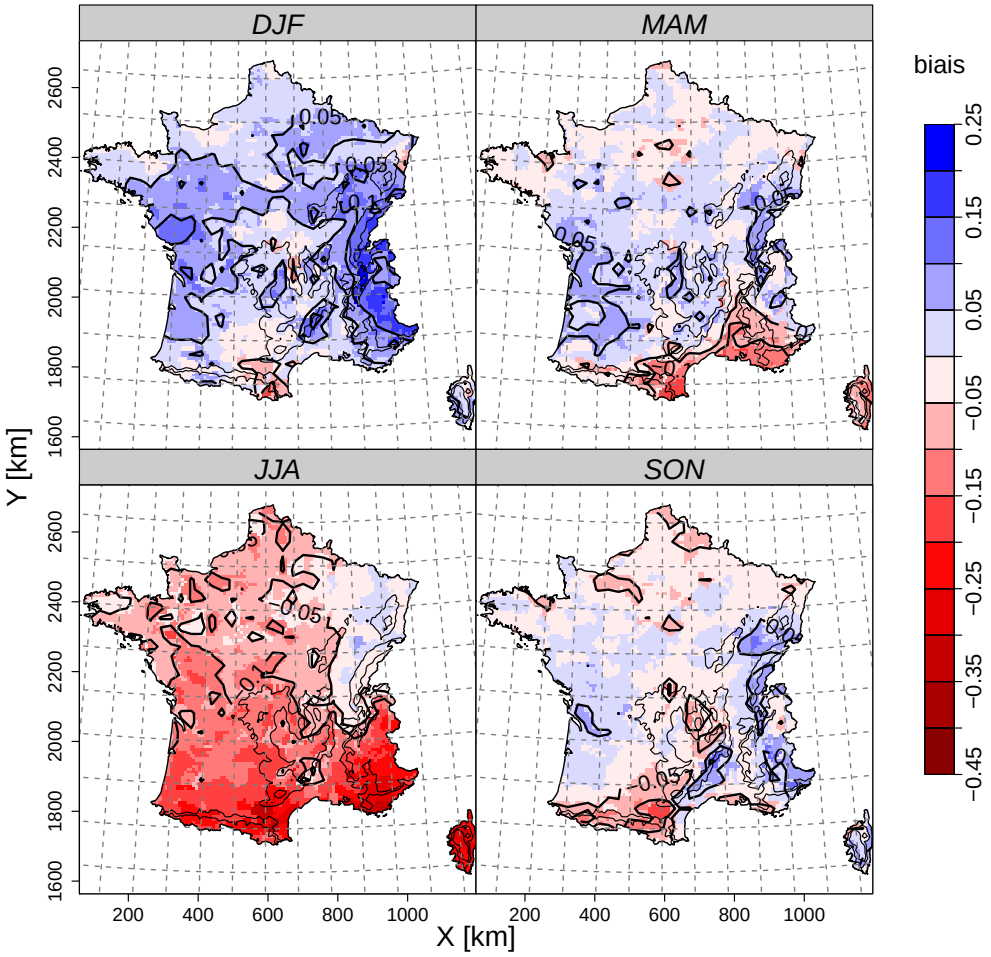

FIGURE III.10 – Biais relatifs obtenus lorsque le modèle MA_p est appliqué à la maille p en fonction des saisons.

l'ensemble du territoire. Sur le pourtour Atlantique et l'ensemble des massifs montagneux de l'Est de la France, ces biais sont supérieurs à 5%. A l'inverse, les biais sont négatifs en été. Seul le quart Nord-Est de la France obtient un très faible biais compris entre -5 et 5%. Ainsi, les biais d'hiver et d'été s'annulent et conduisent à l'obtention d'un biais global annuel quasiment nul. Comme expliqué dans la section 4.1 de CHARDON et al. [2014], un biais positif résulte du sur-échantillonnage en moyenne de journées plus pluvieuses au détriment de journées analogues plus sèches (et inversement pour les biais négatifs). Même si des investigations supplémentaires ont été conduites [1], nous n'avons pas pu identifier les raisons menant à de tels biais.

3.3. Evaluation par type de temps

La figure III.11 représente les performances en CRPSS obtenues en fonction des types de temps. Pour un type de temps donné, le terme d'incertitude $\overline{\mathrm{U}}$ nécessaire à l'estimation du CRPSS est déterminé à partir des prédictions issues du système basé sur la climatologie qui sont émises pour les

1. Une seconde optimisation de la fenêtre d'analogie a été effectuée pour les 8 981 MAs en considérant cette fois comme variable d'intérêt la racine carrée des précipitations. Il a été remarqué que l'identification de la fenêtre était sensible à cette transformation de la variable d'intérêt, ce qui conduisait à l' obtention de biais globaux à l'échelle annuelle et saisonnière plus importants que lorsque l'optimisation est conduite sur la précipitation brute (*cf.* section 2 de l'annexe A).

jours appartenant au type de temps considéré. La figure III.11 détaille donc, pour chaque type de temps, le gain apporté par le modèle MA par rapport à une prédiction basée sur la climatologie [1].

Pour le TT2 qui correspond à une circulation d'Ouest, de bonnes performances sont obtenues sur l'ensemble du territoire, avec des maxima atteignant 0,4 sur la côte Atlantique, l'Ouest du Massif Central et le Nord des Alpes. Seules les vallées de la Loire amont, de l'Allier et du Rhône obtiennent de faibles performances proches de 0,2. Ces vallées correspondent aux régions qui peuvent potentiellement être abritées des masses d'air humides provenant de l'Ouest. Pour le TT1, des performances atteignant 0,5 sont observées sur le Sud-Ouest de la France et sur certains reliefs comme le Nord des Alpes et la partie Ouest du Massif Central. Comme on peut le remarquer à la figure II.7, les précipitations associées au TT1 sont en moyenne pour ces régions plus importantes que la précipitation moyenne annuelle. Les performances sont moindres (proches de 0,05) pour les régions protégées des flux de Nord-Ouest, comme le Languedoc-Roussillon et les Pyrénées Orientales. Pour le TT3, les seules régions obtenant les meilleures performances (proches de 0,35) sont la Bretagne, le Nord de la côte Atlantique et le Lyonnais, correspondant une fois de plus pour la plupart d'entre elles aux régions directement exposées au flux de Sud-Ouest.

Une évaluation similaire peut être effectuée pour les circulations de Sud. Pour le TT7, les meilleures performances sont obtenues pour l'ensemble des régions exposées aux flux entrant d'humidité, *i.e.* le Sud-Est, le Massif Central et le Sud des Alpes jusqu'à la Bourgogne. Le TT4 acquiert quand à lui de bonnes performances sur les massifs exposés au flux de Sud-Est (*i.e.* les Cévennes-Vivarais) et pour lesquels la précipitation est en général plus de deux fois supérieure à la précipitation moyenne (figure II.7). De bonnes performances sont aussi obtenues à partir des Alpes jusqu'au Nord-Est de la France. Pour les régions abritées par les Alpes suisses et italiennes, les précipitations observées pour ce type de temps sont très faibles voir nulles. Dans le cas du TT6, la région la plus exposée au retour d'Est (*i.e.* le Sud-Est) est celle qui possède la meilleure performance (environ 0,3). De bonnes performances peuvent être aussi observées à l'autre bout du territoire, *i.e.* en Bretagne et le long de la Manche où de très faibles cumuls sont observés (figure II.7). Pour le TT5, de bonnes performances atteignant parfois 0,4 sont seulement constatées en Bretagne, le long de la côte Atlantique et sur les Cévènnes-Vivarais où des cumuls quasiment nuls sont obtenus (figure II.7). Enfin, le TT8 – correspondant aux jours les plus secs – possède les meilleures performances avec des valeurs variant de 0,5 à 0,8 en fonction de la région considérée. Quelques mailles situées dans l'extrême Sud-Est de la France et en Corse obtiennent des performances moindres atteignant 0,3.

Finalement, pour un type de temps donné, il semble qu'il existe une relation entre la direction des flux, les performances de prédiction du modèle MA et les précipitations observées :

- Pour un type de temps donné (excepté le TT8 et le TT5), les régions directement exposées aux flux, et à plus forte raison lorsqu'il s'agit de reliefs importants, reçoivent en moyenne des précipitations plus importantes qu'ailleurs. Ces régions obtiennent également les plus fortes performances en CRPSS.
- Les régions éloignées de l'origine des flux, et recevant par conséquent pour ce type de temps très peu de précipitations en moyenne, obtiennent aussi une bonne performance de prédiction. Ceci est valable pour tous les types de temps excepté le TT2 où l'on remarque sur la figure II.7 que

1. La climatologie est celle définie à la section 2.2.2 du chapitre 2. Elle est calendaire et indépendante du type de temps.

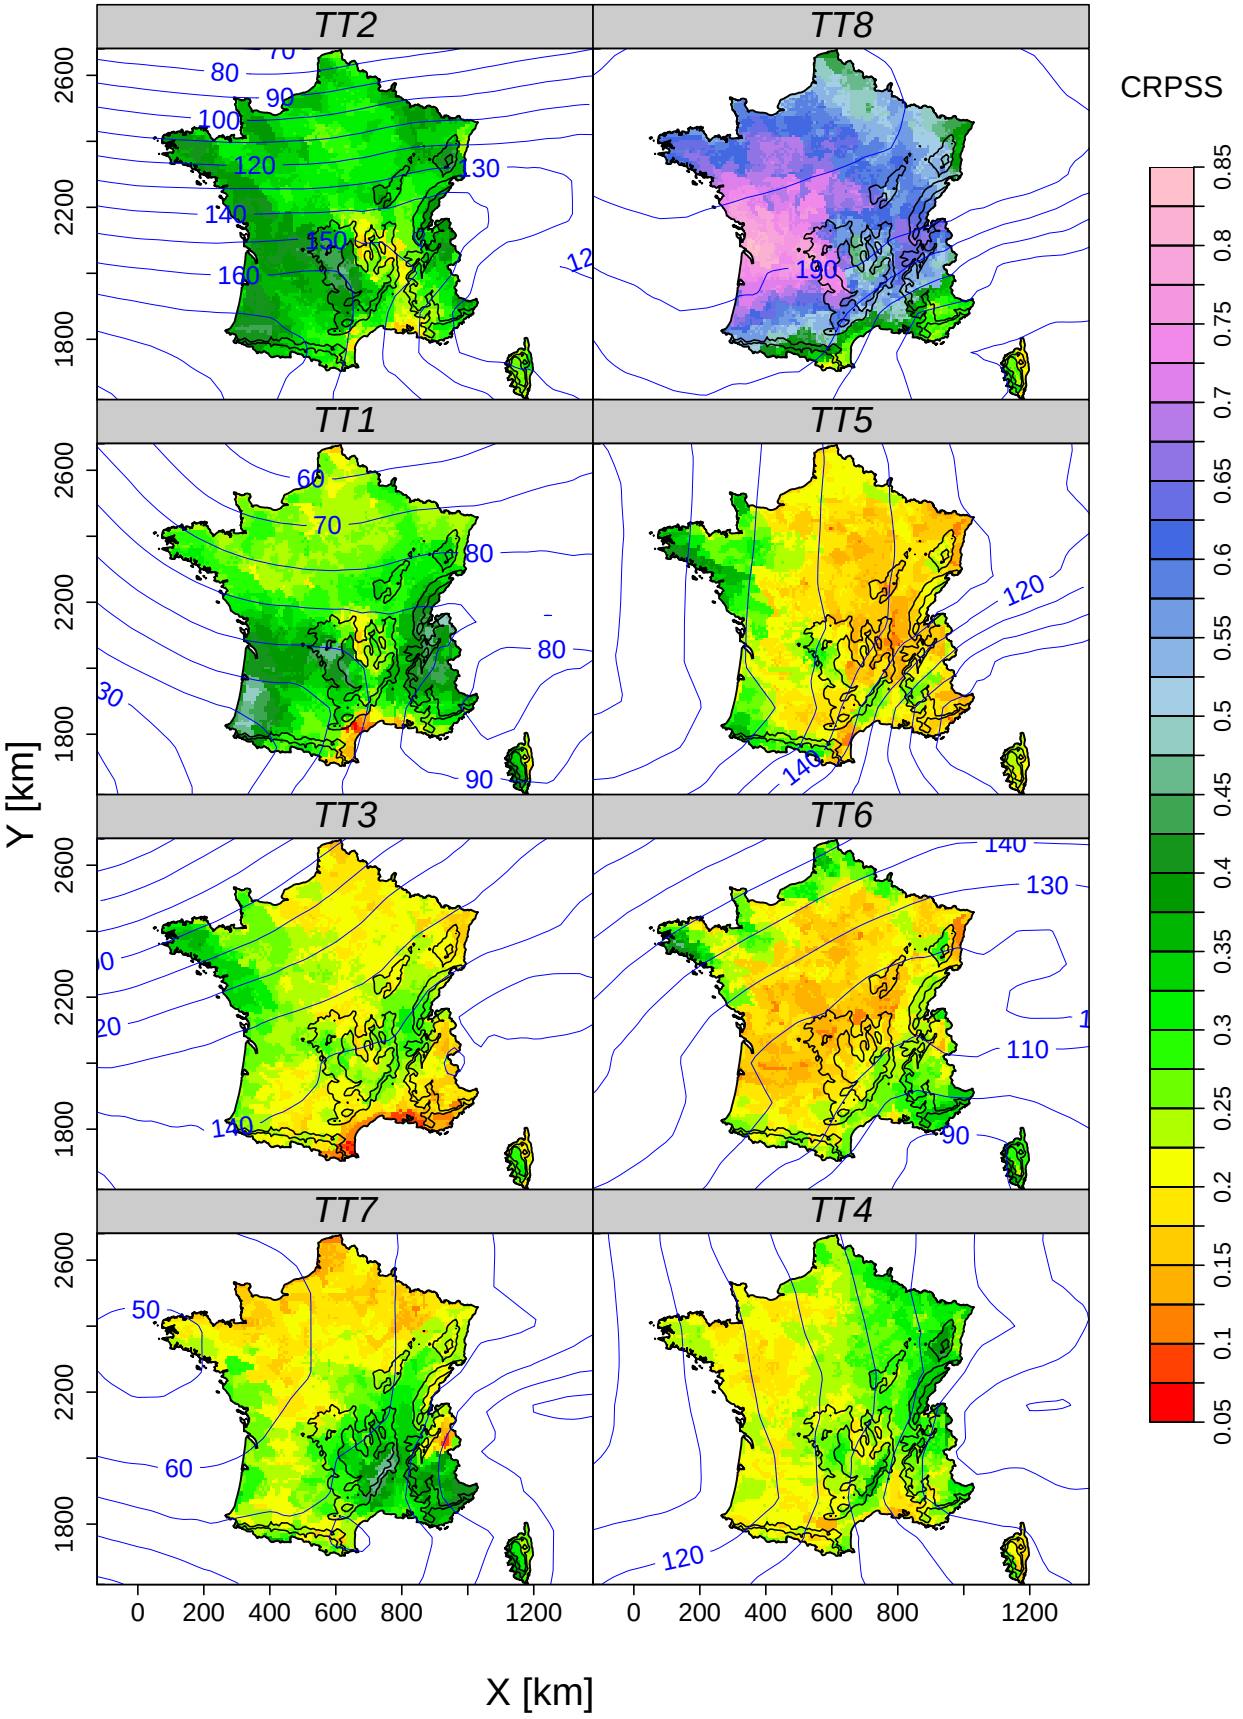

FIGURE III.11 – Performance en CRPSS en fonction des types de temps. Les lignes bleues représentent la hauteur (en mètres) du géopotentiel à 1000 hPa.

la région du Sud-Est correspondant à la zone la plus sèche est celle qui obtient les plus faibles performances (figure III.11).

- Les régions intermédiaires reçoivent généralement des précipitations proches de la moyenne. Elles obtiennent dans la majeure partie des cas des performances réduites.

En première approximation, il semble donc plus facile de prédire les précipitations lorsque celles-ci sont fortement probables ou, à l'inverse, fortement improbables du fait de l'origine des masses d'air.

Les biais sont fortement dépendant du type de temps et de la région. Nous n'avons pas pu identifier les causes à l'origine des distributions spatiales observées. Cependant, il est intéressant de noter la forte cohérence spatiale de ces biais. A titre d'illustration, la figure III.12 représente le biais relatif en fonction des types de temps. Les lignes de contours correspondent ici à un biais relatif de ± 10% (contrairement aux figures III.8 et III.10 où elles représentaient des biais de ± 5%). Pour le TT1, le biais est quasiment nul pour l'ensemble du territoire excepté pour le Sud-Est de la France pour lequel il est fortement négatif avoisinant les -30 à -50%. Pour le TT8, le biais est, à l'exception des Alpes du Sud, fortement positif partout ; les biais les plus forts étant parfois supérieurs à 200%. Pour cette situation, ce résultat peut s'expliquer par une pluie moyenne quasiment nulle sur l'ensemble du territoire, et par conséquent un numérateur faible, ce qui tend à accroître le biais relatif vers l'infini.

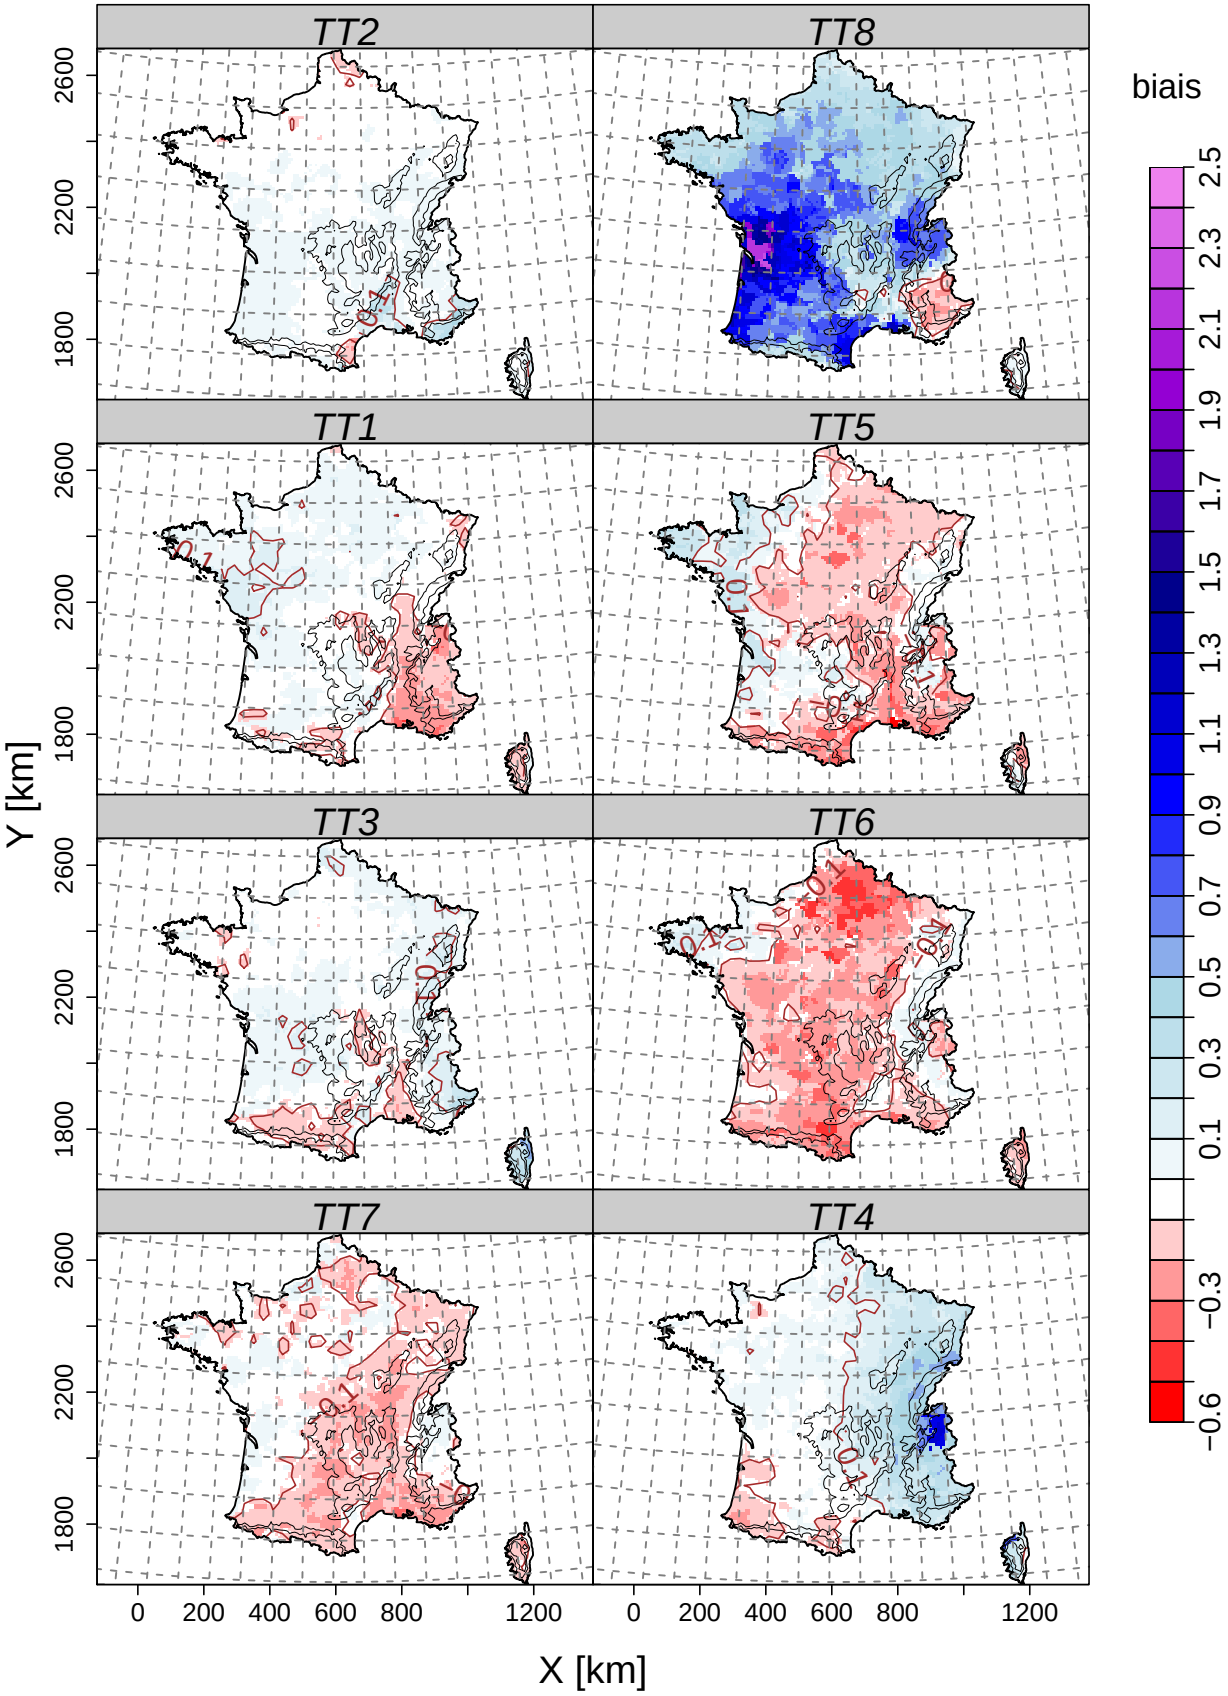

FIGURE III.12 – Biais relatifs du modèle MA_{25} en fonction des types de temps. Les lignes de contours représentées en marron correspondent à un biais relatif de ± 10%.

Chapitre IV

Transposabilité spatiale des dates analogues

Dans ce chapitre, nous nous questionnons sur la possibilité d'utiliser un seul modèle MA pour la prédiction des précipitations en tout point d'une vaste région donnée. Pour répondre à cette question, nous avons évalué la perte de performance obtenue lorsqu'un modèle MA localement optimisé pour une précipitation Safran p était appliqué pour la prédiction des précipitations en chaque maille du territoire. Douze modèles MAs [1] – dont chacun a été optimisé pour une précipitation Safran donnée selon la procédure itérative décrite à la section 1 du chapitre III – ont été testés pour la prédiction des précipitations sur la France. Les mailles pour lesquelles ces modèles ont été localement optimisés sont présentées sur la figure IV.1 alors que le tableau IV.1 indique leurs dénominations. Ces mailles sont dénommées par la suite *"mailles d'accroche"*.

Tableau IV.1 – Dénomination des mailles d'accroche représentées sur la figure IV.1.

Sigle → Dénomination	**Sigle → Dénomination**
NW → Nord-Ouest	NE → Nord-Est
W → Ouest	E → Est
SW → Sud-Ouest	SE → Sud-Est
N → Nord	S → Sud
C → Centre	MC → Massif Central
B → Bretagne	Co → Corse

L'étude de la transposabilité spatiale d'un modèle MA a été menée à partir de ces douze modèles. Pour des raisons de synthèse, les résultats présentés dans la suite de ce chapitre ne concerneront seulement qu'un nombre restreint de ces modèles. Cette étude a fait l'objet d'une publication dans

1. Ces douze modèles MA ont été optimisés pour douze mailles Safran couvrant l'ensemble du territoire français (figure IV.1).

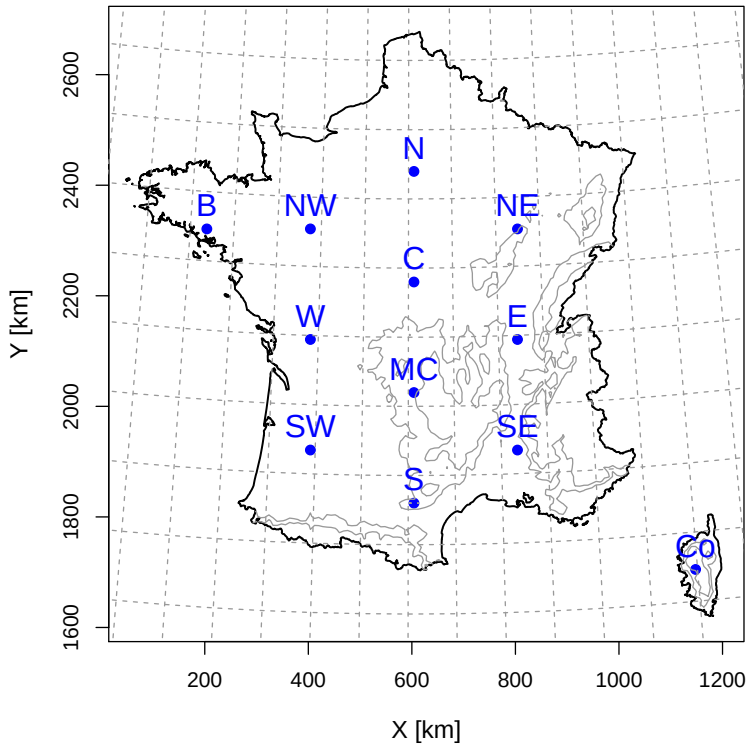

FIGURE IV.1 – Mailles Safran à partir desquelles les modèles MA testés ont été transposés. La dénomination de chacune des mailles est donnée dans le tableau IV.1.

la revue *Journal of Climate* s'intitulant *"Spatial similarity and transferability of analog dates for precipitation downscaling over France"*[1]. Un résumé étendu en français de cette publication se trouve à la première section de ce chapitre. Une version de l'article est disponible à la deuxième section. Comme une telle présentation conduit inévitablement à des redites dans un manuscrit de thèse, un lecteur pressé pourra ignorer les parties introductives de l'article (de la partie 1 à la partie 2.2 incluse) dont les points évoqués auront déjà été présentés précédemment. Dans une troisième partie, nous présentons différentes analyses complémentaires qui évaluent la transposabilité spatiale du modèle MA en fonction de différents filtres saisonniers (*i.e.* par saisons ou types de temps).

1. Résumé étendu

Depuis les années 2000, les MDES ont beaucoup été utilisées pour la génération de scénarios météorologiques en un site unique. Dans ce cas, le développement de la MDES requise, qu'elle soit de type analogique, fonction de transfert ou conditionnée au type de temps, est assez aisé. En revanche, la génération de scénarios couvrant plusieurs sites d'une région ou d'un hydrosystème de grande taille donné est une tâche plus difficile, en particulier lorsque l'on souhaite respecter la cohérence spatiale des précipitations à prédire.

Dans ce contexte, les approches de type analogique offrent un avantage particulièrement intéressant pour la génération de scénarios spatialement cohérents en comparaison aux autres approches. Sur la base d'un critère d'analogie et d'une archive météorologique, une ou plusieurs situations analogues

1. J. CHARDON et al. [**2014**]. "Spatial similarity and transferability of analog dates for precipitation downscaling over France". *Journal of Climate*. Vol. 27. no. 13, p. 5056–5074. doi : `10.1175/JCLI-D-13-00464.1`.

sont retenues pour prédire les variables locales. Lorsque la même date analogue est utilisée en plusieurs lieux, la cohérence spatiale du scénario météorologique local produit est de fait automatiquement reproduite.

Cependant, les prédicteurs choisis pour la sélection des dates analogues sont souvent optimisés pour l'endroit en lequel la prédiction doit être effectuée. Ils peuvent d'ailleurs fortement dépendre de la région considérée [Cavazos & Hewiston, 2005 ; Mezghani et al., 2012]. Dans ce contexte, la question que nous explorons ici est la suivante : dans quelle mesure et jusqu'à quelle distance un MA optimisé pour un site donné peut-il être utilisé pour la prédiction en un autre site ? En d'autres termes, quelle est la transposabilité spatiale d'un modèle localement optimisé ?

Dans ce chapitre, nous évaluons la transposabilité spatiale de douze modèles MAs optimisés pour les différentes mailles d'accroche mentionnées en introduction. Le modèle considéré est utilisé pour la prédiction des précipitations en toute autre maille du territoire. Pour chacun des sites, la performance de prédiction résultant du modèle transposé est comparée à la performance de prédiction du modèle MA optimisé pour ce site. La transposabilité spatiale est évaluée par la perte de performance obtenue avec le modèle transposé.

Les résultats montrent que pour un modèle MA seulement basé sur des géopotentiels, la perte de performance engendrée est inférieure à 1 point de CRPSS sur des distances pouvant atteindre 400 km à partir de la maille p pour laquelle un modèle transposé MA_p a été optimisé, indiquant ainsi une forte transposabilité spatiale. Cette transposabilité spatiale s'avère sensible à la présence des principaux reliefs comme le Massif Central qui peuvent jouer le rôle de barrière topographique. Par ailleurs, une évaluation de la similarité entre les dates analogues d'un modèle transposé MA_p et celles de tout autre modèle MA_k met en évidence qu'il n'est pas nécessaire de disposer de dates analogues similaires pour permettre une bonne transposition spatiale du modèle MA_p. En résumé, une performance quasi-optimale peut être obtenue avec un MA transposé jusqu'à une distance de 400 km environ, pour autant que la maille cible ne soit pas séparée de la maille d'accroche par une barrière topographique majeure.

Il s'avère que la génération de scénarios de précipitation à partir d'un modèle MA_p transposé ne produit pas de biais importants (entre $\pm 5\%$) pour les mailles dont la distance est inférieure à 200 km de la maille p. Pour les autres mailles, des biais non-négligeables (dont la valeur absolue moyenne est égale à 20%) peuvent être obtenus : un modèle $\mathrm{MA}_{\mathrm{SE}}$ optimisé pour une maille du Sud-Est produit par exemple un biais positif important lorsqu'il est transposé dans le Nord-Ouest de la France. A l'inverse, un modèle $\mathrm{MA}_{\mathrm{NW}}$ optimisé pour une maille du Nord-Ouest obtient un biais négatif important lorsqu'il est transposé dans le Sud-Est. Ces biais sont dus à un échantillonnage hétérogène des situations analogues passées contenues dans l'archive historique.

Dans une seconde partie, nous discutons de l'influence des paramètres du MA sur la transposabilité spatiale des dates analogues. Dans ce but, un modèle Analog à deux niveaux d'analogie [Bontron, 2004 ; Marty et al., 2012] est introduit : les 25 journées analogues utilisées pour la prédiction sont sélectionnées parmi un ensemble de 60 journées analogues à la situation cible en terme de circulation atmosphérique. La seconde sélection est effectuée sur une analogie en terme d'humidité de l'air (*i.e.* le produit de l'eau précipitable dans la colonne d'atmosphère par l'humidité relative à 850 hPa). De par l'ajout d'une information locale, les performances obtenues par ce nouveau modèle Analog sont

supérieures à celles obtenues avec le modèle MA à un seul niveau d'analogie. Cependant, il apparaît que ce gain de performance est dommageable à la bonne transposabilité du modèle : l'extension des domaines pour lesquels une faible perte de performance est obtenue est moins importante que celle précédemment obtenue avec le modèle à un seul niveau d'analogie. Des résultats similaires sont trouvés lorsque le nombre N_d de dates analogues varie : plus le nombre N_d est grand, plus la performance locale de prédiction devient faible, et meilleure devient la transposabilité. En résumé, plus le modèle est performant localement, moins il semble transposable en d'autres régions. Sur de vastes territoires, un compromis entre performance du modèle MA et sa bonne transposabilité spatiale peut alors s'avérer nécessaire.

2. Publication dans Journal of Climate

Spatial similarity and transferability of analog dates for precipitation downscaling over France

Jeremy Chardon[1], Benoit Hingray[1,2], Anne-Catherine Favre[1,3]

[1] *Univ. Grenoble Alpes, LTHE UMR 5564, Grenoble, F-38000, France*

[2] *CNRS, LTHE UMR 5564, Grenoble, F-38000, France*

[3] *Univ. Grenoble Alpes, GINP/ENSE3, BP 53, 38041 Grenoble Cedex 9, France*

Philemon Autin[3], Joël Gailhard[4]

[4] *EDF-DTG, 21 Avenue de l'Europe, BP 41, 38040 Grenoble Cedex 9, France*

Isabella Zin[1,3], Charles Obled[1,3]

Abstract

High-resolution weather scenarios generated for climate change impact studies from the output of climate models must be spatially consistent. Analog Models (AMs) offer a high potential for the generation of such scenarios. For each prediction day, the scenario they provide is the weather observed for days in a historical archive that are analogous according to different predictors. When the same "analog date" is chosen for a prediction at several sites, spatial consistency is automatically satisfied. The optimal predictors and consequently the optimal analog dates are however expected to depend on the location for which the prediction is to be made.

In the present work, the predictor (1000 and 500 hPa geopotentials) domain of a benchmark AM is optimized for the probabilistic daily prediction of 8,981 local precipitation "stations" over France. The corresponding 8,981 locally domain-optimized AMs are used to explore the spatial transferability and similarity of the optimal analog dates obtained for different locations. Whereas the similarity is very low even when the locations are close, the spatial transferability of the optimal analog dates for a given location is high. When they are used for the prediction at all other locations, the loss of prediction performance is therefore very low over large spatial domains (up to 500 km). Spatial transferability is lower in the presence of high mountains. It also depends on the parameters of the AM, e.g. its archive length, predictors and number of analog dates used for the prediction. In the present case, AMs with higher prediction skill exhibit lower transferability.

1 Introduction

High-resolution scenarios of various surface meteorological variables are classically required for impact studies at regional scales. Climate models usually exhibit severe limitations for simulating such scenarios. Their coarse spatial resolution leads for instance to a crude representation of precipitation related processes (e.g. Giorgi and Mearns, 1991, Frei et al., 2003). Precipitation outputs are therefore classically biased and often exhibit unrealistic spatial patterns (Salathe, 2003) and variability (Burger and Chen, 2005). They are moreover often available at spatial and temporal scales that are much too coarse with respect to the scales required for operational purposes or impact studies. Similar limitations are known for other surface meteorological variables such as temperature, wind and radiation. Statistical Downscaling Models (SDMs) are often used to overcome these limitations and produce the required meteorological scenarios from climate models outputs. They are based on the following twofold rationale: 1) local meteorological variables are strongly influenced by the state of the atmosphere and its circulation at the synoptic scale and 2) synoptic-scale atmospheric variables are better simulated by climate models. SDMs are thus based on empirical relationships established, for recent decades and generally for a daily time step,

between a selection of large-scale atmospheric variables (called the predictors) and the required local meteorological variables (called the predictands).

A large number of SDMs have been proposed over the last two decades (see Maraun et al., 2010, for a review). They are widely used to generate weather scenarios for past or future climates from outputs of climate models (e.g. Wilby et al., 1999, Hanssen-Bauer et al., 2005, Boé et al., 2007, Lafaysse et al., 2014). They can also be used to reconstruct weather scenarios from atmospheric reanalysis data (specific events as in Auffray et al. (2011) or time sequences covering 50 to 100 past years as in Mezghani and Hingray (2009), Kuentz et al. (2013) and Wilby and Quinn (2013)). Another application is weather forecasting on the basis of the outputs of regional or synoptic scale numerical weather prediction models (e.g. Obled et al., 2002, Gangopadhyay et al., 2005, Marty et al., 2012, 2013). Perfect Prog approaches (Maraun et al., 2010), mainly based on transfer functions or analog resampling methods, are SDMs of particular interest because they use the time variations of large-scale variables (e.g. pseudo-observations of the recent climate) to reproduce the time variations that would have been obtained for local scale surface meteorological variables (e.g. observations for the same recent climate period).

Most SDMs have been used to generate precipitation and temperature time series as main meteorological variables for hydrological applications. Over recent years, SDMs have focused even more on other meteorological variables used in agro- and bio-meteorology and also climate related energy sources (relative humidity, wind speed, potential evaporation, solar radiation ...). Key scientific challenges for future decades include the generation of relevant scenarios for multiple weather variables at multiple sites within a region of interest (Wilks, 2012). A number of critical issues arise here. They mainly involve the difficulty of generating, from both a statistical and physical viewpoint, relevant weather scenarios with respect to 1) space-time fluctuations of each weather variable and 2) space-time cofluctuations between weather variables.

For instance, transfer functions (e.g. based on non-linear regressions, artificial neural networks or principal component analysis) have been widely used to generate different weather variables at a single site or areal averages. They can be extended to create multivariate and multisite (or even true spatial) generators, i.e. adapted and used for multiple locations and multiple variables simultaneously (e.g. Roessler et al., 2012). The use of common large-scale predictors induces some spatial correlation between the generated predictands. Some temporal correlation (autocorrelation) is also obtained as a result of the significant persistence of driving atmospheric indices chosen as predictors (Buishand et al., 2004). However, the level of correlation obtained either in space or time may be not sufficient unless the generation at individual sites is forced by spatially and temporally correlated random-numbers (e.g. Wilks and Wilby, 1999, Mezghani and Hingray, 2009). The reproduction of observed correlation structures from a statistical point of view is moreover not a guarantee that generated space-time patterns are relevant from a physical point of view, especially for infrequent events. This may be for instance a critical limitation for the generation of major precipitation events presenting major spatial heterogeneities such as those frequently observed in regions with complex and marked topography (e.g. Mezghani and Hingray, 2009).

A good alternative consists of non-parametric SDMs based on the k-nearest neighbor (kNN) resampling approach. These approaches have been widely used in recent years for the generation of daily weather variables at multiple sites (e.g. Buishand and Brandsma, 2001, Gangopadhyay et al., 2005). A number of recent works have extended their application to the generation of a number of covariates (e.g. precipitation, temperature, relative humidity, long and short wave radiation and wind speed in Boé et al., 2007, Lee et al., 2012, Lafaysse et al., 2014). Analog dates of the current generation day are searched for in the historical database on the basis of a similarity criterion. A daily state vector characterizing the daily atmospheric circulation and state is used to identify the days that are the most similar to the current day. The required surface weather variables observed for one or for a selection of the kNNs are then used as a weather scenario for the current day. A number of variants of the kNN approach have been presented over the last decade. Differences are related to 1) the vector of large-scale predictors (e.g. given fields of synoptic variables (Obled et al., 2002) or vector of synthetic indices extracted from these fields via Principal Component Analysis (PCA) (Zorita and von Storch, 1999)), 2) the distance criterion used to identify the kNNs (e.g. Euclidean, Mahalanobis, Teweles-Wobus) and 3) the method used to estimate the predictand from these kNNs. The analog method classically refers to the configuration where the nearest neighbor is selected as the scenario for each generation day (e.g.

Zorita and von Storch, 1999). A probabilistic estimation of predictands is also often achieved when all kNNs are retained as scenarios (Gangopadhyay et al., 2005, Marty et al., 2012, Lafaysse et al., 2014). The major advantage of kNN resampling approaches is that they do not require restrictive assumptions concerning the joint distribution of the different predictands. Therefore, they can be easily applied to the generation of non-normally distributed data. As surface weather variables are sampled simultaneously from historical records for a given analog day, generated fields are physically realistic and consistent (because already observed) within each day. Generated weather variables are consequently expected to reproduce not only the observed distributions but also cross-correlations between variables and sites much better than parametric models (e.g. Mehrotra and Sharma, 2007, Boé et al., 2007, Lee et al., 2012). This applies to the generation time step (usually daily) and to sub-generation time steps (for example hourly if such a resolution is available in the archive, e.g. Mezghani and Hingray, 2009). The only limitation concerning the number of covariates generated and the space-time resolution of generated time series is related to the available data in the archive of observations.

kNN approaches therefore offer a powerful means to generate physically relevant high resolution space-time scenarios for impact studies. The large-scale predictors used to identify analog dates are however classically optimized for the site and the variable for which a prediction is needed. As a result, the optimal predictor set is expected to strongly depend on the considered region. This is illustrated by the varying predictive power of different types of individual predictors for different sites around the world (e.g. Cavazos and Hewiston, 2005, Timbal et al., 2008) and also for sites located within small geographical domains (e.g. Reichert et al., 1999, Mezghani et al., 2014). When the same predictors can be retained, the optimal large-scale domain over which the similarity between daily predictors must be evaluated is also expected to depend on the site (Horton, 2012, Radanovics et al., 2013). The analog dates obtained for a model optimized for a given site can of course be used for prediction at other sites. The resulting predictions are however likely to be sub-optimal.

As precipitation is of major interest in hydrological impact studies, the present work is only focused on this meteorological variable. The methodology could however be easily applied to any other predictand. This paper explores the spatial transferability of analog dates identified from a locally optimized reference Analog Model (AM) for the probabilistic prediction of precipitation at neighboring sites throughout France. The experiment is based on precipitation estimates obtained on a grid from Safran precipitation reanalysis (Quintana-Segui et al., 2008, Vidal et al., 2010). The large-scale analogy domain of the reference AM is optimized for each grid cell leading to a set of locally optimal analog models that can be in turn applied to precipitation prediction elsewhere. The spatial transferability of a model can be assessed by comparing its performance at each site with the performance obtained with the locally domain-optimized AM for this site.

The structure of this paper is as follows: Section 2 describes the data, the reference analog model and the evaluation criteria used to assess the local performance of the models, spatial similarity and transferability of analog dates. Results from the transferability assessment experiment are presented in Section 3 and discussed in Section 4. Finally Section 5 draws a number of conclusions.

2 Data, Model & Evaluation

2.1 Data

The large-scale predictors used to identify the analog dates are geopotentials taken from the European Centre for Medium-Range Weather Forecasts (ECMWF) 40-year reanalysis (ERA-40) (Uppala et al., 2005), with a spatial resolution of $1.125° \times 1.125°$.

The predictand corresponds to the daily total precipitation taken from the Safran near-surface reanalysis (Quintana-Segui et al., 2008, Vidal et al., 2010) with a resolution of 8×8 km^2. This local reanalysis covers France and includes a set of 8,981 grid points. Precipitation values estimated for these grid points are considered as "pseudo-observations". In the following, the Analog SDM is applied to predict the precipitation on each Safran grid point.

2.2 The analog SDM

The analog model applied in this study is based on previous developments for probabilistic quantitative precipitation forecasts (Bontron and Obled, 2005, Marty et al., 2012) for several catchments in France. The model involves four steps:

1. A seasonal filter is first applied in order to keep only candidates that belong to the same period of year: calendar days are selected as candidates with a moving window of $\pm\ j$ calendar days centered on the target day. Note that the target day and neighboring days in a temporal window of $\pm$ 5 days were excluded from the candidates.

2. A criterion for similarity between the target day and each candidate day is then computed. The chosen criterion is the Teweles-Wobus score (TWS, Teweless and Wobus, 1954) that compares two geopotential gradients providing information on the origin of the air masses. Note that an analogy based on the TWS performs better than a classical Euclidean distance applied to the principal components previously derived for the predictor fields – here the geopotential heights – retained for the analogy (e.g. Guilbaud and Obled, 1998, Wetterhall et al., 2005).

3. The candidate days are then sorted according to the TWS and the nearest analog dates are kept.

4. The predictive precipitation for the target day is obtained from the empirical distribution of the precipitation values of the N_d nearest analogs.

The analog model requires optimization of several parameters including for instance the type or level of predictors, the domain used to compute the similarity criterion and the similarity criterion itself. These parameters are expected to be dependent on the predictand – *i.e.* on the predictand target grid point in our case. Ideally these parameters should be optimized together as proposed by Horton (2012). For our domain, geopotential fields at 1000 hPa and 500 hPa respectively at +12h and +24h were found to be the most informative predictors by Bontron (2004). The seasonal filter was set to one month before and after the target day. A preliminary analysis showed that a number N_d equal to 25 was a good compromise to obtain on average the best performance (the performance is expressed by the $\overline{\text{CRPS}}$ skill score as described in Section 22.3) below) over France. For every grid point p in $[1, \ldots, 8,981]$, the performance loss obtained when comparing an AM with a number N_d of analog dates equal to 25 to an AM with an optimal number of analog dates – varying between 10 and 40 for the Safran grid points – is lower than 0.01 (results not shown here).

The predictor domain was conversely optimized for each target grid point by maximizing the performance of the prediction. The domain optimization results from a growing rectangular analogy domain algorithm, as explained by Bontron (2004). The algorithm steps are the following:

1. The elementary ERA-40 grid cell centered on a given target Safran grid point is chosen as an initial predictor domain.

2. For each cardinal direction, four alternative domains – obtained by an extension of one ERA-40 grid cell – based on the initial predictor domain are tested as predictor domains. The domain obtaining the best score is kept.

3. Step 2 is repeated considering the predictor domain kept in Step 2 as the initial predictor domain until no better performance is obtained for all of the four alternative extended predictor domains. The final predictor domain obtained from this iterative procedure corresponds to the analogy domain with the optimal score. No tolerance criterion is used here.

This algorithm leads to what we will call "the locally domain-optimized analog model for the target predictand k", denoted hereafter AM_k.

2.3 Evaluation scores

Each analog model AM_k leads to a set of N_d analog dates for each issued prediction. These dates can be used for the prediction of precipitation for any target grid point p. As each issued prediction is based on an ensemble of N_d analog dates, the criterion used for the evaluation of the

AM should be a probabilistic score. Inspired by common practice in Ensemble Prediction System (EPS) evaluation, we use a skill score based on the expected Continuous Ranked Probability Score - called $\overline{\text{CRPS}}$ - introduced by Brown (1974) and Matheson and Winkler (1976). The $\overline{\text{CRPS}}_k(p)$ value for an AM_k used for prediction at a given grid point p is defined as:

$$\overline{\text{CRPS}}_k(p) = \frac{1}{M}\sum_{i=1}^{M}\int_{-\infty}^{+\infty}\left[F_{k,i}(x_p) - H_{o_{p,i}}(x_p)\right]^2 dx_p \tag{1}$$

where $H_{o_{p,i}}$ and $F_{k,i}$ respectively denote the cumulative distribution function (cdf) of the observations $o_{p,i}$ and the cdf derived from AM_k for the issued prediction i and where M is the number of issued predictions. x_p denotes the precipitation quantiles of the cdfs on grid point p. Note that $H_{o_{p,i}}$ corresponds to the Heaviside function where $H_{o_{p,i}} = 1$ if $x_p \geq o_{p,i}$ and $H_{o_{p,i}} = 0$ otherwise. For a prediction i, the integral in Eq. (1) is equal to the area of the squared differences between the predicted and the observed cdfs, as illustrated in Fig. 1 and detailed in the Appendix. The

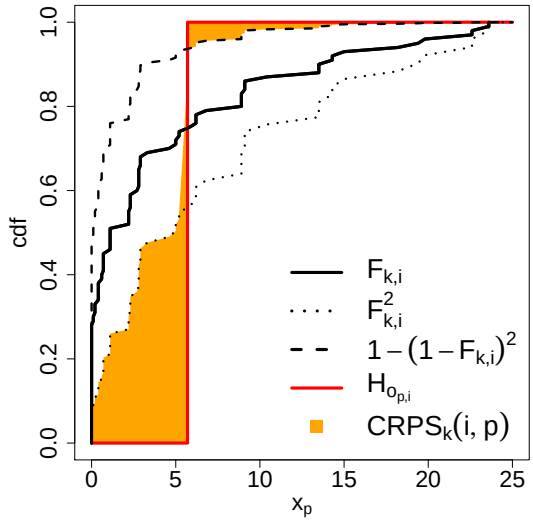

Figure 1: Illustration of the CRPS for a given issued prediction. Integral of Eq. (1) corresponds to the sum of the orange areas; the areas correspond to the squared difference between the cdf of the observation (in red) and the predicted cdf (in black) integrated over all probabilities. An expression of the CRPS explaining this graphical representation is given in the Appendix.

$\overline{\text{CRPS}}$ has several advantages:

- it evaluates the entire probabilistic prediction,
- it is a proper score (for the definition see Eq. (1) in Gneiting and Raftery, 2007, Bröcker and Smith, 2007),
- it can be interpreted as an integral over all possible Brier scores (Brier, 1950),
- it is equal to the mean absolute error (MAE) for a deterministic prediction.

The Continuous Ranked Probability Skill Score (CRPSS) is used to compare the model performance to the performance of a reference prediction model. In the present work, the reference prediction model is simply a calendar climatology defined for each prediction day by the precipitation distribution of the days belonging to a seasonal window ($\pm$ 30 days) centered on the corresponding calendar day. The skill score of AM_k when applied to grid point p is defined as:

$$\text{CRPSS}_k(p) = 1 - \frac{\overline{\text{CRPS}}_k(p)}{\overline{\text{CRPS}}_{\text{Clim}}(p)} \tag{2}$$

where $\overline{\text{CRPS}}_{\text{Clim}}(p)$ corresponds to $\overline{\text{CRPS}}$ obtained by the climatological model applied to grid point p. CRPSS is a positive oriented score: a CRPSS equal to 1 corresponds to a perfect AM whereas a negative CRPSS indicates that the performance for the considered AM is worse than that of the climatological model. As $\overline{\text{CRPS}}_k$ and $\overline{\text{CRPS}}_{\text{Clim}}$ are expressed in the same units as the predictand, CRPSS is a dimensionless performance score which makes it possible to compare the performance obtained between two grid points.

In addition to $\overline{\text{CRPSS}}_k(p)$, the relative bias $b_k(p)$ of the averaged scenario predicted by AM_k when applied to grid point p can be computed to evaluate the averaged predicted precipitation quantity as follows:

$$b_k(p) = \frac{1}{\overline{o_p}} \cdot \left[\frac{1}{M} \sum_{i=1}^{M} \overline{x_{p,i}}_{|\text{AM}=\text{AM}_k} - \overline{o_p} \right] \tag{3}$$

where $\overline{x_{p,i}}_{|\text{AM}=\text{AM}_k}$ is the mean precipitation scenario at grid point p predicted by AM_k for a given issued prediction i. $\overline{o_p}$ is the observed interannual mean precipitation.

2.3.1 Evaluation of spatial transferability

For a given grid point p, the predictions obtained with AM_k are expected to have lower performance than those obtained with AM_p. We further estimate the spatial transferability for a given AM_k using the following differences:

$$\Delta\text{CRPSS}_k(p) = \text{CRPSS}_k(p) - \text{CRPSS}_p(p) \tag{4}$$

$$\Delta b_k(p) = b_k(p) - b_p(p) \tag{5}$$

where $\text{CRPSS}_k(p)$ and $\text{CRPSS}_p(p)$ correspond to CRPSS obtained when respectively applying AM_k and AM_p to grid point p. For $\Delta b_k(p)$, a positive value means that AM_k predicts an increase of the averaged predicted precipitation compared to that estimated by AM_p at grid point p.

2.3.2 Evaluation of spatial similarity of analog dates

We additionally estimate the similarity of analog dates obtained from two analog models AM_x and AM_y. Each issued prediction $i \in [1, \ldots, M]$ derived from these models is composed of N_d analog dates as described in Fig. 2. A daily similarity score s_i corresponding to the number of similar analog dates between the two predictions issued respectively by AM_x and AM_y can be computed for each prediction day i. To evaluate a mean similarity level between analog dates produced by AM_x and AM_y, we determine the proportion of issued predictions O_{s_0} for which the daily similarity score s_i exceeds a given similarity level s_0.

$$O_{s_0} = \frac{1}{M} \sum_{i=1}^{M} \mathbb{I}\{s_i \geq s_0\} \tag{6}$$

For a given prediction day i, $\mathbb{I}\{s_i \geq s_0\}$ denotes the indicator function equal to 1 if $s_i \geq s_0$ and 0 otherwise. A value of 60% for O_{s_0} means for instance that for 60% of the issued predictions, the number of similar analog dates between both models is greater than s_0. For a given s_0 threshold, the larger the value for O_{s_0}, the more similar the dates from the two models are. Therefore, the lower the level s_0, the greater the percentage of issued predictions O_{s_0}. Perfect equality between analog dates is obtained when $O_{100\%}$ is equal to 1.

3 Results

In the following sections, the optimization of the set of locally domain-optimized analog models AM_p is performed on the corresponding grid points p for the twenty year period covering 1982-08-01 to 2001-07-31. The transferability of analog models is evaluated over the same period. Note that the evaluation period could have been different from the calibration period. However, it would then have been difficult to determine to what degree any modification in model performance was due to temporal and/or spatial transferability.

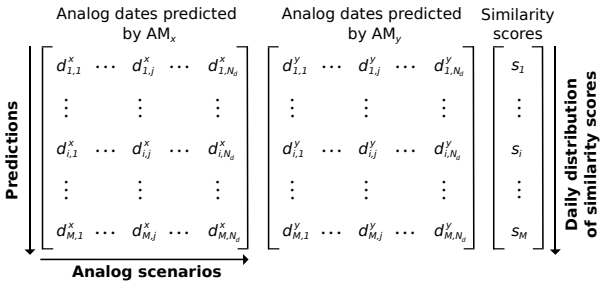

Figure 2: Schematic of the analog dates predicted by AM_x and AM_y for each issued prediction $i \in [1, \ldots, M]$. For every issued prediction i, a percentage of similar dates s_i between the dates $d^x_{i,j}$ and $d^y_{i,j}$ for all j in $1, \ldots, N_d$ is computed. M denotes the number of issued predictions and N_d the number of analog dates.

3.1 Evaluation of the locally domain-optimized analog model

In this subsection, we evaluate the performance when applying each model AM_p to the corresponding grid point p for the prediction of precipitation. The spatial distribution of the skill score $\mathrm{CRPSS}_p(p)$ over France is illustrated in Fig. 3. Its high spatial variability depends on the topog-

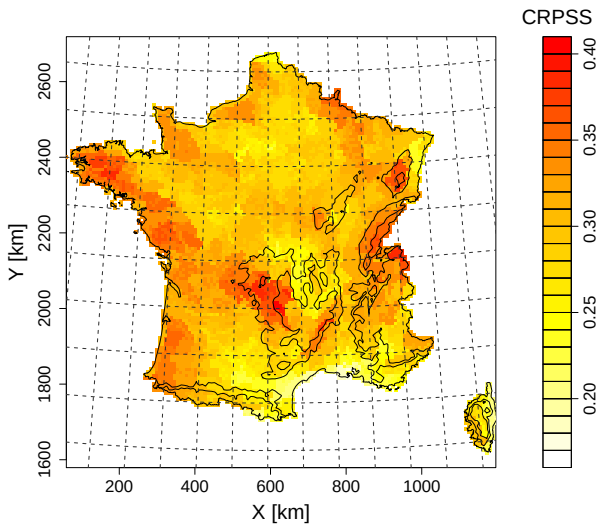

Figure 3: Spatial distribution of the $\mathrm{CRPSS}_p(p)$ when applying AM_p to grid point p. The number of analog dates N_d is set equal to 25. Black solid lines correspond to French borders and the contours around mountainous regions (400 and 800 m elevation) while the dashed lines show the ERA-40 grid mesh.

raphy, with a high performance of 0.4 in the West part of the Massif Central mountains and in the North Alps. Lower prediction skill varying around 0.28 is observed in the plains, reaching 0.35 along the Atlantic coast. The important variability of precipitation in the Mediterranean region – characterized by a coefficient of variation ranging between 2.25 and 4.5 whereas this coefficient is lower than 2.25 for the other Safran grid points (results not shown here) – could explain the lowest skill observed in this region. As shown by Mezghani et al. (2014), the predictive power is lower for regions with more frequent convective precipitation where a weaker link with large-scale circulation can be observed.

The spatial distribution of the relative bias $b_p(p)$ obtained from each AM_p is illustrated in Fig. 4. For a majority of grid points, the absolute value of relative bias of the mean scenario is less

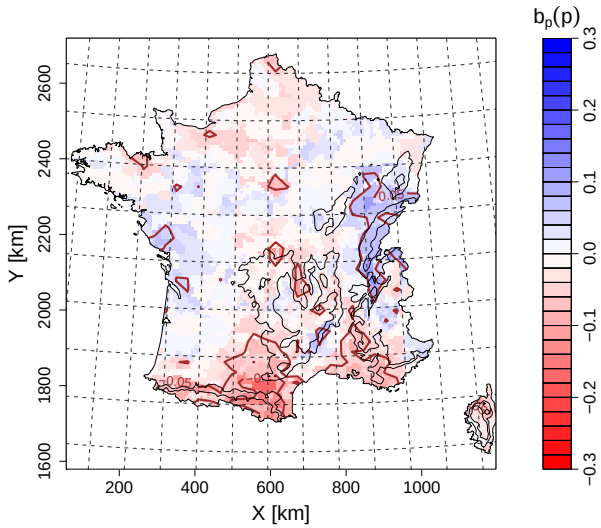

Figure 4: Spatial distribution of the relative bias $b_p(p)$. Brown lines correspond to an absolute bias larger than 5 and 10% respectively. See Fig. 3 for more caption details.

than 5%. However, two areas stand out from this trend:

1. the South-Western of France where precipitation is underestimated with a relative bias of around -12% and

2. the Northern Alps with a bias of up to 10%.

In the following, the performance obtained with the model AM_p applied to grid point p is used as a benchmark for assessing the transferability of analog models to other grid points. The spatial transferability and similarity of analog dates have been evaluated for 12 analog models locally optimized for 12 grid points uniformly distributed over France. Results will be described for only two of these models which are representative of the results obtained with the other transferred AMs.

3.2 Evaluation of spatial transferability

Fig. 6 and 7 illustrate the spatial transferability of two analog models locally optimized for two grid points: one located in the North-West of France – hereafter called NW grid point – and one located in the South-East of France – hereafter called SE grid point.

The analogy domain of $\mathrm{AM}_{\mathrm{NW}}$ is illustrated in Fig. 5. It extends to the Atlantic ocean and to the South-Western part of France. On the other hand, the analogy domain of $\mathrm{AM}_{\mathrm{SE}}$ covers the South-Eastern part of France, extending over the Mediterranean sea (see Fig. 5). The Atlantic ocean and the Mediterranean sea constitute the major sources of humidity for the generation of precipitation over France. As shown by Boé and Terray (2008) and Garavaglia et al. (2010), westerly Atlantic and southerly Mediterranean circulation is mainly responsible for the precipitation. In the following, $\mathrm{AM}_{\mathrm{NW}}$ and $\mathrm{AM}_{\mathrm{SE}}$ are applied to predict precipitation at each grid point $p \in [1, \ldots, 8,981]$.

Fig. 6a) illustrates $\Delta b_{\mathrm{NW}}(p)$ when applying $\mathrm{AM}_{\mathrm{NW}}$ to all Safran grid points. We observe that the relative bias increases by 5 percentage points for grid points situated 100 km North of the NW grid point. For grid points with a Y-coordinate ranging from 2,200 to 2,400 km, $\Delta b_{\mathrm{NW}}(p)$ remains between -5 and 5%. Below 2,200 km North, the bias is affected by the Massif Central mountains where a decrease of 5 percentage points is observed in the Western area whereas it is greater in the Eastern part. The relative bias decreases by more than 10 percentage points in the South-Eastern part of France.

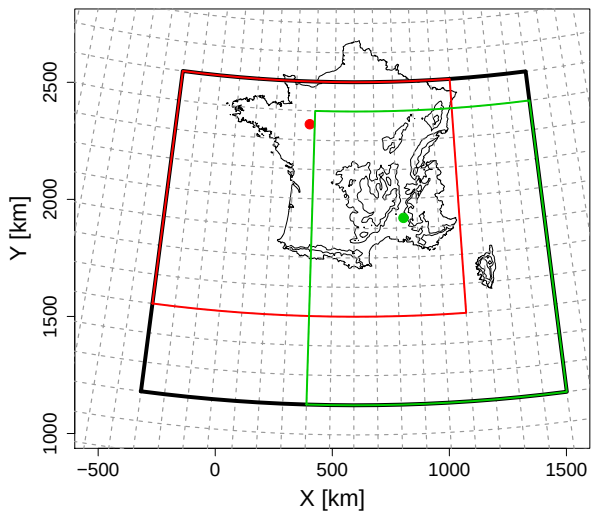

Figure 5: Boundaries of the analogy domains for AM_{NW} (in red) and AM_{SE} (in green). The spatial window used for the PCA is delimited in black. See Fig. 3 for more caption details.

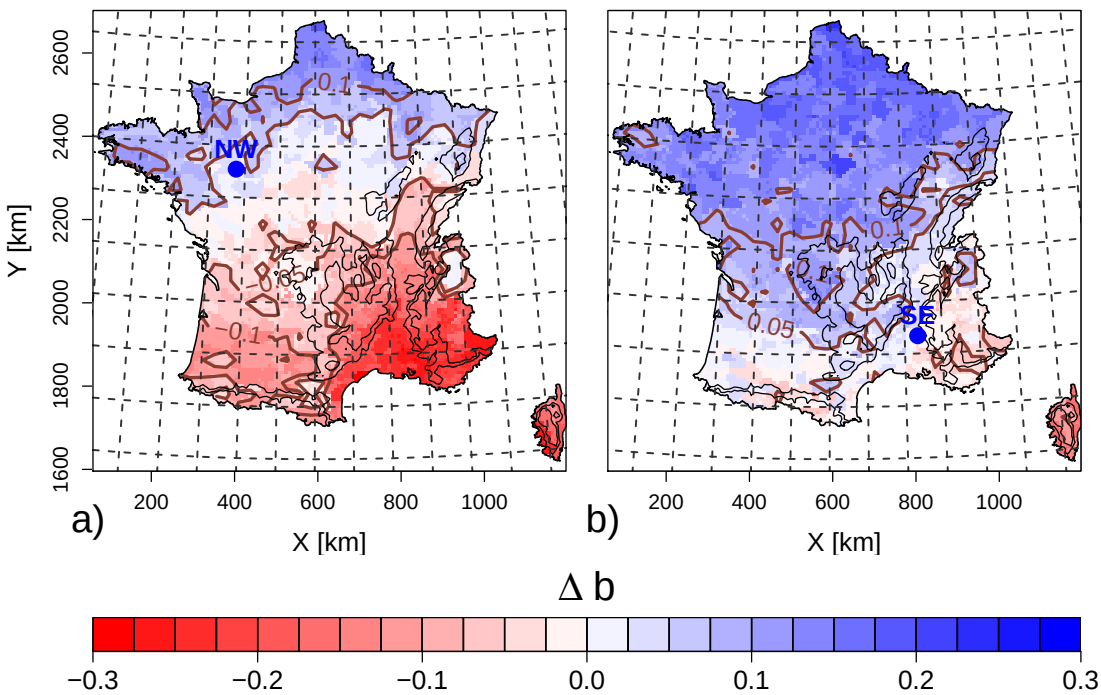

Figure 6: Spatial distribution of Δb for a) AM_{NW} and b) AM_{SE}. Brown lines correspond to absolute values of Δb greater than 5 and 10% as indicated. See Fig. 3 for more caption details.

A similar behavior is observed when transferring AM_{SE}. A bias increase of more than 5 percentage points is observed North of the SE grid point and West of the Massif Central mountains whereas a bias decrease ranging between 5 and 10 percentage points can be seen on the island of Corsica. In the South West and East of France, $\Delta b_{NW}(p)$ varies from -5 to 5 percentage points.

With respect to the CRPSS, the spatial transferability of AM_{NW} and AM_{SE} is very high. Fig. 7a) illustrates the CRPSS loss when transferring AM_{NW}. The absolute value of the loss is less than 0.05 for a large majority of grid points. It even becomes less than 0.01 for grid points in a roughly

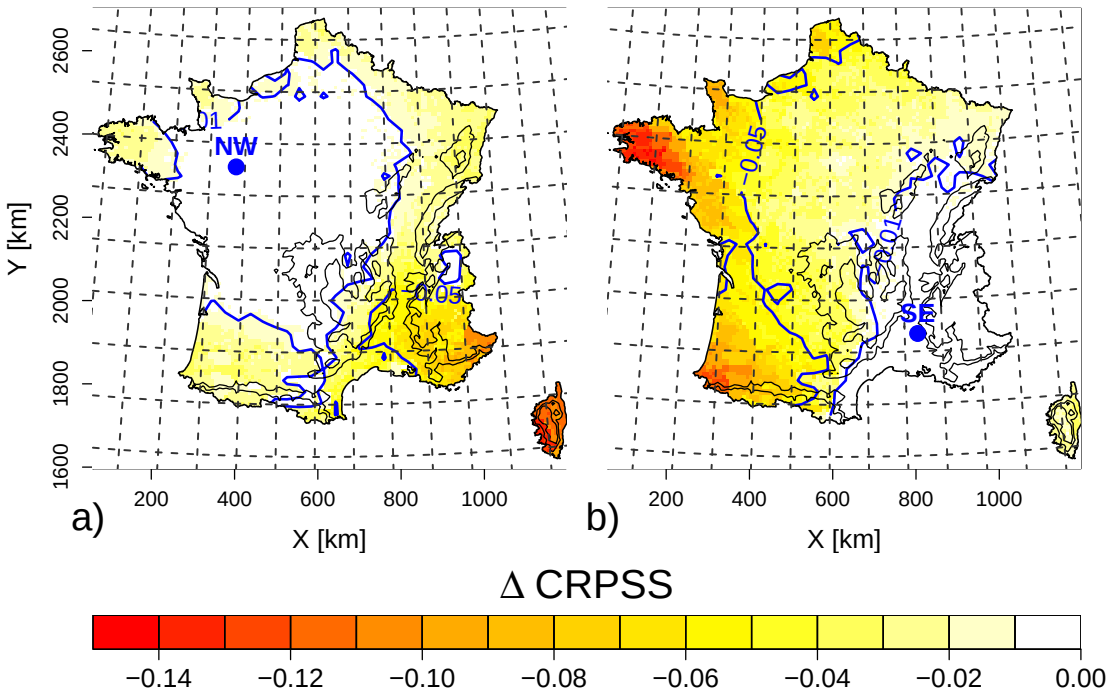

Figure 7: CRPSS loss when transferring the locally domain-optimized AM_{NW} (a) and AM_{SE} (b) for the prediction at all other Safran grid points. The blue lines correspond to losses equal to 0.01 and 0.05 as indicated. See Fig. 3 for more caption details.

500 km wide region around the NW point, which extends to the Massif Central mountains. A high loss equal to -0.13 is only obtained for the far South-Eastern region including Corsica.

The spatial transferability of AM_{SE} is smaller as illustrated in Fig. 7b). The region showing a -0.01 loss is 300 km wide and 500 km long. The CRPSS absolute loss remains smaller than 0.01 for more than 400 km when transferring AM_{SE} to the North. Conversely, $\Delta CRPSS_{SE}$ shows a large decrease from -0.01 to -0.05 when crossing the Massif Central mountains from South-East to North-West, reaching a value equal to -0.15 in Brittany. The Massif Central mountains thus play an important climatological barrier role in the region. The same is expected for the Alps and also for the Pyrenees mountains as illustrated by Bontron (2004).

The very small loss observed for large areas in Fig. 7a) and b) shows that the performance obtained when transferring AM_k to a broad region containing k is regionally similar to the performance of the locally domain-optimized AM.

3.3 Similarity of analog dates

A reason for the small CRPSS loss observed in Section 33.2) could be that the analog dates obtained with two AMs respectively optimized for two close grid points do not differ greatly. The mean similarity level between analog dates produced by two different AMs is expected to depend on the number of analog days retained for the prediction. This is discussed in Section 44.2). In the present work, we present the mean similarity level when 25 analog dates are retained.

To compare the 25 analog dates obtained from AM_{NW} and each locally domain-optimized AM_p, we estimated for each grid point p the percentage of issued predictions $O_{80\%}$ for which the daily similarity level exceeds the 80% daily similarity threshold.

The spatial distribution of $O_{80\%}$ is plotted in Fig. 8a). The percentage of issued predictions for the 80% daily similarity threshold is surprisingly low or very low, even where a very good spatial transferability of AM_{NW} is obtained. Around the -0.01 CRPSS loss contour, the percentage of issued predictions exceeding the 80% daily similarity threshold is around 20%. It vanishes to 0% where the CRPSS loss is around -0.05. The largest percentage (up to 100%) is obtained for a very

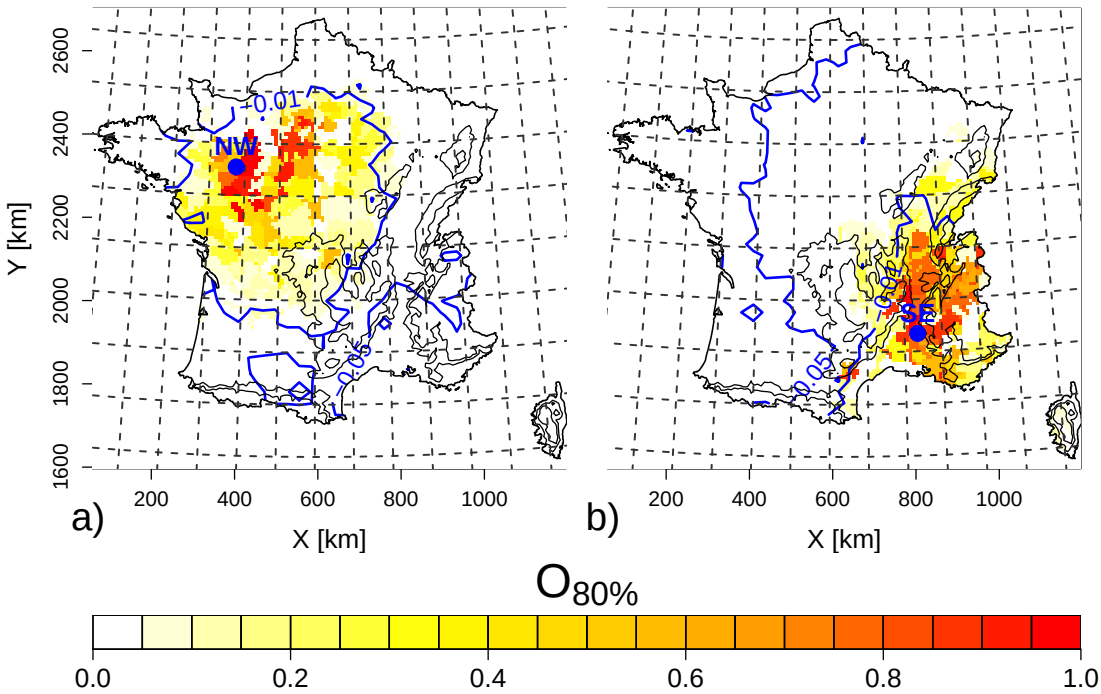

Figure 8: Percentage of issued predictions $O_{80\%}$ for which the daily similarity level exceeds the 80% daily similarity threshold for a) $\mathrm{AM_{NW}}$ and b) $\mathrm{AM_{SE}}$ applied over the whole of France. The -0.01 and -0.05 CRPSS loss contours observed in Fig. 7 are shown in blue. See Fig. 3 for more caption details.

small number of grid points located in the close neighborhood of the NW grid point.

A similar behavior is observed for $\mathrm{AM_{SE}}$ in Fig. 8b). Grid points near the -0.01 CRPSS loss contour obtain once again a $O_{80\%}$ value of around 20% and only a few points located near the SE grid point have a high value of $O_{80\%}$. Nevertheless similarity strongly depends on the relief because its pattern is stretched from South to North and delimited on either side by the Massif Central mountains and the Alps.

Spatial transferability of an AM therefore does not require having the best analog dates. Even if the transferred analog dates differ from the optimal ones, they lead to similar predictions in terms of precipitation for grid points located quite far away. The spatial transferability of an AM therefore does not require a high level of similarity of analog dates. It can also be concluded that a similarity of the domain boundaries of the predictors used to identify the analog dates is not necessary for spatial transferability.

4 Discussion

4.1 Extraction of rainy and dry days

This section aims to explain the increasing bias pattern obtained in this study when a transferred AM is used instead of the locally domain-optimized one. Note first that for the daily precipitation prediction for the 1982-2001 period, 25 analog dates are extracted for each day from the same period. If each date would have been extracted 25 times, the mean precipitation amount from the probabilistic prediction over the whole period would have been exactly equal to the climatology and thus to the observed mean. A wet bias occurs because wetter days are on average more frequently extracted than drier days (e.g. wet days versus dry days or rainy days with large precipitation amounts versus rainy days with small precipitation amounts). Thus an increase in the wet bias in the North using $\mathrm{AM_{NW}}$ suggests a larger extraction frequency of wetter days in this region.

This is illustrated in Fig. 9a) to 9d). In each figure, a point corresponds to one day of the period

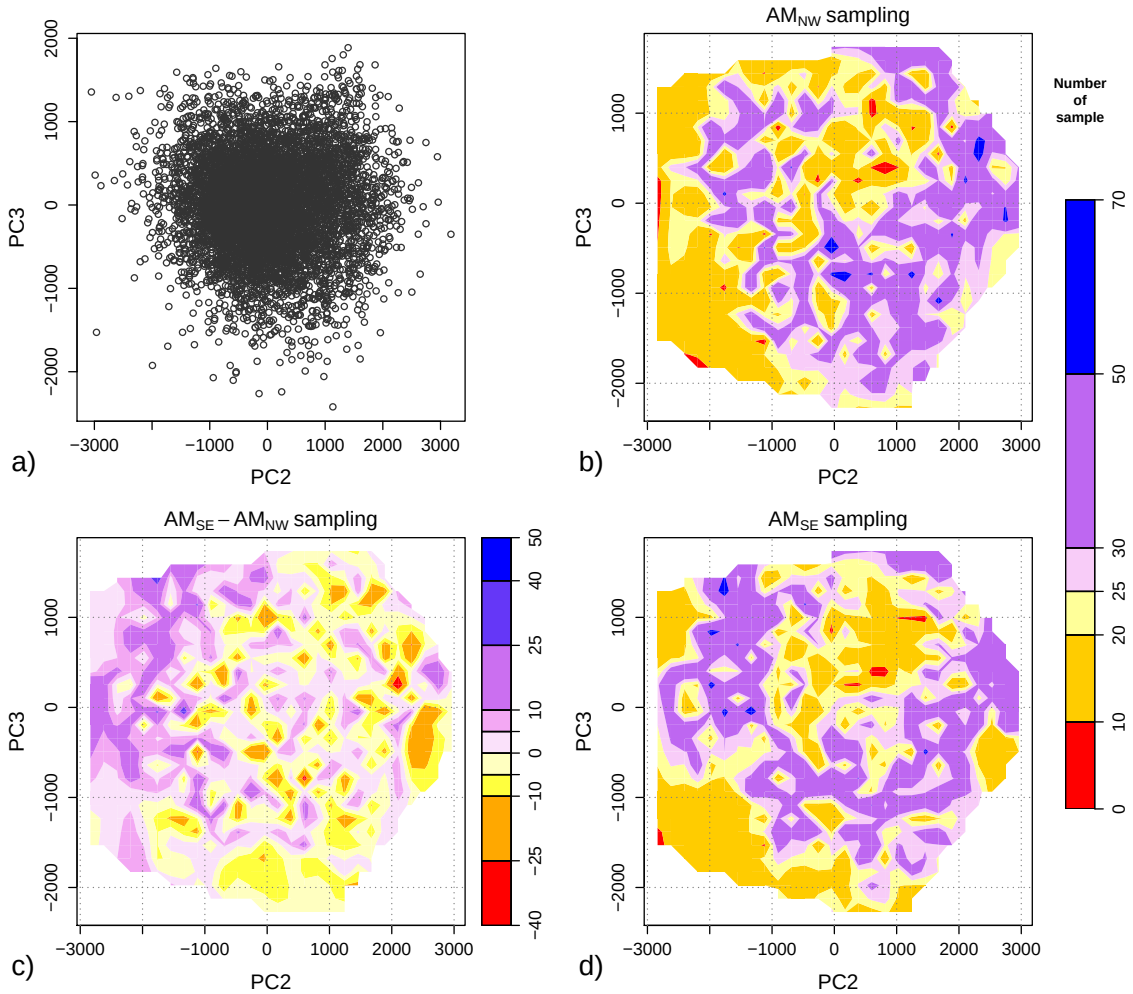

Figure 9: a) Days included in the period from 1982-08-01 to 2001-07-31 and the number of extractions represented in the 2nd and 3rd PCs for b) AM_{NW} and d) AM_{SE}. c) Extraction difference between AM_{SE} and AM_{NW}.

1982-2001. The coordinates are presented on the second and third Principal Components (PCs) of a Principal Components Analysis (PCA) carried out using the geopotentials Z_{1000} +12h and Z_{500} +24h over a larger domain – delimited by the coordinates 12.375 E, 6.75 W, 38.25 N, 50.625 S – represented in black in Fig. 5. The first PC is not used here as it roughly represents the geopotential mean level which is not accounted for by the TW distance criterion used to identify the archive days. The first three PCs explain respectively 69.2, 14.1 and 6.6% of the total variance. Fig. 9a) highlights the varying density of days according to their synoptic situation in this two-dimensional space. For each day of the archive period represented by its second and third PCs in Fig. 9a), we can compute the number of times that this day is chosen as one of the 25 analog dates by an AM for the M issued predictions. If a day is extracted more than 25 times, this day is over-extracted. If the number of extractions is lower than 25, the day is under-extracted. Fig. 9b) and Fig. 9d) illustrate the extraction frequency of each day obtained with respectively AM_{NW} and AM_{SE}. Fig. 10a) represents in the same way the local precipitation anomaly – defined as the ratio of the precipitation observed for each day over the daily average precipitation – for the NW grid point. The extraction bias from Fig. 9b) combined with the precipitation anomalies from Fig. 10a) explains the bias obtained for the reproduction of the mean interannual precipitation over the period. A similar interpretation is possible for Fig. 9d) representing the day extraction applied by

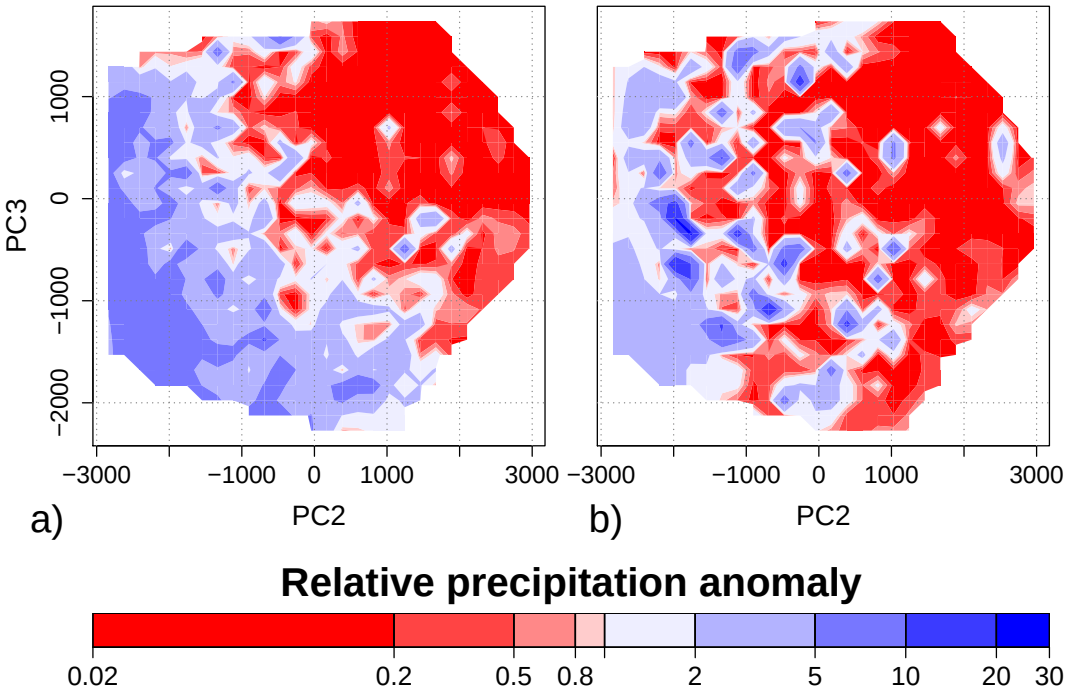

Figure 10: Relative precipitation anomalies following the 2nd and 3rd PCs derived from geopotentials for a) AM_{NW} and b) AM_{SE}.

AM_{SE} to local precipitation anomalies of SE grid point represented in Fig. 10b).

Transferring AM_{SE} to the NW grid point leads to applying the extraction scheme of AM_{SE} represented in Fig. 9d) to the local observed precipitation of the NW grid point as shown in Fig. 10a). We notice in Fig. 9c), representing the difference in extraction frequency between AM_{SE} and AM_{NW}, that AM_{SE} tends to extract the negative more than the positive coordinates of PC2. As the days having a negative PC2 coordinate correspond mostly to rainy days for the NW grid point, AM_{SE} will generate more precipitation for the NW grid point than AM_{NW}. The increased positive bias difference observed in Fig. 6b) when transferring AM_{SE} to the North of France can be explained in the same way. On the other hand, days with positive PC2 coordinates are more frequently extracted by AM_{NW}. These days are dry days for the SE grid point, as illustrated in Fig. 10b). Applying AM_{NW} to the SE grid point leads to an increase in the precipitation negative bias observed in Fig. 6b). This could be generalized to the South of France.

4.2 Sensitivity of similarity and transferability to the number of analog dates

A study on the sensitivity of similarity and transferability to the number of analog dates N_d retained for each prediction was carried out. Results are presented for predictions deduced from AM_{NW} and AM_{SE}. Similar results are obtained for predictions issued from an AM optimized for other locations (not shown).

Increasing the number of analog dates is expected to increase the mean daily similarity level of analog dates obtained from two models AM_x and AM_y. Fig. 11a) and b) illustrate the mean similarity level $O_{80\%}$ for AM_{NW} and AM_{SE} with N_d equal to 250. The region covered by a value of $O_{80\%}$ equal to 0.7 (delimited by the blue line in Fig. 11a) and b)) is 400 to 500 km wide compared to the region which is only 100 to 200 km wide for 25 analog dates (see Fig. 8a) and b)).

Fig. 12a) and b) show the CRPSS loss when applying either AM_{NW} or AM_{SE} with 250 analogs compared to the optimal configuration for 250 analogs. In both locations, the spatial pattern of ΔCRPSS is roughly the same as that for 25 analogs (see Fig. 7a) and 7b) respectively). The spatial transferability of AM_{NW} and AM_{SE} tends however to be higher with 250 analogs as demonstrated

for instance by the smaller CRPSS loss observed towards the extreme South-East of France when applying AM_{NW} or towards the extreme West when applying AM_{SE}. The larger sample of analogs makes the differences between the optimal predictions at different locations smoother.

Similar results were obtained when predictions were based on other sizes of analog sample. Fig. 13a) represents the proportion of grid points for which the mean similarity level $O_{80\%}$ (cumulated probability plot of $O_{80\%}$) is larger than a given value for N_d equal to 25, 50, 100, 150, 250 and 500. For both NW and SE cases and in line with what was pointed out earlier, the percentage of grid points which have a given value of $O_{80\%}$ (e.g. 0.7) increases with N_d. The spatial transferability of both models tends to increase with N_d, very slightly for NW, especially for small N_d values, but much more significantly for SE (Fig. 13b).

Note also that the skill of the locally domain-optimized AM significantly decreases as N_d increases. This can be seen in Fig. 13c) representing the cdf of the optimal CRPSS for different analog sample sizes. The median value of the optimal CRPSS decreases from 0.3 to 0.15 as N_d increases from 25 to 500. As increasing the size of the analog sample only leads to a slight gain in spatial transferability, the performance of the transferred AM thus significantly decreases. If the skill of the method can be optimized with an appropriate selection of the number of analog dates, its spatial transferability is much less dependent on this value and seems to be more an intrinsic characteristic of the region, related to climatological barriers induced by the presence of significant mountain ranges.

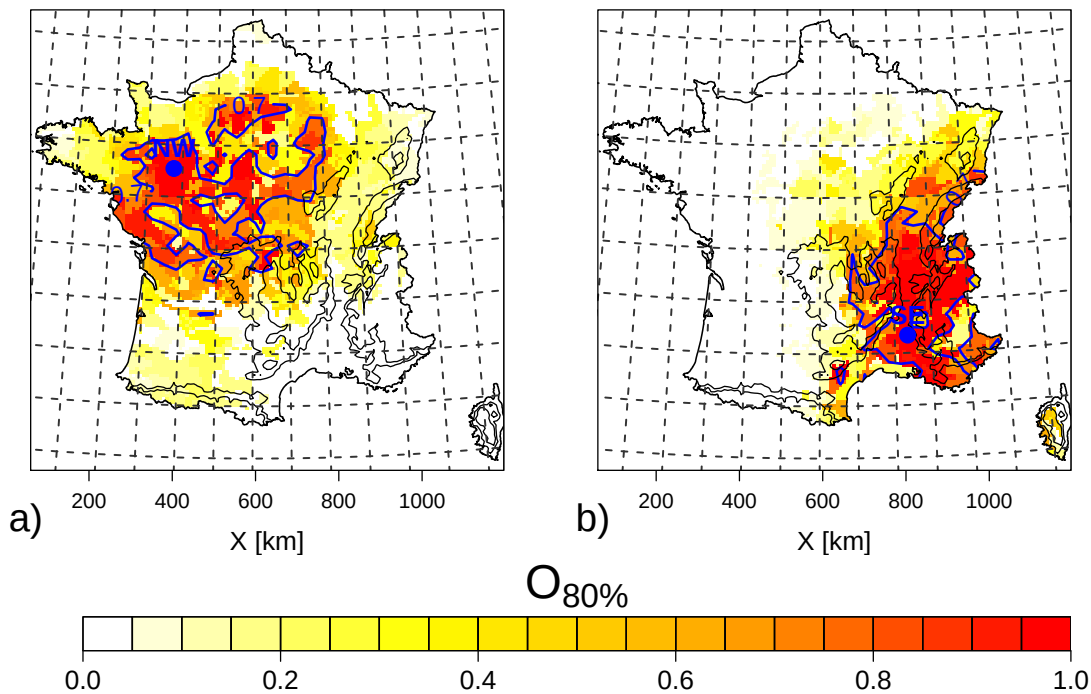

Figure 11: Percentage of issued predictions $O_{80\%}$ for which the daily similarity level exceeds the 80% daily similarity threshold for a) AM_{NW} and b) AM_{SE} applied over the whole of France with N_d equal to 250. The blue line corresponds to a value of $O_{80\%}$ equal to 0.7. See Fig. 3 for more caption details.

4.3 Sensitivity of spatial transferability to the selection of the analog days

The spatial transferability is expected to depend on the predictors chosen to identify the analog dates. In the present section, we present the same analyses as in the previous sections with a two-level AM (further referred to as AM2) including in addition atmospheric humidity as a predictor (e.g. Horton, 2012, Marty et al., 2012). The 25 analog dates retained for the prediction are also

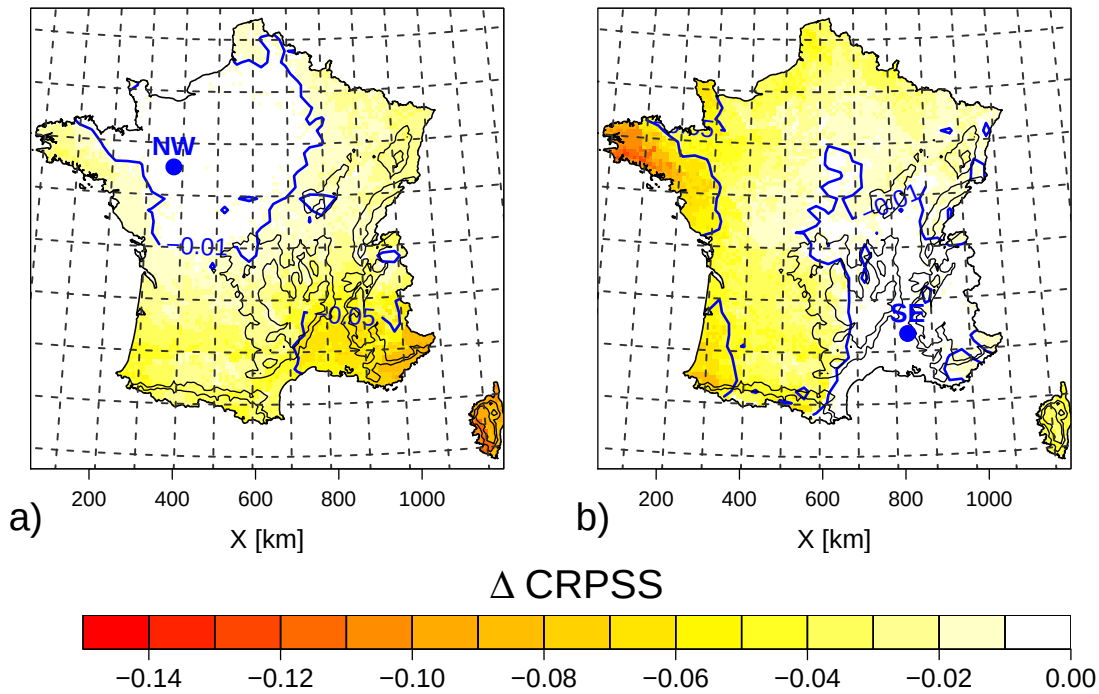

Figure 12: CRPSS loss when transferring the locally domain-optimized AM_{NW} (a) and AM_{SE} (b) for the prediction at all other Safran grid points with N_d equal to 250. The blue lines correspond to a loss equal to 0.01 and 0.05 respectively. See Fig. 3 for more caption details.

chosen in the 1982-2001 historical period of the ERA-40 reanalysis but they are, for each target day, selected within a sub-set of 60 preselected candidate dates that correspond to the nearest spatial patterns in terms of atmospheric circulation. Similar to the one-level AM case considered in the last sections (hereafter referred to as AM1), the pre-selection of the 60 candidate dates is based on the Teweless-Wobus distance for the 1000 and 500 hPa geopotential fields. According to Marty et al. (2012), the second-level selection of the 25 dates is based on the Euclidean distance for the humidity variable defined as the product of precipitable water and relative humidity at 850 hPa. As previously, the spatial domain used for the first analogy level was optimized for the prediction at each Safran grid point. The humidity predictor is also Safran grid dependent and it corresponds to an inverse-distance weighted average computed on the four neighboring ERA-40 grid points.

The mean daily similarity level of analog dates obtained with two AM2 models when locally domain-optimized for different grid points is very similar to what was found before (for the locally domain-optimized AM1 models), i.e. low to very low (not shown). The spatial transferability of analog dates obtained with AM2 models is on the other hand rather different than that obtained with AM1 models. Fig. 14a) and b) illustrates the CRPSS loss obtained for each Safran grid point when the AM2 models optimized for the NW and SE grid points are applied instead of the locally optimized ones. For each AM2 model ($AM2_{NW}$ or $AM2_{SE}$), the CRPSS loss increases much faster than the one obtained from the transfer of the corresponding AM1 model (respectively $AM1_{NW}$ or $AM1_{SE}$). When the CRPSS loss was 0.01 with the AM1 model, it becomes higher than 0.05 with AM2. The area for which a 0.01 CRPSS loss is obtained covers a roughly 200 km wide region with AM2 compared to the 500 km previously found with AM1.

As already shown by Bontron (2004) for a number of raingauges in South-Eastern France, the integration of the humidity predictor improves the prediction skill of the locally domain-optimized AMs for every location in France. The CRPSS gain between AM1 and AM2 is roughly 0.03 for a large part of France (Fig. 15). However, the lower spatial transferability of a locally best performing AM2 model results in lower performance than the locally less performing AM1 model when both are transferred to far locations. This is highlighted in Fig. 16 where the performance

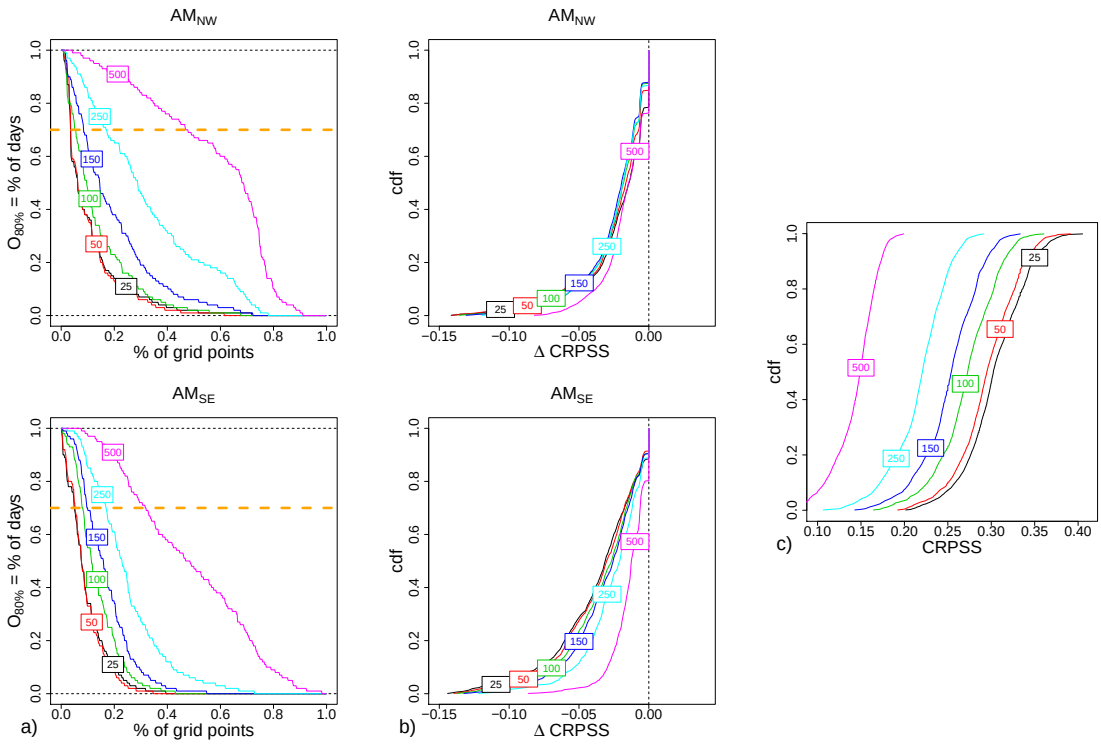

Figure 13: a) Distribution of the mean similarity level $O_{80\%}$ of similarity analog dates depending on the percentage of grid points, b) ΔCRPSS obtained by an AM_p applied to grid point p for N_d equal to 25, 50, 100, 150, 250 and 500 for $\mathrm{AM}_{\mathrm{NW}}$ (top row) and $\mathrm{AM}_{\mathrm{SE}}$ (bottom row). Distributions of optimal $\mathrm{CRPSS}_p(p)$ are plotted in c) for each value of N_d.

of the transferred $\mathrm{AM2}_{\mathrm{NW}}$ model is better than the performance of the transferred $\mathrm{AM1}_{\mathrm{NW}}$ model only for the grid points that are within a 150 to 500 km wide area around the NW grid point. The same conclusion can be drawn for the SE grid point. On the other hand, the transferred AM1 model presents higher skill for more grid points situated far away. The increased performance allowed from the introduction of humidity therefore makes the model much more region-specific and thus much less transferable.

It is interesting to note that these results are in line with those presented in Section 44.2. We found that increasing the number of analog days used for the prediction 1) slightly increases the spatial transferability of AM1 but 2) conversely drastically reduces its overall skill. A similar conclusion is also obtained when the length of the archive period is modified. Timbal et al. (2003) showed that the larger the size of the archive from which the analogs are selected is, the higher the skill of the prediction is. The k-nearest neighbors of any day are actually expected to be better analogs of this day when they are identified in a longer archive. We have also tested the transferability of the 25-nearest analog dates when identified in a longer archive (1959-2001 instead of 1982-2001). As expected, the skill of the locally optimized models increases (by roughly 0.05 CRPSS points) but again the transferability of the AM decreases (not shown here).

5 Conclusions & Perspectives

The spatial transferability of analog dates for the probabilistic prediction of local precipitation is a key requirement for the generation of spatially and physically consistent weather scenarios for impact studies. It was first explored in the present study over France with a basic domain-optimized analog model based on the large-scale circulation (*i.e.* geopotential heights Z_{1000} +12h and Z_{500} +24h).

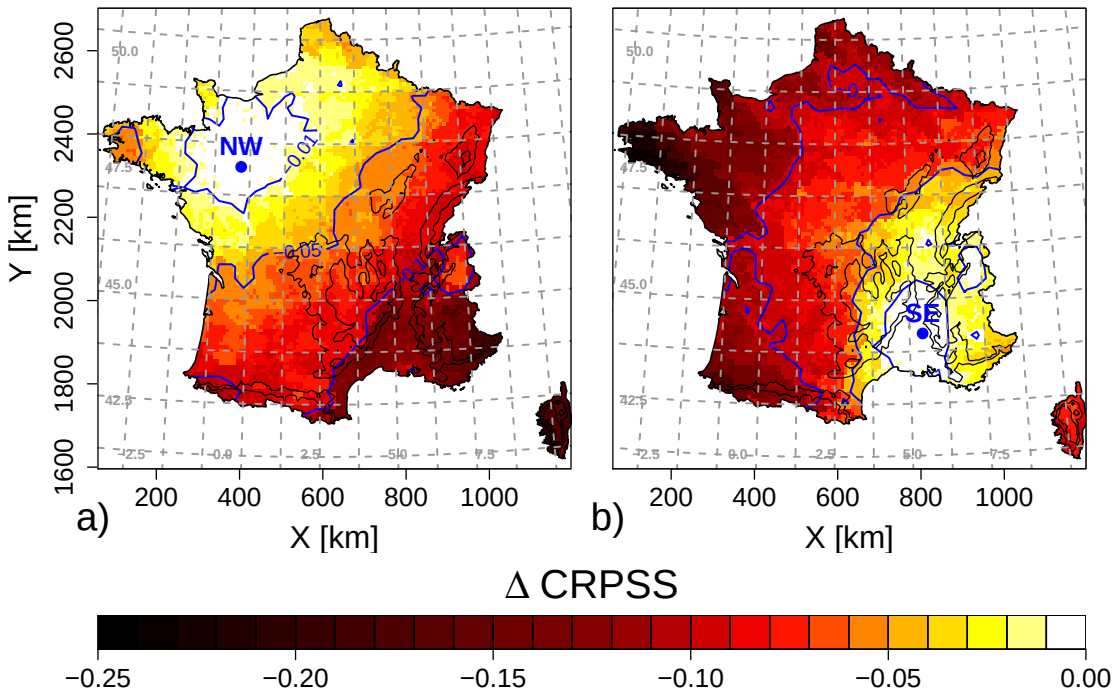

Figure 14: CRPSS loss when transferring the locally domain-optimized $AM2_{NW}$ (a) and $AM2_{SE}$ (b) for the prediction at all other Safran grid points. The blue lines correspond to a loss equal to 0.01, 0.05 and 0.1. See Fig. 3 for more caption details.

The mean similarity level between analog dates obtained for AMs optimized respectively for two different locations is low to very low. Despite this, the spatial transferability of analog dates, with respect to the CRPSS of the prediction, is high to very high. The loss of performance obtained using a transferred model instead of the locally domain-optimized model remains very low over large spatial domains which can sometimes be 500 km wide. The spatial transferability of a given model is however not isotropic and especially depends on the topography of the studied region. The spatial range of transferability is reduced in presence of major mountainous areas. The Massif Central mountains constitute for instance a clear meteorological barrier in France.

Using more analog dates for the prediction obviously increases the similarity of analog dates. It leads however to only a very slight increase of their spatial transferability and to a large decrease of the absolute prediction skill of the model. For the studied area, the prediction skill is therefore much more sensitive to this parameter than to the large-scale domain used to identify the analogs, provided that the different sites for which a prediction is required are not too far from each other from a meteorological (and topographical) point of view.

The spatial transferability of the analog dates was found to be dependent on the parameters of the AM used for their identification. In France, it is lower when the length of the archive period is longer and when humidity is included as a second-level predictor.

Results are of course expected to be dependent on the specific geographical and meteorological context of the studied area. In recent years, the climate and weather forecast research communities in particular have made major efforts to develop high-resolution gridded reanalysis of precipitation for large domains at the country or continental scales from dense networks of daily raingauge data (e.g. in French mountainous regions (Gottardi et al., 2012), in Europe (Haylock et al., 2008), North America (Maurer et al., 2002), South America (Liebmann and Allured, 2005) or Asia (Xie et al., 2007)). These datasets provide a powerful opportunity to better explore the spatial transferability of analog dates across larger domains and the possibility to generate spatially consistent scenarios for regional scale impact studies.

Results obtained in this paper highlight some practical solutions for the generation of weather scenarios suited for regional scale impact studies:

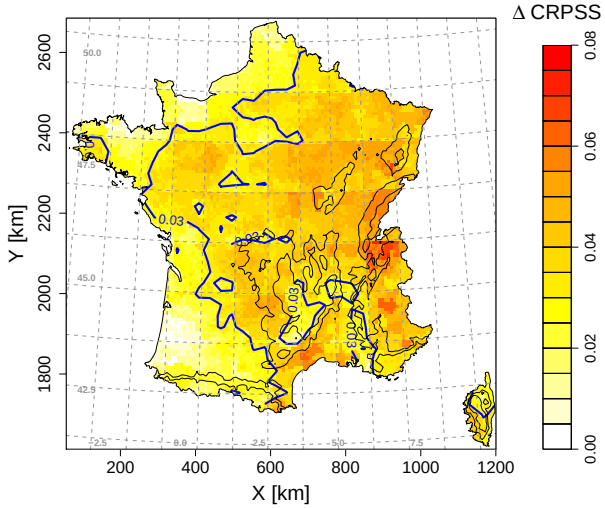

Figure 15: CRPSS gain of the locally domain-optimized AM when humidity is included as a second-level analogy predictor (for a given Safran grid point, the gain is defined as the difference between the CRPSS obtained with the two-level $AM2_p$ and the single-level $AM1_p$). The blue contour line corresponds to a CRPSS gain equal to 0.03. See Fig. 3 for more caption details.

- A high level of similarity in optimal analog dates is not mandatory for the spatial transfer of an AM. Even when the level of similarity is low, optimal analog dates for a given site have potentially a quasi-optimal predictive power for remote locations. As a consequence, a strict similarity of the optimal large-scale analogy domains identified for the prediction at different locations is also not mandatory for the transferability of the optimal analog dates from one location to the other.

- The generation of probabilistic precipitation prediction with the studied AM was found to produce a non-negligible bias in the mean inter-annual daily precipitation. This results from the fact that historical days are not extracted with the same frequency over the simulation period. The transfer of analog dates to remote sites is expected to modify the bias depending on both the location of the target and of the grid points used for the optimization of the AM but the overall bias remains lower than 20%. As several sets of analog dates can lead to the same performance, it can be supposed that a set of analog dates exists that reduces the observed absolute bias when transferring an AM for locations situated far away. Optimizing the analogy criterion by minimizing the resulting absolute bias could lead to analog dates providing similar performance and lower biases.

- When the analog dates are identified from geopotential fields, the spatial transferability of locally domain-optimized analog dates is high and a quasi-optimal prediction can be obtained within large areas with analog dates identified from a unique analogy domain.

- The refinement of an analog prediction model is potentially detrimental to its spatial transferability. In the present study, when humidity is included as a second-level predictor, the local skill of a locally domain-optimized model is improved but its spatial transferability is found to be much lower. This does not mean that the overall performance of the refined model becomes lower than the performance of the rough model. In the present case, the skill improvement due to the introduction of humidity is larger than the skill loss resulting from its transferability to locations that are up to 400 km from the grid point used for the optimization. Depending on the extent of the domain for which scenarios are required, a lower spatial transferability can be limiting and a mandatory compromise may be necessary between the performance of the AM and its spatial transferability. If spatially consistent scenarios have to be produced for very large domains, a lower skill of the AM may be preferred

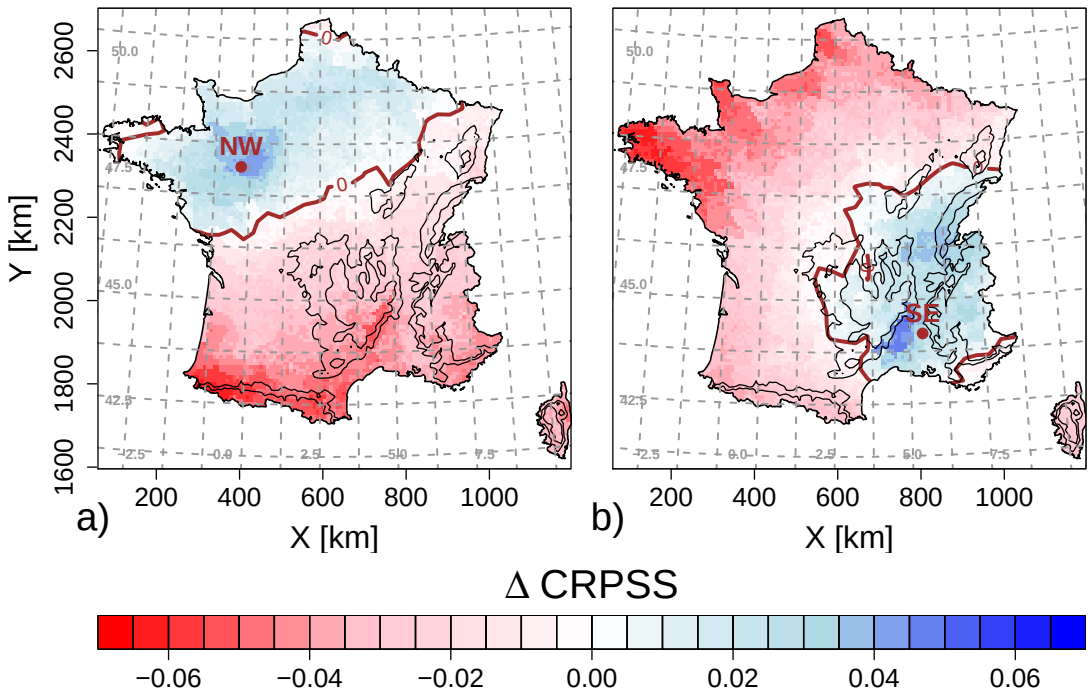

Figure 16: CRPSS gain (positive value) or loss (negative value) when transferring a) $AM2_{NW}$ instead of $AM1_{NW}$ and b) $AM2_{SE}$ instead of $AM1_{SE}$. The brown lines correspond to the zero CRPSS gain contour. See Fig. 3 for more caption details.

as it is more transferable in space.

- The analog predictions could be easily used to generate probabilistic scenarios for every other gauge with available observation data and located in the neighborhood of those over which the analogy domains was optimized, provided that mountainous regions are not located in between them. The analog approach therefore also has the potential of generating spatially consistent precipitation scenarios at the scale of regional impact studies covering tens of thousands of square kilometers or even more. As analog dates can also be used to extract non-precipitation variables, spatial and physical consistency is also expected for multivariate and multisite scenarios at these scales. However, the spatial transferability of analog dates may be quite different for other predictands. Further work should be carried out to explore this.

- The large spatial transferability highlighted here was obtained with the analog dates derived for a locally domain-optimized AM. In the present work, the predictand is one of the 8,981 (8×8 km^2) grid precipitation estimates obtained via optimal interpolation from a country-wide network of 3,000 to 4,500 stations (depending on the year). This strongly suggests that a single gauge would be enough to identify the locally optimal large-scale analogy domain and that the corresponding analog dates would also show such a high spatial transferability. However, a robust identification of the optimal large-scale analogy domain for a given region could not necessarily be achieved from a single-site optimization, especially in areas where precipitation triggering processes are significantly different from one place to another (e.g. in areas with marked relief). In such a case, a more robust strategy would be to carry out a multi-station optimization or an optimization for the prediction of the daily area-average precipitation for the region. This is expected to decrease the prediction skill at individual locations but possibly increase the size of the transferability domain.

- The spatial transferability of the AM was studied here considering all days of the 1982-2001 period. It is however expected to vary according to the season and/or the weather regime

of the day. For anticyclonic conditions over France, for instance, a higher transferability is expected as precipitation is generally zero over large areas. The spatial transferability for wet days is also expected to be larger when precipitation is most often stratiform with wide coverage than when it is convective and therefore local. A similar analysis conditioned by weather regimes could therefore provide a better characterization of analog date spatial transferability.

Acknowledgments.

This work is part of a PhD thesis funded by the French Ministère de l'Enseignement Supérieur et de la Recherche (MESR). We would especially like to thank the three anonymous reviewers for their relevant comments and suggestions that allowed us to improve this study and broaden its scope.

References

A. Auffray, A. Clavel, S. Jourdain, A. Ben Daoud, E. Sauquet, M. Lang, C. Obled, G. Panthou, A. Gautheron, F. Gottardi, and R. Garçon. Reconstructing the hydrometeorological scenario of the 1859 flood of the Isère river. *Houille Blanche*, 1:44–50, 2011. doi: 10.1051/lhb/2011005.

J. Boé and L. Terray. A weather-type approach to analyzing winter precipitation in france: Twentieth-century trends and the role of anthropogenic forcing. *J. Climate*, 21(13):3118–3133, 2008. ISSN 0894-8755. doi: 10.1175/2007JCLI1796.1.

J. Boé, L. Terray, F. Habets, and E. Martin. Statistical and dynamical downscaling of the Seine basin climate for hydro-meteorological studies. *Int. J. Climatol.*, 27(12):1643–1655, 2007. doi: 10.1002/joc.1602.

G. Bontron. *Prévision quantitative des précipitations : adaptation probabiliste par recherche d'analogues.* PhD thesis, Institut National Polytechnique de Grenoble, Grenoble, 2004.

G. Bontron and C. Obled. A probabilistic adaptation of meteorological model outputs to hydrological forecasting. *Houille Banche*, 1:23–28, 2005.

G. W. Brier. Verification of forecasts expressed in terms of probability. *Mon. Weather Rev.*, 78 (1-3), 1950.

J. Bröcker and L. A. Smith. Scoring probabilistic forecasts: the importance of being proper. *Weather Forecast.*, 22(2):382–388, 2007. doi: 10.1175/WAF966.1.

T. A. Brown. Admissible scoring systems for continuous distributions. Manuscript P-5235, The Rand Corporation, The Rand Corporation, Santa Monica, CA, 1974. Available from The Rand Corporation, 1700 Main St., Santa Monica, CA 90407-2138.

T. A. Buishand and T. Brandsma. Multisite simulation of daily precipitation and temperature in the Rhine basin by nearest-neighbor resampling. *Water Resour. Res.*, 37(11):2761–2776, 2001. doi: 10.1029/2001WR000291.

T. A. Buishand, M. V. Shabalova, and T. Brandsma. On the choice of the temporal aggregation level for statistical downscaling of precipitation. *J. Climate*, 17(9):1816–1827, 2004. doi: 10.1175/1520-0442(2004)017¡1816:OTCOTT¿2.0.CO;2.

G. Burger and Y. Chen. Regression-based downscaling of spatial variability for hydrologic applications. *J. Hydrol.*, 311(1-4):299–317, 2005. doi: 10.1016/j.jhydrol.2005.01.025.

T. Cavazos and B. C. Hewiston. Performance of NCEP–NCAR reanalysis variables in statistical downscaling of daily precipitation. *Climate Res.*, 28(2), 2005. doi: 10.3354/cr028095.

C. Frei, J. H. Christensen, M. Deque, D. Jacob, R. G. Jones, and P. L. Vidale. Daily precipitation statistics in regional climate models: Evaluation and intercomparison for the European Alps. *J. Geophys. Res.*, 108(D3), 2003. doi: 10.1029/2002JD002287.

S. Gangopadhyay, M. Clark, and B. Rajagopalan. Statistical downscaling using k-nearest neighbors. *Water Resour. Res.*, 41(2), 2005. doi: 10.1029/2004WR003444.

F. Garavaglia, J. Gailhard, E. Paquet, M. Lang, R. Garçon, and P. Bernardara. Introducing a rainfall compound distribution model based on weather patterns sub-sampling. *Hydrol. Earth Syst. Sc.*, 14(6):951–964, 2010. doi: 10.5194/hess-14-951-2010.

F. Giorgi and L. O. Mearns. Approaches to the simulation of regional climate change - A review. *Rev. Geophys.*, 29(2):191–216, 1991. doi: 10.1029/90RG02636.

T. Gneiting and A. E. Raftery. Strictly proper scoring rules, prediction, and estimation. *J. Am. Stat. Assoc.*, 102(477):359–378, 2007. doi: 10.1198/016214506000001437.

F. Gottardi, C. Obled, J. Gailhard, and E. Paquet. Statistical reanalysis of precipitation fields based on ground network data and weather patterns: Application over french mountains. *J. Hydrol.*, 432:154–167, 2012. doi: 10.1016/j.jhydrol.2012.02.014.

S. Guilbaud and C. Obled. Prévision quantitative des précipitations journalières par une technique de recherche de journées antérieures analogues : optimisation du critère d'analogie. *Comptes Rendus de l'Académie des Sciences - Series IIA - Earth and Planetary Science*, 327(3):181–188, 1998. doi: 10.1016/S1251-8050(98)80006-2.

I. Hanssen-Bauer, C. Achberger, R. E. Benestad, D. Chen, and E. J. Forland. Statistical downscaling of climate scenarios over Scandinavia. *Climate Res.*, 29(3):255–268, 2005. doi: 10.3354/cr029255.

M. R Haylock, N. Hofstra, A. M. G. Klein Tank, E. J Klok, P. D Jones, and M. New. A European daily high-resolution gridded data set of surface temperature and precipitation for 1950-2006. *J. Geophys. Res.-Atmos.*, 113(D20), 2008. doi: 10.1029/2008JD010201.

P. Horton. *Improvements and global optimization of the analogue method for statistical precipitations forecasting.* PhD thesis, Université de Lausanne, Faculté des géosciences et de l'environnement, Lausanne, 2012.

A. Kuentz, T. Mathevet, J. Gailhard, C. Perret, and V. Andreassian. Over 100 years of climatic and hydrologic variability of a mediterranean and mountainous watershed: the durance river. In *Cold And Mountain Region Hydrological Systems under Climate Change: towards improved projections*, volume 360 of *IAHS Publication*, pages 19–25, Symposium of H02m IAHS-IAPSO-IASPEI Assembly, Gothenburg, SWEDEN, 2013.

M. Lafaysse, B. Hingray, L. Terray, J. Gailhard, and A. Mezghani. Sources of uncertainties in future climate and hydrological projections: the Alpine Durance basin. *Under review for Water Resour. Res.*, 2014.

T. Lee, T. B. M. J Ouarda, and J. Changsam. Nonparametric multivariate weather generator and an extreme value theory for bandwidth selection. *J. Hydrol.*, 452:161–171, 2012. doi: 10.1016/j.jhydrol.2012.05.047.

B. Liebmann and D. Allured. Daily precipitation grids for South America. *B. Am. Meteorol. Soc.*, 86(11):1567–1570, 2005. doi: 10.1175/BAMS-86-1567.

D. Maraun, F. Wetterhall, A. M. Ireson, R. E. Chandler, E. J. Kendon, M. Widmann, S. Brienen, H. W. Rust, T. Sauter, M. Themel, V. K. C. Venema, K. P. Chun, C. M. Goodess, R. G. Jones, C. Onof, M. Vrac, and I. Thiele-Eich. Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Rev. Geophys.*, 48,RG3003, 2010. doi: 201010.1029/2009RG000314.

R. Marty, I. Zin, C. Obled, G. Bontron, and A. Djerboua. Toward Real-Time daily PQPF by an analog sorting approach: Application to Flash-Flood catchments. *J. Appl. Meteorol. Clim.*, 51 (3):505–520, 2012. doi: 10.1175/JAMC-D-11-011.1.

R. Marty, I. Zin, and C. Obled. Sensitivity of hydrological ensemble forecasts to different sources and temporal resolutions of probabilistic quantitative precipitation forecasts: flash flood case studies in the cvennes-vivarais region (southern france). *Hydrol. Process.*, 27(1):3344, 2013. doi: 10.1002/hyp.9543.

J. E. Matheson and R. L. Winkler. Scoring rules for continuous probability distributions. *Manage. Sci.*, 22(10):1087–1096, 1976. doi: 10.1287/mnsc.22.10.1087.

E. P. Maurer, A. W. Wood, J. C. Adam, D. P. Lettenmaier, and B. Nijssen. A long-term hydrologically based dataset of land surface fluxes and states for the conterminous United States. *J. Climate*, 15(22):3237–3251, 2002. doi: 10.1175/1520-0442(2002)015¡3237:ALTHBD¿2.0.CO;2.

R. Mehrotra and Ashish Sharma. A semi-parametric model for stochastic generation of multi-site daily rainfall exhibiting low-frequency variability. *J. Hydrol.*, 335(1-2):180–193, 2007. doi: 10.1016/j.jhydrol.2006.11.011.

A. Mezghani and B. Hingray. A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain: development and multi-sacle validation for the Upper Rhone River basin. *J. Hydrol.*, 377(3-4):245–260, 2009. doi: 10.1016/j.jhydrol.2009.08.033.

A. Mezghani, B. Hingray, and M. Lafaysse. Atmospheric predictors for daily precipitation prediction over France. *in revision for J. Geophys. Res-Atmos.*, 2014.

C. Obled, G. Bontron, and R. Garçon. Quantitative precipitation forecasts: a statistical adaptation of model outputs through an analogues sorting approach. *Atmos. Res.*, 63(3-4):303–324, 2002. doi: 10.1016/S0169-8095(02)00038-8.

P. Quintana-Segui, P. Le Moigne, Y. Durand, E. Martin, F. Habets, M. Baillon, C. Canellas, L. Franchisteguy, and S. Morel. Analysis of near-surface atmospheric variables: Validation of the SAFRAN analysis over France. *J. Appl. Meteorol. Clim.*, 47:92–107, 2008. doi: 10.1175/2007JAMC1636.1.

S. Radanovics, J.-P. Vidal, E. Sauquet, A. Ben Daoud, and G. Bontron. Optimising predictor domains for spatially coherent precipitation downscaling. *Hydrol. Earth Syst. Sc. Discuss.*, 10 (4):4015–4061, 2013. doi: 10.5194/hessd-10-4015-2013.

B. K. Reichert, L. Bengtsson, and O. Akesson. A statistical modeling approach for the simulation of local paleoclimatic proxy records using general circulation model output. *J. Geophys. Res.-Atmos.*, 104(D16):19071–19083, August 1999. doi: 10.1029/1999JD900264.

O. Roessler, B. Diekkrueger, and J. Loeffler. Potential drought stress in a Swiss mountain catchment-Ensemble forecasting of high mountain soil moisture reveals a drastic decrease, despite major uncertainties. *Water Resour. Res.*, 48, W04521, 2012. doi: 10.1029/2011WR011188.

E. P. Salathe. Comparison of various precipitation downscaling methods for the simulation of streamflow in a rainshadow river basin. *Int. J. Climatol.*, 23(8):887–901, 2003. doi: 10.1002/joc.922.

J. Teweless and H. Wobus. Verification of prognosis charts. *B. Am. Meterol. Soc.*, 35(10):2599–2617, 1954.

B. Timbal, A. Dufour, and B. McAvaney. An estimate of future climate change for western france using a statistical downscaling technique. *Clim. Dynam.*, 20(7-8):807–823, 2003. doi: 10.1007/s00382-002-0298-9.

B. Timbal, P. Hope, and S. Charles. Evaluating the consistency between statistically downscaled and global dynamical model climate change projections. *J. Climate*, 21(22):6052–6059, 2008. doi: 10.1175/2008JCLI2379.1.

S. M. Uppala, P. W. Kallberg, A. J. Simmons, U. Andrae, V. D. Bechtold, M. Fiorino, J. K. Gibson, J. Haseler, A. Hernandez, G. A. Kelly, X. Li, K. Onogi, S. Saarinen, N. Sokka, R. P. Allan, E. Andersson, K. Arpe, M. A. Balmaseda, A. C. M. Beljaars, L. Van De Berg, J. Bidlot, N. Bormann, S. Caires, F. Chevallier, A. Dethof, M. Dragosavac, M. Fisher, M. Fuentes, S. Hagemann, E. Holm, B. J. Hoskins, L. Isaksen, PAEM Janssen, R. Jenne, A. P. McNally, J. F. Mahfouf, J. J. Morcrette, N. A. Rayner, R. W. Saunders, P. Simon, A. Sterl, K. E. Trenberth, A. Untch, D. Vasiljevic, P. Viterbo, and J. Woollen. The ERA-40 re-analysis. *Q. J. Roy. Meteor. Soc.*, 131 (612, Part b):2961–3012, 2005. doi: 10.1256/qj.04.176.

J.-P. Vidal, E. Martin, L. Franchisteguy, M. Baillon, and J.-M. Soubeyroux. A 50-year high-resolution atmospheric reanalysis over france with the safran system. *Int. J. Climatol.*, 30(11): 1627–1644, 2010. doi: 10.1002/joc.2003.

F. Wetterhall, S. Halldin, and C.-Y. Xu. Statistical precipitation downscaling in central sweden with the analogue method. *J. Hydrol.*, 306(1-4):174 – 190, 2005. doi: 10.1016/j.jhydrol.2004.09.008.

R. L. Wilby and N. W. Quinn. Reconstructing multi-decadal variations in fluvial flood risk using atmospheric circulation patterns. *J. Hydrol.*, 487:109–121, 2013. doi: 10.1016/j.jhydrol.2013.02.038.

R. L. Wilby, L. E. Hay, and G. H. Leavesley. A comparison of downscaled and raw GCM output: implications for climate change scenarios in the San Juan River basin, Colorado. *J. Hydrol.*, 225 (1-2):67–91, 1999. doi: 10.1016/S0022-1694(99)00136-5.

D. S. Wilks and R. L. Wilby. The weather generation game: a review of stochastic weather models. *Prog. Phys. Geog.*, 23(3):329 –357, 1999. doi: 10.1177/030913339902300302.

Daniel S Wilks. Stochastic weather generators for climate-change downscaling, part II: multivariable and spatially coherent multisite downscaling. *Wiley Interdisciplinary Reviews: Climate Change*, 3(3):267–278, 2012. doi: 10.1002/wcc.167.

P. Xie, A. Yatagai, M. Chen, T. Hayasaka, Y. Fukushima, C. Liu, and S. Yang. A gauge-based analysis of daily precipitation over east asia. *J. Hydrometeorol.*, 8(3):607–626, 2007. doi: 10.1175/JHM583.1.

E. Zorita and H. von Storch. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. *J. Climate*, 12(8, 2):2474–2489, 1999. doi: 10.1175/1520-0442(1999)012¡2474:TAMAAS¿2.0.CO;2.

Graphical interpretation of the CRPS for a given prediction

Determining the $\mathrm{CRPS}_k(i,p)$ applied to grid point p for a given prediction i consists in comparing the cdfs of $F_{k,i}$ predicted by AM_k to that of observation $H_{o_{p,i}}$. By definition, $H_{o_{p,i}}(x_p)$ equals 0 when $x_p \in]-\infty, o_{p,i}[$, $H_{o_{p,i}} = 1$ otherwise. The $\mathrm{CRPS}_k(i,p)$ can thus be divided in two sub-integrals as proposed in Eq. (7):

$$\begin{aligned}\mathrm{CRPS}_k(i,p) &= \int_{-\infty}^{+\infty} \left[F_{k,i}(x_p) - H_{o_{p,i}}(x_p)\right]^2 dx_p \\ &= \int_{-\infty}^{o_{p,i}} F_{k,i}^2(x_p)dx_p + \int_{o_{p,i}}^{+\infty} \left[F_{k,i}(x_p) - 1\right]^2 dx_p\end{aligned} \tag{7}$$

By adding and removing 1 in the second right integral of Eq. (7), Eq. (8) we obtain:

$$\mathrm{CRPS}_k(i,p) = \int_{-\infty}^{o_{p,i}} F_{k,i}^2(x_p)dx_p + \int_{o_{p,i}}^{+\infty} 1 - \left\{1 - \left[1 - F_{k,i}(x_p)\right]^2\right\} dx_p \tag{8}$$

In Fig. 1, the left integral of Eq. (8) corresponds to the left orange area whereas the right integral corresponds to the right orange area.

3. Compléments d'étude

Dans cette section, nous étayons l'étude publiée dans *Journal of Climate* sur la transposabilité spatiale des dates analogues. Dans un premier temps, la sensibilité de la transposabilité spatiale à la longueur de l'archive analogue brièvement discutée dans Chardon et al. [2014] est illustrée (section 3.1). Dans un second temps, la sensibilité de la transposabilité spatiale vis-à-vis de plusieurs filtres temporels (*i.e.* saisonniers et par type de temps) est étudiée (section 3.2).

3.1. Sensibilité à la longueur d'archive

La figure IV.2 représente le gain obtenu lorsqu'une archive couvrant la période allant du 01-08-1958 au 31-07-2001 – correspondant à une période de 43 ans – est utilisée par rapport à une archive s'étendant sur la période allant du 01-08-1982 au 31-07-2001 – correspondant à une période de 19 ans. Le gain observé en CRPSS est réparti de façon homogène sur l'ensemble du territoire et il varie autour de 1,7 points de CRPSS. Cependant, la région du Sud-Est et plus particulièrement ses reliefs (les Pyrénées, les Alpes, l'Est et le Sud du Massif Central) s'avèrent plus sensibles à la longueur de l'archive utilisée. Des valeurs de gains supérieures à 2 points de CRPSS sont retrouvées tandis qu'elles sont plus faibles sur le reste du territoire français. A l'Ouest, les précipitations résultent de flux d'Ouest plus ou moins similaires. On remarque par exemple à partir de la figure II.7 que presque la totalité des précipitations obtenues à l'Ouest proviennent de flux d'Ouest. On peut alors supposer que pour un jour cible donné, beaucoup de situations candidates peuvent constituer de bonnes dates analogues. Pour les autres régions en revanche, les précipitations peuvent être obtenues par une diversité plus importante de situations atmosphériques. Par exemple, les précipitations observées pour le Sud des

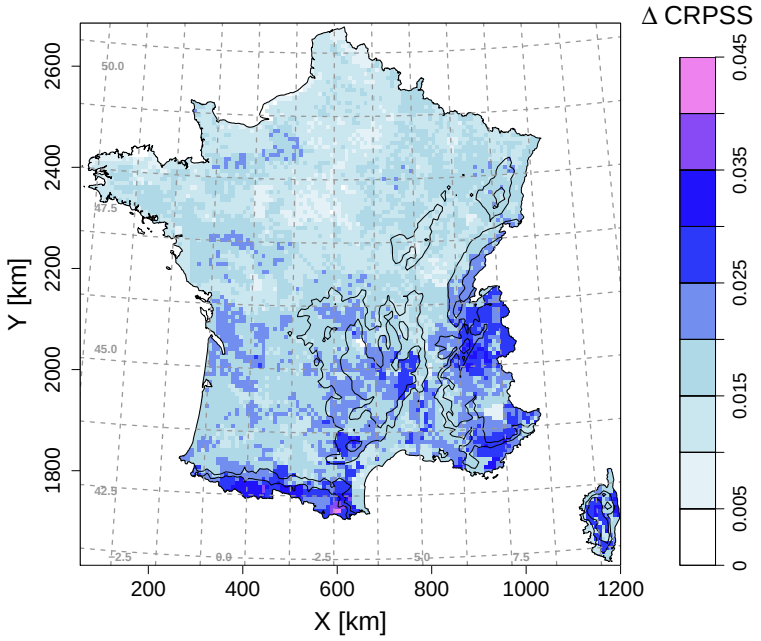

Figure IV.2 – Gain en CRPSS lorsque chaque modèle local optimal MA_p est appliqué à la maille correspondante Safran p avec comme longueur d'archive la période allant du 01-08-1958 au 31-07-2001 par rapport à une archive réduite s'étendant seulement du 01-08-1982 au 31-07-2001 pour la recherche des dates analogues.

Alpes peuvent provenir de circulation de Nord-Ouest, de Sud, de Sud-Est et de retours d'Est (figure II.7). Par conséquent, il devient plus facile de déterminer de meilleures dates analogues pour une région influencée par une large diversité de situations atmosphériques que pour une région influencée par des situations atmosphériques plus ou moins similaires à l'origine de précipitations.

La figure IV.3 compare la transposabilité spatiale des modèles MA_{NW} et MA_{SE} lorsque ces derniers utilisent l'archive courte ou l'archive longue. Sur cette figure, la ligne du haut correspond à la figure 7 présentée dans Chardon et al. [2014]. En comparant les pertes en CRPSS entre les cartes composant la ligne du haut (correspondant aux modèles utilisant l'archive courte) et celles de la ligne du bas (correspondant aux modèles utilisant l'archive longue), on remarque que l'étendue du domaine spatial pour lequel une perte de 1 point de CRPSS est observée est plus faible pour les modèles se basant sur une archive longue comparée aux modèles utilisant une archive courte. Ceci est particulièrement net lorsque la maille d'accroche correspond à la maille SE. La transposabilité spatiale d'un modèle MA se

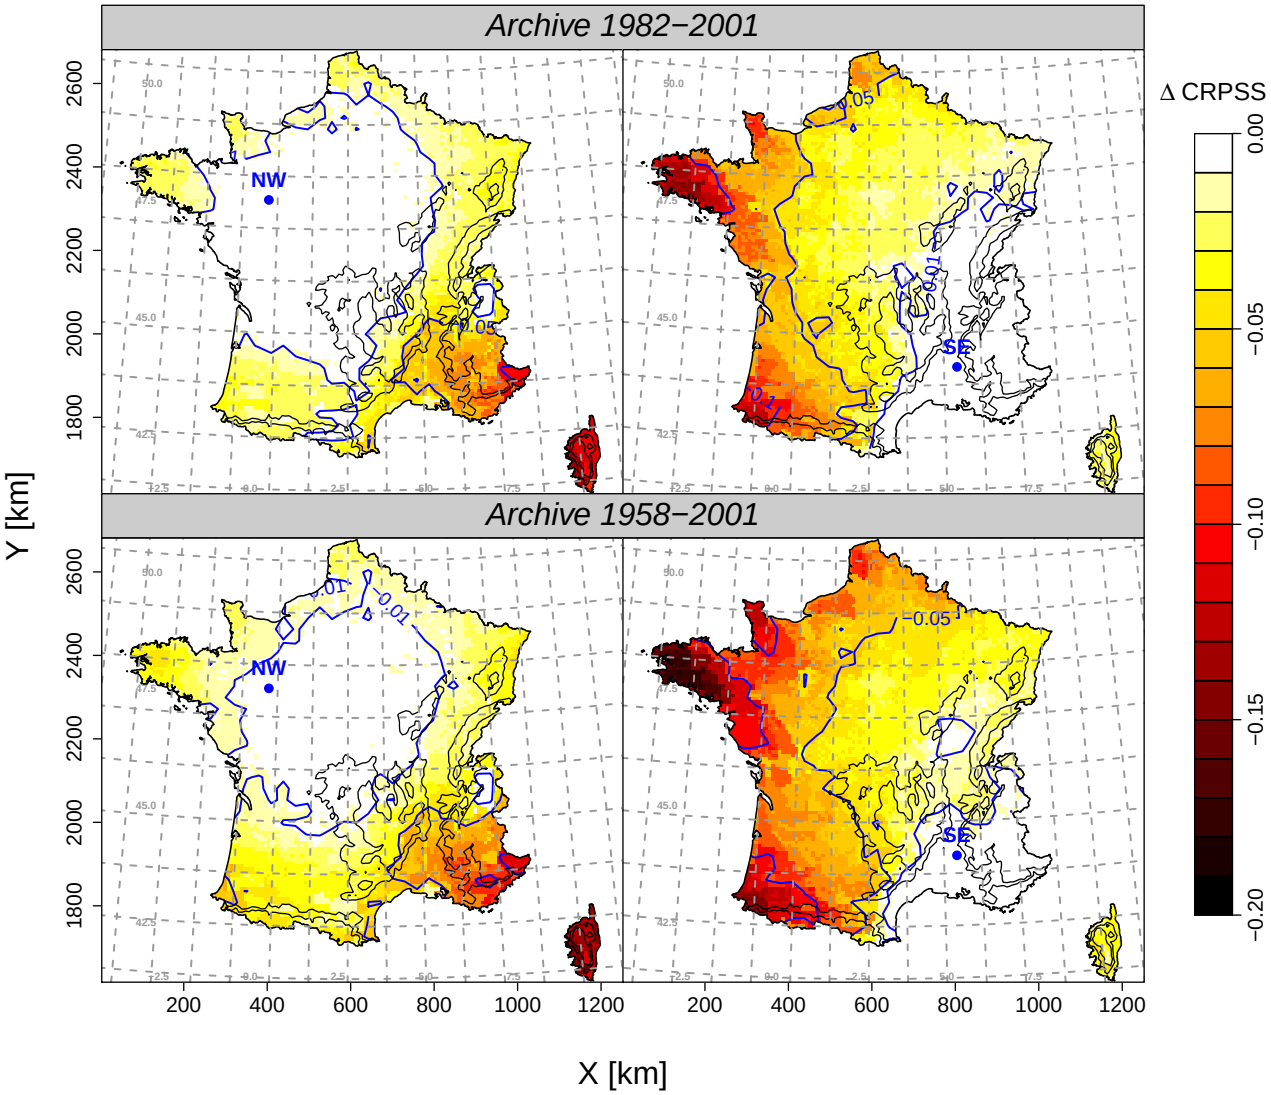

Figure IV.3 – Perte en CRPSS lorsqu'un modèle MA est transposé à l'ensemble de la France avec une archive couvrant la période allant du 01-08-1982 au 31-07-2001 (ligne du haut) et une archive s'étendant du 01-08-1958 au 31-07-2001 (ligne du bas). La colonne de gauche correspond à la transposabilité spatiale du modèle MA_{NW} tandis que la colonne de droite à celle du modèle MA_{SE}.

basant sur une archive de situations candidates longue est plus faible par rapport à celle d'un même modèle MA utilisant une archive plus courte. Le raffinement d'un modèle MA par l'augmentation de la taille de l'archive de situations candidates est dommageable à sa transposabilité. Ce résultat est analogue à celui déduit par Chardon et al. [2014] lors de l'ajout d'un second niveau d'analogie basé sur une variable d'humidité. Toutefois, la sensibilité de la transposabilité spatiale est plus importante pour un modèle MA optimisé pour le Sud-Est que pour le même modèle MA optimisé pour le Nord-Ouest. Comme remarqué à la figure IV.2, le gain de performance lorsqu'une archive longue est utilisée est faible dans le Nord-Ouest, entre 1 et 1,5 points de CRPSS en moyenne. De manière générale, les dates analogues retenues à partir de l'archive longue apportent une information de qualité légèrement supérieure à celle extraite de l'archive courte. Par conséquent, elles sont quasiment autant transposables. Ceci n'est cependant pas le cas pour le modèle $\mathrm{MA_{SE}}$. Comme l'augmentation de la longueur de l'archive permet d'obtenir un gain de performance plus important (parce que de meilleures dates analogues sont plus faciles à trouver pour cette région), la transposabilité du modèle $\mathrm{MA_{SE}}$ est plus sensible à la longueur de l'archive utilisée.

L'augmentation de la longueur de l'archive permet donc d'accroître localement la performance du modèle MA mais conduit à l'inverse à réduire sa transposabilité spatiale. Il n'est donc pas assuré qu'augmenter la longueur de l'archive soit pertinent si l'on souhaite appliquer le même modèle sur des régions étendues. La figure IV.4.a) compare la performance de deux modèles $\mathrm{MA_{NW}}$ transposés, l'un utilisant une archive courte, l'autre une archive longue. Dans ce cas, le modèle $\mathrm{MA_{NW}}$ avec l'archive longue se révèle plus performant que le modèle $\mathrm{MA_{NW}}$ avec l'archive courte. Ceci résulte des transposabilités spatiales très similaires obtenues pour les deux modèles $\mathrm{MA_{NW}}$. La figure IV.4.b) présente les mêmes résultats lorsque la maille d'accroche correspond à la maille SE. Le comportement constaté est ici différent : le modèle $\mathrm{MA_{SE}}$ avec l'archive longue est moins transposable que le modèle $\mathrm{MA_{NW}}$ ayant la même longueur d'archive. Ceci résulte de la transposabilité spatiale nettement moins importante pour le modèle $\mathrm{MA_{SE}}$ ayant une archive longue.

3.2. Sensibilité selon différents filtres temporels

Dans l'étude publiée, l'évaluation de la transposabilité spatiale est seulement effectuée de façon globale à l'échelle annuelle, *i.e.* aucune stratification temporelle n'est considérée. On pourrait se poser également les questions suivantes : est-il plus facile de transposer spatialement un modèle MA en été ou en hiver ? Est-il plus facile de transposer un modèle MA lors de situations anticycloniques ou lorsqu'une perturbation Atlantique survient ? Cette transposition est-elle dépendante de l'endroit géographique considéré ? Dans cette section, nous évaluons la sensibilité de la transposabilité spatiale en fonction des saisons et des types de temps définis par Garavaglia et al. [2010]. Comme nous n'avons pas eu le temps d'approfondir cette étude, les travaux que nous présentons ici sont par conséquent seulement descriptifs. Nous avançons toutefois des hypothèses pouvant expliquer les résultats obtenus en particulier pour les types de temps.

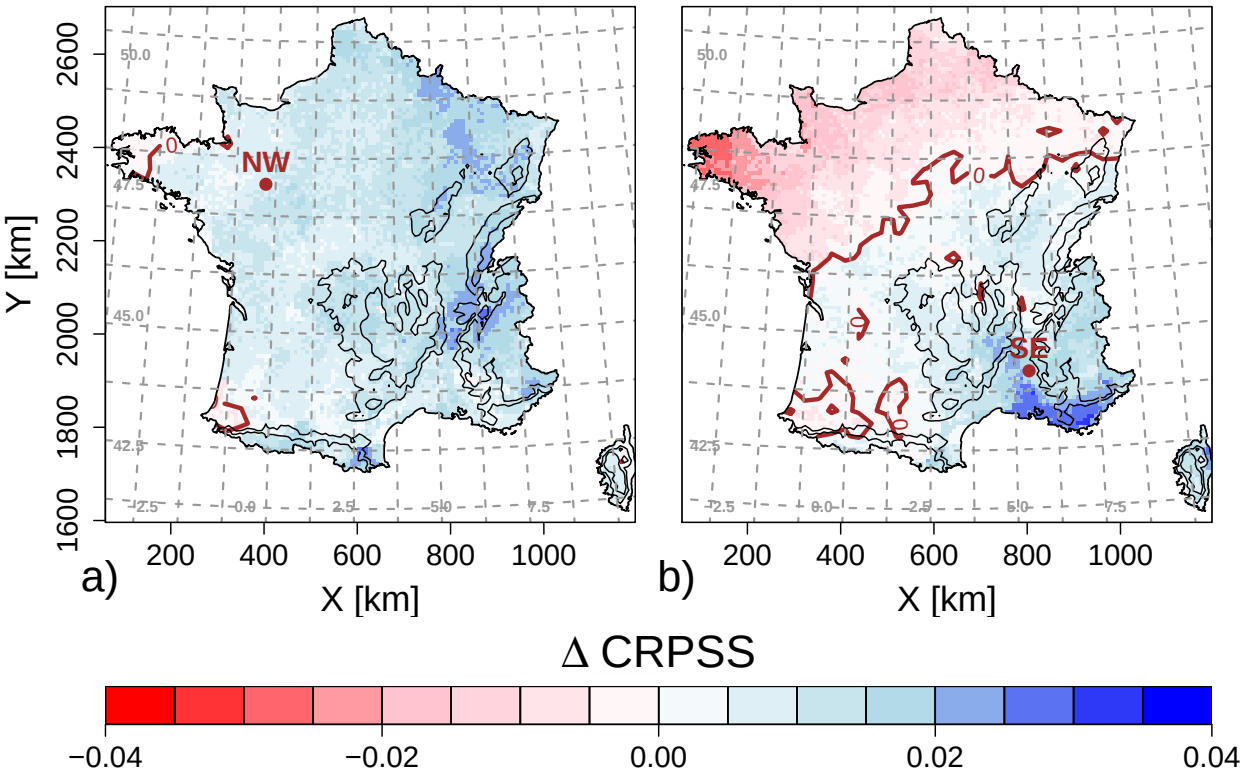

FIGURE IV.4 – Différence en CRPSS lorsque les modèles a) MA_{NW} avec une longue archive et b) MA_{SE} avec une longue archive (de 1958-08-01 à 2001-07-31) sont transposés par rapport aux mêmes MAs utilisant une archive plus courte (de 1982-08-01 à 2001-07-31).

3.2.1. Evaluation saisonnière

La figure IV.5.a) présente la transposabilité spatiale du modèle MA_{NW} en fonction de la saison considérée [1]. On notera que pour chaque site, le modèle MA a été optimisé à l'échelle annuelle. Il est donc possible que ce modèle ne soit pas optimal pour la prédiction des précipitations appartenant à une saison donnée. Par conséquent, il est probable qu'un modèle MA optimal obtenu pour une autre maille que la maille cible soit meilleur, parce que le modèle MA pour cette maille a été optimisé de façon globale pour l'année et non pour chaque saison. Ceci explique le gain de performance que l'on peut observer quand on transpose un modèle MA optimisé pour une maille d'accroche donnée aux sites voisins. On observe ce phénomène sur un certain nombre de mailles sur la figure IV.5. Toutefois, les gains obtenus dans ce cas restent négligeables (car ils sont inférieurs à 1 point de CRPSS dans la majorité des cas) et sont peu sensibles à la fragmentation saisonnière.

Tout comme les distributions spatiales des performances optimales saisonnières du modèle MA (représentées à la figure III.9), les distributions spatiales du ΔCRPSS pour les saisons d'hiver, d'automne et de printemps sont similaires à celle obtenue par l'étude globale à l'échelle annuelle décrite à la figure 7.a) dans CHARDON et al. [2014]. A quelques légères différences près, le domaine spatial sur lequel un ΔCRPSS supérieur à -0,01 est constaté représente une surface de 400 km de large par 400 km de long délimitée par le Massif Central. En été, cette surface devient plus importante : elle couvre dans ce cas une surface plus étendue regroupant l'Ouest entier de la France et une bonne partie des mailles situées au Nord du Massif Central. Comme nous avons pu le remarquer sur les figures II.5, l'été constitue la saison la plus sèche en terme de cumul de précipitation. De plus, il

1. Dans cet exercice, nous avons réutilisé une longueur d'archive couvrant la période du 01-08-1982 au 31-07-2001.

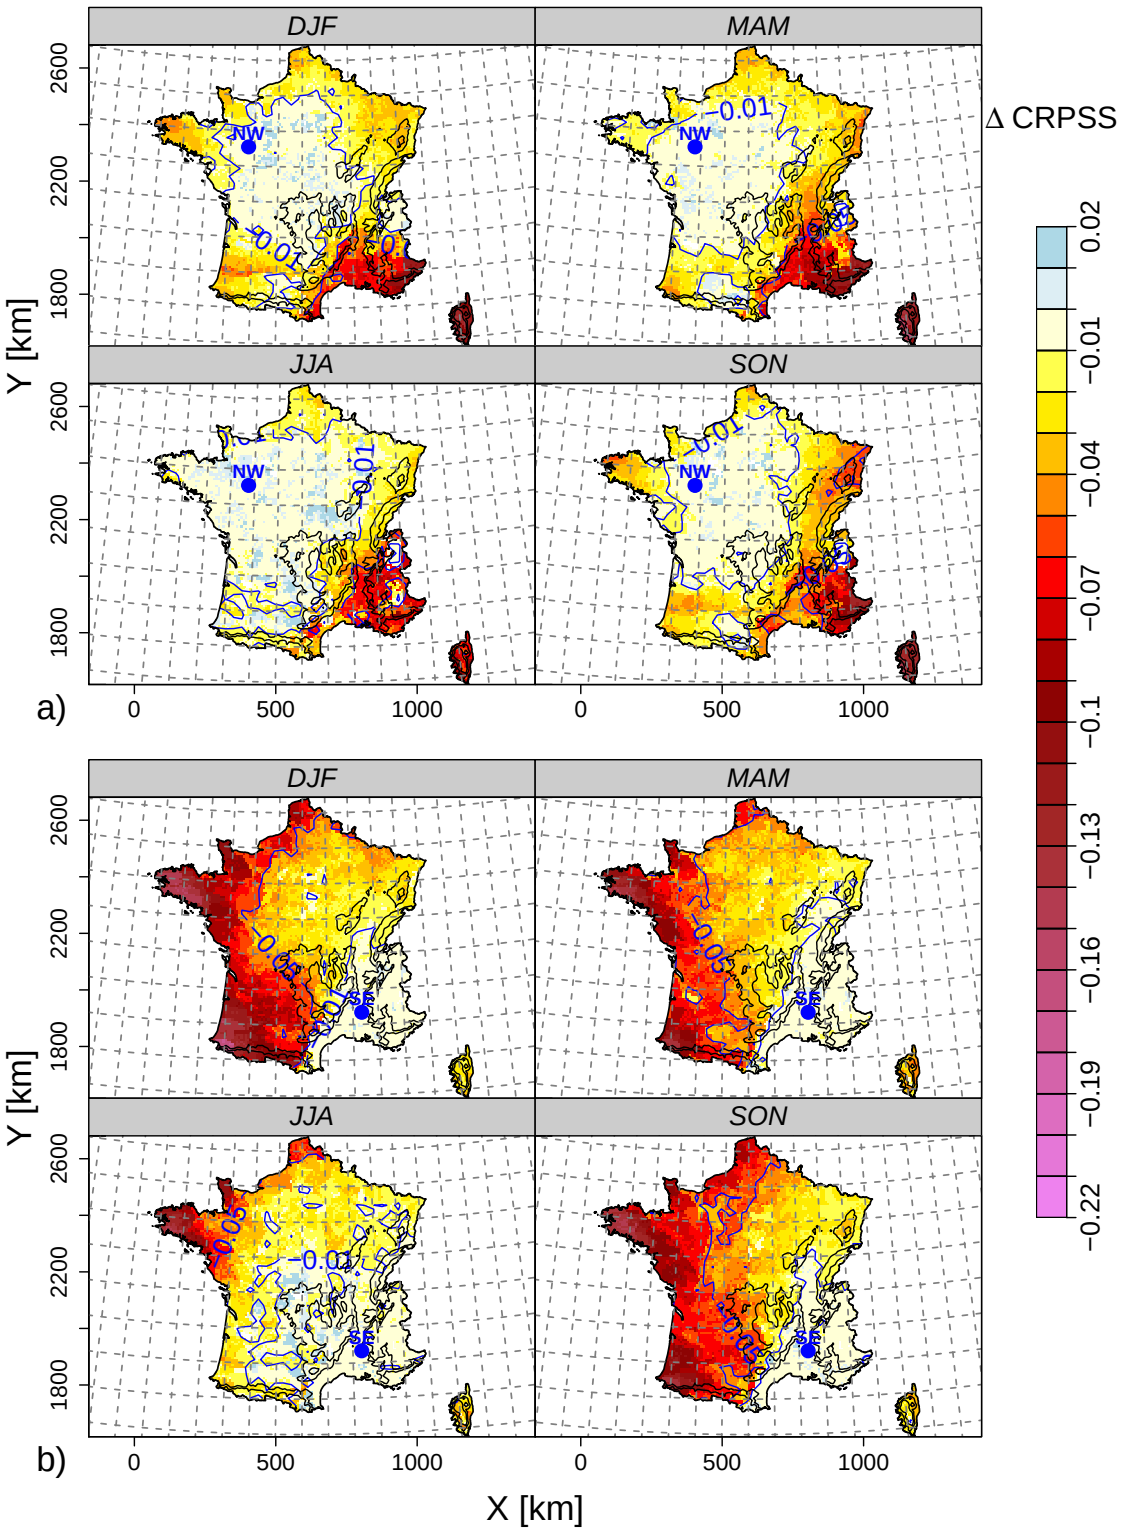

FIGURE IV.5 – Transposabilité spatiale des modèles a) MA_{NW} et b) MA_{SE} en fonction des saisons.

s'agit de la saison pour laquelle il existe le plus de jours secs pour toutes les régions de France. On peut alors supposer qu'en moyenne, pour une prédiction effectuée en été, une grande partie des dates analogues extraites par un modèle MA quelconque soit sèche sur une majorité des mailles Safran. La prédiction de la précipitation à partir de dates analogues sèches issues du modèle MA_{NW} ou d'un modèle MA localement optimisé conduira à émettre une distribution similaire (tendant alors vers une fonction Heaviside en 0), impliquant dans ce cas une forte transposabilité spatiale des dates ana-

logues. Si l'on regarde la tranposabilité spatiale saisonnière du modèle MA_{SE}, un résultat similaire est obtenu également dans ce cas. Seule la distribution spatiale du ΔCRPSS obtenue pour la saison d'été se différencie significativement de la distribution spatiale globale annuelle illustrée à la figure 7.b) [Chardon et al., 2014] et de celles des autres saisons.

3.2.2. Evaluation selon les types de temps

Dans ces travaux de thèse, nous avons également souhaité évaluer la tranposabilité spatiale du modèle MA en fonction des types de temps définis par Garavaglia et al. [2010]. A titre d'illustration, la figure IV.6 représente la perte de performance observée lorsque les modèles MA_{NW} et MA_{SE} sont appliqués pour la prédiction des précipitations sur le territoire français en fonctions des types de temps. Pour un type de temps donné, il semblerait premièrement qu'un modèle MA localement optimisé à partir d'une maille fortement influencée par le type de temps considéré (*i.e.* pour laquelle un cumul moyen important est observé pour ce type de temps) soit facilement transposable en les mailles situées selon l'axe d'advection des masses d'air. Par exemple, lorsque le modèle MA_{NW} est transposé pour le TT1, on remarque que la surface pour laquelle un ΔCRPSS est supérieur à -0,01 s'étire vers le Sud-Est, correspondant à la direction moyenne prise par les masses d'air pour le TT1 (figure II.6). Pour le TT2 (flux d'Ouest), le modèle MA_{NW} est facilement transposable à l'Est de la maille NW. Pour le TT3 (flux de Sud-Ouest), la surface correspondant à un ΔCRPSS s'étire selon un axe Sud-Ouest/Nord-Est. Si l'on considère maintenant la maille SE, le modèle MA_{SE} est fortement transposable selon un axe Sud/Nord et un axe Est/Ouest respectivement pour les TT7 et TT6. Pour cette région, des cumuls importants peuvent être rencontrés pour les TT6 et TT7 (*cf.* figure II.7). Ce constat n'est pas retrouvé pour le TT4 (flux de Sud-Est) où l'on remarque que le modèle MA_{SE} est faiblement transposable en les mailles situées juste derrière le massif des Cévènnes-Vivarais selon l'axe Sud-Est/Nord-Ouest. D'autres exemples (*cf.* annexe B) basés sur la transposabilité spatiale des autres modèles MA localement optimisés pour les autres mailles d'accroche ne permettent cependant pas de valider l'hypothèse avancée, *i.e.* un modèle MA optimisé pour une maille influencée par un type de temps donné est facilement transposable sur les mailles situées sur l'axe d'advection des masses d'air du type de temps considéré.

Une seconde hypothèse est qu'il semblerait que la transposabilité d'un modèle MA est favorisée lorsque les performances des modèles MA optimaux locaux sont faibles. Par exemple, pour les TT4 et TT6, le modèle MA_{NW} obtient une bonne transposabilité spatiale. La fenêtre d'analogie du modèle MA_{NW} étant orientée vers l'Ouest (*cf.* figure 5 de Chardon et al. [2014]), elle ne permet pas de caractériser l'origine des masses d'air, menant ainsi à de faibles performances dans l'Ouest de la France pour ces types de temps. Or, comme l'ensemble des modèles MA de cette région possèdent eux aussi une fenêtre orientée vers l'Ouest, ces modèles conduisent tous à l'obtention de faibles performances en cette région (figure III.11). Comme les performances du modèle MA_{NW} et des modèles MA locaux sont du même ordre de grandeur, la transposabilité spatiale du modèle MA_{NW} est bonne pour ces types de temps.

Une troisième hypothèse est qu'il semblerait que la transposabilité d'un modèle MA peut être très bonne dans le cas d'une situations sèches, à partir du moment où cette situation est sèche à l'échelle régionale voir nationale. Par exemple, le ΔCRPSS obtenu par le modèle MA_{NW} est supérieur à -0,01 jusqu'au Sud de la France pour le TT8. Tout comme pour la saison d'été (*cf.* figure IV.5.a), la

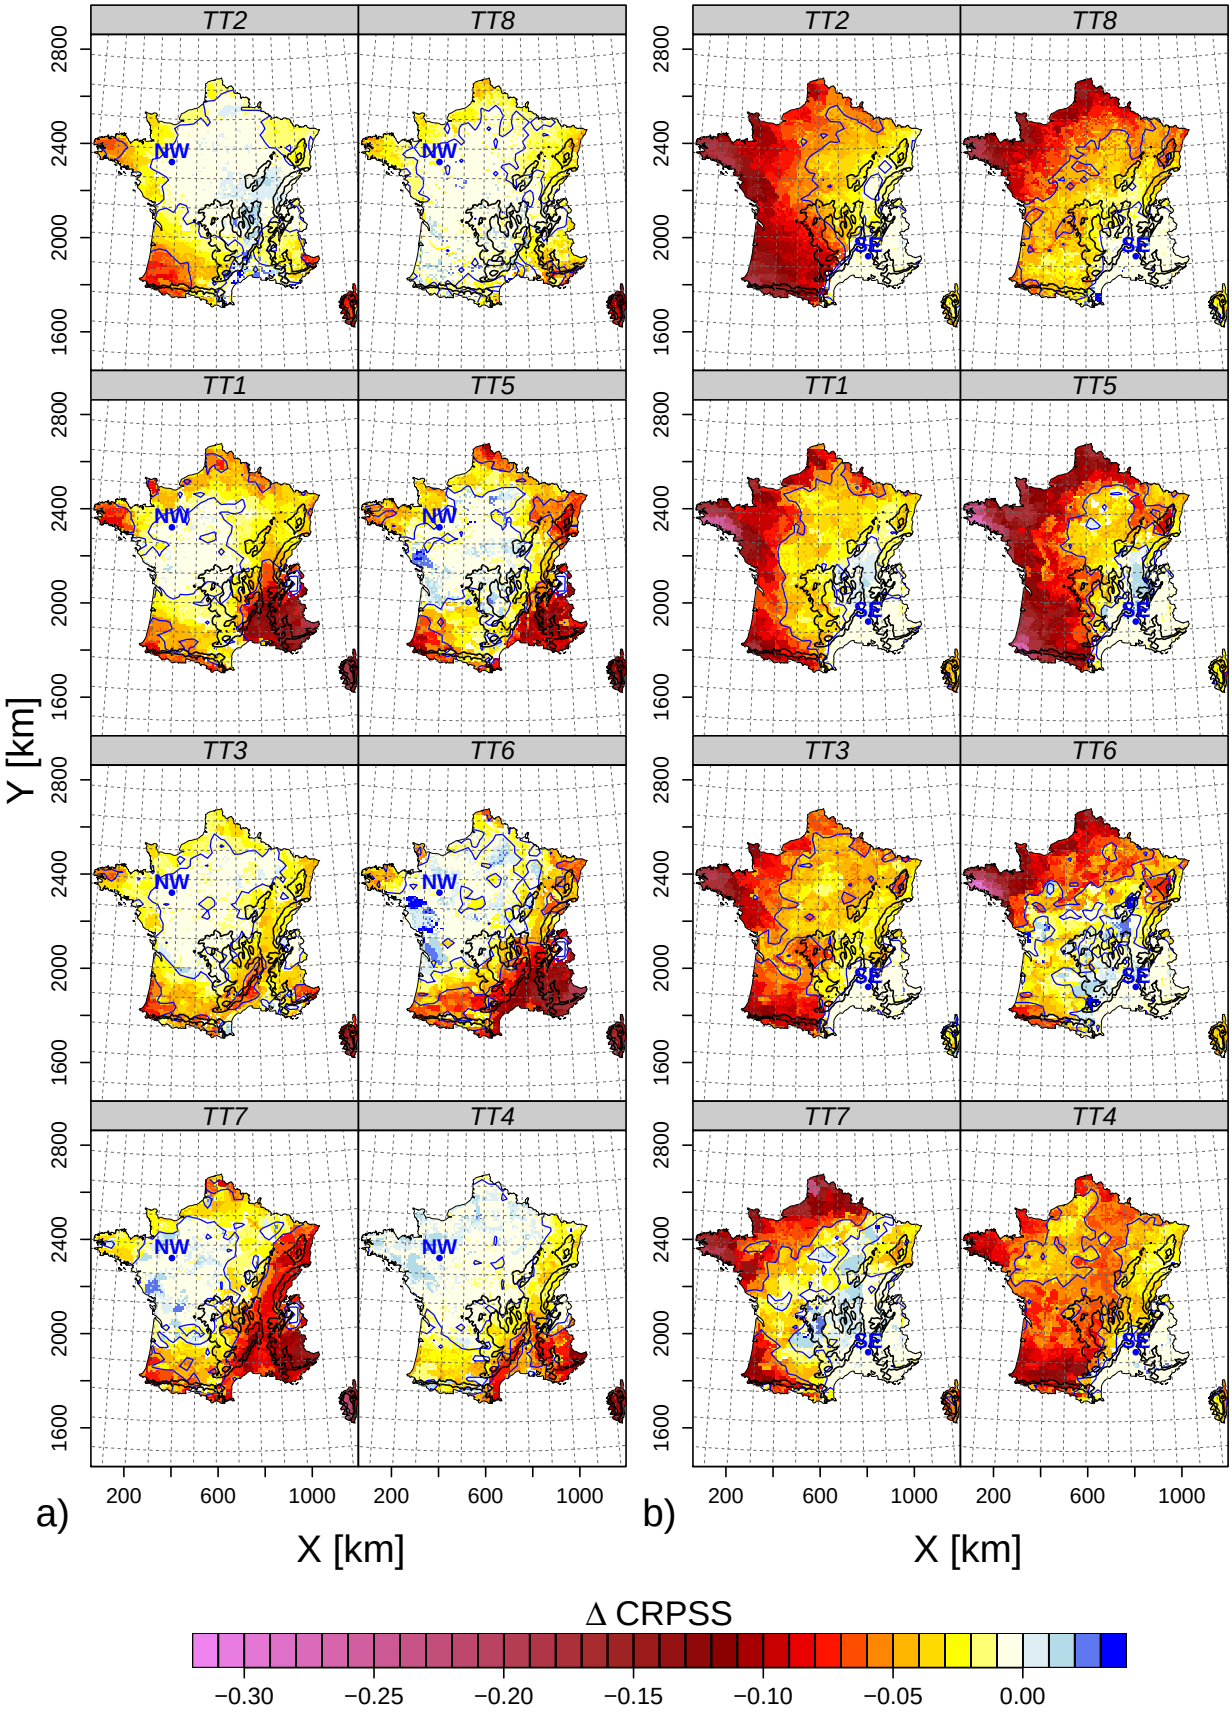

FIGURE IV.6 – Transposabilité spatiale des modèles a) MA_{NW} et b) MA_{SE} en fonction des types de temps.

prédiction de dates analogues sèches par le modèle MA_{NW} permet d'expliquer la bonne transposabilité du modèle. Cependant, cette transposabilité s'avère beaucoup plus limitée pour le modèle MA_{SE}.

Finalement, il apparaît que les résultats sont très sensibles au modèle MA transposé (et donc à la maille d'accroche utilisée pour l'optimisation) et au type de temps. On peut toutefois dire que la transposabilité d'un modèle MA s'avère bonne – *i.e.* le ΔCRPSS est supérieur à -0,01 – lorsque le MA transposé est appliqué sur des mailles situées dans un rayon de 100 km à partir de la maille utilisée pour l'optimisation du modèle MA. Cependant, refaire la même analyse avec un MA optimisé pour une région donnée (et non une seule maille Safran), comportant une longueur d'archive plus importante (de façon à disposer de plus de situations correspondant à un même type de temps) et appliquée sur un territoire plus vaste où les barrières topographiques ne seraient pas aussi ressérées les unes des autres permettrait peut-être d'obtenir des résultats plus robustes.

Chapitre V

Prédiction d'une précipitation spatiale moyenne : sensibilité de la performance à l'échelle d'agrégation

---

L'application d'une MDES pour la génération de scénarios météorologiques locaux à l'échelle d'un territoire donné dans les études d'impact est le plus souvent effectuée en chaque station du territoire concerné [*e.g.* Wetterhall et al., 2006 ; Frost et al., 2011]. La MDES est par suite souvent évaluée par sa performance locale, *i.e.* sa capacité à reproduire les variations temporelles de la variable en chacune des stations.

Dans le chapitre précédent, nous avons évalué la transposabilité spatiale du modèle MA vis-à-vis de cette performance locale. Nous avons montré que cette transposabilité spatiale était relativement importante et qu'elle permettait par suite de prédire des scénarios de précipitations à haute résolution spatialement cohérents sur des territoires pouvant couvrir jusqu'à plusieurs centaines de milliers de km^2.

Pour les analyses hydro-météorologiques régionales et les analyses hydrologiques en particulier, la possibilité de prédire des scénarios spatialement cohérents est évidemment une nécessité. La possibilité de prédire correctement la valeur spatiale moyenne de la variable considérée sur le territoire visé est aussi fortement souhaitée. C'est potentiellement le cas dès lors que l'on s'attaque par exemple à des questions relatives à la ressource en eau ou aux crues à l'échelle d'un bassin versant.

Le pouvoir prédictif d'une MDES est *a priori* différent si la MDES est utilisée pour la prédiction de variables locales ou si elle est utilisée pour la prédiction de variables agrégées à l'échelle d'un territoire donné. L'influence de la résolution spatiale de la variable à prédire sur le pouvoir prédictif d'une MDES donnée a été, à notre connaissance, peu explorée.

La moyenne spatiale opérée sur plusieurs mailles adjacentes conduit en principe à faire ressortir un signal pluviométrique régional moyen, potentiellement d'autant plus robuste que l'échelle d'agrégation est grande. Comme cela a été montré à de nombreuses reprises, les conditions atmosphériques de grande échelle conditionnent les précipitations locales. On s'attend cependant à ce qu'elles expliquent mieux ce signal pluviométrique régional moyen constituant un signal plus robuste que les conditions pluviométriques locales, pouvant être considérées comme plus "chaotiques" car dépendantes de beaucoup de facteurs physiographiques locaux et de processus atmosphériques de petites échelles. On peut donc s'attendre *a priori* à ce que l'agrégation spatiale conduisent à de meilleures performances de prédiction du fait de la réduction du bruit associée au processus de lissage obtenu par moyenne spatiale.

L'augmentation du pouvoir prédictif avec l'agrégation spatiale a été suggérée par Wilby et al. [2003] et illustrée par Mezghani & Hingray [2009]. Pour le bassin du Rhône à l'amont du Léman, Mezghani & Hingray [2009] ont comparé la variance expliquée obtenue 1) pour la prédiction de précipitations locales en 48 stations, 2) pour la prédiction de précipitations spatiales moyennes à l'échelle du bassin complet (5 500 km^2) et 3) pour la prédiction des précipitations moyennes à l'échelle de ses sous-bassins versants (six sous-bassins variant entre 650 et 1400 km^2). L'agrégation (du local au sous-bassin, puis au bassin versant complet) conduit toujours à un gain de performance. Quand on passe de la station à l'échelle du bassin complet, le gain relatif monte jusqu'à 30% pour la prédiction de la probabilité d'occurrence (équivalent à un gain de 10 points de variance expliquée) et jusqu'à 60% pour la prédiction de la hauteur précipitée (ce qui représente un gain de 11 points de variance expliquée).

Les conclusions de l'étude de Gangopadhyay et al. [2004] sont plus incertaines. Les auteurs ne notent pas de différence significative entre les performances obtenues pour les précipitations de bassin et pour les précipitations locales. Ce résultat contre intuitif peut cependant s'expliquer en partie par la petite taille des bassins versants et surtout le nombre parfois très faible de stations utilisées pour estimer les précipitations de bassins (qui sont de fait similaires voir parfois identiques aux précipitations mesurées aux stations). Lorsque les auteurs considèrent non plus les précipitations issues de stations mais des précipitations moyennes obtenues sur la base de toutes les stations contenues dans un rayon donné, autour d'une station cible choisie, la performance augmente clairement avec le rayon considéré (et donc le nombre de sites utilisés pour le calcul de la précipitation moyenne). Le gain est particulièrement important pour les premiers niveaux d'agrégation considérés (jusqu'à un rayon de 50 km), il augmente continûment mais de façon moins soutenue jusqu'au niveau d'agrégation maximal considéré (égal à 150 km). Les gains varient suivant la station initialement considérée mais aussi suivant les saisons. Ils sont plus forts en été qu'en hiver.

Dans le présent chapitre, nous tentons de préciser les principes suggérés par ces études en explorant la façon dont la performance de la prédiction évolue avec l'échelle d'agrégation pour les précipitations journalières en France. Le maillage carré régulier de la ré-analyse Safran nous permet d'avoir une analyse homogène sur un support régulier couvrant l'ensemble du territoire. Nous ne serons donc pas limités dans nos analyses par l'hétérogénéité inévitable rencontrée sur les tailles des régions considérées lorsque le découpage en région est considéré sur des critères hydrologiques. Nous pourrons aussi élargir nos analyses à des échelles d'agrégation dépassant largement la taille des bassins hydrologiques

considérés dans les études précédentes. Cela nous permettra en particulier d'identifier si l'augmentation du pouvoir prédictif de la descente d'échelle augmente continûment avec l'échelle d'agrégation ou s'il existe une échelle d'agrégation optimale en deçà de laquelle elle viendrait à diminuer. Pour un jour donné, les processus météorologiques à l'origine des précipitations étant potentiellement différents selon les régions, on pourrait en effet s'attendre à ce que la performance de la MDES soit moindre dès lors que les précipitations régionales moyennes à prédire résultent trop fréquemment d'un mixte trop hétérogène de situations locales.

Nous présentons dans une première section les données et la MDES considérée pour cette étude. Dans la deuxième section, nous présentons comment les résultats de notre analyse dépendent de la région considérée et du niveau d'agrégation considéré. Dans une troisième section, nous mettons empiriquement en évidence l'effet de la corrélation spatiale des précipitations journalières sur nos résultats. Dans une quatrième section, nous tentons d'expliquer comment la corrélation spatiale joue sur l'amélioration de la performance avec l'échelle d'agrégation. Nous effectuons à cet effet différentes expériences de simulation que nous avons proposées pour cette analyse. Nous discuterons enfin les résultats de simulation obtenus.

1. Modèle & données

Le chapitre IV a montré qu'un modèle MA_{25} permettait de prédire des précipitations spatialement cohérentes sur des territoires allant de quelques kilomètres carrés (8×8, soit 64 km^2) à plusieurs dizaines de milliers de kilomètres carrés. Par la suite, un modèle MA_{25} unique est utilisé pour la génération de scénarios de précipitations sur la France entière. Ce modèle a été optimisé en maximisant la performance moyenne de la prédiction locale sur les 8 981 mailles Safran du territoire français. Ce modèle est noté MA_{F} par la suite. La fenêtre d'analogie du modèle MA_{F} obtenue est orientée à l'Ouest vers l'océan Atlantique et ainsi qu'au Sud vers la Méditerranée, car ces deux étendues d'eau constituent les sources majeures d'humidité à l'origine des précipitations (figure V.1.a). En un point p donné, la performance du modèle MA_{F} est légèrement moins bonne que celle du modèle MA local dont le domaine d'analogie a été optimisé pour ce point. La figure V.1.b) représente la perte de performance $\Delta\mathrm{CRPSS}_F$ correspondante :

$$\Delta\mathrm{CRPSS}_F(p) = \mathrm{CRPSS}_F(p) - \mathrm{CRPSS}_p(p) \tag{V.1}$$

où $\mathrm{CRPSS}_F(p)$ et $\mathrm{CRPSS}_p(p)$ correspondent à la performance en CRPSS obtenue respectivement avec MA_{F} et MA_p.

Pour les mailles situées dans le centre de la France, la perte de performance est inférieure à 0,01. En revanche, pour les mailles situées aux extrémités de la France (*e.g.* celles situées en Bretagne, dans le Sud-Ouest et le Sud-Est), la perte de performance est plus importante et peut même être supérieure à 5 points de CRPSS en Corse. Cette perte de performance résulte d'un compromis pour lequel les mailles situées au centre de la France, par conséquent plus nombreuses, ont un poids plus important par rapport à celles situées aux extrémités pour l'optimisation du domaine d'analogie.

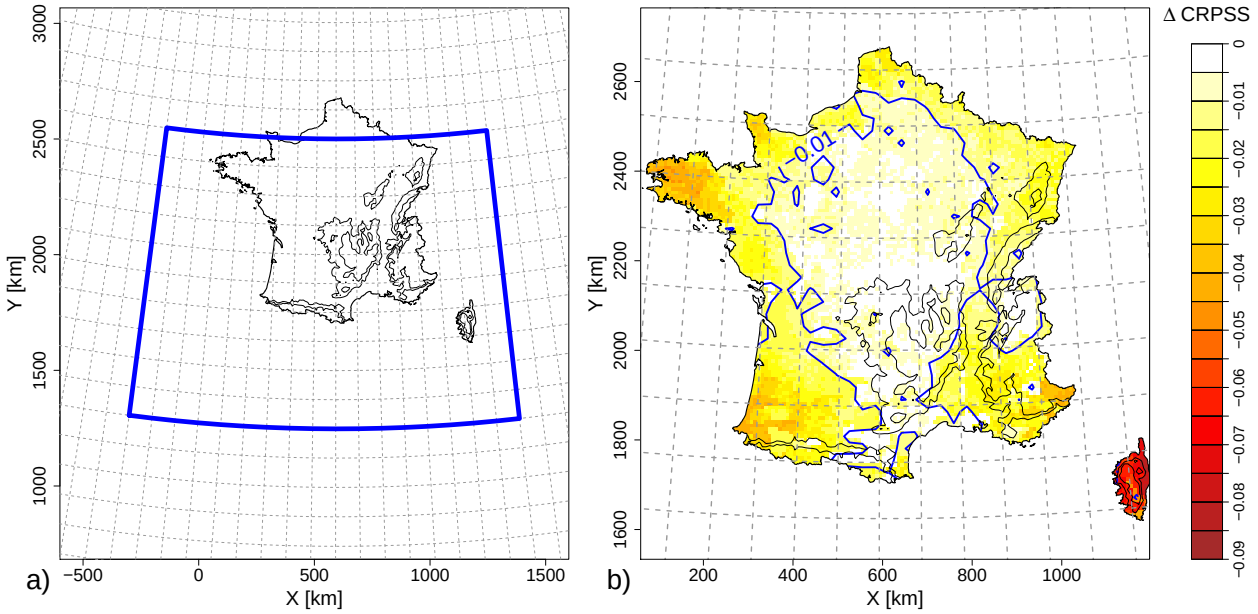

FIGURE V.1 – a) Fenêtre d'analogie optimisée pour le modèle MA_F. Le contour pointillé bleu représente la fenêtre initiale pour l'algorithme d'optimisation. b) Perte de CRPSS obtenue par le modèle MA_F par rapport à un modèle MA_{25} optimisé en chaque maille Safran. La ligne de contour en bleue représente une perte de performance égale à 0,01.

Dans ce chapitre, le prédictand n'est pas une précipitation locale mais une précipitation agrégée à l'échelle d'un territoire. Pour une maille p donnée et un niveau d'agrégation spatial SAL (*Spatial Aggregation Level*) donné, la précipitation agrégée est issue des précipitations Safran contenues sur un territoire délimité par les mailles distantes de n mailles de p selon les quatre directions S, N, E, W. Par conséquent, une précipitation agrégée résultant d'un SAL égal à n revient à agréger $(2 \times n + 1)^2$ précipitations issues des mailles Safran centrées sur la maille p. Pour un SAL donné, la chronique de précipitation agrégée est déterminée pour chaque maille Safran dès lors que la région couverte par le pavé de côté $(2 \times n + 1)$ mailles correspondant à ce SAL et centrée sur la maille considérée est constituée d'au moins 75% de mailles disposant de données. De ce fait, les mailles Safran situées aux frontières ou en bordure du territoire peuvent être exclues de l'analyse. Enfin, un SAL égal à 0 revient à ne pas effectuer d'agrégation.

Par la suite, les dates analogues issues du modèle MA_F sont appliquées sur la France pour la prédiction des précipitations agrégées pour différentes valeurs de SAL données. Sur la base des dates analogues, une distribution prédictive peut être estimée pour la prédiction de la précipitation agrégée. La performance de prédiction du modèle MA pour un territoire est finalement évaluée par sa capacité à prédire la précipitation agrégée correspondante au travers du CRPSS.

2. Sensibilité des performances à l'agrégation spatiale

La figure V.2 représente les performances en CRPSS obtenues par le modèle MA_F pour des niveaux d'agrégation spatial égaux à 0, 1, 3, 8, 16 et 23 – ce qui revient pour les cinq dernières valeurs de SAL à agréger [1] sur des surfaces respectivement égales à 576 km^2, 3 136 km^2, 18 496 km^2, 69 696 km^2, 141

1. Pour mémoire, la surface couverte par une maille Safran est de 8×8 km^2, soit 64 km^2.

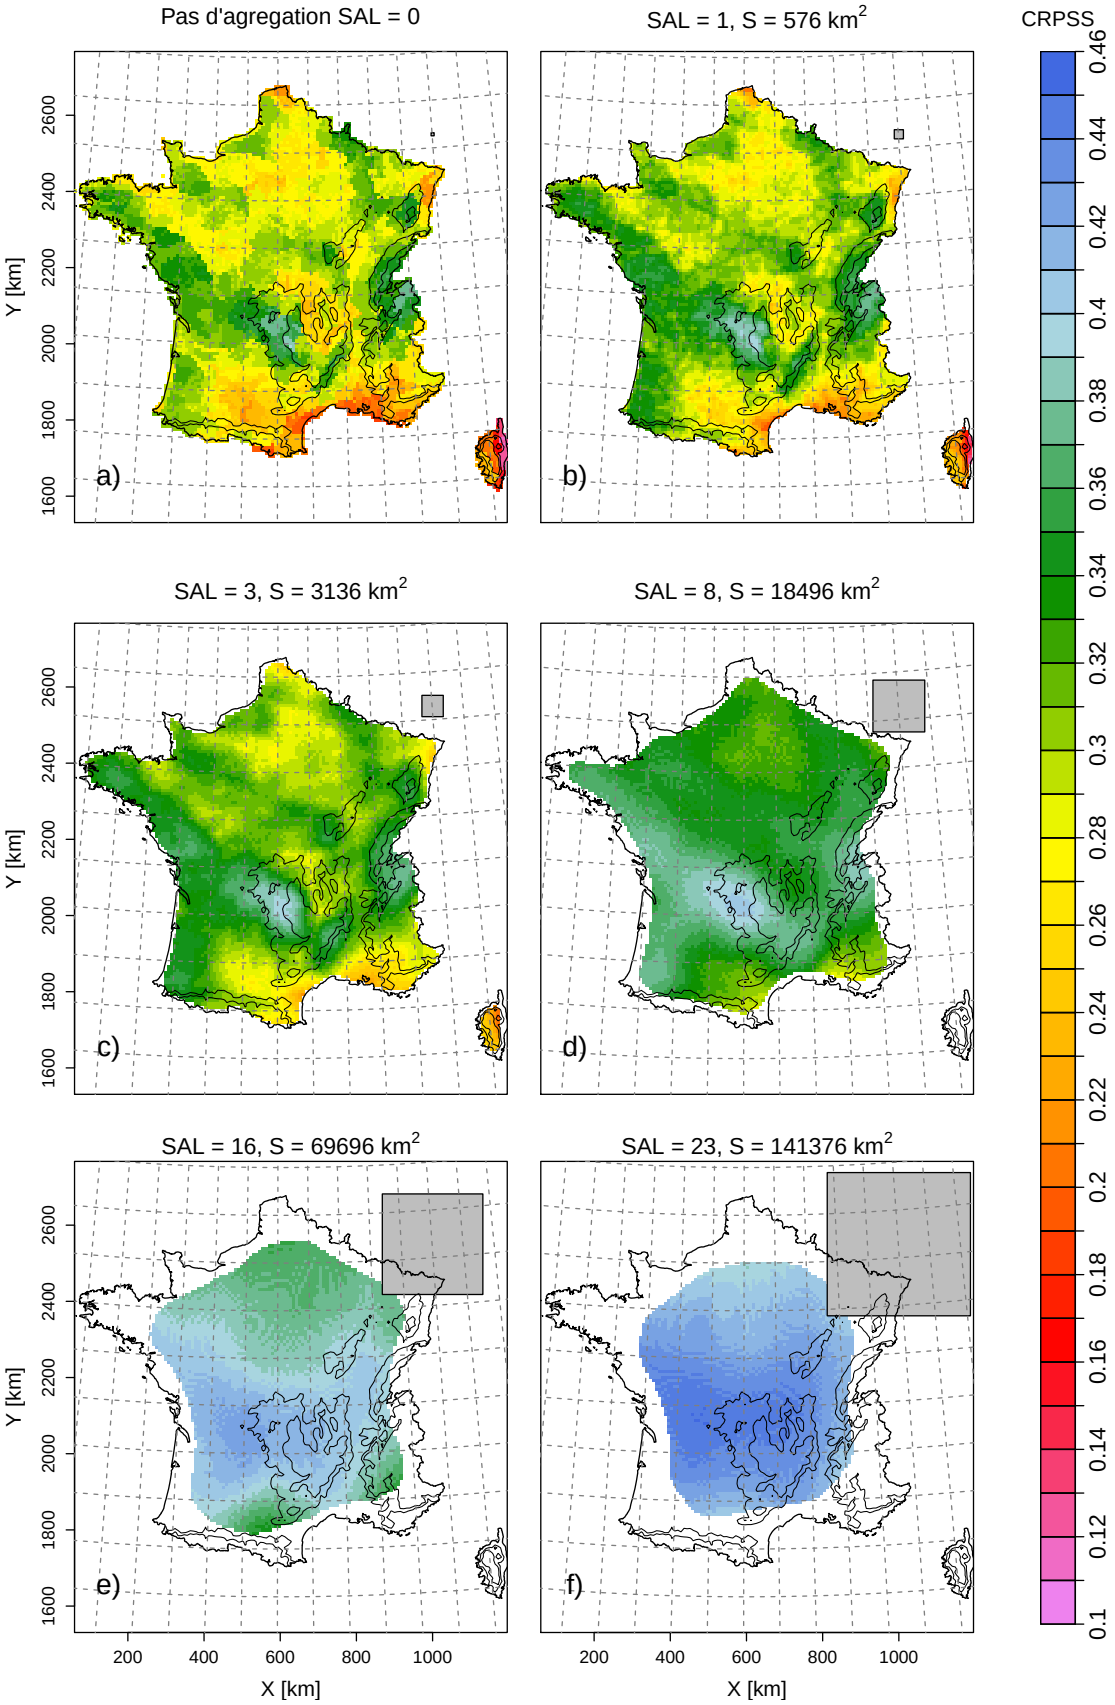

FIGURE V.2 – Sensibilité des performances en CRPSS en fonction du niveau d'agrégation SAL considéré. a) Aucune agrégation, b) SAL égal à 1, c) SAL égal à 3, d) SAL égal à 8, e) SAL égal à 16 et f) SAL égal à 23. La surface considérée pour l'agrégation des précipitations est représentée par le carré gris en haut à droite.

376 km^2. On remarque que les performances en CRPSS croissent avec le niveau d'agrégation. Plus le SAL est important, plus la performance de prédiction est importante, quelle que soit la maille Safran et aucun optimum n'est *a priori* obtenu.

La figure V.3.a) représente l'évolution des distributions de CRPSS en fonction du niveau d'agrégation considéré. Comme il a été montré à la section 3.1 du chapitre III que le terme de fiabilité $\overline{\text{Rel}}$ était négligeable devant les autres termes de la décomposition du $\overline{\text{CRPS}}$, seules les distributions des termes de résolution $\overline{\text{Res}}$ et d'incertitude $\overline{\text{U}}$ sont représentées aux figures V.3.b) et V.3.c). Il a été toutefois vérifié que le terme de fiabilité était peu sensible au SAL (non montré dans cette thèse). A partir de la figure V.3, l'augmentation de performance en CRPSS s'explique à la fois par une augmentation du terme de résolution $\overline{\text{Res}}$ et par la diminution du terme d'incertitude $\overline{\text{U}}$.

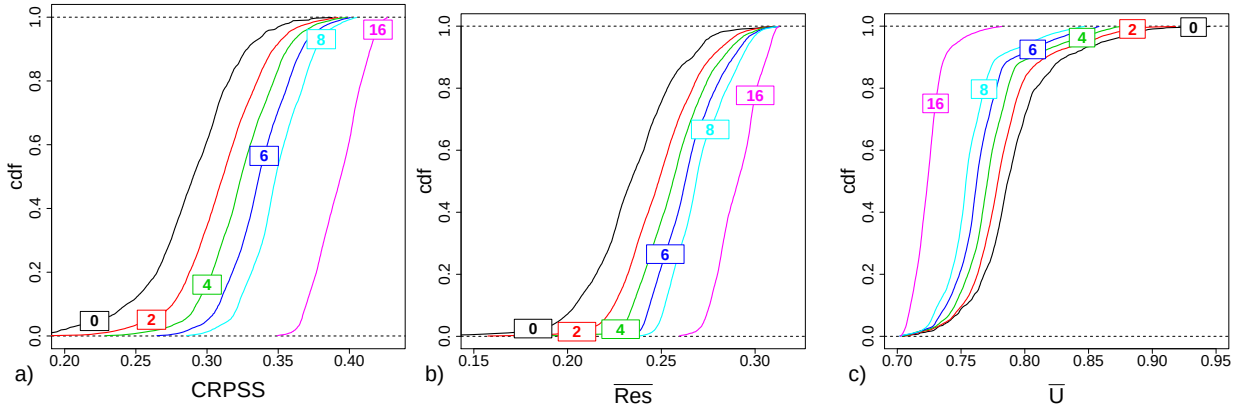

FIGURE V.3 – Sensibilité des performances en a) CRPSS, b) résolution $\overline{\text{Res}}$ et de c) l'incertitude $\overline{\text{U}}$ pour un SAL variant de 0 à 16.

La figure V.2 montre que les performances en terme de CRPSS entre deux valeurs de SAL sont corrélées dans l'espace : les maxima de CRPSS se retrouvent sur la côte Atlantique, sur la partie Ouest du Massif Central et sur le Nord des Alpes. En ces régions, les valeurs de CRPSS gagnent 5 points passant de 0,35 (pour un SAL égal à 0) à 0,4 (pour un SAL égal à 8). Les régions obtenant les plus faibles performances lorsque les précipitations ne sont pas agrégées restent les mêmes lorsque le SAL augmente. Cependant, la variation des performances en fonction du SAL semble plus importante en ces régions : par exemple pour le Sud-Est et le Sud-Ouest de la France, le CRPSS vaut 0,2 pour un SAL égal à 0 tandis qu'il atteint 0,35 pour un SAL égal à 8, ce qui correspond à un gain de 15 points.

La figure V.4.a) représente la corrélation spatiale moyenne régionale des précipitations journalières. Pour une maille Safran donnée, la corrélation moyenne est définie comme la moyenne des coefficients de corrélation obtenus respectivement entre cette maille et chacune des mailles distantes de moins de 75 km. La figure V.4.b) représente le gain de performance obtenu lorsque le modèle MA_F est appliqué pour la prédiction des précipitations Safran agrégées pour un SAL égal à 8 par rapport au cas où le modèle MA_F est appliquée aux précipitations non-agrégées Safran. Sur cette figure, les gains de CRPSS les plus important sont obtenus pour les régions pour lesquelles la corrélation spatiale moyenne des précipitations journalières est la plus faible, comme c'est le cas par exemple pour les régions du Sud-Est et du Sud-Ouest de la France.

De façon à évaluer l'influence de la corrélation spatiale sur l'augmentation des performances avec l'agrégation spatiale des précipitations, une expérience a été menée à la section 3.1.

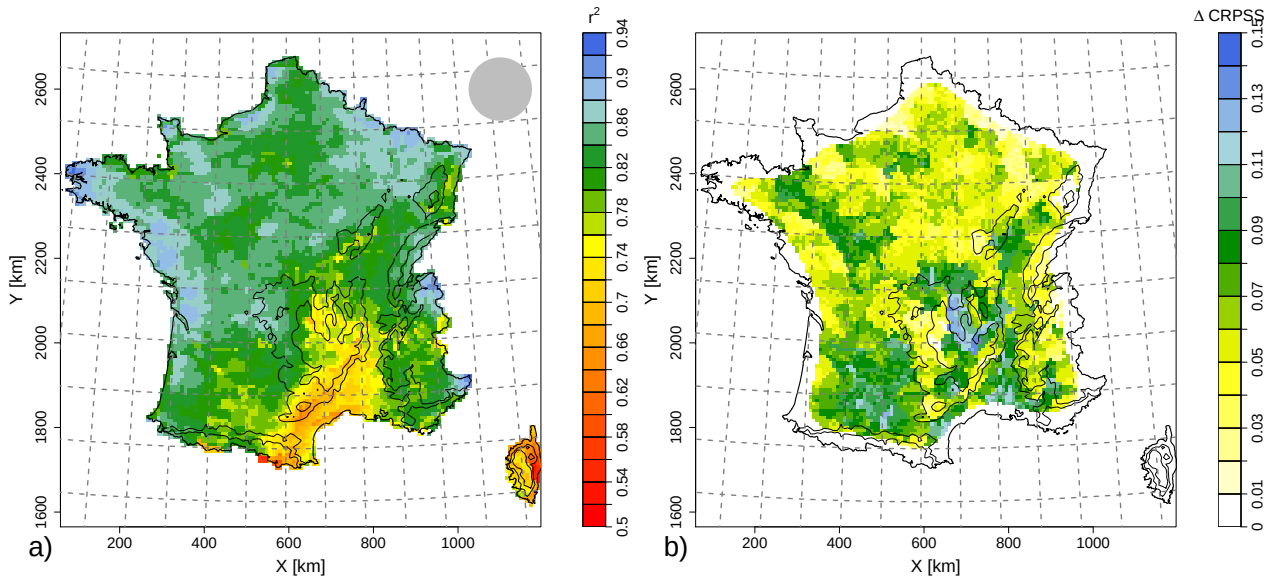

FIGURE V.4 – a) Corrélation moyenne entre les précipitations contenues dans un cercle de 75 km de rayon (représenté en haut à droite). b) ΔCRPSS obtenu par le modèle MA_F pour la prédiction des précipitations agrégées correspondant à un SAL égal à 8 par rapport au cas où aucune agrégation n'est effectuée.

3. Influence de la corrélation spatiale

3.1. Analyse expérimentale

Pour évaluer l'influence de la corrélation spatiale sur la prédiction d'une précipitation agrégée, nous avons construit un jeu de précipitations Safran pour lequel la corrélation spatiale est détruite : la chronique de précipitations issue de chaque maille Safran a été affectée de manière aléatoire à une autre maille Safran. Par construction, la corrélation entre deux mailles voisines est plus faible sinon nulle dans ce nouveau jeu de données Safran – dénommé par la suite "Safran Aléatoire" – que celle du jeu de données Safran original. Par la suite, les dates analogues issues du modèle MA_F ont été appliquées sur le jeu de données Safran Aléatoire pour une valeur de SAL égale à 3.

La figure V.5 représente les performances en CRPSS et $\overline{\text{Res}}$ obtenues par le modèle MA_F pour le jeu Safran Aléatoire et le terme d'incertitude $\overline{\text{U}}$ correspondant. On remarque que le CRPSS varie entre 0,45 et 0,53, ce qui est supérieur aux performances obtenues lorsque le modèle MA_F est appliqué au jeu de données Safran original dans le cas d'une valeur de SAL égale à 8. Les valeurs obtenues pour $\overline{\text{Res}}$ sont dans une large majorité supérieures à 0,30, donc supérieures aux termes de résolution obtenus pour le jeu de données original lorsqu'un SAL égal à 8 était considéré. A l'inverse, les valeurs de $\overline{\text{U}}$ sont quant à elles plus faibles (inférieures à 0,70) que celles obtenues par le jeu de données Safran original.

A partir de cette expérience, il apparaît que les performances de prédiction obtenues par le modèle MA_F sont meilleures sur le jeu de données Safran Aléatoire que celles obtenues à partir du jeu

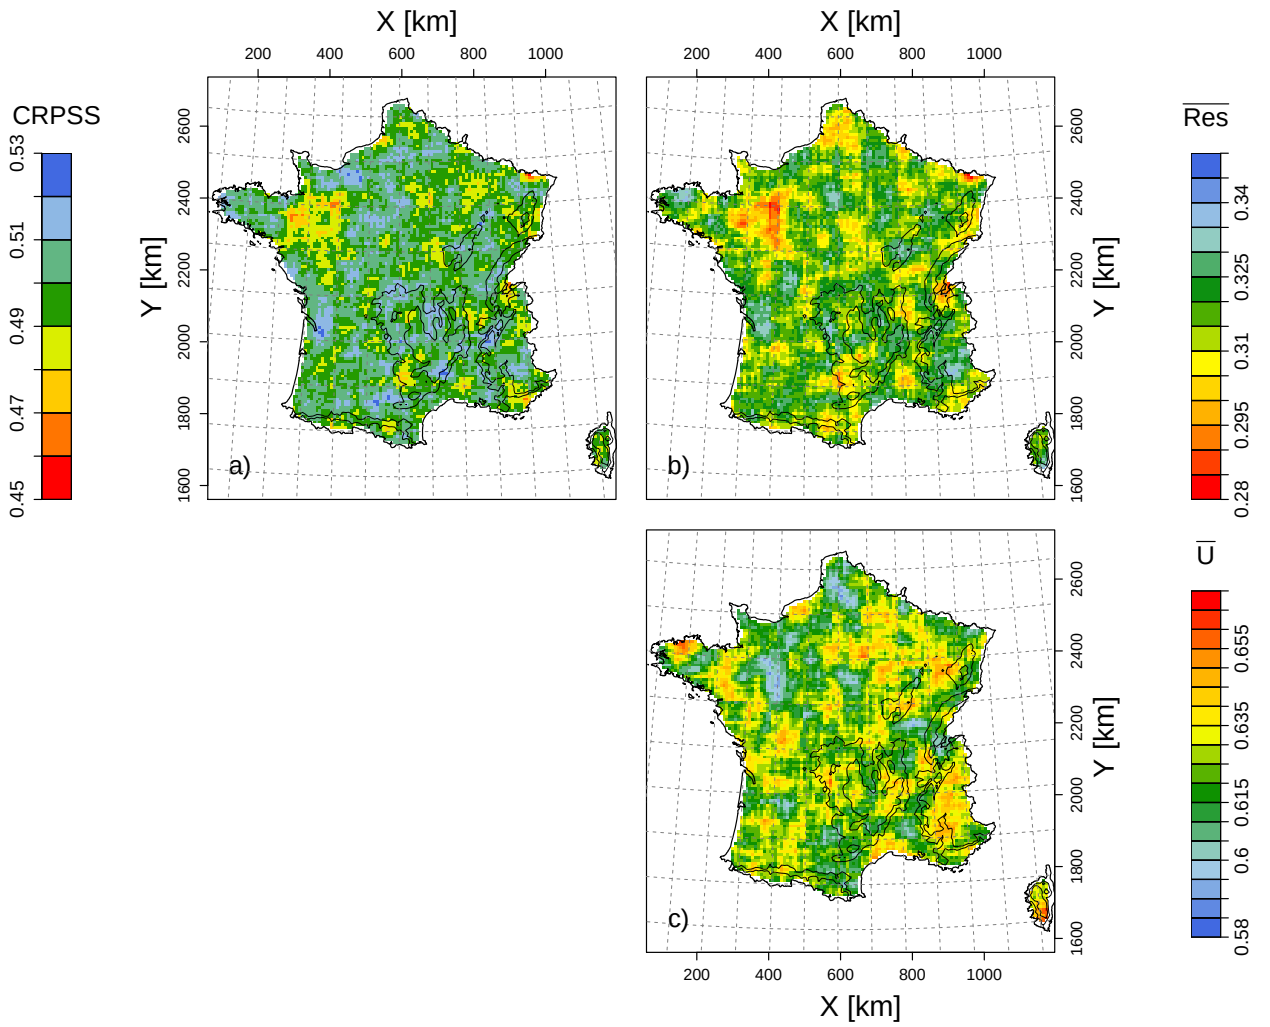

FIGURE V.5 – a) CRPSS, b) $\overline{\text{Res}}$ obtenus par le modèle MA_F et c) $\overline{\text{U}}$ pour un SAL égal à 3.

de données Safran original. L'accroissement des performances avec l'agrégation spatiale est donc limité lorsque les précipitations sont corrélées spatialement. Cela revient à dire que prédire une précipitation agrégée issue de précipitations indépendantes spatialement est plus facile que de prédire une précipitation agrégée issue de précipitations corrélées. Ce résultat nous a paru surprenant dans un premier temps et a motivé la mise en place d'un cadre simulatoire par l'utilisation d'un générateur spatio-temporel de précipitations dans le but de mieux comprendre l'influence de la corrélation sur les performances de prédiction d'une précipitation agrégée.

3.2. Analyse simulatoire

De façon à comprendre au mieux l'influence de la corrélation, un générateur spatio-temporel de champs est développé et appliqué dans cette section. Ce générateur est noté $\mathcal{P}$ dans la suite de ce document. De par la nature intermittente et la forte asymétrie de la distribution des précipitations, la génération de champs spatio-temporels de précipitation représentatifs de la réalité constitue une tâche ardue. Par simplicité, nous avons décidé de travailler sur une variable hypothétique dont les champs journaliers sont gaussiens. La génération de champs gaussiens est en effet assez aisée et permet de traiter sans difficulté différentes structures de corrélations spatiales. Toutefois, les conclusions issues de ce chapitre restent les mêmes.

Après avoir défini le prédictand et le générateur spatio-temporel de prédiction utilisé, cette section évalue l'influence de certains des paramètres du générateur sur les performances en CRPSS et les scores de la décomposition de Hersbach [2000]. Elle s'attarde de plus à comprendre le rôle de la corrélation sur les performances de prédiction d'une variable agrégée.

3.2.1. Définition du cadre simulatoire

Dans la suite de cette section, plusieurs variables représentant soit le prédictand, soit les scénarios émis par le générateur de prédiction $\mathcal{P}$ sont introduites. Comme il est d'usage dans la littérature statistique, une variable aléatoire sera désignée par une lettre majuscule tandis qu'une réalisation d'une variable aléatoire sera notée en minuscule. La variable aléatoire $\widehat{X}$ est une estimation d'une variable aléatoire X. Par la suite, les lettres M, S et N représentent respectivement le nombre de prédictions émises, le nombre de sites pour lesquels une précipitation est générée et le nombre de scénarios d'une prédiction probabiliste. Les indices i, s et n correspondent respectivement à une prédiction émise donnée, une station donnée et un membre donné de la distribution émise.

3.2.1.a. Modélisation du predictand

Pour chaque jour i, nous considérons que le prédictand Y_i^s est isotrope et stationnaire de second ordre en chaque station s de la région considérée. La moyenne spatiale μ_{Y_i} du champ généré varie pour chaque jour i. Sur la base de ce champ moyen μ_{Y_i}, un champ gaussien $\mathbf{\Lambda_{Y_i}}$ – dont le champ moyen égal à $\mathbf{0}$ et la matrice de variance-covariance $\mathbf{\Sigma_{\Lambda_Y}}$ ne varient pas d'un jour à l'autre – est ajouté de façon à obtenir le champ à prédire $\mathbf{Y}_i$.

$$\begin{aligned} \mathbf{Y}_i|_{\mathbf{M}_{Y_i}} &= \mu_{Y_i} \cdot \mathbf{1}_S + \mathbf{\Lambda_{Y_i}} \\ \mathbf{\Lambda_{Y_i}} &\sim \mathcal{N}_S(\mathbf{0}, \mathbf{\Sigma_{\Lambda_Y}}) \end{aligned} \tag{V.2}$$

μ_{Y_i} est ici une réalisation du signal M_{Y_i} [1] pouvant être gouverné par un ensemble de prédicteurs de grande échelle au travers d'un lien d'échelle. La variable M_{Y_i} suit une loi normale centrée-réduite définie par la relation V.3 suivante :

$$\mathrm{M}_{Y_i} \sim \mathcal{N}(0,1) \tag{V.3}$$

La structure spatiale du champ $\mathbf{Y}_i$ est défini par le variogramme exponentiel :

$$\begin{aligned} \gamma_Y(h) &= \sigma^2_{\Lambda_Y} \left\{ 1 - \exp\left(-\frac{h}{h_Y} \right) \right\} \\ &= C_Y(0) - C_Y(h) \end{aligned} \tag{V.4}$$

$\sigma^2_{\Lambda_Y}$ et h_Y correspondent respectivement à la variance et à la portée du variogramme et la fonction $C_Y(\cdot)$ correspond ici à la fonction co-variogramme. Plusieurs autres formes de variogrammes classiquement rencontrés dans la littérature (*e.g.* les variogrammes sphériques ou gaussiens) peuvent être utilisés. Ici, nous avons décidé de retenir le variogramme exponentiel car ce dernier est celui qui possède le plus faible nombre de paramètres.

1. Attention, la variable M_{Y_i} ne doit pas être confondue avec le nombre de prédictions M. Dans cette section, la lettre M correspond à la majuscule de la lettre grecque μ.

Le co-variogramme $C_Y(\cdot)$ permet de définir la matrice de variance-covariance $\mathbf{\Sigma_{\Lambda_Y}}$ par la relation suivante :

$$C_Y(h_{kl}) = \mathbb{C}\text{ov}\left(Y^k, Y^l\right) \tag{V.5}$$

h_{kl} correspond à la distance entre les sites k et l, $k, l \in \{1, \ldots, S\}$. La matrice de variance-covariance $\mathbf{\Sigma_{\Lambda_Y}}$ est alors égale à :

$$\mathbf{\Sigma_{\Lambda_Y}} = \begin{bmatrix} \mathbb{V}\left(Y^1\right) & \mathbb{C}\text{ov}\left(Y^1, Y^2\right) & \cdots & \mathbb{C}\text{ov}\left(Y^1, Y^S\right) \\ \mathbb{C}\text{ov}\left(Y^2, Y^1\right) & \mathbb{V}\left(Y^2\right) & \cdots & \mathbb{C}\text{ov}\left(Y^2, Y^S\right) \\ \vdots & \vdots & \vdots & \vdots \\ \mathbb{C}\text{ov}\left(Y^S, Y^1\right) & \mathbb{C}\text{ov}\left(Y^S, Y^2\right) & \cdots & \mathbb{V}\left(Y^S\right) \end{bmatrix} \tag{V.6}$$

et

$$\mathbb{V}\left(Y^s\right) = \mathbb{C}\text{ov}\left(Y^s, Y^s\right) \tag{V.7}$$

où $\mathbb{V}$ correspond à la variance. Pour un jour i et un site s donnés, la distribution de la variable Y_i^s est celle d'une loi normale $\mathcal{N}(0, 1 + \sigma^2_{\Lambda_Y})$.

Dans la suite de ce chapitre, la variable M_{Y_i} sera nommée le signal régional tandis que la variable $\mathbf{\Lambda_{Y_i}}$ est désigné comme le champ local caractéristique de la variabilité locale du prédictand.

3.2.1.b. Le générateur de prédictions spatio-temporelles

Similairement au champ défini à l'équation V.2, le générateur $\mathcal{P}$ génère pour chaque prédiction i un ensemble de N champs spatiaux issus du vecteur $\widehat{\mathbf{Y}}_{\mathbf{i,n}}$ résultant de la combinaison d'un signal $\widehat{\mu}_{Y_{i,n}}$ moyen à l'échelle du territoire auquel est ajouté un champ spatial issu du vecteur $\widehat{\mathbf{\Lambda}}_{\mathbf{Y_{i,n}}}$, tel que

$$\widehat{\mathbf{Y}}_{\mathbf{i,n}}|_{\widehat{\mathbf{M}}_{\mathbf{Y_i}}} = \widehat{\mu}_{Y_{i,n}} \cdot \mathbf{1_J} + \widehat{\mathbf{\Lambda}}_{\mathbf{Y_{i,n}}}, \qquad n \in \{1, 2, \ldots, N\} \tag{V.8}$$

où $\widehat{\mu}_{Y_{i,n}}$ est ici une réalisation du signal $\widehat{\mathrm{M}}_{Y_i}$ représentant le signal moyen régional prédit par $\mathcal{P}$. Pour une prédiction i donnée, le générateur spatio-temporel gaussien $\mathcal{P}$ prédit un ensemble de N scénarios $\widehat{\mu}_{Y_{i,n}}$ dits régionaux, constants à l'échelle de la région dont l'erreur moyenne – elle aussi constante à l'échelle de la région – par rapport à μ_{Y_i} est δ_i. Ainsi, l'espérance des scénarios régionaux émis est égal à

$$\mathbb{E}\left[\widehat{\mathrm{M}}_{Y_i}|\mathrm{M}_{Y_i}, \Delta_i\right] = \mu_{Y_i} + \delta_i \tag{V.9}$$

La variable Δ_i représente l'erreur moyenne régionale. Elle est supposée distribuée selon une loi normale de moyenne 0 et de variance σ^2_Δ.

Pour chaque prédiction i, la procédure de génération est celle détaillée à la figure V.6.

Etape 1 : une erreur régionale moyenne δ_i est générée à partir de la distribution $\Delta_i \sim \mathcal{N}\left(0, \sigma^2_\Delta\right)$.

Etape 2 : pour des valeurs de μ_{Y_i} et de δ_i données, un ensemble de N scénarios régionaux $\widehat{\mu}_{Y_{i,n}}$ est généré selon la distribution normale suivante :

$$\widehat{\mathrm{M}}_{Y_i}|_{\mathrm{M}_{Y_i}, \Delta_i} \sim \mathcal{N}(\mu_{Y_i} + \delta_i, \sigma^2_H) \tag{V.10}$$

où le paramètre σ_H^2 permet de contrôler la dispersion des scénarios régionaux générés autour de leur espérance $\mu_{Y_i} + \delta_i$.

Etape 3 : pour chaque scénario régional $n \in \{1, 2, \ldots, N\}$, un champ local $\widehat{\boldsymbol{\lambda}}_{\mathbf{Y_{i,n}}}$ est généré sur les S stations à partir du vecteur aléatoire $\widehat{\boldsymbol{\Lambda}}_{\boldsymbol{Y_{i,n}}}$ tel que

$$\widehat{\boldsymbol{\Lambda}}_{\mathbf{Y_{i,n}}} \sim \mathcal{N}_S(\mathbf{0}, \boldsymbol{\Sigma}_{\widehat{\boldsymbol{\Lambda}}_{\boldsymbol{Y}}}) \tag{V.11}$$

Dans cette expérience de simulation, nous supposons que les caractéristiques statistiques spatiales locales des champs prédits sont les mêmes que celles du prédictand définies à l'équation V.4. Autrement dit, les matrices de covariance $\boldsymbol{\Sigma}_{\widehat{\boldsymbol{\Lambda}}_{\boldsymbol{Y}}}$ et $\boldsymbol{\Sigma}_{\boldsymbol{\Lambda_Y}}$ sont identiques. Dans ce cas, les scénarios $\widehat{y}^s_{i,n}|_{\widehat{\mathrm{M}}_{Y_i}}$ générés en une station s donnée et pour une prédiction i donnée suivent la loi suivante :

$$\widehat{Y}^s_i|_{\widehat{\mathrm{M}}_{Y_i}} \sim \mathcal{N}(\mu_{Y_i} + \delta_i, \sigma_\Lambda^2 + \sigma_H^2) \tag{V.12}$$

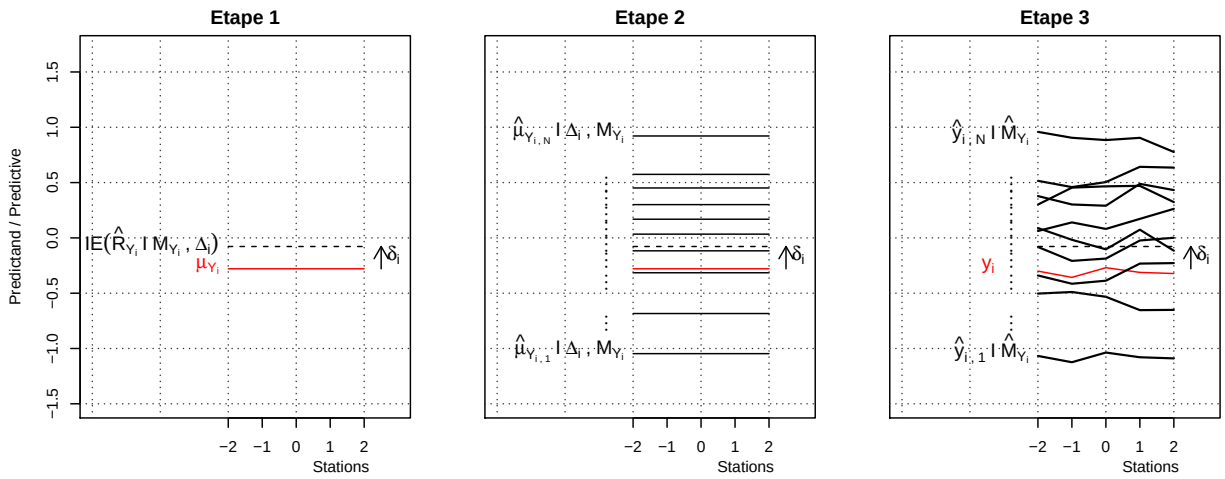

FIGURE V.6 – Schéma 1D des trois étapes effectuées par $\mathcal{P}$ pour une prédiction i donnée. Exemple pour 5 stations. Les lignes rouges plate et brisée représentent respectivement une réalisation μ_{Y_i} du signal régional du prédictand et le champ spatial correspondant y_i. Etape 1 : à une réalisation μ_{Y_i}, une erreur régionale moyenne δ_i issue de $\mathcal{P}$ est associée. Etape 2 : les lignes noires continues correspondent aux scénarios régionaux émis $\widehat{\mu}_{Y_i}$. Etape 3 : un champ spatial est généré à partir de $\widehat{\boldsymbol{\lambda}}_{\boldsymbol{Y_{i,n}}}$ et ajouté pour chaque scénario régional $\widehat{\mu}_{Y_{i,n}}$, menant à la génération d'un ensemble de N champs $\widehat{\mathbf{y}}_{\mathbf{i,n}}|_{\widehat{\mathbf{M}}_{\mathbf{Y_i}}}$. A l'étape 1, le symbole IE représente l'opérateur mathématique $\mathbb{E}$.

Le jeu de paramètres définissant le modèle est alors le suivant :

- l'écart-type σ_Δ de l'erreur régionale,
- l'écart-type σ_H entre les scénarios émis pour chaque prédiction,
- l'écart-type local du prédictand σ_{Λ_Y},
- la portée h_Y du variogramme définissant la structure statistique du champ autour de sa valeur régionale moyenne.

Dans la suite de cette section, le générateur gaussien $\mathcal{P}$ est utilisé pour évaluer la sensibilité des performances de prédiction aux paramètres ci-dessus. Les performances de prédiction de $\mathcal{P}$ en fonction du niveau d'agrégation sont évaluées selon un protocole expérimental similaire à celui développé à la section 2 pour la MDES Analog. Cet exercice est réalisé sur un axe 1D composé d'un nombre S égal à 25 stations réparties de façon régulière et systématique. Le nombre de prédictions émises M

est égal à 10 000. Pour chaque station s et chaque prédiction i, la distribution émise est construite à partir d'un nombre N de 50 scénarios issus du générateur $\mathcal{P}$.

3.2.2. Sensibilité aux paramètres régionaux

Dans un premier temps, nous évaluons la capacité du générateur $\mathcal{P}$ à prédire la moyenne régionale du prédictand. Aucune dimension spatiale n'est prise en compte ici. La variable prédite par $\mathcal{P}$ pour chaque prédiction i est celle dont la distribution est définie à l'équation V.10. La performance de prédiction dépend alors seulement de l'écart-type σ_Δ de l'erreur moyenne régionale et de la dispersion σ_H inter-scénarios.

Les figures V.7.a) à V.7.c) illustrent respectivement le terme de fiabilité $\overline{\text{Rel}}$, le terme de résolution $\overline{\text{Res}}$ et le CRPSS en fonction de σ_Δ et σ_H. Sur la figure V.7.a), une valeur de $\overline{\text{Rel}}$ égale à 0 est obtenue sur la première bissectrice lorsque σ_Δ est égal à σ_H. Dans ce cas, le générateur $\mathcal{P}$ est un système de prédiction fiable. De chaque côté de la première bissectrice, le terme de fiabilité $\overline{\text{Rel}}$ augmente indiquant que la fiabilité se dégrade : pour une valeur de σ_Δ donnée, $\overline{\text{Rel}}$ augmente dès lors que σ_H s'éloigne de la valeur prise par σ_Δ et vice-versa. Il apparaît cependant que la fiabilité est plus sensible à l'écart-type σ_Δ de l'erreur régionale pour laquelle de plus fortes valeurs de $\overline{\text{Rel}}$ sont obtenues plus rapidement.

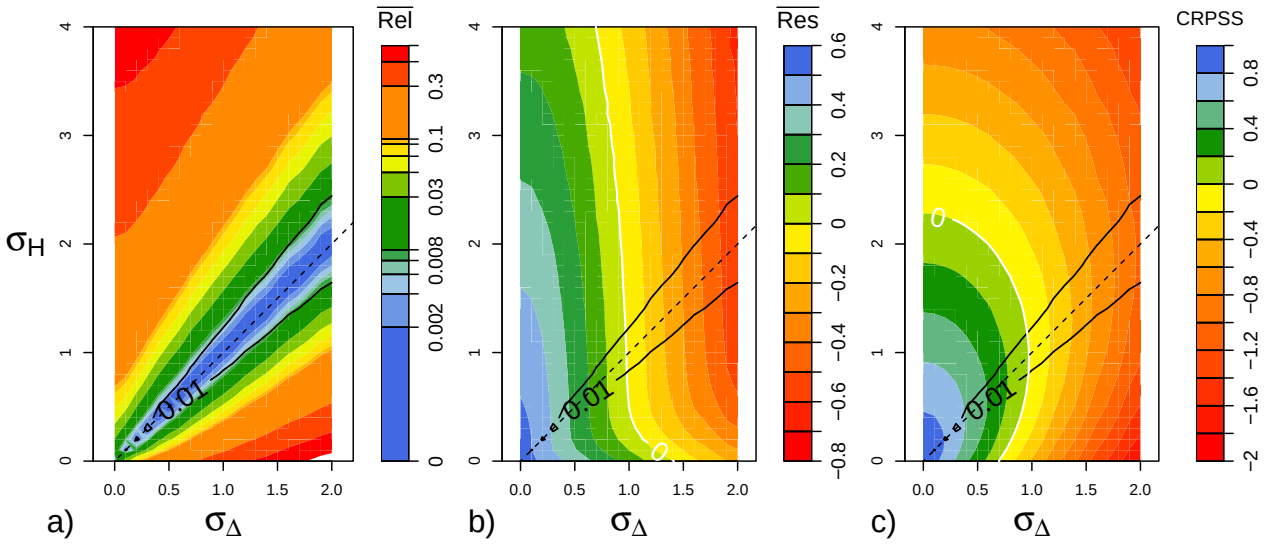

FIGURE V.7 – Sensibilité a) du terme de fiabilité $\overline{\text{Rel}}$, b) du terme de résolution $\overline{\text{Res}}$ et c) du CRPSS en fonction de l'écart-type σ_Δ de l'erreur régionale et de la dispersion inter-scénarios σ_H. La ligne pointillée noire indique la première bissectrice où une fiabilité parfaite est obtenue. La ligne de contour noire délimite la surface pour laquelle le terme de fiabilité $\overline{\text{Rel}}$ explique au plus 1% du $\overline{\text{CRPS}}$, ce qui peut être considéré comme négligeable. La ligne de contour blanche tracée sur la figure V.7.c) délimite la surface pour laquelle le CRPSS est positif.

La figure V.7.b) montre que la résolution est d'autant moins bonne que σ_Δ et/ou σ_H augmente. Le terme de résolution $\overline{\text{Res}}$ est aussi plus sensible à l'écart-type σ_Δ de l'erreur régionale. Comme remarqué à la figure V.7.c), ceci impacte le CRPSS dont la valeur reste positive pour de plus importantes valeurs de σ_H comparées à σ_Δ.

Deux comportements classiques d'un système de prédiction sont illustrés à la figure V.7 :

- Augmenter la valeur de σ_H pour une valeur de σ_Δ donnée revient à "étirer" l'enveloppe des scénarios émis. Les observations sont majoritairement retrouvées vers le centre des prédictions émises et à l'inverse se situent rarement aux extrémités de ces dernières. Le système $\mathcal{P}$ n'est donc pas fiable. De plus, plus la dispersion des prédictions émises est importante, moins le générateur $\mathcal{P}$ arrive à discriminer les évènements entre eux. Dans ce cas, $\mathcal{P}$ est dit sur-dispersif.
- Accroître la valeur de σ_Δ pour une valeur de σ_H donnée revient à retrouver majoritairement les observations en dehors des prédictions émises ou à ces extrémités. La fiabilité n'est pas respectée car les observations ne sont pas distribuées de façon homogène dans les distributions émises. Pour des valeurs de σ_H inférieures à celles de σ_Δ, $\mathcal{P}$ est dit sous-dispersif. Selon Hersbach [2000], le terme de résolution $\overline{\text{Res}}$ est très sensible aux observations trouvées en dehors de la gamme de valeurs couverte par les distributions émises. Si ces cas sont fréquents et les valeurs observées très éloignées de la distribution, $\overline{\text{Res}}$ sera d'autant plus faible, menant ainsi à un CRPSS plus dégradé.

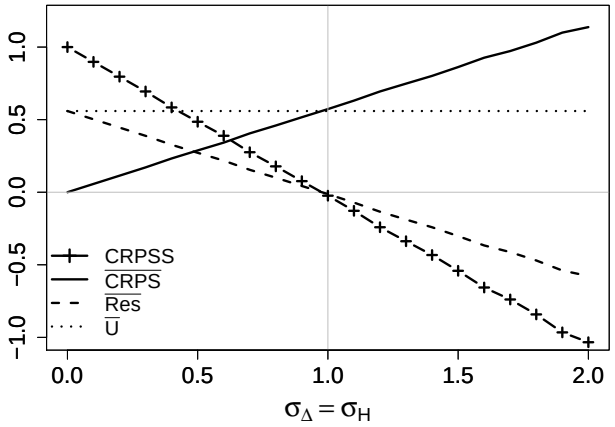

Figure V.8 – Sensibilité du CRPSS, du $\overline{\text{CRPS}}$ et du terme de résolution $\overline{\text{Res}}$ aux écart-types de l'erreur moyenne régionale σ_Δ et de la dispersion inter-scénarios σ_H lorsque $\sigma_H = \sigma_\Delta$. La ligne pointillée horizontale représente le terme d'incertitude $\overline{\text{U}}$ déduit du prédictand M_{Y_i} indépendant de $\mathcal{P}$.

Les résultats présentés dans la section 3.1 du chapitre III montrent que le modèle MA est par construction un système fiable. Par suite, nous considérons uniquement un système de prédiction $\mathcal{P}$ fiable, *i.e.* $\sigma_H = \sigma_\Delta$. Le terme de fiabilité $\overline{\text{Rel}}$ étant nul, le CRPSS est pour un tel système égal au quotient du terme de résolution $\overline{\text{Res}}$ sur l'incertitude $\overline{\text{U}}$ à l'équation III.13. Pour la présente configuration, $\overline{\text{U}}$ est ici égal à 0,56 et ne varie pas car il ne dépend pas du générateur gaussien $\mathcal{P}$. A l'inverse, $\overline{\text{Res}}$ décroît linéairement jusqu'à 0 lorsque σ_H augmente jusqu'à 1, imposant alors un CRPSS nul (*cf.* annexe C.1). Pour des valeurs de σ_H plus importantes, le CRPSS devient négatif, aucun gain n'est obtenu par rapport au système $\mathcal{P}_\varphi$ basé sur la climatologie φ. En d'autres termes, le système de prédiction probabiliste fiable considéré ici est plus performant qu'une prédiction climatologique dès lors que la variabilité de l'erreur régionale moyenne est inférieure à la variabilité de la variable à prédire.

Ce comportement peut être retrouvé théoriquement lorsque la distribution émise suit une loi normale. Gneiting et al. [2005] propose une expression analytique du CRPS journalier. Dans notre configuration où le système de prédiction $\mathcal{P}$ est fiable, cette expression permet d'établir l'expression suivante du $\overline{\text{CRPS}}$. Il est montré à l'annexe C.2) que le $\overline{\text{CRPS}}$ est égal à $\sigma_H/\sqrt{\pi}$, ce qui dans notre cas correspond à $1/\sqrt{\pi}$ – soit environ 0.56 – pour le système $\mathcal{P}_\varphi$ basé sur la climatologie avec un

écart-type égal à 1. Dans ce cas, l'expression du CRPSS devient :

$$\text{CRPSS} = 1 - \sigma_H \tag{V.13}$$

La figure III.6.b) montre que la performance en CRPSS du modèle MA_F est positive. A partir de cette étude, nous retenons le couple de valeurs $\sigma_H = \sigma_\Delta = 0,1$ car il conduit à un CRPSS positif.

3.2.3. Influences de l'agrégation et de la corrélation spatiale

Pour déterminer l'influence de l'agrégation et de la corrélation spatiale, nous devons considérer maintenant la distribution spatiale de la variable à prédire $\widehat{Y}_i^s$. Pour chaque scénario n, le protocole expérimental consiste à agréger les prédictions sur un nombre K de mailles voisines et à évaluer le comportement des différents scores. Dans la suite de cette section, les seuls paramètres que nous faisons varier sont la portée h_Y du variogramme exponentiel définie à l'équation V.4 et le nombre K de variables locales agrégées. La variable issue de l'agrégation des K plus proches stations centrées sur la station s pour une prédiction i est représentée par $W_i^{s,K}$.

$$W_i^{s,K} = \frac{1}{K} \sum_{k \in \text{NN}(s,K)} Y_i^k \tag{V.14}$$

où $\text{NN}(s,K)$ représente les K plus proches voisins de la station s.

De manière similaire, pour un scénario n donné, la variable $\widehat{W}_{i,n}^{s,K}|_{\text{M}_{Y_i},\Delta_i}$ correspond à l'agrégation des K plus proches stations centrées sur la station s.

$$\widehat{W}_{i,n}^{s,K}|_{\text{M}_{Y_i},\Delta_i} = \frac{1}{K} \sum_{k \in \text{NN}(s,K)} \widehat{Y}_{i,n}^k|_{\text{M}_{Y_i},\Delta_i} \tag{V.15}$$

A partir des valeurs de σ_H et σ_Δ fixées à la section 3.2.2, la simulation est réalisée selon une seule dimension représentée ici par un axe composé de 25 stations. Une simulation 2D mène à des résultats similaires car seul le nombre K de stations à agréger influence les résultats.

La figure V.9 présente le terme de résolution $\overline{\text{Res}}$, d'incertitude $\overline{\text{U}}$ et le CRPSS en fonction de la portée h_Y du variogramme exponentiel et du nombre de stations agrégées K dans le cas d'un système $\mathcal{P}$ fiable. Pour l'ensemble des valeurs h_Y considérées, les résultats expérimentaux de la section 2 obtenus pour la France sont retrouvés : plus le niveau d'agrégation est grand, plus la performance en CRPSS est importante. Cela résulte conjointement de la hausse du terme de résolution $\overline{\text{Res}}$ et de la baisse du terme d'incertitude $\overline{\text{U}}$ avec l'agrégation.

Considérons maintenant les deux cas limites suivants :

- Si le prédictand est entièrement corrélé, *i.e.* la portée h_Y est infinie et $r_{l,m}^2 = 1$, l et $m \in \{1, 2, \ldots, 25\}$, alors

$$\widehat{W}_{i,n}^{s,K}|_{\widehat{\text{M}}_{Y_i}} \sim \mathcal{N}\left(\mu_{Y_i} + \delta_i, \sigma_H^2 + \sigma_\Lambda^2\right) \tag{V.16}$$

  En utilisant les équations V.13 et V.16, on obtient un CRPSS égal à :

$$\text{CRPSS} = 1 - \sqrt{\sigma_H^2 + \sigma_\Lambda^2} \tag{V.17}$$

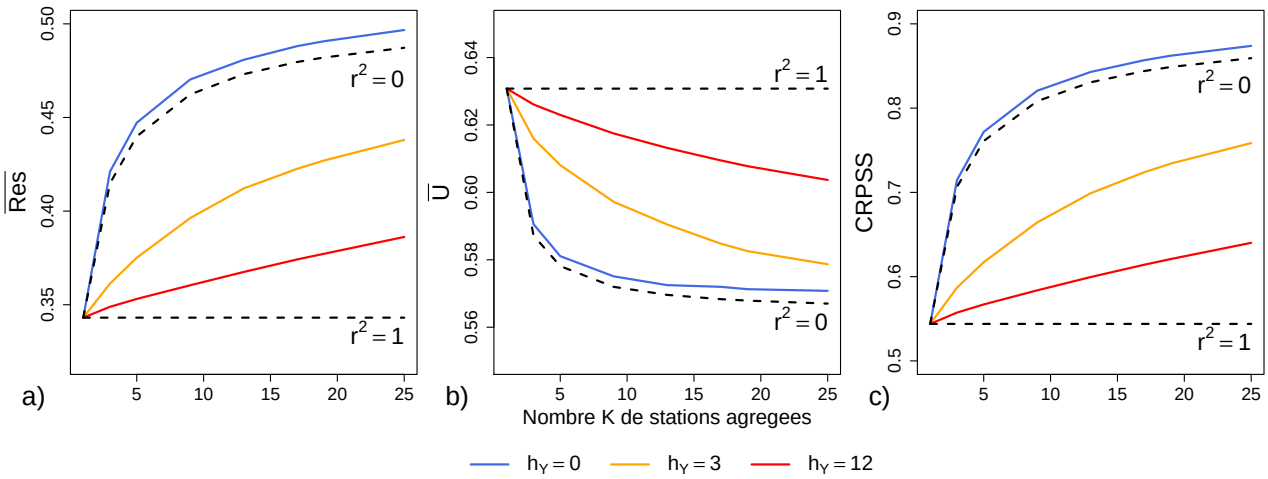

FIGURE V.9 – Terme a) de résolution $\overline{\text{Res}}$, b) d'incertitude $\overline{\text{U}}$ et c) CRPSS en fonction de la portée h_Y du variogramme exponentiel pour une variabilité locale σ_Λ égale à 0,5 et une valeur de σ_H égale à 0,1. Cette expérience se situe dans le cadre d'un générateur $\mathcal{P}$ fiable ($\sigma_H = \sigma_\Delta = 0.1$).

- Si la corrélation spatiale du prédictand est nulle, *i.e.* la portée du variogramme est nulle et $r^2_{l,m} = 0$, l et $m \in \{1, 2, \ldots, 25\}$, alors

$$\widehat{W}^{s,K}_{i,n}|_{\widehat{\mathrm{M}}_{Y_i}} \sim \mathcal{N}\left(\mu_{Y_i} + \delta_i, \sigma^2_H + \frac{\sigma^2_\Lambda}{K}\right) \tag{V.18}$$

et par suite,

$$\text{CRPSS} = 1 - \sqrt{\sigma^2_H + \frac{\sigma^2_\Lambda}{K}} \tag{V.19}$$

Ces deux cas limites sont représentés à la figure V.9 par les lignes noires pointillées. La faible différence observée entre le cas théorique (représenté en pointillé noir) et la courbe résultant des simulations (en bleue) vient des arrondis effectués par l'algorithme. Si le prédictand est entièrement corrélé, la variance de la variable $\widehat{W}^{s,K}_{i,n}|_{\widehat{\mathrm{M}}_{Y_i}}$ ne dépend pas du nombre de stations agrégées K et reste constante, tout comme le CRPSS (équation V.17). Dans le cas où le champ est complètement décorrélé (équation V.19), si le nombre K de stations agrégées croît, la variance de la variable $\widehat{W}^{s,K}_{i,n}|_{\widehat{\mathrm{M}}_{Y_i}}$ décroît continûment, menant alors à une augmentation du CRPSS.

A la section 2, nos analyses expérimentales suggéraient qu'un lien existait entre la vitesse d'augmentation des performances et le degré de corrélation spatiale des précipitations. Ces résultats permettent de confirmer les hypothèses que nous avions formulées lors de nos analyses expérimentales sur la prédiction des précipitations sur la France.

4. Considération de deux régions hétérogènes

Les résultats des deux expériences, expérimentale d'une part (section 2) et simulatoire d'autre part (section 3.2), pourraient suggérer que la performance de prédiction croît continûment et indéfiniment avec le SAL. Nos expériences supposent implicitement que les prédictands en deux sites distants sont expliqués par la même information de grande échelle et plus précisément pour l'expérience simulatoire,

que la performance prédictive est homogène dans la région considérée, ce qui n'est généralement pas le cas en pratique. Nous tentons d'illustrer cet aspect dans la présente section.

Les situations synoptiques à l'origine des précipitations ne sont pas les mêmes en fonction des régions considérées, ce qui implique que les processus – ici en terme de circulation atmosphérique – mis en cause varient. Dans le chapitre IV précédent, nous avons montré que le Massif Central représentait une barrière topographique limitant la bonne transposabilité spatiale lorsque des dates analogues optimisées d'un côté de ce massif sont transposées de l'autre côté. Pour ces deux raisons, nous considérons que les régions situées à l'Est et à l'Ouest du Massif Central ont des fonctionnements météorologiques hétérogènes. Par la suite, nous souhaitons évaluer comment les performances évoluent lorsqu'un modèle Analog optimisé pour l'une de ces deux régions est appliqué pour la prédiction d'une précipitation agrégée à partir de mailles Safran appartenant à deux régions hétérogènes.

Le chapitre IV précédent s'est particulièrement concentré sur la transposabilité spatiale des modèles localement optimisés $\mathrm{MA_{NW}}$ et $\mathrm{MA_{SE}}$. Dans cette section, nous retenons le modèle $\mathrm{MA_{SE}}$ comme un modèle adapté pour la prédiction des précipitations dans le Sud-Est de la France. Similairement à l'expérience de simulation menée à la section 3.2.3, le modèle $\mathrm{MA_{SE}}$ est utilisé pour la prédiction d'une précipitation agrégée à partir des précipitations issues des mailles situées sur un transect Est/Ouest défini par la coordonnée Y du point SE (ici égale à 1921 km Nord). Sur cette axe Est/Ouest, l'agrégation est effectuée de trois manières différentes :

Ag. → Ouest et Est : la précipitation à prédire résulte de l'agrégation des n mailles les plus proches et centrées sur la maille SE et également réparties vers l'Ouest et l'Est.

Ag. → Ouest : la précipitation à prédire est issue de l'agrégation des n mailles les plus proches uniquement réparties à l'Ouest de la maille SE.

Ag. → Est : la précipitation à prédire résulte de l'agrégation des n mailles les plus proches uniquement réparties à l'Est de la maille SE.

La figure V.10.a) représente les performances en CRPSS en fonction de la maille Safran ajoutée à l'agrégation selon que l'on se déplace à l'Est ou à l'Ouest pour l'agrégation (Ag. → Est et Ag. → Ouest). Les résultats issus d'une agrégation dans les deux directions (Ag. → Ouest et Est) sont reportés symétriquement pour les deux directions (courbes rouges). Sur cette figure, les performances en CRPSS obtenues par le modèle localement optimisé $\mathrm{MA_{SE}}$ (courbes continues) peuvent être comparées à celles obtenues par le modèle $\mathrm{MA_F}$ (courbes pointillées). La figure V.10.b) représente la distribution spatiale du coefficient de corrélation entre les précipitations issues de la maille SE (représenté par le point rouge au point 0) et celles issues des mailles Safran. La figure V.10.c) représente la perte de performance en CRPSS engendrée par le modèle $\mathrm{MA_{SE}}$ lorsqu'il est transposé dans le Sud-Est de la France par rapport à l'application d'un modèle MA optimisé localement. Sur les figures V.10.b) et V.10.c), les mailles situées sur l'axe Ouest/Est utilisées pour l'agrégation sont délimitées par un rectangle noir.

Similairement à la figure V.10.a), la figure V.11.a) représente les performances obtenues par les modèles $\mathrm{MA_{SE}}$ et $\mathrm{MA_F}$ pour trois agrégations menées selon un transect Sud/Nord. Un code couleur identique est utilisé pour caractériser les trois d'agrégations **Ag. → Sud et Nord** (rouge), **Ag. → Sud** (orange) et **Ag. → Nord** (bleu) et la couleur grise indique les performances obtenues pour la prédiction des précipitations locales.

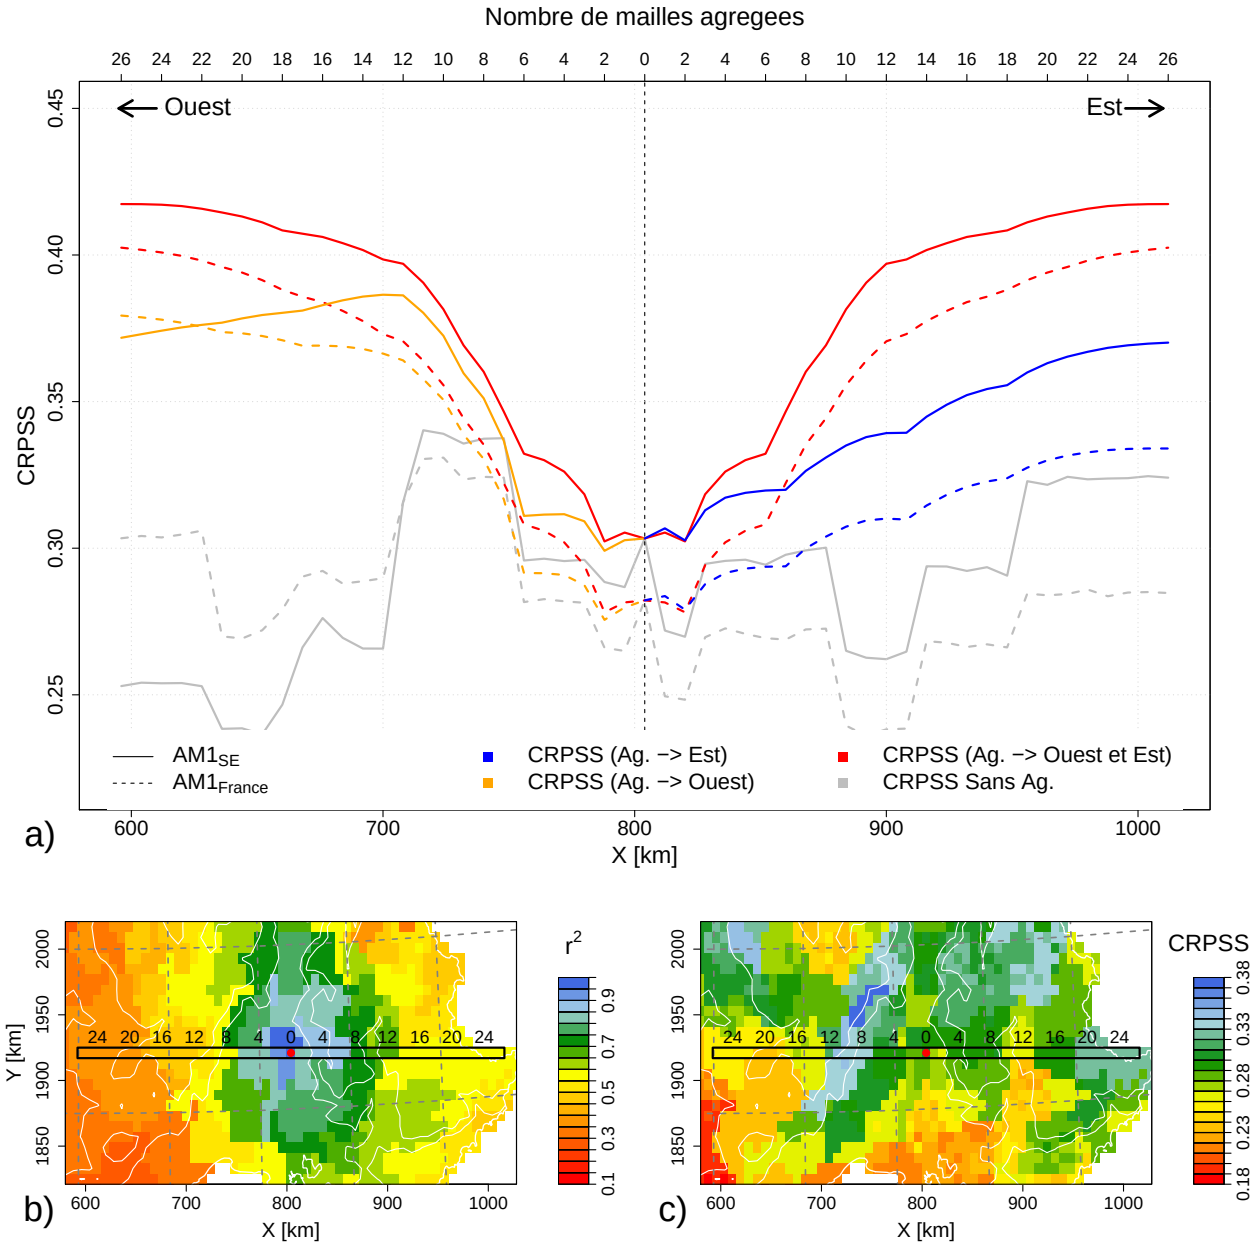

FIGURE V.10 – a) Performances en CRPSS obtenues pour les trois types d'agrégation (Ag. → Ouest et Est, Ag. → Ouest, Ag. → Est) en fonction de la maille Safran ajoutée (représentée par ses coordonnées Lambert II étendues selon l'axe X) pour l'agrégation. Les courbes rouges, correspondant à l'agrégation dans les deux directions Est et Ouest, sont symétriques. Sur cette figure, les courbes grises correspondent à la performance en CRPSS obtenue en chacune des mailles Safran sur le transect Ouest/Est lorsqu'aucune agrégation n'est faite. Les courbes pointillées correspondent à l'application du modèle MA_F tandis que les courbes continues réfèrent au modèle MA_{SE}. b) Distribution du coefficient de corrélation entre la précipitation en la maille SE et les autres précipitations Safran. Le rectangle noir représente les mailles (repérées par leur éloignement de la maille SE) considérées pour les différentes agrégations. c) Performance en CRPSS lorsque le modèle MA_{SE} est transposé sur la France.

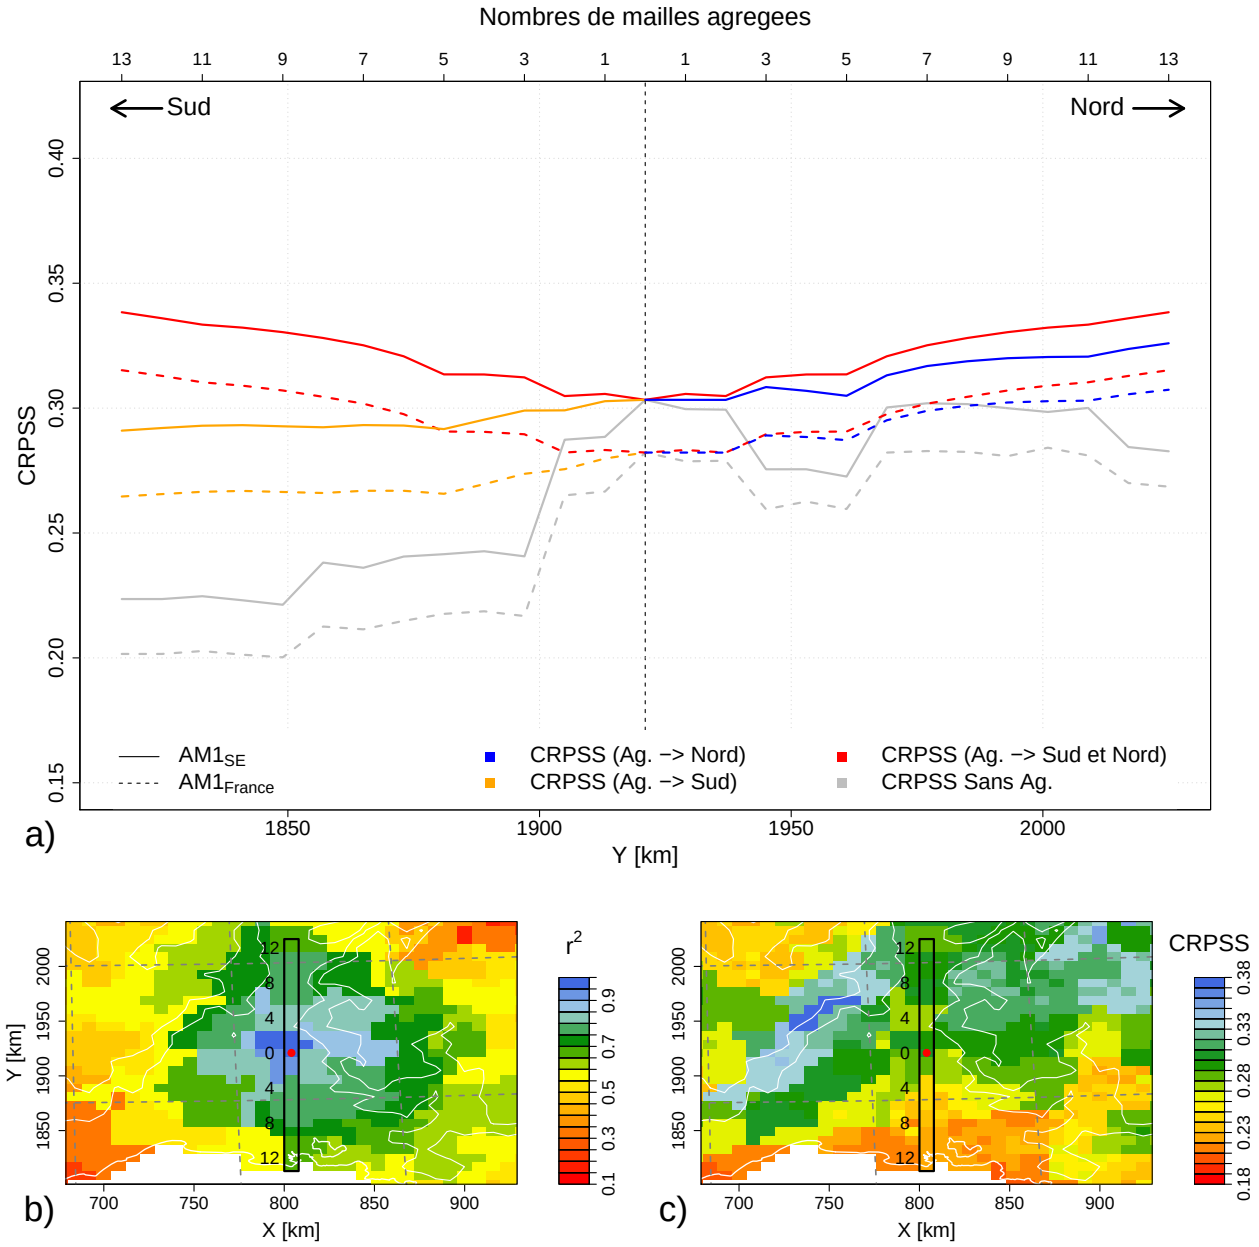

FIGURE V.11 – a) Performances en CRPSS obtenues pour les trois types d'agrégation (Ag. → Sud et Nord, Ag. → Sud, Ag. → Nord) en fonction de la maille Safran ajoutée (représentée par ses coordonnées Lambert II étendues selon l'axe Y) pour l'agrégation. Les courbes rouges correspondant à l'agrégation dans les deux directions Sud et Nord sont symétriques. Sur cette figure, les courbes grises correspondent à la performance en CRPSS obtenue en chacune des mailles Safran sur le transect Sud/Nord lorsqu'aucune agrégation n'est faite. Les courbes pointillées correspondent à l'application du modèle MA_F tandis que les courbes continues réfèrent au modèle MA_{SE}. b) Distribution du coefficient de corrélation entre la précipitation en la maille SE et les autres précipitations Safran. Le rectangle noir représente les mailles (repérées par leur éloignement de la maille SE) considérées pour les différentes agrégations. c) Performance en CRPSS lorsque le modèle MA_{SE} est transposé sur la France.

Sur les figures V.10.a) et V.11.a), les courbes grises montrent que les modèles MA_F et MA_{SE} obtiennent des performances locales en CRPSS variables dans l'espace. Par exemple, les performances sont moins bonnes lorsque l'on se déplace vers le Sud de la maille SE comparées à celles obtenues lorsque l'on se déplace vers le Nord. Par suite, les performances obtenues lors de l'agrégation spatiale des précipitations résultent d'un compromis entre la variabilité locale des performances et l'effet bénéfique du processus d'agrégation en région homogène :

- Si les performances locales voisines de la maille SE sont inférieures à celle de la maille SE, l'effet négatif de la moins bonne prédiction des mailles voisines peut être facilement dépassé par l'effet positif de l'agrégation. C'est par exemple le cas des modèles MA_F et MA_{SE} lorsqu'ils sont utilisés pour la prédiction d'une précipitation agrégée issue des mailles situées au Nord (figure V.11.a) ou à l'Est (figure V.10.a) de la maille SE. Lorsque l'agrégation est orientée vers l'Ouest (figure V.10.a), ce résultat est seulement obtenu pour le modèle MA_F.
- Si les performances locales voisines de la maille SE sont inférieures, l'effet négatif de la moins bonne prédiction des mailles voisines peut être prépondérant et occulter l'effet positif de l'agrégation. C'est par exemple le cas des modèles MA_F et MA_{SE} lorsque l'agrégation est orientée vers le Sud (figure V.11.a).
- Dans certains cas où la variation du CRPSS locale est très importante, un optimum peut être obtenu pour un certain niveau d'agrégation. C'est le cas du modèle MA_{SE} lorsque l'agrégation est orientée vers l'Ouest (figure V.10.a). Jusqu'à la douzième maille, les performances locales des mailles voisines sont équivalentes ou supérieures à celle de la maille SE. Dans ce cas, l'effet bénéfique de la bonne prédiction des mailles voisines s'additionne à l'effet bénéfique de l'agrégation. A partir de la treizième maille, les performances locales décroissent fortement (de 0,34 à 0,25) et sont presque toutes inférieures à celle de la maille SE. Dans ce cas, l'effet négatif des plus faibles performances obtenues pour les mailles voisines est prépondérant sur l'effet positif de l'agrégation et un optimum de performance est obtenu lorsque seules douze mailles sont retenues.

Synthèse

Quelle est la performance de la MDES Analog à l'échelle de la France ?

Nous avons considérés un modèle Analog (MA) où l'analogie est recherchée en terme de circulation atmosphérique par le biais de la forme des hauteurs de géopotentiels à 1000 et 500 hPa. Les performances de prédiction de ce modèle MA ont été évaluées à partir d'un ensemble de 8 981 modèles MAs dont la fenêtre d'analogie a été localement optimisée pour chacune des 8 981 mailles Safran correspondantes. Une première évaluation des performances selon la décomposition de Hersbach [2000] a montré que le modèle Analog était une méthode de prédiction fiable pour l'ensemble du territoire français.

Dans un second temps, la performance en CRPSS a été évaluée de manière globale et par une discrétisation temporelle saisonnière et par type de temps. D'une manière générale, les performances de prédiction sont plus importantes sur la côte Atlantique, l'Ouest du Massif Central et le Nord des Alpes. Lorsque l'on se déplace dans les terres ou sur le pourtour Méditerranéen, les performances diminuent. L'évaluation des performances saisonnières a montré que la méthode obtenait de meilleures performances pour les saisons humides (DJF, SON, puis MAM). Les performances diminuent fortement en été de part le nombre plus important de précipitations convectives pour lesquelles une analogie de circulation ne permet pas de capter les processus à l'origine de ces précipitations. Ce résultat correspond à ce qui est classiquement obtenu dans des études similaires [*e.g.* Timbal et al., 2003].

Lors d'une discrétisation en types de temps, la distribution des performances s'avère plus sensible et dépend de l'impact que possède le type de temps considéré sur une région : que ce soit à l'occasion de flux d'Ouest ou de Sud, de bonnes performances sont obtenues pour les régions exposées au flux considéré qui sont en moyenne impactées par une forte précipitation. Pour une région où le type de temps n'apporte pas de pluie, parce qu'elle peut être située à l'opposé de l'origine des masses d'air advectées sur le territoire ou parce qu'elle est relativement bien abritée par une zone de relief, le modèle Analog sélectionne en majorité des dates analogues sèches et obtient alors de bonnes performances. Dans les cas où une précipitation de l'ordre de la précipitation moyenne est observée (*i.e.* les précipitations correspondantes ne sont ni trop fortes, ni trop faibles), les performances sont en général réduites.

En parallèle, une étude des biais obtenus par le modèle Analog a été menée. En moyenne, les scénarios émis par les dates analogues obtiennent un biais compris entre ± 5%. Cependant, lorsque l'étude porte sur les saisons ou les types de temps, les biais peuvent devenir importants (*e.g.* jusqu'à +15% dans le Nord des Alpes en été).

Sur quelle distance est-il possible de transposer spatialement un modèle Analog ? Dans une étude publiée dans *Journal of Climate* [Chardon et al., 2014], nous avons évalué la transposabilité spatiale des dates analogues représentée par la capacité d'un modèle Analog optimisé pour une maille donnée à être appliqué sur le territoire français. A partir d'une évaluation globale, il s'est avéré que la transposition spatiale d'un modèle Analog seulement basé sur les hauteurs de géopotentiels permet d'obtenir des performances quasi-optimales pour des mailles situées jusqu'à 400 km de la maille pour laquelle le modèle a été optimisé. Pour obtenir cette bonne transposabilité, il n'est pas nécessaire de disposer de dates analogues similaires entre le modèle transposé et le modèle localement optimisé. Cette transposabilité est toutefois limitée en présence des principaux massifs montagneux.

Une étude de sensibilité de la transposabilité spatiale des dates vis-à-vis des paramètres du modèle Analog a ensuite été effectuée. Lorsque la sélection des dates analogues est améliorée (*e.g.* par l'augmentation de la taille de l'archive ou par l'ajout d'un second niveau d'analogie), la transposabilité du modèle Analog est réduite. Le raffinement d'un modèle Analog s'avère alors néfaste pour sa bonne transposabilité.

Enfin, la transposabilité spatiale des dates analogues a été évaluée en fonction des saisons et des types de temps. En été, la transposabilité devient très bonne de part la prédiction de nombreuses dates analogues sèches. Pour les autres saisons, la transposabilité spatiale reste similaire à celle obtenue à l'évaluation globale. Lorsque l'étude est menée sur la base d'une discrétisation en type de temps, les résultats s'avèrent sensibles au type de temps considéré. Il semblerait que la transposabilité spatiale des dates analogues soit dépendante de l'origine des masses d'air advectées. Cependant, ce résultat n'a pas pu être validé sur l'ensemble des cas considérés. Toutefois, la transposabilité d'un modèle Analog est favorisée lorsque les performances des modèles Analog optimaux locaux sont faibles. Dans le cas de situations sèches, la transposabilité d'un modèle Analog est très bonne à partir du moment où les dates analogues émises sont sèches.

Comment la performance de prédiction varie-t-elle lorsque la précipitation à prédire est agrégée sur des surfaces de plus en plus importantes ?
Sur la base d'un modèle MA_F unique pour la France optimisé globalement pour l'ensemble des précipitations Safran, une étude expérimentale a été menée pour évaluer l'évolution des performances de prédictions en fonction du niveau d'agrégation spatial d'une précipitation pour un territoire donné. Il apparaît que la performance du modèle MA_F augmente de manière continue avec l'agrégation spatiale. Cette augmentation est sensible à la corrélation spatiale des précipitations puisqu'il est plus aisé de prédire une précipitation agrégée issue d'un champ spatialement décorrélé que d'un champ corrélé. Pour la bonne compréhension de ces résultats, un cadre simulatoire a été défini.
Un générateur spatio-temporel a été mis en place pour la prédiction de champs gaussiens stationnaires pour un territoire donné. Comme la fiabilité de la MDES Analog est bonne, la main mise sur le générateur nous a permis de déterminer un jeu de paramètres permettant de rendre ce dernier fiable. Une étude de sensibilité vis-à-vis de l'agrégation et de la corrélation spatiale nous a permis de montrer que l'augmentation des performances avec l'agrégation résultait d'une part de la diminution de la variabilité du prédictand due au processus d'agrégation et d'autre part, de la meilleure performance en résolution du modèle MA (et au plus faible terme d'incertitude). Les variables de grande échelle ont un pouvoir prédictif plus important pour une précipitation locale agrégée, car cette dernière constitue un signal plus robuste de la variabilité pluviométrique résultant de la variabilité des prédicteurs. Enfin, plus le prédictand est spatialement décorrélé, plus la variabilité du prédictand agrégé est faible et plus les performances deviennent importantes avec l'agrégation.

La présence de zones hétérogènes du point de vue de leur lien avec la grande échelle a-t-elle un impact sur la performance de prédiction d'une précipitation agrégée ?
Les résultats ci-dessus s'expliquent par le fait que le lien d'échelle considéré est spatialement homogène et qu'il a le même pouvoir prédictif en toute maille du territoire. La réalité est toutefois différente. Le lien d'échelle pour une maille donnée est de moins en moins adapté lorsque l'on s'éloigne de la maille considérée, traduisant le fait que les régions réagissent différemment à la grande échelle. L'évaluation du CRPSS avec l'agrégation résulte alors d'un compromis entre 1) la baisse de performance du fait de l'intégration progressive de mailles trop éloignées qui sont moins représentées par le lien d'échelle considéré et 2) le gain de performance provenant du processus d'agrégation qui a pour effet de révéler le signal régional et de supprimer le bruit dû aux processus de petites échelles non capté par le lien d'échelle.

Troisième partie

ADAPTABILITÉ DU LIEN D'ÉCHELLE PAR LA COMBINAISON D'UN MODÈLE ANALOGIQUE ET D'UN MODÈLE DE RÉGRESSION.

Dans la partie II, nous avons montré qu'il était possible d'utiliser un modèle MA pour la prédiction de champs météorologiques locaux sur des surfaces relativement importantes. Nous avons aussi montré qu'il était préférable de ne pas appliquer un modèle MA en des régions pour lesquelles les processus atmosphériques à l'origine des précipitations diffèrent de ceux pour lequel le modèle MA a été optimisé. Pour les études d'impacts hydrologiques, il est alors préconisé d'appliquer un modèle MA donné seulement pour les sites inclus dans une région considérée comme homogène selon la variable d'intérêt.

Dans cette partie, nous souhaitons améliorer les performances locales des champs générés par le modèle MA tout en conservant leur cohérence spatiale. L'amélioration des performances peut s'effectuer par un apport d'information issu de nouveaux prédicteurs. Comme nous l'avons remarqué à la section 4.3 de Chardon et al. [2014], une façon d'augmenter les performances est de raffiner les dates analogues par l'ajout d'un second niveau d'analogie reposant sur une variable synoptique propre à la région. Cependant, cette stratégie réduit la transposabilité spatiale du modèle MA. Une autre manière de concilier performance locale et cohérence spatiale des champs météorologiques générés consiste à appliquer une régression sur noyau sur la base des valeurs de nouveaux prédicteurs extraites des dates analogues retenues. L'extrapolation effectuée par un modèle de régression permettrait alors de raffiner les prédictions tandis que les dates analogues assurerait la bonne cohérence spatiale des champs générés. En pratique, les modèles de régression généralement utilisés pour les précipitations sont souvent basés sur les Modèles Linéaires Généralisés (GLM) [Mezghani & Hingray, 2009].

Un autre intérêt, cette fois cognitif, réside dans la combinaison d'un modèle MA avec un modèle de régression : pour une prédiction donnée, nous pouvons déterminer les prédicteurs, extraits des dates analogues, qui sont les plus explicatifs de la précipitation. A partir d'un nombre conséquent de prédictions émises, nous pouvons vérifier si ces prédicteurs dépendent d'un type de circulation donnée et/ou s'ils diffèrent d'un site à l'autre à l'échelle du territoire français.

Dans cette partie, seule l'amélioration des performances locales par la combinaison d'un modèle MA avec un modèle de régression est considérée. Par manque de temps, les aspects de transposabilité et de cohérence spatiales de ce modèle combiné ne sont pas traités dans cette thèse. Dans le chapitre VI, nous présentons le cadre théorique lié aux modèles GLM ainsi que les différentes étapes de la combinaison du modèle MA et des modèles GLM. Dans le chapitre VII, nous sélectionnons un ensemble de prédicteurs potentiels pour la mise en place d'un GLM pour l'occurrence et pour la quantité. Sur la base de la combinaison d'un modèle d'occurrence et de quantité et de chaque modèle MA optimisé localement à la section 1 du chapitre III, nous optimisons les prédicteurs de l'occurrence et évaluons la performance de prédiction obtenue (chapitre VIII). Une démarche similaire est adoptée pour la prédiction de la quantité dans le chapitre IX. Le chapitre X évalue la contribution apportée d'une part, par la régression portant sur l'occurrence et d'autre part, par la régression portant sur la quantité. Enfin, les principaux résultats sont résumés dans une synthèse finale.

Chapitre *VI*

Un modèle adaptatif sur la base des dates analogues

1. De la nécessité de s'adapter – Motivations

La plupart des études portant sur la modélisation des précipitations à l'aide de MDES utilisent une paramétrisation globale de la MDES applicable à toutes les périodes ou situations atmosphériques considérées. Cependant, comme les processus physiques à l'origine des précipitations varient dans le temps, certains auteurs tels que Abdellatif et al. [2012] considèrent des prédicteurs différents en fonction des saisons. D'autres études utilisent une fonction cosinus pour tenir compte de la saisonnalité des précipitations [Beuchat et al., 2012 ; Chun et al., 2013]. Au lieu d'appliquer une paramétrisation donnée en fonction de la saison, une autre alternative consiste à conditionner la paramétrisation en fonction de la situation atmosphérique rencontrée, comme par exemple grâce à une classification en type de temps. Toutefois, cela impose de déterminer *a priori* le type de temps auquel appartient la situation à prédire. De plus, si la situation se trouve à la limite de plusieurs types de temps, le lien d'échelle prédicteur/prédictand – déduit du type de temps retenu – ne sera pas le plus adapté et des performances de prédiction réduites peuvent être potentiellement obtenues.

Un moyen de contourner ce problème consiste à définir un ensemble de situations similaires pour chaque prédiction émise. Par la suite, un lien peut être estimé entre le prédictand et les prédicteurs sur la base de ces situations. Chaque prédiction se voit alors constituer son propre type de temps, adapté à la situation synoptique correspondante. Un moyen de satisfaire ce besoin est l'utilisation d'une MDES de type analogique. L'identification de N_d jours analogues revient à travailler sur les différentes journées d'un type de temps centré sur le jour cible considéré. Les valeurs de prédicteurs et

de prédictands sont extraites à partir des dates analogues retenues et peuvent permettre d'optimiser d'une part le jeu de prédicteurs et d'autre part les paramètres du lien d'échelle pour chaque prédiction.

Dans la littérature, plusieurs études utilisent une MDES "hybride" sur la base d'une méthode Analog. Imbert & Benestad [2005] et Ribalaygua et al. [2013] couplent par exemple une méthode analogique avec une régression linéaire, Ibarra-Berastegi et al. [2011] avec un algorithme de "forêts d'arbres décisionnels" (appelé aussi Random Decision Forests). Imbert & Benestad [2005] et Ibarra-Berastegi et al. [2011] justifient la combinaison des deux MDES par une lacune du modèle Analog qui est son incapacité à extrapoler en dehors de la gamme des valeurs observées. Ribalaygua et al. [2013] considèrent quant à eux préférable de ne pas effectuer de stratification saisonnière dans un contexte de changement climatique où les caractéristiques climatiques calendaires peuvent varier et qu'une méthode analogue permet de pallier ce problème. Notre motivation dans cette thèse se base sur l'hypothèse qu'un jeu de prédicteurs différents peut être déterminé pour les différentes situations synoptiques rencontrées. L'utilisation de prédicteurs adaptés à la journée cible permettrait alors d'augmenter les performances locales de prédiction. Par suite, nous cherchons donc à construire un modèle hybride sur la base d'un modèle MA et d'un modèle de régression. De part la forte asymétrie et la masse de valeurs nulles, la forme spécifique de la distribution des précipitations rend la mise en place d'un modèle de régression compliquée. Une approche courante consiste à appliquer un modèle linéaire généralisé [ou Generalized Linear Model – GLM, *e.g.* Wilby & Wigley, 2000 ; Mezghani & Hingray, 2009 ; Chun et al., 2013]. Dans ce cas, la variable précipitation est le plus souvent décomposée en une variable d'occurrence et une variable de quantité de précipitation. Deux modèles GLM sont alors développés : l'un pour l'occurrence et l'autre pour la quantité des précipitations.

2. Modélisation des précipitations par les GLM

2.1. Théorie des GLM

Le modèle linéaire généralisé [ou Generalized Linear Model, Nelder & Wedderburn, 1972] est dérivé de la régression linéaire multiple qui consiste à relier $K+1$ variables explicatives regroupées dans un vecteur $\mathbf{X} = \{1, X_1, \ldots, X_K\}$ à une variable à expliquer Y. Le modèle de régression linéaire multiple est écrit à l'équation VI.1,

$$Y = \mathbf{x}^{\mathrm{T}}\boldsymbol{\beta} + \varepsilon, \quad \varepsilon \overset{iid}{\sim} \mathcal{N}(0, \sigma^2) \tag{VI.1}$$

où $\boldsymbol{\beta}$ correspond au vecteur des coefficients de la régression linéaire $\{\beta_0, \beta_1, \ldots \beta_K\}$, β_0 étant l'ordonnée à l'origine du modèle régressif. $\mathbf{x}$ est le vecteur des réalisations des variables explicatives $\{1, x_1, \ldots, x_K\}$. L'exposant ^{T} correspond ici à la transposition d'un vecteur ou d'une matrice. ε représente l'erreur aléatoire suivant une loi normale d'espérance 0 et de variance σ^2. Comme l'espérance de ε est nulle, l'espérance de la variable Y est la suivante :

$$\mathbb{E}[Y\ ] = \mathbf{x}^{\mathrm{T}}\boldsymbol{\beta} \tag{VI.2}$$

Dans ce cas, la variable Y suit une loi normale $\mathcal{N}(\mathbf{x}^t\boldsymbol{\beta}, \sigma^2)$.

Par extension, les GLM permettent d'introduire une non-linéarité dans la structure de la régression. De plus, ils s'appliquent à n'importe quelle variable Y distribuée selon une loi appartenant à la famille des distributions exponentielles (regroupant les distributions de type Poisson, Binomial, Gaussien et Gamma). De manière similaire à l'équation VI.2, l'espérance d'une variable Y peut être exprimée par une fonction monotone γ :

$$\mathbb{E}[Y] \equiv \mu = \gamma\left(\mathbf{x}^{\mathrm{T}}\boldsymbol{\beta}\right), \quad Y \overset{iid}{\sim} \text{Famille de distributions exponentielles} \tag{VI.3}$$

En pratique, l'équation VI.3 s'exprime au travers d'une fonction lien $g = \gamma^{-1}$ telle que

$$g(\mu) = \mathbf{x}^{\mathrm{T}}\boldsymbol{\beta} \equiv \eta \tag{VI.4}$$

où η est dénommé le *prédicteur linéaire*.

2.2. Application aux précipitations

Coe & Stern [1982] et Stern & Coe [1984] furent les premiers à modéliser les précipitations à l'aide des GLM. Plus récemment, de nombreux auteurs utilisent encore cette méthode pour la prédiction des précipitations [*e.g.* Wilby & Wigley, 2000 ; Abaurrea & Asn, 2005 ; Mezghani & Hingray, 2009 ; Frost et al., 2011 ; Abdellatif et al., 2012 ; Beuchat et al., 2012 ; Kenabatho et al., 2012 ; Chun et al., 2013] ou de leurs caractéristiques [Rudolph & Friedrich, 2014]. Dans cette thèse, notre intérêt repose sur l'émission d'une distribution cumulée F_Y de la variable aléatoire Y représentant les précipitations pour chaque prédiction. Pour une réalisation y de la variable aléatoire Y, $F_Y(y)$ est égal à la probabilité que la variable aléatoire Y soit inférieure ou égale à la valeur y :

$$F_Y(y) = \mathbb{P}\mathrm{r}(Y \leq y) \tag{VI.5}$$

Comme décrit par Marty [2010], une façon de modéliser cette distribution est de considérer d'une part une masse en 0 pouvant être caractérisée par une fréquence f_0 des précipitations nulles et d'autre part une distribution F_Q des pluies positives.

$$F_Y(y) = f_0 + (1 - f_0) \cdot F_Q\,(q = y) \tag{VI.6}$$

En exprimant la fréquence des pluies nulles f_0 en fonction de la probabilité qu'il précipite π, l'équation VI.6 peut s'exprimer comme suit :

$$F_Y(y) = (1 - \pi) + \pi \cdot F_Q\,(q = y) \tag{VI.7}$$

A partir de l'équation VI.7, il est possible de modéliser les précipitations à l'aide de deux variables que sont l'occurrence O des précipitations – prenant pour valeur 0 ou 1 – et la quantité Q des précipitations – dont les valeurs ne peuvent être que positives. L'occurrence O est une variable suivant une loi binomiale $\mathcal{B}(N, \pi)$ où N dénote le nombre de points à partir duquel la distribution cumulée F_Y est estimée empiriquement. La distribution des valeurs positives de précipitations Q est

quant à elle, souvent assimilée à une loi gamma $\Gamma(\nu, \alpha)$ de paramètres de forme ν et d'échelle α.

$$F_Q\left(q; \nu, \alpha\right) = \frac{1}{\Gamma(\nu)} \int_0^q e^{-\frac{t}{\alpha}} \left(\frac{t}{\alpha}\right)^{\nu-1} dt \tag{VI.8}$$

Pour une distribution gamma, le paramètre d'échelle α est égal au ratio de l'espérance μ de la variable Q sur le paramètre de forme ν.

Les distributions de type binomiale et gamma appartenant aux familles de distributions exponentielles, il est possible de modéliser les paramètres π et μ par deux modèles GLM. Pour une variable suivant une loi binomiale dont la probabilité de succès est π, il est courant d'utiliser une fonction lien logit équivalente à effectuer une régression logistique (équation VI.9).

$$\log\left(\frac{\pi}{1-\pi}\right) = \mathbf{x^o}^{\mathrm{T}} \boldsymbol{\beta^o} \tag{VI.9}$$

où $\mathbf{x^o}$ et $\boldsymbol{\beta^o}$ désignent respectivement le vecteur des valeurs de prédicteurs et le vecteur de coefficients pour le modèle d'occurrence. Pour une variable Q distribuées selon une loi gamma, une régression logarithmique est un modèle adapté pour l'estimation de sa moyenne μ :

$$\log\left(\mu\right) = \mathbf{x^q}^{\mathrm{T}} \boldsymbol{\beta^q} \tag{VI.10}$$

où $\mathbf{x^q}$ et $\boldsymbol{\beta^q}$ désignent respectivement le vecteur des valeurs de prédicteurs et le vecteur des coefficients pour le modèle de quantité.

2.3. Détermination d'un modèle GLM approprié

La détermination d'un modèle GLM repose sur le choix d'un jeu de prédicteurs approprié et l'estimation des coefficients de la régression. Pour l'estimation de ces derniers, l'algorithme des *moindres carrés repondérés itérativement* (Iterative Re-weighted Least Squares – IRLS) proposé par Nelder & Wedderburn [1972] est classiquement utilisé pour maximiser le logarithme de la vraisemblance.

Pour comparer les performances de deux modèles GLM, plusieurs critères numériques (*e.g.* le C_p de Mallows ou le critère d'Akaike AIC – Akaike [1974]) peuvent être utilisés. Dans notre cas, nous avons décidé de retenir le Critère d'Information Bayésien (ou Bayesian Information Criterion – BIC) pour les raisons suivantes : tout comme l'AIC, ce critère inclut la performance exprimée par le logarithme de la vraisemblance. Cependant, il pénalise plus fortement la complexité – à savoir le nombre de prédicteurs – d'un modèle GLM. Ce critère peut être écrit comme suit :

$$\mathsf{BIC} = -2l(\widehat{\boldsymbol{\beta}}) + \log_e\left(n\right) p' \tag{VI.11}$$

Le terme $l(\widehat{\boldsymbol{\beta}})$ correspond au logarithme de la vraisemblance obtenue par le modèle GLM pour les paramètres estimés $\widehat{\boldsymbol{\beta}}$. Le terme p' représente le nombre de coefficients à estimer pour le modèle GLM. n est la taille de l'échantillon. Le modèle possédant le BIC le plus faible est considéré comme le meilleur modèle.

A l'aide du critère BIC, trois procédures de sélection itérative peuvent être appliquées pour retenir un modèle adapté pour la situation à prédire. Ces trois procédures sont décrites dans les sections 2.3.1 à 2.3.3.

2.3.1. La méthode d'inclusion

La méthode d'inclusion (aussi appelée approche *forward*) consiste à évaluer le gain apporté selon un critère donné (*e.g.* le BIC) par l'ajout d'un prédicteur pour la détermination du modèle GLM. La procédure se décompose selon les étapes suivantes :

1. On commence tout d'abord par construire un modèle GLM seulement à l'aide de l'ordonnée à l'origine β_0 et l'on évalue sa performance.
2. On cherche ensuite, parmi tous les modèles GLM construit à partir de chaque prédicteur, celui qui conduit à la meilleure performance.
3. Si la performance du GLM retenu à l'étape 2 est meilleure que celle du modèle basique de l'étape 1, le prédicteur utilisé pour la construction du GLM retenu à l'étape 2 est alors conservé. La performance du GLM correspondant sert de référence et remplace celle du modèle basique de l'étape 1. On répète la procédure jusqu'à ce qu'aucun prédicteur ne permette d'obtenir un gain de performance lorsqu'il est ajouté pour la détermination du GLM.

2.3.2. La méthode d'exclusion

La méthode d'exclusion (aussi appelée approche *backward*) consiste, à l'inverse de la méthode d'inclusion, à évaluer le gain apporté lorsque l'on exclut un prédicteur pour la détermination du modèle GLM. La procédure se décompose selon les étapes suivantes :

1. On commence tout d'abord par construire un modèle GLM complet basé sur l'ensemble des prédicteurs disponibles et l'on évalue sa performance.
2. On cherche ensuite, parmi tous les modèles GLM pour lesquels chaque prédicteur est exclu du modèle GLM complet, celui qui conduit à la meilleure performance.
3. Si la performance du GLM retenu à l'étape 2 est meilleure que celle du modèle complet de l'étape 1, le prédicteur exclu pour la construction du GLM retenu à l'étape 2 est alors retiré définitivement. La performance du GLM correspondant sert de référence et remplace celle du modèle complet de l'étape 1. On répète la procédure jusqu'à ce qu'aucun prédicteur ne permette d'obtenir un gain de performance lorsqu'il est retiré pour la construction du GLM.

2.3.3. Combinaison des méthodes d'inclusion et d'exclusion

Un défaut des approches d'inclusion et d'exclusion est que les différents choix faits par ces algorithmes ne sont jamais remis en question. Prenons par exemple une méthode d'inclusion avec cinq prédicteurs $\{X_1, X_2, X_3, X_4, X_5\}$. Imaginons qu'après trois itérations, les prédicteurs ont été sélectionnés dans l'ordre suivant : l'algorithme décide de retenir d'abord le prédicteur X_2, puis le prédicteur X_1, puis le prédicteur X_5. Cependant, il est possible qu'en retirant le prédicteur X_2, une meilleure performance soit obtenue. Comme cette combinaison n'est pas testée par l'algorithme, elle ne pourra pas être choisie.

Un algorithme combinant l'inclusion et l'exclusion permet de pallier ce problème. Après avoir ajouté un prédicteur, on met en œuvre la méthode d'exclusion. A chaque étape, les choix antérieurs sont remis en question et les prédicteurs qui pénalisent la performance du GLM sont rejetés avant d'ajouter de nouveaux prédicteurs. L'algorithme se termine lorsqu'aucun gain n'est observé lors de l'ajout ou le retrait d'une variable.

Du fait du plus grand nombre de combinaisons testées, l'algorithme combinant l'inclusion et l'exclusion nécessite un coût de calculs plus important que les deux autres algorithmes pris séparément. Il est cependant conseillé de le mettre en œuvre étant donné sa meilleure exploration des combinaisons.

3. Mise en œuvre d'un GLM sur la base des dates analogues

Pour une situation synoptique cible, le modèle Analog retient un nombre N_d de dates analogues caractérisant la circulation atmosphérique car l'analogie est effectuée sur les hauteurs de géopotentiel seules. A partir de ces dates analogues, N_d valeurs de prédictand/prédicteurs sont extraites et deux modèles GLM peuvent être développés, l'un pour l'occurrence et l'autre pour la quantité. A partir de ces deux modèles GLM, les valeurs π et μ sont estimées. Il est alors possible de prédire une distribution F_Y cumulative des précipitations. Par la suite, ce modèle combiné est dénommé MA+GLM. Pour chaque prédiction, il se décompose en trois parties que constituent 1) l'extraction des prédicteurs et des prédictands déduite des dates analogues, 2) la détermination des modèles d'occurrence et de quantité les plus adaptés pour cet ensemble de dates analogues et 3) l'estimation et l'émission d'une distribution des précipitations pour la journée cible (appelée phase d'assemblage). Ces parties sont décrites dans les sections 3.1 à 3.3 et illustrées sur le schéma VI.2.

3.1. L'extraction

La première étape consiste à extraire les valeurs d'occurrence et de quantité de précipitations correspondants aux N_d dates analogues, ainsi que les prédicteurs nécessaires à l'établissement des modèles d'occurrence et de quantité. Pour chaque date analogue, une valeur d'occurrence est déterminée comme suit : si la valeur de précipitation est supérieure ou égale à un seuil donné (ici pris égal à 0.1 [mm]), la journée correspondant à la date analogue est considérée comme humide. Dans ce cas, il y a effectivement eu présence de précipitation et la valeur prise par la variable O est égale à 1. Dans le cas contraire (*i.e.* la valeur de précipitation est inférieure à 0,1 [mm]), la journée est considérée comme sèche et la variable O prend alors une valeur égale à 0. L'ensemble de ces valeurs sont regroupées dans un vecteur occurrence $\mathbf{o} = \{o_1, o_2, \ldots, o_{N_d}\}$ comme représenté sur la figure VI.2. Par la suite, le nombre de valeurs pour lesquelles il y a eu effectivement précipitation est représenté par le paramètre $\widetilde{N}_d$.

Pour chaque date analogue humide [1], les valeurs de pluies correspondantes sont extraites pour former le vecteur $\mathbf{q}$ des $\widetilde{N}_d$ précipitations analogues $\left\{q_1, q_2, \ldots, q_{\widetilde{N}_d}\right\}$ qui constituent un échantillon de la variable aléatoire quantité de précipitation Q.

1. Une date analogue "humide" est un abus de langage de notre part : cela signifie que la précipitation observée pour la date analogue est supérieure ou égale à 0,1 mm. Dans le cas où la valeur de précipitation observée pour la date analogue considérée est inférieure à 0,1 mm, nous qualifierons cette date analogue de "sèche".

Enfin, les valeurs de prédicteurs pour l'occurrence et la quantité correspondants aux dates analogues sont également extraites. Le nombre de prédicteurs disponibles pour l'occurrence est noté $\widetilde{K}_o$ et $\widetilde{K}_q$ pour la quantité. *A priori*, il n'est pas nécessaire que les jeux de prédicteurs disponibles pour l'occurrence et la quantité soient les mêmes, ni que les valeurs $\widetilde{K}_o$ et $\widetilde{K}_q$ soient égales.

3.2. Détermination d'un modèle d'occurrence et de quantité

La deuxième étape consiste à déterminer un modèle GLM pour l'occurrence et la quantité. L'algorithme de sélection itérative décrit à la section 2.3.3 combinant les méthodes d'inclusion et d'exclusion permet de retenir la régression logistique et la régression logarithmique les plus adaptées sur la base des valeurs de prédictand/prédicteurs extraites par les dates analogues à l'étape 1. Pour le modèle d'occurrence (respectivement de quantité), un nombre K_o (respectivement K_q) de prédicteurs sélectionnés parmi les $\widetilde{K}_o$ (respectivement $\widetilde{K}_q$) prédicteurs potentiels est retenu.

Pour chacune des deux régressions, la significativité des coefficients estimés $\widehat{\beta}_i^o$ (respectivement $\widehat{\beta}_i^q$) de chaque prédicteur X_i^o (respectivement X_i^q) est évaluée par le test Z (respectivement le test t de Student). Si la p-valeur correspondant à chaque coefficient est inférieure à 0,05, le modèle GLM est retenu. Dans le cas contraire, le prédicteur dont le coefficient obtient la plus grande p-valeur est retiré de l'ensemble des prédicteurs potentiels. L'algorithme de sélection itérative est mis en œuvre sur un nouvel ensemble de prédicteurs n'incluant pas le prédicteur exclu.

Dans les cas où tous les coefficients sont significatifs, les valeurs de prédicteurs correspondant à la journée cible permettent d'estimer une probabilité qu'il précipite $\widehat{\pi}$ et une valeur moyenne de quantité de précipitation $\widehat{\mu}$ pour la journée cible considérée. Par ailleurs, il est nécessaire d'estimer le paramètre de forme ν pour définir la distribution statistique de la variable aléatoire quantité Q. A partir des résidus de Pearson, l'estimation $\widehat{\nu}$ est calculée à l'aide de la variance estimée $\widehat{\sigma}^2$ de Q [McCullagh & Nelder, 1989, pp. 296], qui s'écrit comme :

$$\widehat{\sigma}^2 = \frac{1}{\left\{\widetilde{N}_d - (K_q + 1)\right\}} \sum_{n=1}^{\widetilde{N}_d} \frac{(q_n - \widehat{\mu})^2}{\widehat{\mu}^2} \tag{VI.12}$$

où $(K_q + 1)$ correspond au nombre de coefficients de la régression à estimer. Le paramètre de forme $\widehat{\nu}$ est égal à l'inverse de la variance estimée $1/\widehat{\sigma}^2$. La distribution cumulative prédite des précipitations positives $\widehat{F}_Q$ est alors la loi gamma de paramètres de forme $\widehat{\nu}$ et d'échelle $\widehat{\mu}/\widehat{\nu}$. Le cas où tous les coefficients sont significatifs est un cas idéal qui n'est pas toujours rencontré. En pratique, les coefficients du modèle d'occurrence peuvent en effet être non-significatifs tout comme ceux du modèle de quantité.

Lorsqu'un modèle de régression n'a pas pu être déterminé pour l'occurrence (*i.e.* parce que les coefficients ne respectaient pas le seuil de significativité), le modèle MA_{25} est utilisé comme modèle alternatif pour la prédiction de l'occurrence. La probabilité d'occurrence $\widehat{\pi}$ est alors estimée à partir des précipitations extraites par le modèle MA_{25} comme :

$$\widehat{\pi} \equiv \widehat{\pi}_{\mathrm{MA}_{25}} = \frac{1}{25} \sum_{n=1}^{25} o_n \tag{VI.13}$$

où $\widehat{\pi}_{\mathrm{MA}_{25}}$ correspond à l'estimation de la probabilité qu'il précipite à partir du modèle MA_{25}.

Lorsque cette fois, un modèle de régression n'a pas pu être établi (*i.e.* parce que les coefficients ne respectaient pas le seuil de significativité) pour la prédiction de la quantité, la distribution des précipitations F_Q est déduite de la distribution des précipitations positives du modèle MA_{25} comme :

$$\widehat{F}_Q(q) \equiv \widehat{F}_{Q,\mathrm{MA}_{25}}(q) = \frac{\widehat{F}_{\mathrm{MA}_{25}}(q) - (1 - \widehat{\pi}_{\mathrm{MA}_{25}})}{\widehat{\pi}_{\mathrm{MA}_{25}}} \tag{VI.14}$$

$\widehat{F}_{Q,\mathrm{MA}_{25}}$ et $\widehat{F}_{\mathrm{MA}_{25}}$ correspondent aux distributions cumulatives estimées des précipitations positives et des précipitations analogues (incluant les précipitations nulles). La distribution $\widehat{F}_{Q,\mathrm{MA}_{25}}$ des précipitations positives analogues est quant à elle définie par une relation linéaire par morceaux. Comme illustrée à la figure VI.1, la distribution cumulative des précipitations positives analogues $F_{Q,\mathrm{MA}_{25}}$ résulte d'une dilatation de la distribution des précipitations analogues $F_{\mathrm{MA}_{25}}$. Elle peut aussi être utilisée dans les cas où le nombre $\widetilde{N}_d$ de dates analogues humides n'est pas suffisant pour permettre une bonne estimation de la régression. Par suite, nous avons imposé que ce nombre devait être supérieur ou égal à dix.

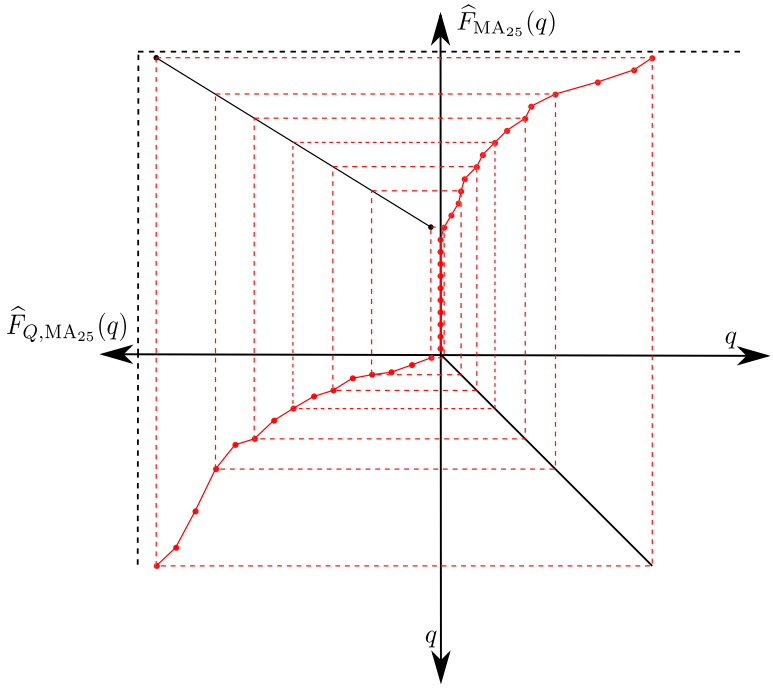

FIGURE VI.1 – Relation entre la distribution des précipitations analogues $\widetilde{F}_{\mathrm{MA}_{25}}$ et la distribution des précipitations positives analogues $\widetilde{F}_{Q,\mathrm{MA}_{25}}$.

3.3. La phase d'assemblage

La dernière étape consiste à déterminer la distribution cumulative mise à jour des précipitations pour le jour cible en assemblant 1) la probabilité qu'il précipite et 2) la distribution des précipitations positives. On utilise à cet effet le même modèle défini à l'équation VI.6. On obtient alors :

$$\widehat{F}_Y(y) = (1 - \widehat{\pi}) + \widehat{\pi} \cdot \widehat{F}_Q(q = y) \tag{VI.15}$$

A cette étape, quatre possibilités se présentent. Elles sont illustrées à la figure VI.2.

Cas 1 : Le modèle d'occurrence et le modèle de quantité n'ont pas pu être retenus, les coefficients des GLM respectifs étant tous non significatifs. Dans ce cas, aucune mise à jour de la distribution des précipitations est effectuée. La distribution prédite est égale à la distribution des précipitations analogues du modèle MA_{25}.

Cas 2 : Le modèle d'occurrence est retenu tandis que le modèle de quantité ne l'est pas. La distribution prédite résulte 1) de la mise à jour de la probabilité qu'il précipite et 2) de la distribution des précipitations positives analogues prédite par MA_{25}. Pour les prédictions où la probabilité mise à jour qu'il précipite est supérieure à celle prédite par le modèle MA_{25}, il est nécessaire de connaître la distribution des précipitations aux extrêmes de la distribution $\widehat{F}_{Q,\mathrm{MA}_{25}}$ – *i.e.* entre 0 et la valeur de précipitation la plus faible et entre la valeur de précipitation la plus forte et 1. Comme ces parties de la distribution ne nous sont pas connues, nous avons décidé de ré-échantillonner la plus faible et la plus forte valeur lorsqu'il s'agit d'émettre une prédiction en dehors de la plage de valeurs connues de $\widehat{F}_{Q,\mathrm{MA}_{25}}$.

Cas 3 : Le modèle d'occurrence n'est pas retenu et le modèle de quantité l'est. La distribution prédite résulte 1) de la probabilité qu'il précipite estimée à partir du modèle MA_{25} et 2) de la distribution des précipitations positives prédite par le modèle de régression logarithmique. Seule la distribution des précipitations positives est alors mise à jour.

Cas 4 : Le modèle d'occurrence et le modèle de quantité sont retenus. La distribution prédite résulte 1) de la mise à jour de la probabilité qu'il précipite et 2) de la distribution des précipitations positives délivrées respectivement par les modèles d'occurrence et de quantité.

On notera enfin que la mise en œuvre du modèle combiné MA+GLM nécessite l'optimisation de certains paramètres :

- Le nombre de dates analogues N_d à retenir. Si ce nombre est faible, les paramètres des modèles de régression ne seront pas estimés de façon fiable. En revanche, s'il est trop important, une partie des dates analogues retenues ne sera plus réellement similaire à la journée cible. La possibilité d'identifier les prédicteurs explicatifs des précipitations pour la journée cible est potentiellement réduite, surtout s'ils sont spécifiques à la situation rencontrée. Au final, la pré-sélection effectuée par les dates analogues perd de son intérêt. Le cas le plus extrême est rencontré lorsque toutes les dates analogues sont retenues. Le modèle correspondrait alors à un modèle de régression simple estimé sur l'ensemble des situations.
- Les jeux de K_o et K_q prédicteurs potentiels qui peuvent être retenus par l'algorithme de sélection itérative respectivement pour l'occurrence et la quantité pour chaque prédiction.

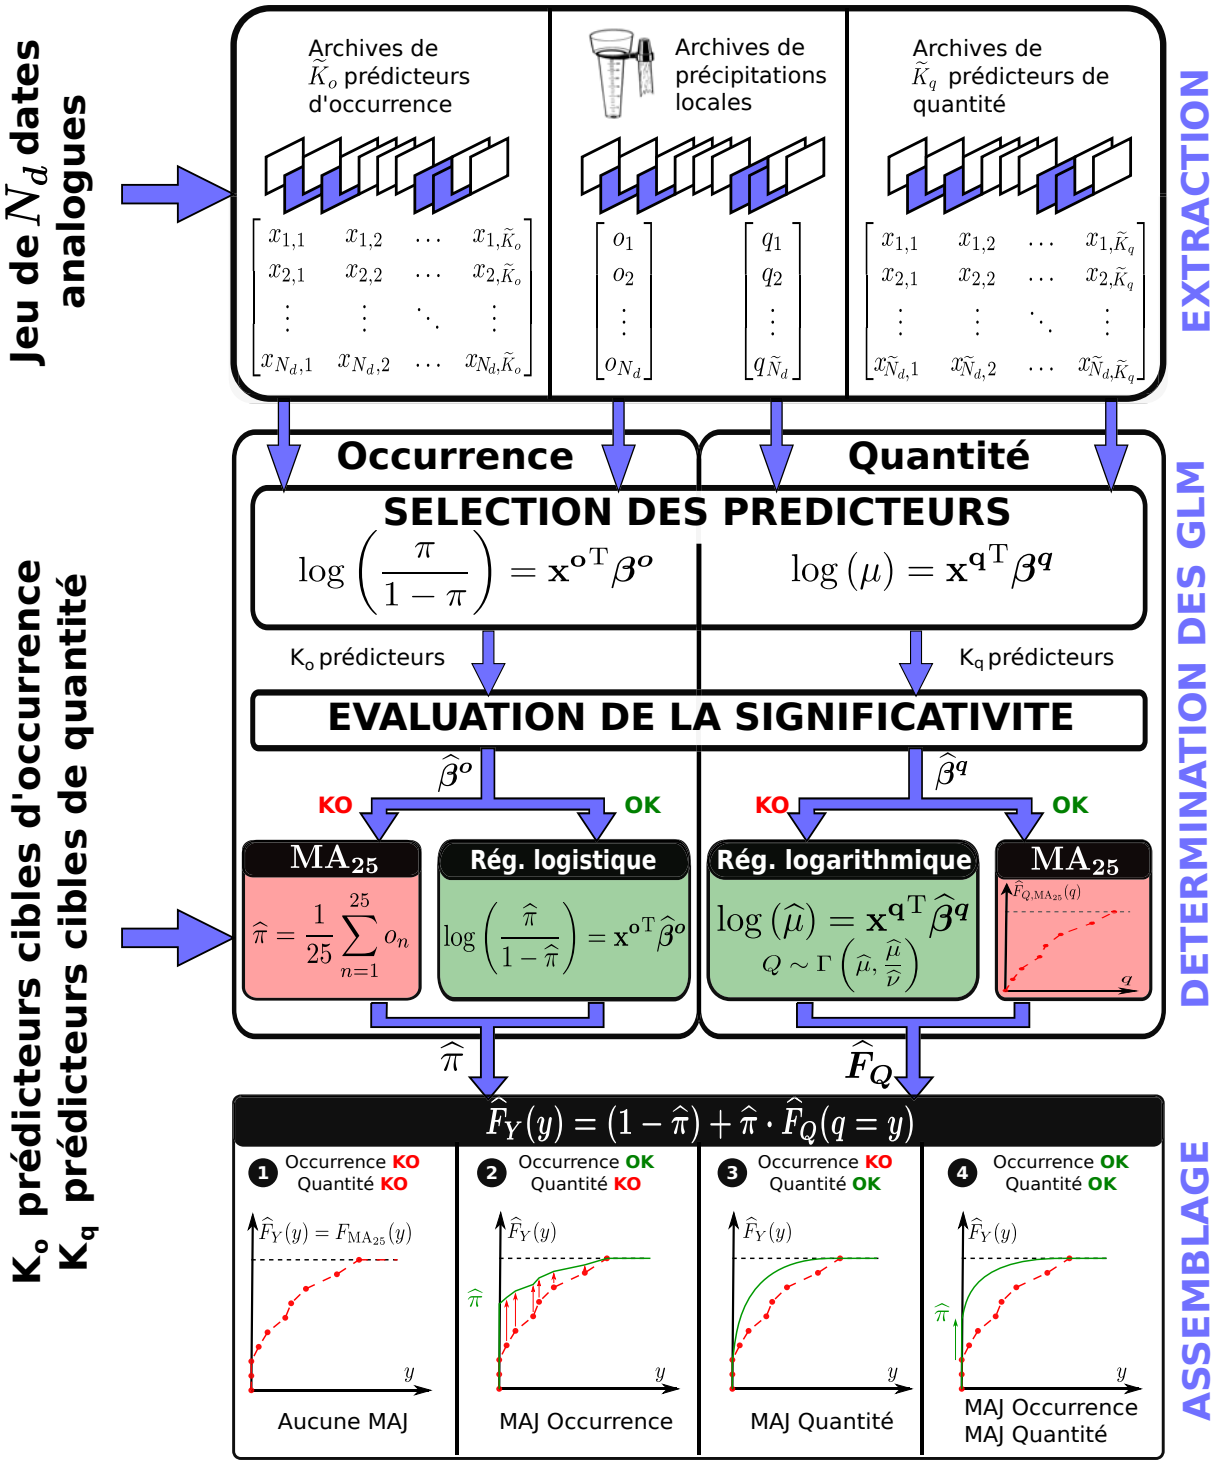

FIGURE VI.2 – Schématisation de la mise en œuvre d'un modèle GLM sur la base de N_d dates analogues. Le sigle **KO** indique qu'un modèle GLM n'a pas pu être retenu pour l'occurrence ou la quantité. A l'inverse, le sigle **OK** indique qu'il a pu être établi.

Chapitre VII

Constitution d'un jeu de prédicteurs

Dans ce chapitre, notre but est d'établir un ensemble de prédicteurs potentiellement informatifs pour la prédiction des précipitations en France. Comme plusieurs types de précipitations peuvent être retrouvées à nos latitudes, nous tentons de retenir des prédicteurs qui puissent être caractéristiques des processus atmosphériques à l'origine de ces différentes précipitations. Dans une première section, nous décrivons les différents types de précipitations rencontrées sur le territoire français et les contextes météorologiques dans lesquels ces précipitations surviennent. Dans une seconde section, nous listons les différentes familles de prédicteurs intervenant dans les processus générateurs de précipitations, ce qui nous permet d'établir un premier jeu de prédicteurs potentiels. Il est important d'éviter la multicolinéarité des variables explicatives dans la régression. Par conséquent, nous effectuons une étude des corrélations entre prédicteurs en dernière partie de façon à établir une liste de prédicteurs potentiels évitant au mieux les informations redondantes pour l'optimisation d'un modèle d'occurrence et d'un modèle de quantité.

1. Caractérisation des précipitations

Trois types de précipitations peuvent être considérés sur le territoire français : les précipitations de types stratiforme (section 1.1), orographique (section 1.2) ou convective (section 1.3).

1.1. Précipitation de type stratiforme

Les précipitations de type stratiforme sont induites par les perturbations baroclines rencontrées aux moyennes latitudes et provenant de l'Atlantique. Elles surviennent majoritairement pendant la saison hivernale et impactent l'ensemble de la France parfois pendant plusieurs jours. Elles sont pilotées par un centre de bas géopotentiel résultant de l'interaction entre une zone de basse tropopause

avec un centre de basse pression au sol. Autour de ce centre s'enroule une perturbation généralement constituée d'un front chaud, d'un front froid et parfois d'une occlusion, dont les flux ascendants mènent à la formation de nuages lorsque l'humidité arrive à saturation (pp. 451 Malardel, 2005). Plus le système dépressionnaire est dynamique – autrement dit la dépression est creuse – plus les vitesses verticales peuvent être importantes.

1.2. Précipitation de type orographique

Comme leur nom l'indique, les précipitations orographiques se produisent en présence de reliefs. Elles résultent du soulèvement par le relief d'une masse d'air humide qui se refroidit au fur et à mesure qu'elle s'élève. La formation de nuages se produit lorsque les conditions thermodynamiques permettent d'atteindre le point de condensation, entraînant potentiellement des précipitations.

1.3. Précipitation de type convective

Les précipitations convectives proviennent de l'élévation par la poussée d'Archimède d'une masse d'air humide due à l'instabilité de l'air. Elles sont générées par des cellules convectives pouvant être de différentes formes : par exemple la cellule ordinaire et isolée (d'une durée de vie de l'ordre de l'heure) ou l'organisation de plusieurs cellules ou orages "multi-cellulaires" où le cisaillement vertical du vent constitue un paramètre important pour la génération de la convection profonde (durée de vie variant entre une heure et une dizaine d'heures). L'étendue spatiale de ces phénomènes varie du kilomètre à plusieurs dizaines de kilomètres. Selon Doswell [1987], les trois éléments nécessaires à la convection sont l'humidité, l'instabilité et le mouvement vertical. Il est alors nécessaire de disposer de cette information pour la prédiction des précipitations convectives. De part les échelles spatiales et temporelles de ces systèmes qui sont inférieures à celles des ré-analyses ERA-40, la prédiction de ces précipitations reste une tâche hasardeuse. Cependant, les situations synoptiques pour lesquelles il est probable que des précipitations convectives surviennent peuvent tout de même être caractérisées par un jeu de prédicteurs de grande échelle.

2. Composition d'un jeu de prédicteurs

Dans cette section, nous identifions un premier jeu de prédicteurs potentiels qui puisse améliorer les performances locales des champs de précipitations prédits. Il est à noter que, contrairement aux hauteurs de géopotentiel utilisées par le modèle MA, les prédicteurs décrits dans cette section et utilisés dans le reste de la partie III correspondent à des scalaires et non des champs synoptiques. Par conséquent, l'information qu'ils apportent relèvent d'une échelle plutôt locale, tandis que les dates analogues sont informatives de la circulation à large échelle.

2.1. Typologie des prédicteurs

2.1.1. Les prédicteurs dynamiques

Les prédicteurs dynamiques caractérisent la circulation atmosphérique de grande-échelle et regroupent par exemple la pression au niveau de la mer (*SLP – Sea Level Pressure*), les hauteurs de géopotentiels Z et les vitesses zonale U et méridienne V des vents décrits sur plusieurs niveaux de pression. Dans notre contexte, une part de l'information délivrée par ces variables est déjà portée par les dates analogues. Toutefois, une information locale de ces variables pourrait peut-être s'avérer utile pour raffiner les prédictions émises. Par exemple, les vitesses U et V peuvent être considérées comme une information locale de l'origine des masses d'air et permettrait de caractériser les précipitations de type orographique en zone de montagne. Dans la littérature, les variables Z, U et V utilisées sont souvent prises dans les basses et moyennes couches de l'atmosphère entre 850 et 500 hPa (*e.g.* Wilby & Wigley, 2000 ; Mezghani & Hingray, 2009 ; Frost et al., 2011 ; Abdellatif et al., 2012 ; Kenabatho et al., 2012 ; Chun et al., 2013, pour les modèles d'occurrence et/ou de cumul de précipitations basés sur la régression et Wetterhall et al. [2005] ; Bontron & Obled [2005] ; Schoof et al. [2010] ; Hertig et al. [2013] pour d'autres SDMs).

2.1.2. Les prédicteurs d'humidité

L'humidité constitue un élément nécessaire à la formation des précipitations quelle que soit leur nature. Plus une masse d'air est humide, plus la chance d'observer des précipitations est importante. A l'inverse, plus l'air est sec, moins une précipitation risque d'être observée. C'est pourquoi de nombreuses études retiennent l'humidité relative R et/ou l'humidité spécifique S. L'humidité relative constitue un indicateur du degré de saturation de l'eau dans l'atmosphère et est considéré comme un moteur potentiel de la génération de précipitations [Beckmann & Buishand, 2002]. L'humidité spécifique renseigne quant à elle sur le contenu en eau de l'atmosphère. Les niveaux de pression pour lesquels ces variables sont généralement retenues varient entre 850 et 500 hPa car les nuages dont la base est située au dessus du géopotentiel 500 hPa ne produisent généralement pas de précipitations au sol. Certains auteurs comme Mezghani & Hingray [2009] utilisent aussi l'équivalent en eau contenue dans une colonne d'atmosphère (*TCW – Total Column Water*). Beaucoup d'études introduisent un ou plusieurs prédicteurs d'humidité comme variable(s) explicative(s). Un grand nombre d'entre elles combinent ces prédicteurs avec des prédicteurs dynamiques (*e.g.* Wilby & Wigley, 2000 ; Wetterhall et al., 2005 ; Bontron & Obled, 2005 ; Mezghani & Hingray, 2009 ; Schoof et al., 2010 ; Frost et al., 2011 ; Abdellatif et al., 2012 ; Kenabatho et al., 2012 ; Hertig et al., 2013 ; Chun et al., 2013) car la combinaison de ces deux informations permet d'estimer la part d'eau contenue dans les masses d'air advectées sur le territoire.

2.1.3. Les prédicteurs thermiques

Les prédicteurs thermiques informent de la température d'une masse d'air. Ils regroupent par exemple la température T [Wilby & Wigley, 2000 ; Abaurrea & Asn, 2005 ; Schoof et al., 2010 ; Frost et al., 2011 ; Kenabatho et al., 2012 ; Chun et al., 2013] et l'épaisseur Δ_Z de la colonne d'atmosphère entre deux géopotentiels [Cavazos & Hewiston, 2005]. L'intérêt des prédicteurs de température consiste à renseigner sur la capacité d'une masse d'air à contenir de l'eau sous forme de

vapeur et sur la facilité à condenser la vapeur en goutte d'eau. Plus une masse d'air est chaude, plus il est possible de stocker de l'eau sous forme de vapeur. Cependant, il sera plus difficile d'atteindre le niveau de saturation en vapeur d'eau. Inversement, si la température de la masse d'air diminue, la capacité de stockage décroît et il sera plus facile d'atteindre le niveau de saturation. Un autre prédicteur thermique parfois utilisé est la baroclinicité B [*e.g.* Mezghani & Hingray, 2009]. Cette variable décrit les gradients horizontaux de température et indique par conséquent l'évolution dans l'espace horizontal de la capacité de stockage de l'atmosphère.

2.1.4. Les prédicteurs de mouvements verticaux

Les mouvements verticaux à l'échelle synoptique permettent de détecter les fronts entre deux masses d'air de caractéristiques différentes (*e.g.* température et hygrométrie) capables de générer des précipitations. Plusieurs variables peuvent décrire ces mouvements verticaux. Par exemple Mathes et al. [2008] et Ben Daoud et al. [2011] utilisent la vitesse verticale W à 850 hPa comme prédicteur. Wilby & Wigley [2000] et Abdellatif et al. [2012] ont retenu la divergence du vent au sol et/ou à 500 hPa.

2.1.5. Les prédicteurs de persistance

Il arrive en France que certaines situations synoptiques soient persistantes sur le territoire, comme par exemple les situations anticycloniques qui durent en été. Pour ces situations, un prédicteur caractérisant la persistance peut s'avérer pertinent. Par exemple, Mezghani & Hingray [2009] et Chun et al. [2013] utilisent l'occurrence de la veille du jour de prédiction – notée *Occ-1* par la suite – pour prédire la probabilité qu'il précipite tandis que Wilby & Wigley [2000] l'introduisent également pour prédire le cumul. Chun et al. [2013] appliquent une fonction logarithmique (*i.e.* $\ln\left[1 + Y\left(t-1\right)\right]$) sur le cumul de la veille pour prédire le cumul de précipitation.

2.1.6. Les prédicteurs d'instabilité thermo-dynamique

Des indices peuvent parfois être utilisés pour prédire les précipitations de type convectives. Hertig et al. [2013] retiennent par exemple le *Showalter-Index* (Showalter, 1953) pour caractériser l'instabilité convective. D'autres indicateurs tels que la $CAPE$ (*Convective Available Potential Energy*) peuvent aussi être utilisés. Hertig et al. [2013] introduisent également la CIN (*Convective INhibition*, Myoung & Nielsen-Gammon [2010]) pour caractériser l'énergie nécessaire pour libérer la $CAPE$.

A partir de cette revue bibliographique, plusieurs prédicteurs ont été retenus pour notre étude :

- Les humidités relatives R_1, R_2 et R_3 respectivement aux pressions 850, 700 et 500 hPa. Comme cette variable est l'une des plus importantes pour la prédiction des précipitations [Wetterhall et al., 2006], il a été décidé de retenir ces trois niveaux de pression de façon à déterminer quel est celui permettant d'expliquer le mieux les précipitations,
- L'équivalent en eau TCW contenue dans la colonne d'atmosphère,
- La température T à 700 hPa,
- L'épaisseur Δ_Z de la colonne d'atmosphère entre les hauteurs de géopotentiel entre 700 et 1000 hPa,
- La baroclinicité B à 700 hPa,

- Les géopotentiels Z_1 et Z_2 respectivement à 1000 et 700 hPa.
- Les vents U zonal et V méridien à 700 hPa,
- La vitesse W du vent vertical à 700 hPa,
- L'occurrence de précipitation de la veille *Occ-1*.

Parmi ces variables, le niveau de pression égal à 700 hPa a été majoritairement retenu car il permet d'avoir une image moyenne de ces dernières à la fois pour les basses et moyennes couches.

Nous avons décidé de tester également l'information apportée par d'autres prédicteurs. Ces prédicteurs, pouvant être bruts ou issus d'une transformation, sont décrits dans la section 2.2 ci-dessous.

2.2. Prédicteurs composites & autres variables

2.2.1. Produit de l'humidité relative par l'équivalent en eau

Dans sa thèse, Bontron [2004] avait déterminé qu'un prédicteur composite $RTCW$ défini comme le produit de l'humidité relative R_1 à 850 hPa par l'équivalent en eau contenue dans une colonne d'atmosphère TCW était informatif des précipitations. Nous avons par ailleurs pu vérifier dans la section 4.3 de l'article Chardon et al. [2014] que l'ajout d'un second niveau d'analogie basé sur cette variable permettait d'obtenir localement de meilleures performances de prédiction. Par suite, cette variable est retenue comme prédicteur potentiel pour les modèles GLM d'occurrence et de quantité des précipitations.

2.2.2. Flux d'humidité

Dans le cadre de cette étude, nous souhaitons évaluer le gain apporté par un flux d'humidité basé sur le produit de la résultante du vent F par l'humidité relative, informant sur la quantité d'humidité advectée par un flux d'air, comme utilisé par Wetterhall et al. [2006]. Le flux d'humidité FR pour un niveau de pression donné est défini par la relation VII.1 comme :

$$\begin{aligned} F &= \sqrt{U^2 + V^2} \\ FR &= R \cdot F \end{aligned} \tag{VII.1}$$

où U et V correspondent aux vitesses du vent zonal et méridien, F est la résultante du vent et R représente l'humidité relative. Par la suite, le niveau de pression retenu est égal à 700 hPa. Nous avons de plus considéré les composantes zonales UR et méridiennes VR du flux d'humidité, calculés sur le même principe que l'équation VII.1.

2.2.3. Différence de températures potentielles

La température potentielle θ correspond à la température qu'aurait une parcelle d'air si elle était ramenée à un niveau de référence (choisi égal à 1000 hPa) par une transformation adiabatique et s'il n'y avait pas de changement de phase. Elle est définie par l'équation VII.2 comme :

$$\theta = T \left(\frac{1000}{p} \right)^{\frac{R_a}{C_p}} \tag{VII.2}$$

où T désigne la température de la parcelle considérée au niveau de pression p. R_a correspond à la constante des gaz parfaits et C_p à la chaleur massique à pression constante de l'air. Le rapport de R_a par C_p est égal à 0,286. A la différence de la température T, la température potentielle θ varie seulement lorsque des échanges de chaleur ont lieu entre une masse d'air et l'extérieur.

Une manière de caractériser l'instabilité dans les basses couches nécessaire à la convection (*cf.* section 1.3) consiste à regarder la variation $\Delta\theta$ de température potentielle entre 925 et 700 hPa, définie par :

$$\Delta\theta = \theta_{700} - \theta_{925} \tag{VII.3}$$

Si la température potentielle à 925 hPa est plus importante que celle obtenue à 700 hPa (*i.e.* $\Delta\theta < 0$), la situation est qualifiée de convectivement instable. La situation est convectivement neutre si ces deux températures potentielles sont égales, et convectivement stable si θ_{925} est inférieure à θ_{700} (*i.e.* $\Delta\theta > 0$.

2.2.4. La vorticité potentielle

Lors de systèmes dépressionnaires (résultant de l'intéraction d'une zone de basse tropopause avec un centre de basse pression au sol), des précipitations peuvent également être générées par les nuages convectifs de traîne se situant à l'arrière du front froid. Par exemple, la figure VII.1.a) est une vue satellite centrée sur l'Europe pour le 27 décembre 2013 à 12h UTC. Sur cette figure, les différents fronts (chaud, froid et occlusion) sont représentés. La zone située à l'arrière du front froid est caractérisée par un mouvement de subsidence à l'échelle synoptique. Cependant, on remarque à une échelle plus locale la présence de nuages convectifs de traîne (surface turquoise). Sur la figure VII.1.b) correspondant à l'intensité des précipitations (issue d'un produit satellite Eumetsat), on remarque que ces nuages de traîne génèrent des précipitations convectives en aval du front froid.

Une manière de repérer ces zones de basse tropopause où ce type de précipitations peut être retrouvé est d'utiliser l'altitude de la vorticité potentielle PV prise égale à 1,5 pvu (valeur délimitant la troposphère de la stratosphère). Cependant, cette donnée n'est pas disponible dans les ré-analyses ERA-40. Nous avons alors décidé de retenir la vorticité potentielle PV au niveau de pression 400 hPa [*i.e.* niveau de pression pour lequel la vorticité potentielle vaut en moyenne 1,5 pvu à nos latitudes selon Malardel, 2005, pp. 111]. Si la valeur de PV à 400 hPa est supérieure à 1,5, nous sommes en présence d'une tropopause plus basse que la normale. Si en revanche elle est plus faible, nous sommes en présence d'une tropopause plus haute.

A titre d'illustration, la figure VII.2 représente la hauteur du géopotentiel à 1000 hPa [extraites des données ERA-Interim, Dee et al., 2011] pour la journée du 27-12-2013 à 12h UTC. La zone de basse pression au sol est localisée sur le nord du Royaume Uni par les teintes de couleurs bleues. Sur la figure VII.2, la vorticité potentielle au niveau 400 hPa est représentée par les lignes de contours marron. Sur la figure VII.2, l'anomalie de basse tropopause est repérable par des valeurs de PV atteignant 6 pvu. On remarque aussi que pour la région où des précipitations dues aux nuages de traîne sont rencontrées (*cf.* figure VII.1.b), les valeurs prises par PV sont proches à 4 pvu, ce qui correspond à une zone de basse tropopause.

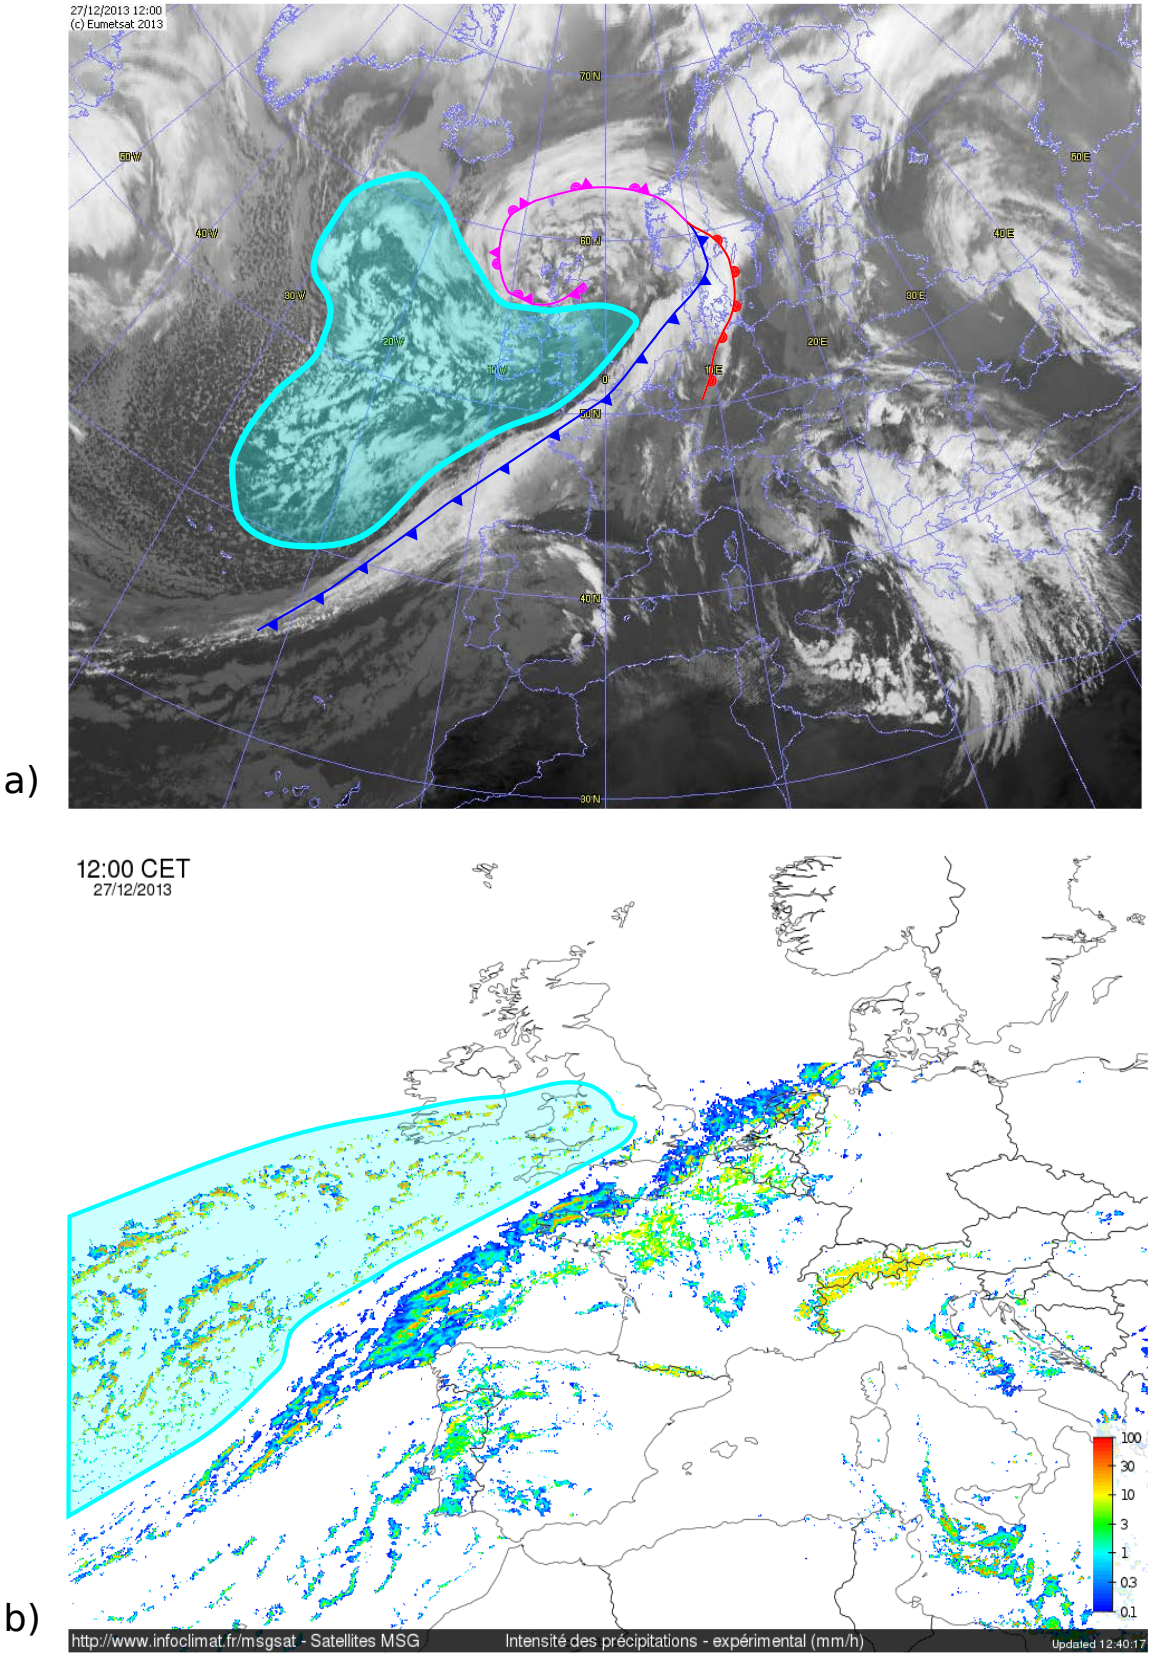

FIGURE VII.1 – a) Image satellite (Eumetsat 2013) représentant une perturbation cyclonique atteignant l'Europe le 27-12-2013 à 12h UTC. Sur cette image, le front froid est représenté en bleu, le front chaud en rouge et l'occlusion en violet. La surface turquoise représente le ciel de traîne où des nuages convectifs sont localement retrouvés. b) Intensité des pluies photographiées par le satellite géostationnaire MSG. La surface bleue turquoise représente les précipitations dues aux nuages de traîne.

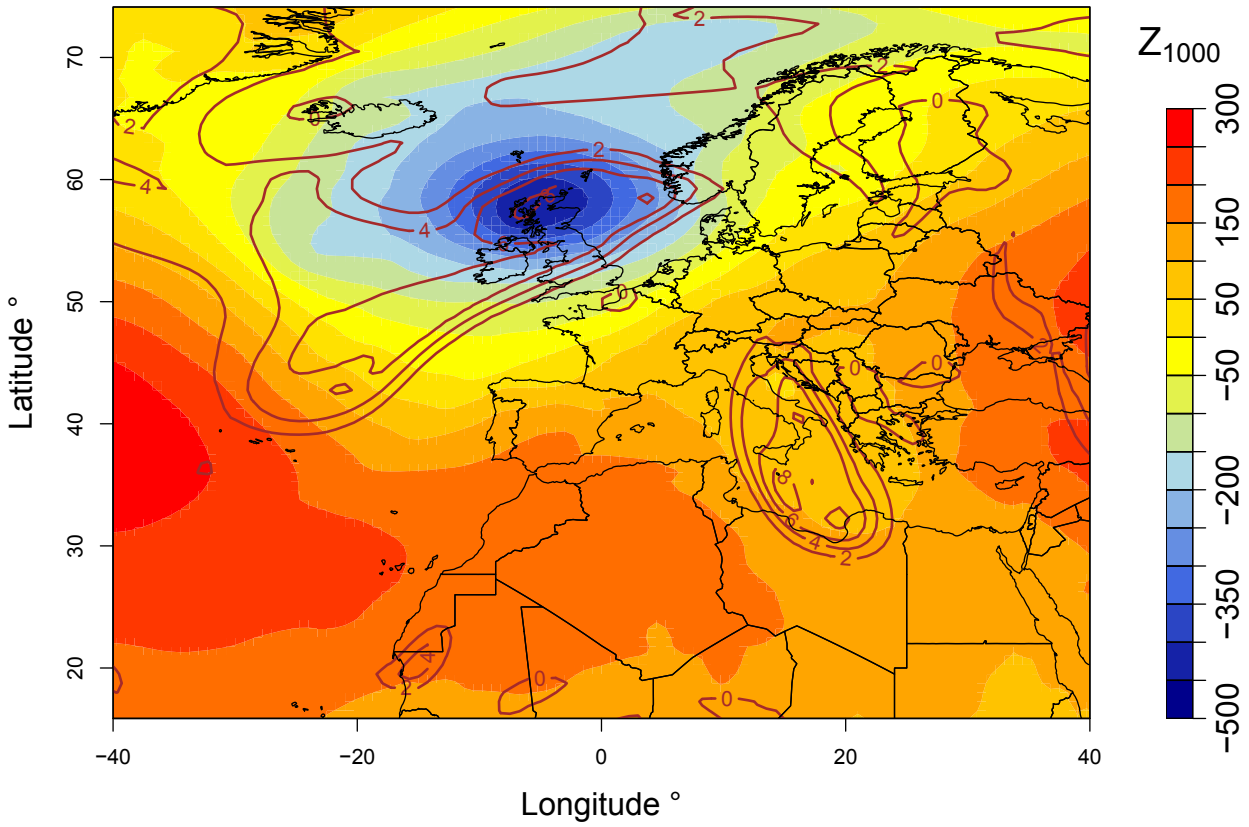

FIGURE VII.2 – Localisation de la dépression cyclonique par le géopotentiel Z_{1000} (plage de couleurs) pour le 27-12-2013. Les lignes de contours correspondent à la valeur prise par la vorticité potentielle PV à 400 hPa (exprimée en unités pvu). Données ERA-Interim [DEE et al., 2011].

.

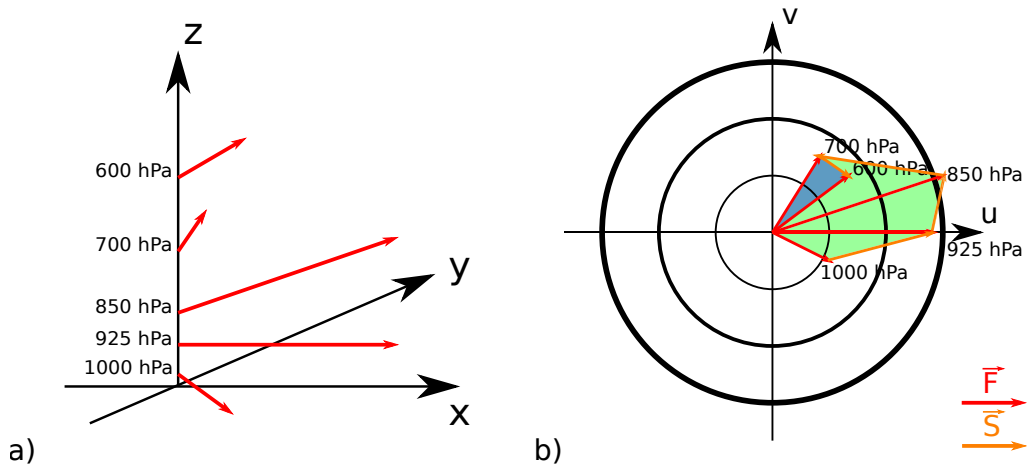

FIGURE VII.3 – Représentation schématique d'un hodographe. a) Le vent $\vec{F}$ à chaque niveau de pression est représenté dans un repère (x,y,z). b) Le vent $\vec{F}$ est projeté dans un repère (O, u, v) pour chaque niveau de pression. La valeur de l'hélicité H est déduite par la somme des aires vertes auxquelles les aires bleues sont retranchées. Adapté de MALARDEL [2005, pp. 497].

2.2.5. Divergence du flux d'humidité en basse couche

Les zones de convergence des masses d'air s'accompagnent de mouvement verticaux et peuvent produire des précipitations. Un moyen de caractériser cette convergence consiste à utiliser l'opérateur divergence ∇ appliqué à la résultante F du vent. Comme la précipitation est favorisée en présence d'humidité, nous considérerons par la suite la divergence ∇FR du flux d'humidité de basse couche (ici 850 hPa). Une valeur négative de ∇FR traduit une situation de convergence et donc potentiellement favorable à la génération de précipitations.

2.2.6. L'hélicité

La formation de systèmes convectifs organisés et persistants tels que les orages "multi-cellulaires" est favorisée lorsqu'il y a présence de cisaillement vertical du vent. Généralement, le cisaillement est représentée sur un hodographe dont un schéma est montré à la figure VII.3 : pour chaque niveau de pression ou d'altitude, la vitesse du vent F est projetée dans un repère (O, u, v) (figure VII.3.b). Le vecteur cisaillement vertical du vent $\vec{S} = \partial\vec{F}/\partial z$ est obtenu par la différence des vecteurs vents $\vec{F}$ entre deux niveaux successifs (représenté en orange sur la figure VII.3.b).

Cependant, il est difficile de caractériser le cisaillement en tout niveau à l'aide d'une seule variable. C'est pourquoi nous avons décidé de ne retenir que l'aire délimitée par les vecteurs vents entre deux niveaux successifs. Si le cisaillement se déplace dans le sens inverse des aiguilles d'une montre, l'aire est positive (aire en vert). Inversement, l'aire est négative si le cisaillement tourne dans le sens des aiguilles d'une montre (aire en bleu). La somme de ces aires entre les niveaux Z_A et Z_B constitue ce que nous appellerons l'hélicité H par la suite, comme définie à l'équation VII.4 :

$$H = \int_{Z_A}^{Z_B} F(z)dz \tag{VII.4}$$

Dans la suite de l'étude, les niveaux Z_A et Z_B sont respectivement égaux à 1000 et 500 hPa.

Finalement, l'ensemble des prédicteurs retenus pour la prédiction des précipitations par le modèle MA+GLM sont listés dans le tableau VII.1. Par suite, les valeurs des prédicteurs dépendent de la localisation de la maille Safran considérée et sont calculées selon une interpolation de type inverse-distance basée sur les quatre mailles ERA-40 avoisinant la maille Safran d'intérêt.

3. Etude des corrélations entre prédicteurs

L'application d'un modèle de type GLM nécessite de disposer d'un jeu de prédicteurs dont chacun est porteur d'une information différente pour l'explication de la variable d'intérêt. Si les prédicteurs sont linéairement dépendants entre eux, l'estimation des coefficients $\widehat{\beta}$ devient très sensible aux variations de Y et n'est pas robuste (*cf.* section 1 de l'annexe D).

De façon à écarter les effets néfastes de la multicolinéarité, deux méthodes peuvent être utilisées pour détecter les liens entre différentes variables. La première est une Analyse en Composantes Principales (ACP). Cette approche a été appliquée dans notre contexte par Cavazos & Hewiston

Tableau VII.1 – Jeu de prédicteurs potentiels pour la description des précipitations en France.

Prédicteurs d'humidité	
R_1	Humidité relative à 850 hPa
R_2	Humidité relative à 700 hPa
R_3	Humidité relative à 500 hPa
TCW	Equivalent en eau dans la colonne d'atmosphère
$RTCW$	Produit de R_1 par TCW (équivalent à la seconde variable d'analogie du modèle MA utilisé dans la section 4.3 de Chardon et al. [2014])
Prédicteur d'instabilité thermo-dynamique	
$\Delta\theta$	Gradient de température potentielle entre les niveaux 925 et 700 hPa
Prédicteur caractéristique de zones de basse tropopause	
PV	Vorticité potentielle à 400 hPa
Prédicteurs thermiques	
T	Température à 700 hPa
Δ_Z	Epaisseur de la colonne d'atmosphère entre les géopotentiels 700 et 1000 hPa
B	Baroclinicité à 700 hPa
Prédicteurs dynamiques	
Z_1	Hauteur du géopotentiel à 1000 hPa
Z_2	Hauteur du géopotentiel à 700 hPa
U	Vent zonal à 700 hPa
V	Vent méridien à 700 hPa
F	Résultante du vent à 700 hPa
H	Hélicité intégrée entre 1000 et 500 hPa
Prédicteurs de flux d'humidité	
UR	Flux d'humidité méridien à 700 hPa
VR	Flux d'humidité zonal à 700 hPa
FR	Intensité du flux d'humidité à 700 hPa
∇FR	Divergence du flux d'humidité à 700 hPa
Prédicteurs de mouvement vertical	
W	Vitesse verticale à 700 hPa
Prédicteur d'autocorrélation temporelle	
Occ-1	Occurence de pluie de la veille du jour à prédire

[2005], Mathes et al. [2008], Ben Daoud [2010], Kenabatho et al. [2012] ou encore Hertig et al. [2013]. La localisation des prédicteurs projetés dans les plans définis par les axes les plus explicatifs en terme de variance permet de regrouper les prédicteurs apportant une information similaire. La sélection d'un prédicteur parmi les groupes identifiés permet de constituer un ensemble de prédicteurs apportant chacun une information différente. La seconde méthode, celle que nous avons retenue, constitue ce groupe de prédicteurs sur la base de l'évaluation des corrélations croisées entre chaque couple de prédicteurs. Le coefficient de corrélation utilisé ici est le rho de Spearman qui est égal au coefficient de corrélation de Pearson calculé sur les rangs. Ce coefficient est non paramétrique et permet de détecter des liens non-linéaires entre deux variables. En pratique, si la valeur absolue du rho de Spearman entre deux prédicteurs est supérieure à un seuil fixé *a priori*, le couple de prédicteurs est rejeté. Dans notre cas, les valeurs des prédicteurs étant extraites des dates analogues et, ces dernières variant entre chaque prédiction, il est probable que les valeurs des coefficients de corrélation changent selon le jour cible de prédiction. Notre étude des corrélations est menée par conséquent à partir des

dates analogues. Pour M prédictions pour lesquelles un ensemble de dates analogues sont émises par le MA, M rho de Spearman peuvent être estimés pour chaque couple de prédicteurs.

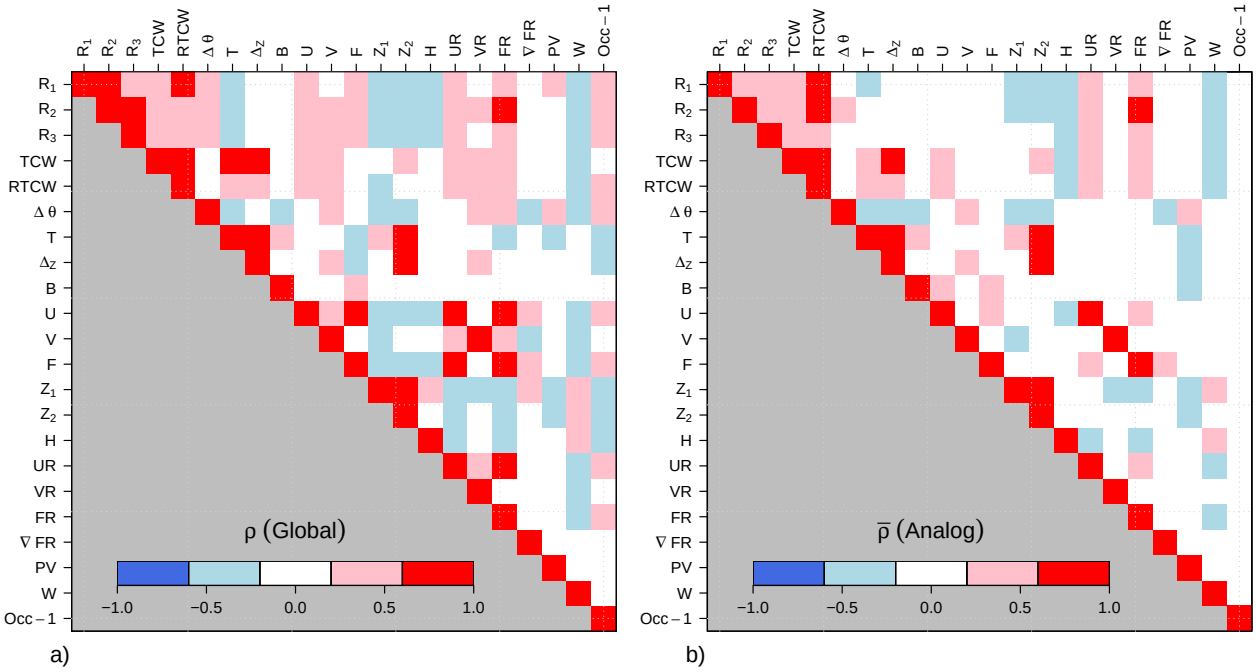

FIGURE VII.4 – a) Coefficient de corrélation de Spearman estimé à partir des chroniques de prédicteurs et b) coefficient de corrélation de Spearman moyen obtenu à partir des dates analogues déduites du modèle MA_{100} pour chaque couple de prédicteurs pour la maille Safran NW.

La figure VII.4.a) représente le coefficient de corrélation de Spearman global (noté ρ par la suite) classiquement estimé entre les deux séries temporelles issues de chaque couple de prédicteurs pour la période allant du 01-08-1982 au 31-07-2001 et pour la maille d'accroche NW (*cf.* figure IV.1). La figure VII.4.b) représente le rho de Spearman moyen (noté $\overline{\rho}$) obtenu pour chaque couple de prédicteurs conditionnés par les dates analogues. Pour un couple de prédicteurs (X, Y), une valeur absolue de $\overline{\rho}$ inférieure à celle de ρ indique qu'en moyenne, les variables X et Y sont moins corrélées lorsqu'elles sont échantillonnées à partir des dates analogues. Si l'on compare les figures VII.4.a) et b), on constate que la structure de corrélation entre prédicteurs est très similaire. Cependant, la figure VII.4.b) présente des corrélations moyennes plus faibles. Par exemple, pour la maille d'accroche NW considérée, les couples (R_1, R_2), (R_2, R_3), (T, TCW), (F, UR), (U, FR) sont fortement corrélés avec un ρ global compris entre 0,6 et 1 alors que leurs corrélations moyennes diminuent lorsqu'elles sont calculées à partir des dates analogues ($\overline{\rho}$ désormais compris entre 0,2 et 0,6). De même, le $\overline{\rho}$ entre le prédicteur de persistance *Occ-1* et les autres prédicteurs est compris entre -0,2 et 0,2, alors que sa valeur absolue globale est située entre 0,2 et 0,6 pour quasiment tous les autres prédicteurs (excepté TCW, B, V, ∇FR, PV et W). Cette baisse de corrélation peut s'expliquer par le fait qu'une partie de la corrélation dérive de la forte saisonnalité de certaines de ces variables. A l'inverse, certains liens s'accentuent comme l'illustre le couple (R_2,$RTCW$) dont la valeur du coefficient est plus élevée. De même, une corrélation négative plus forte est visible pour les couples (Δ_θ, Δ_Z),(TCW,H), ($RTCW$,H),(PV,Δ_Z), (PV,B).

L'échantillonnage par les dates analogues a en moyenne pour effet de réduire la corrélation entre les prédicteurs. Cependant, il est probable qu'une valeur de corrélation moyenne proche de 0 résulte seulement d'une somme de jours de prédiction pour lesquelles les corrélations sont soit positives, soit

négatives. Les figures VII.5.a) et b) représentent le pourcentage de cas où ρ est supérieur à 0,6 ou inférieur à -0,6. Pour la majeure partie des couples de prédicteurs, la structure de corrélation est stable : pour l'ensemble des prédictions, la valeur de corrélation pour un couple de prédicteurs – dont les valeurs sont issues des dates analogues – est toujours positive ou toujours négative. Seules quelques couples de prédicteurs obtiennent à la fois des corrélations positives et négatives. Par exemple, V et F sont corrélés négativement dans 50% des cas (lorsque V est négatif) et corrélés positivement (lorsque V est positif) dans les autres cas. Un résultat similaire peut être retrouvé pour les couples (VR, FR) et (R_2, VR).

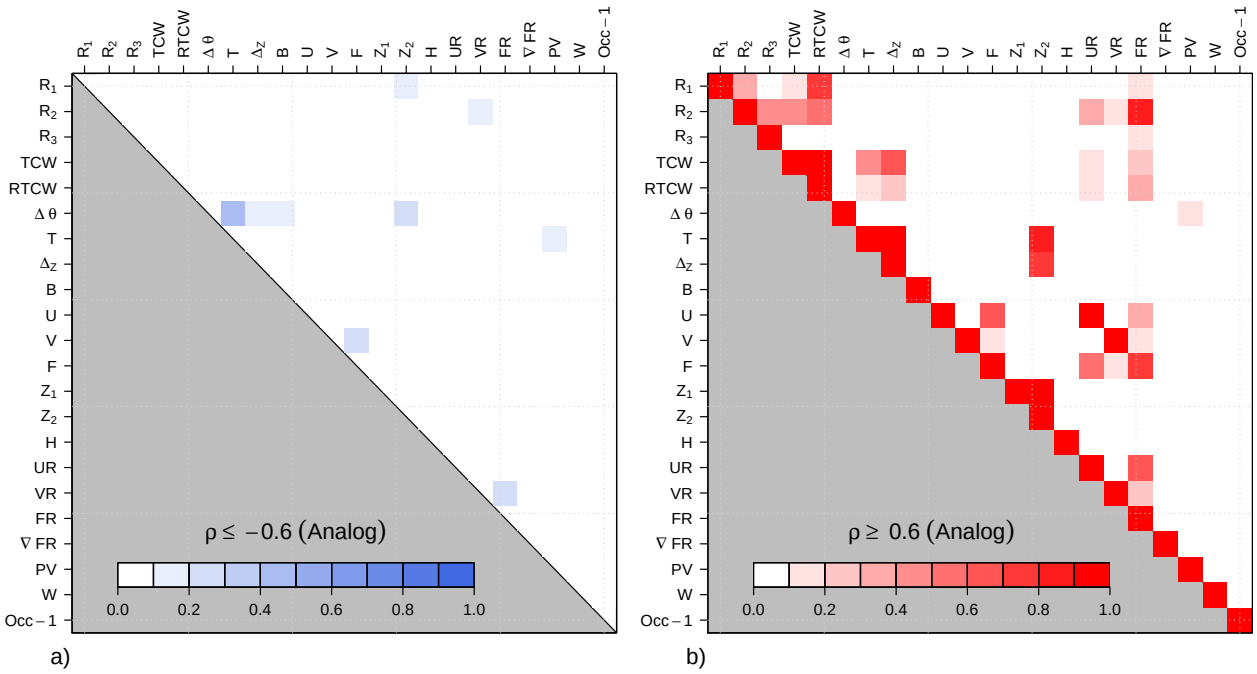

FIGURE VII.5 – Pourcentage de coefficients de corrélation de Spearman a) inférieurs à -0.6 et b) supérieurs à 0.6 estimés à partir des dates analogues pour la maille Safran NW.

Pour conclure, cette étude montre que l'ensemble des prédicteurs d'humidité (R_1, R_2, R_3, TCW et $RTCW$) sont fortement corrélés entre eux. Par construction, le prédicteur R_2 est de plus lié aux flux d'humidité UR, VR et FR. Pour la même raison, les prédicteurs dynamiques U, V et F sont eux aussi corrélés avec UR, VR et FR. Enfin, TCW et son dérivé $RTCW$ sont fortement corrélés avec les prédicteurs thermiques T et Δ_Z, eux-mêmes très liés à Z_2. Ces résultats sont similaires à ceux retrouvés lorsque l'étude de corrélation est développée sur les mailles d'accroche NE, SW et SE, de part la faible variabilité spatiale de ces prédicteurs à l'échelle du territoire français.

Par la suite, les deux prochains chapitres ont pour but de déterminer deux jeux de prédicteurs adaptés pour la prédiction de l'occurrence et de la quantité de précipitations. Pour chacune de ces deux variables (*i.e.* occurrence et quantité), une étude préliminaire consiste à évaluer le pouvoir prédictif de chaque prédicteur potentiel pris indépendamment. De façon à limiter les calculs, une sélection effectuée *a priori* sur la base de l'étude des corrélations peut être faite. Comme les prédicteurs d'humidité sont sélectionnés dans beaucoup d'études [*e.g.* ABAURREA & ASN, 2005 ; CAVAZOS & HEWISTON, 2005 ; MATHES et al., 2008 ; MEZGHANI & HINGRAY, 2009 ; FROST et al., 2011 ; ABDELLATIF et al., 2012 ; KENABATHO et al., 2012 ; CHUN et al., 2013], nous avons décidé de tous les retenir. De même, tous les prédicteurs de flux d'humidité ont été testés. Les prédicteurs U, V et F

Tableau VII.2 – Jeu de prédicteurs potentiels pour la détermination des modèles d'occurrence et de quantité.

Prédicteurs d'humidité	
R_1	Humidité relative à 850 hPa
R_2	Humidité relative à 700 hPa
R_3	Humidité relative à 500 hPa
TCW	Equivalent en eau dans la colonne d'atmosphère
$RTCW$	Produit de R_1 par TCW (équivalent à la seconde variable d'analogie du modèle MA utilisé dans la section 4.3 de Chardon et al. [2014])
Prédicteur d'instabilité thermo-dynamique	
$\Delta\theta$	Gradient de température potentielle entre les niveaux 925 et 700 hPa
Prédicteur caractéristique de zones de basse tropopause	
PV	Vorticité potentielle à 400 hPa
Prédicteurs thermiques	
T	Température à 700 hPa
B	Baroclinicité à 700 hPa
Prédicteurs dynamiques	
Z_1	Hauteur du géopotentiel à 1000 hPa
H	Hélicité intégrée entre 1000 et 500 hPa
Prédicteurs de flux d'humidité	
UR	Flux d'humidité méridional à 700 hPa
VR	Flux d'humidité zonal à 700 hPa
FR	Intensité du flux d'humidité à 700 hPa
∇FR	Divergence du flux d'humidité à 700 hPa
Prédicteurs de mouvement vertical	
W	Vitesse verticale à 700 hPa
Prédicteur d'autocorrélation temporelle	
Occ-1	Occurence de pluie de la veille du jour à prédire

n'ont pas été retenus car ils sont fortement corrélés aux flux d'humidité. Une autre raison justifiant de ce choix est que U, V et F apportent *a priori* une information similaire à celle incluse dans les dates analogues (basées sur les hauteurs de géopotentiels et informant sur l'origine et l'intensité des flux). Les hauteurs de géopotentiel Z_1 et Z_2 étant fortement corrélées entre elles, seule Z_1 est conservée car elle n'est pas corrélée avec Δ_Z et T (contrairement à Z_2). De même, comme Δ_Z et T sont fortement corrélés, seul le prédicteur T est retenu. Finalement, les prédicteurs restants (*i.e.* Δ_θ, B, H, ∇FR, W, PV et *Occ-1*) ont tous été retenus car ils présentent des corrélations plus faibles avec l'ensemble des variables. La liste de prédicteurs potentiels pour l'établissement des modèles d'occurrence et de quantité est fournie dans le tableau VII.2.

Chapitre VIII

Détermination d'un modèle régressif unique d'occurrence des précipitations

Avant de commencer l'étude, certains tests préliminaires non étayés dans ce document ont été effectués. Une première étude de sensibilité a montré qu'un prédicteur journalier agrégé de 6h00 UTC J jusqu'à 06h00 UTC J+1 était plus adapté qu'une agrégation temporelle journalière couvrant la période 00h00 UTC à 23h00 UTC. Une raison probable expliquant ce résultat est que la fenêtre 06h00 UTC J à 06h00 UTC J+1 correspond à la fenêtre d'agrégation des précipitations journalières. De plus, sur la base du prédicteur d'analogie de second niveau du modèle MA utilisé à la section 4.3 de Chardon et al. [2014], une seconde étude préliminaire a mis en évidence qu'un nombre N_d égal à 100 dates analogues permettait d'obtenir avec le modèle combiné MA+GLM les meilleures performances en terme de CRPSS. Par suite, le nombre de dates analogues utilisé pour chaque prédiction pour la combinaison des modèles est égal à 100 et le modèle combiné est noté MA_{100}+GLM. Dans ce chapitre et les chapitre suivants, les performances du modèle MA_{100}+GLM seront comparées avec celles d'un modèle MA basé sur une analogie des hauteurs de géopotentiel. Pour une maille Safran donnée, les 100 dates analogues utilisées pour le modèle MA_{100}+GLM correspondent à celles issues du modèle MA localement optimisé pour la maille considérée. Pour le modèle MA, nous avons déterminé à la section 1 du chapitre III que le nombre de dates analogues optimal à retenir était égal à 25. Ce modèle est noté par la suite MA_{25}. Similairement, un modèle MA retenant les cent premières dates analogues sera noté MA_{100} par la suite.

Dans le présent chapitre, l'évaluation du pouvoir prédictif de chaque prédicteur retenu à la section 3 du chapitre VII permet de sélectionner plusieurs jeux de prédicteurs informatifs pour la prédiction de l'occurrence de précipitation (section 1). Nous en déduisons ensuite le groupe de prédicteurs optimal (section 2). Nous évaluons enfin la performance du modèle d'occurrence obtenu avec ce jeu de prédicteurs (section 3).

1. Pouvoir prédictif de chacun des prédicteurs

Dans cette section, nous déterminons les prédicteurs – parmi ceux listés dans le tableau VII.2 – pour lesquels le modèle combiné MA_{100}+GLM apporte un gain de performance par rapport au modèle MA_{25}. Le gain de performance ΔBSS obtenu pour une maille Safran donnée est défini comme :

$$\Delta\text{BSS} = \text{BSS}_{\text{MA}_{100}+\text{GLM}} - \text{BSS}_{\text{MA}_{25}} \tag{VIII.1}$$

où $\text{BSS}_{\text{MA}_{100}+\text{GLM}}$ correspond à la performance en BSS obtenue par le modèle combiné MA_{100}+GLM et $\text{BSS}_{\text{MA}_{25}}$ correspond à la performance en BSS obtenue par le modèle MA_{25} de référence. Si pour un prédicteur donné, la différence ΔBSS est positive, cela indique que le modèle combinant le GLM avec les dates analogues est en moyenne plus informatif que le modèle MA_{25} (et inversement dans le cas contraire).

Les figures VIII.1 et VIII.2 représentent la distribution spatiale de ΔBSS pour l'ensemble des prédictions émises. Parmi l'ensemble des prédicteurs, les prédicteurs d'humidité R_1, R_2, TCW et $RTCW$ apparaissent comme étant les plus explicatifs de la probabilité d'occurrence des précipitations en France. De manière générale, le gain est plus important sur les reliefs (*i.e.* Pyrénées, Massif Central et Alpes) et sur le bord méditerranéen – où il peut atteindre jusqu'à 0,10 – qu'en plaine. Seul le prédicteur R_3 obtient un nombre important de mailles Safran pour lesquelles une perte est observée, excepté dans le Sud-Est où des gains sont observés. On peut en déduire qu'il vaut mieux inclure dans le modèle MA_{100}+GLM de l'humidité dans la basse troposphère (ici à 850 et 700 hPa) plutôt qu'à un niveau de pression plus élevé (*i.e.* 500 hPa). Pour TCW, le gain obtenu varie graduellement de 0 à partir de la Bretagne et du Nord de la France à 0,04 sur les Alpes. L'information apportée par ce prédicteur est plus importante dans le quart Sud-Est de la France où un gain supérieur à 1 point de BSS est observé. Enfin, les gains obtenus par les prédicteurs R_2 et $RTCW$ s'avèrent être les plus homogènes sur le territoire français et plus importants (environ 4,5 points de BSS) que ceux obtenus par le prédicteur R_1. Cependant, R_2 et $RTCW$ étant corrélés entre eux (*cf.* section 3 du chapitre VII), il est nécessaire de retenir un seul de ces deux prédicteurs pour caractériser l'humidité dans l'atmosphère. Le prédicteur $RTCW$ étant plus corrélé à la température, R_2 sera le seul retenu par la suite pour la prédiction de l'occurrence.

Les gains/pertes des prédicteurs UR, VR et FR sont représentés sur la figure VIII.2. Les gains obtenus par UR se situent seulement sur les Alpes (où le gain est maximum, à savoir de 4 points de BSS) et quelques mailles du pourtour Méditerranéen. En dehors de ces deux régions, des pertes atteignant 2 points de BSS sont observées. Pour VR, des valeurs plus faibles de gains (proches de 1 point de BSS) sont observées. Ces gains se situent pour leur majorité sur la partie Est de la France. De même, des pertes sont observées sur la partie Ouest. Seul le prédicteur FR obtient des gains en BSS sur l'ensemble du territoire. Ces gains sont en moyenne égaux à 1 point de BSS et peuvent même atteindre 4 points sur le Nord des Alpes. Au regard des autres prédicteurs (excepté les prédicteurs d'humidité), combiner le flux d'humidité FR à la dynamique décrite par les dates analogues s'avère être une opération judicieuse. Toutefois, même si nous avons montré ici l'intérêt d'utiliser FR, ce dernier reste par construction corrélé au prédicteur R_2 précédemment retenu (voir figures VII.4.b) et VII.5.b). Pour les questions de multi-colinéarité évoquées précédemment et parce que le prédicteur

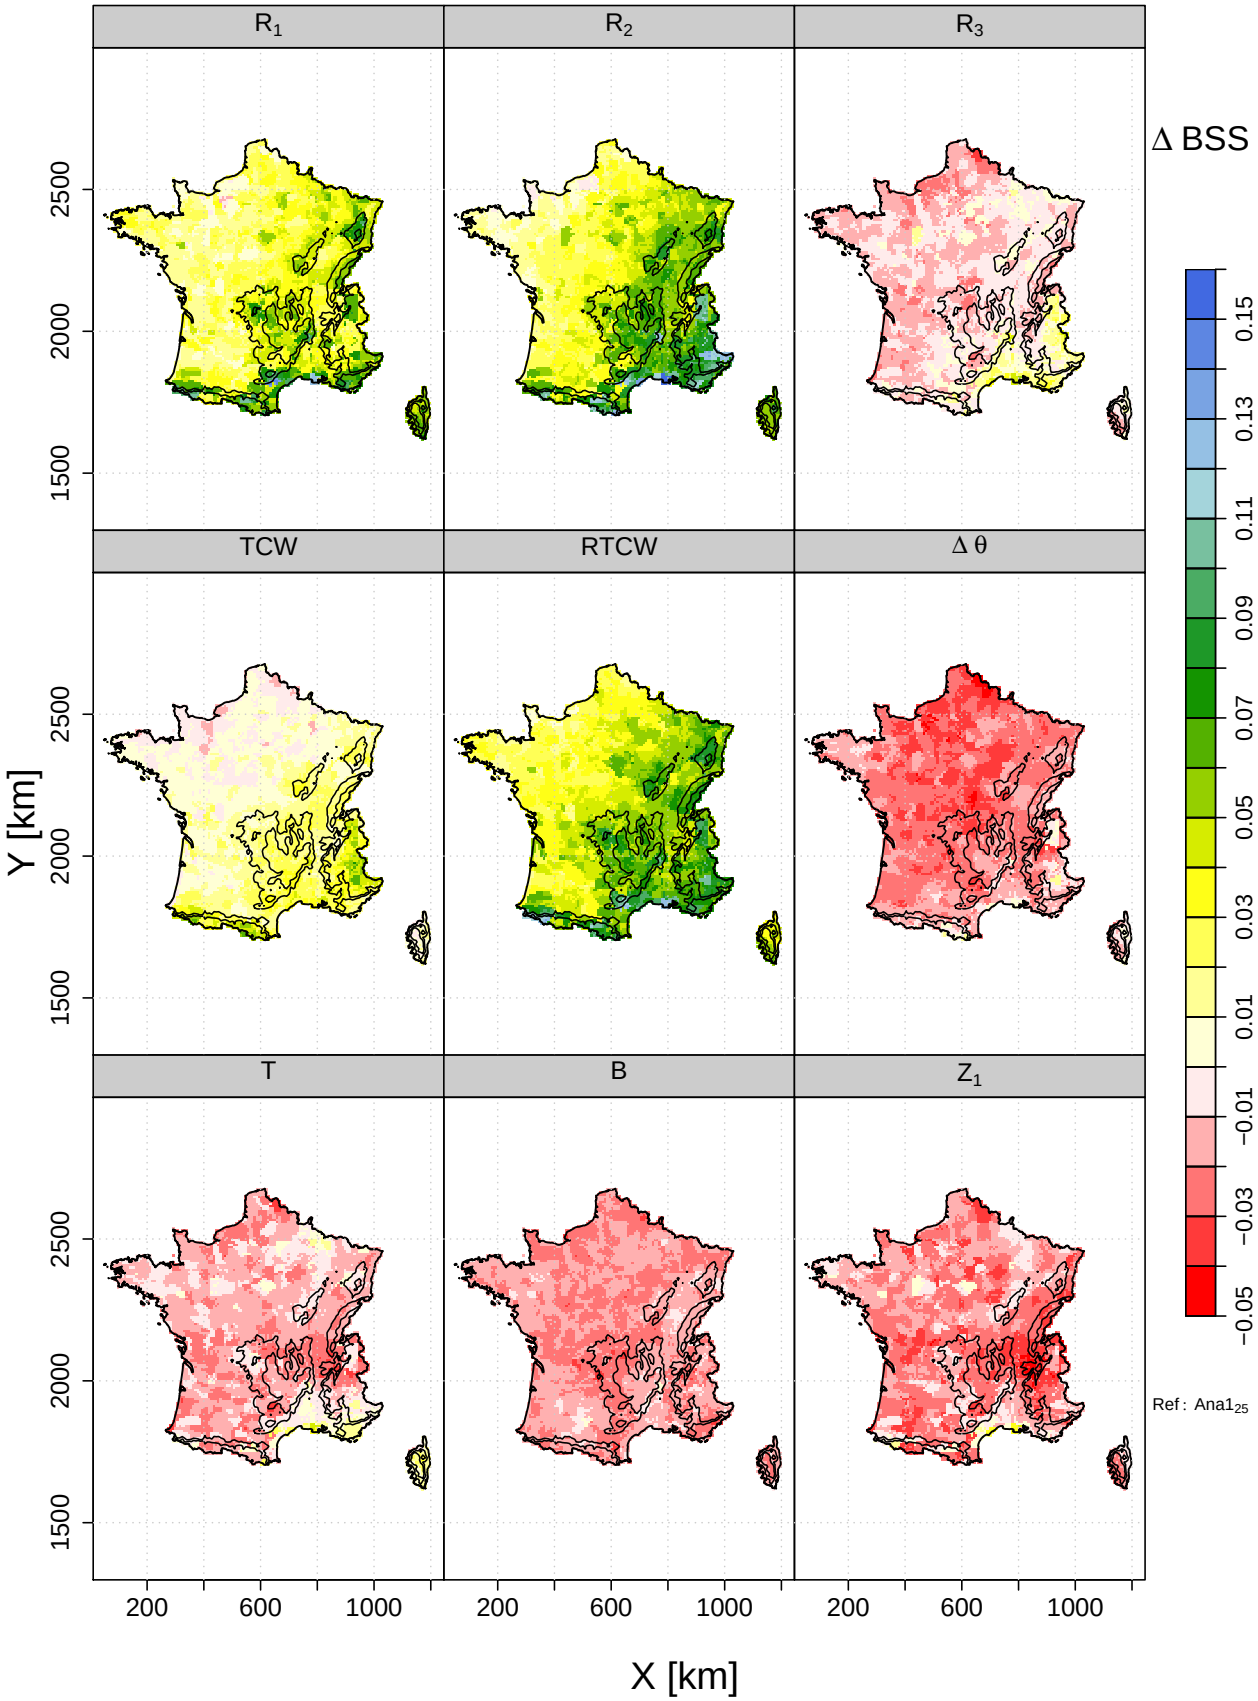

FIGURE VIII.1 – ΔBSS obtenu entre un modèle combiné MA_{100}+GLM uniprédicteur (prédicteurs R_1, R_2, R_3, TCW, $RTCW$, $\Delta\theta$, T, B et Z_1) et le modèle MA_{25} de référence.

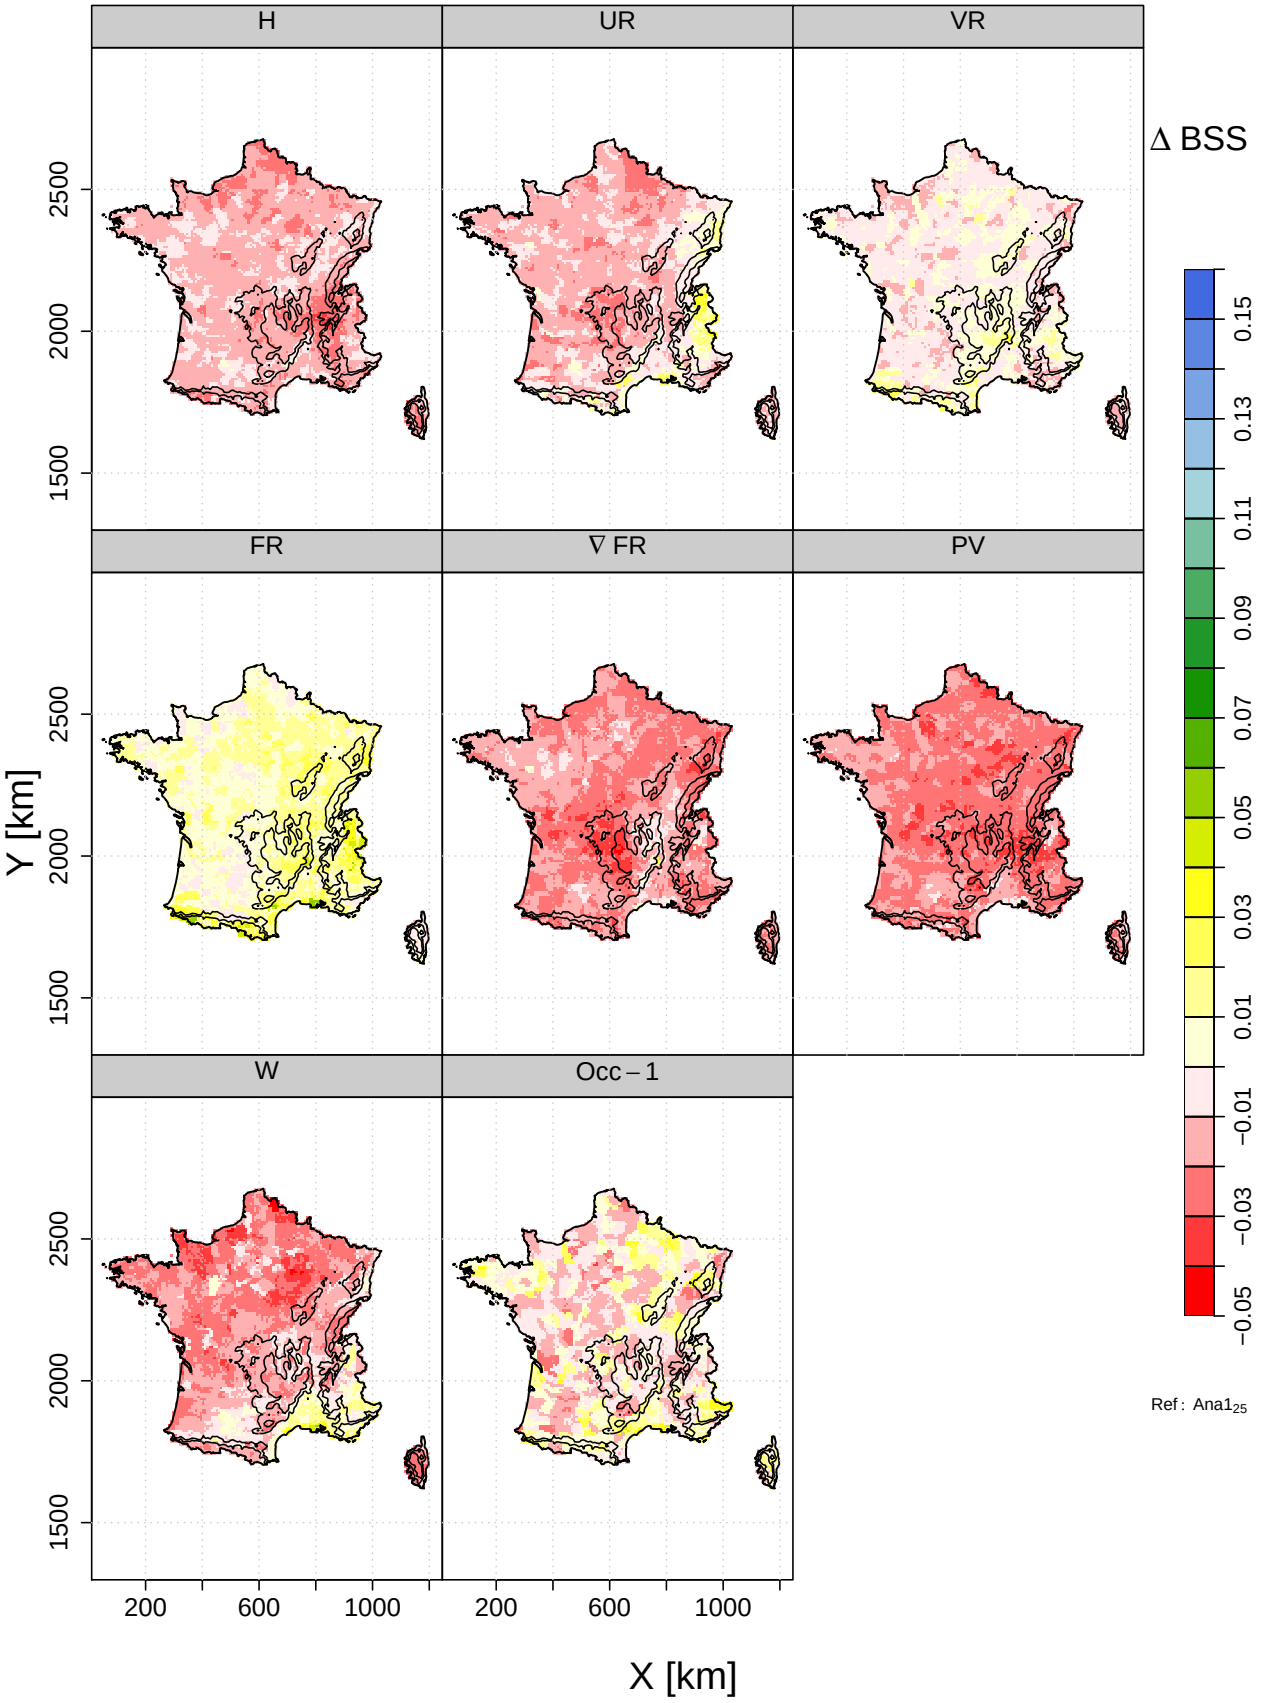

FIGURE VIII.2 – Idem que la figure VIII.1 pour les prédicteurs H, UR, VR, FR, ∇FR, PV, W et *Occ-1*.

d'humidité R_2 conduit à de meilleures performances, le prédicteur FR n'est finalement pas inclus dans le modèle.

Parmi les autres prédicteurs, l'utilisation de T et W conduit seulement à un léger gain (0,02 au maximum) pour la région méditerranéenne et la vallée du Rhône. Le prédicteur de persistance *Occ-1* obtient lui aussi des gains proches de 0,02 mais la structure spatiale de ces gains est plus aléatoire. Les variables $\Delta\theta$, B, Z_1, H, ∇FR et PV conduisent quant à elles à des pertes sur tout le territoire. Cependant, il est possible que dans certaines situations particulières (*e.g.* pour un type de circulation atmosphérique donné), ces prédicteurs s'avèrent pertinents. Une évaluation des performances en BSS par type de temps montre qu'un gain peut s'obtenir pour certains des prédicteurs, comme par exemple pour le type de temps 8 où les prédicteurs $\Delta\theta$, B, H et ∇FR apportent pour certaines régions un gain en BSS (figure VIII.3). Les prédicteurs et les types de temps correspondants, pour lesquels des gains en BSS ont été observés à l' échelle d'une région, sont listés dans le tableau VIII.1. La représentation des gains obtenus par chaque couple (type de temps, prédicteur) est fournie à l'annexe D.1.

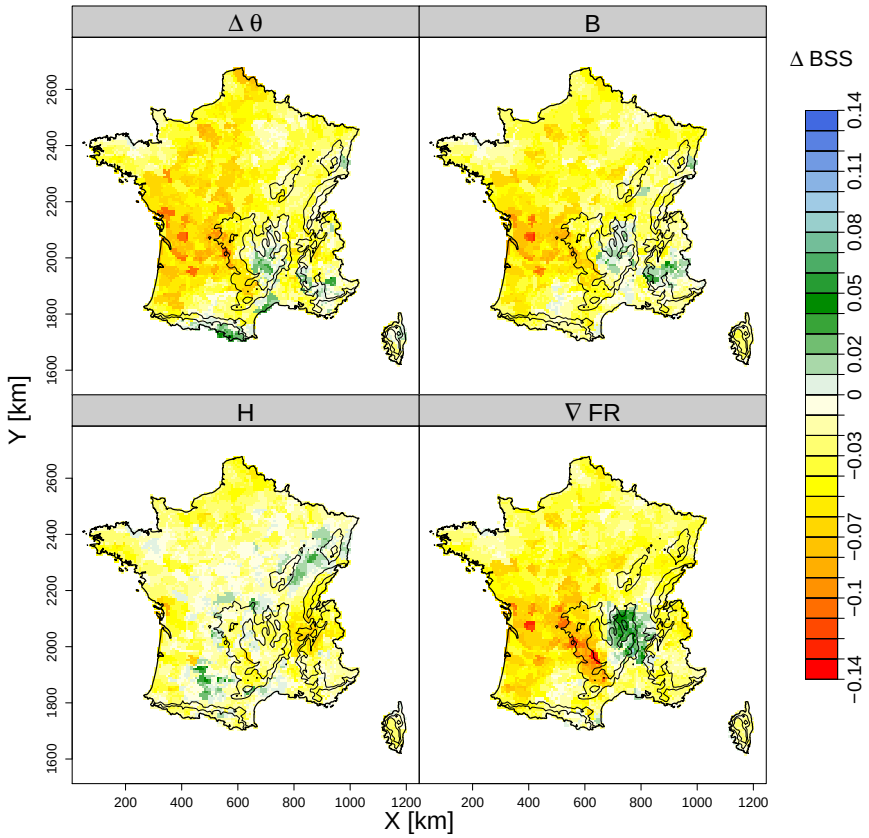

FIGURE VIII.3 – Gains en BSS obtenus par les modèles d'occurrence seulement basés sur les prédicteurs Δ_θ, B, Z_1, H et ∇FR pour le type de temps 8.

Tableau VIII.1 – Types de temps pour lesquels les prédicteurs Δ_θ, B, Z_1, H et ∇FR apportent un gain de BSS par rapport à MA_{25}.

Prédicteurs	Type de temps
$\Delta\theta$	8
B	8
Z_1	1,2,6,7
H	6,8
∇FR	2,8

Parmi les prédicteurs initialement testés, les prédicteurs R_2, $\Delta\theta$, T, B, Z_1, H, ∇FR, W et *Occ-1* constituent un ensemble final de neuf prédicteurs potentiels pour la détermination d'un modèle d'occurrence unique pour la France.

2. Optimisation du modèle d'occurrence

Une des qualités recherchée de notre modèle constitue à s'adapter en fonction des situations de grande échelle et des endroits géographiques par la sélection des prédicteurs et l'estimation des paramètres de la régression. Similairement à l'étude menée par Woodcock [1980] pour la prévision de la température maximale journalière, l'adaptation du lien régressif se traduit ici par la sélection d'un jeu de prédicteurs choisis dans un ensemble de prédicteurs potentiels. De part cette adaptation prédictive, nous pensions *a priori* qu'un modèle basé sur l'ensemble des neuf prédicteurs identifiés à la section 1 conduirait dans le pire des cas aux mêmes performances qu'un modèle basé sur un nombre restreint de ces prédicteurs. La réalité est cependant différente. Lorsque l'ensemble des prédicteurs retenus à la section 1 sont introduits dans le modèle MA_{100}+GLM, les performances observées s'avèrent plus faibles qu'un modèle basé sur un sous-échantillon de prédicteurs. Plusieurs causes peuvent être à l'origine de ce résultat :

- Premièrement, la non-indépendance des prédicteurs peut être mise en cause. Même si une étude basée sur la corrélation des prédicteurs a permis d'écarter certains couples de prédicteurs corrélés, des relations multi-colinéaires peuvent tout de même exister entre des triplets ou des ensembles plus nombreux de prédicteurs (*cf.* section 2.2 de l'annexe D).
- Deuxièmement, le nombre de dates analogues (*i.e.* 100) peut être potentiellement trop faible pour l'établissement d'un lien régressif basé sur un grand nombre de prédicteurs (par exemple 5 ou 6). L'estimation des coefficients devient dans ce cas peu fiable, menant ainsi à de plus fortes erreurs lors de la prédiction de l'occurrence des précipitations. Pour permettre une estimation plus fiable des coefficients lors de l'utilisation d'un grand nombre de prédicteurs, on pourrait augmenter le nombre de dates analogues. En revanche, cela reviendrait à dégrader l'information portée par ces dernières menant à réduire leur capacité de discrimination entre les prédictions.

Par suite, la détermination d'un ensemble de prédicteurs adaptés pour la prédiction de l'occurrence a été effectuée en trois étapes :

1. Sur la base des neuf prédicteurs retenus à la section 1, une optimisation du jeu de prédicteurs a été effectuée pour chaque maille d'accroche à l'aide d'un algorithme de sélection itérative combinant

l'inclusion et l'exclusion (*cf.* section 2.3.3 du chapitre VI). Nous avons alors constaté i) que l'ensemble des modèles retenus retenait le prédicteur R_2 et ii) que le nombre de prédicteurs issus de chacune des optimisations variait entre deux et quatre. Par la suite, nous avons décidé que le jeu de prédicteurs du modèle d'occurrence unique pour la France devait comporter quatre prédicteurs dont l'un d'entre eux devait être l'humidité R_2.

2. Dans une seconde étape, l'ensemble des combinaisons possibles (56 au total) de trois prédicteurs – auxquelles le prédicteur R_2 est ajouté – ont été explorées pour la prédiction de l'occurrence de précipitation en chaque maille d'accroche. Pour chacune de ces mailles, la combinaison de quatre prédicteurs qui obtient la meilleure performance en BSS est conservée. Les combinaisons retenues sont listées dans le tableau VIII.2. On remarque alors que le prédicteur *Occ-1* constitue un prédicteur important pour le modèle d'occurrence car il est retenu par 6 modèles sur les 7 déterminés. L'information de mouvement vertical (représentée par le prédicteur W de vitesse verticale et se retrouvant dans le prédicteur de divergence ∇FR) est présente dans 5 modèles. Enfin, la combinaison des prédicteurs précédents avec un prédicteur faisant intervenir la température (T, B ou encore $\Delta\theta$) représente la principale structure retenue pour la prédiction de l'occurrence de précipitation.

Tableau VIII.2 – Combinaisons optimales de quatre prédicteurs pour chaque maille d'accroche pour la prédiction de l'occurrence de précipitation.

Dénominations	Combinaisons	Maille d'accroche
ModOcc1	$R_2 + T + H + \nabla FR$	NW
ModOcc2	$R_2 + \nabla FR + W + Occ\text{-}1$	N,NE,E
ModOcc3	$R_2 + H + W + Occ\text{-}1$	W,MC,SE
ModOcc4	$R_2 + B + W + Occ\text{-}1$	C
ModOcc5	$R_2 + B + H + Occ\text{-}1$	SW
ModOcc6	$R_2 + T + \nabla FR + Occ\text{-}1$	B
ModOcc7	$R_2 + T + H + Occ\text{-}1$	S,Co

3. Dans un troisième temps, chaque combinaison de prédicteurs déterminée à l'étape 2 a été testée pour la prédiction de l'occurrence en chacune des mailles Safran. Le gain de performance en BSS obtenu par chacune de ces combinaisons est représenté sur la figure VIII.4. On remarque que la distribution spatiale du gain est la même pour l'ensemble des modèles et seules quelques faibles variations du gain peuvent être remarquées. D'une manière générale, un gain faible – variant de 0,02 à 0,05 – est rencontré le long de la côte Atlantique tandis qu'il s'accroît lorsque l'on se déplace vers l'Est atteignant des valeurs proches de 0,08. Le gain est maximal sur les reliefs (Alpes, Pyrénées et Massif Central) où il peut être localement égal à 0,15. Cette similarité spatiale entre les distributions de gains est due à la présence du prédicteur R_2 dans chacune des combinaisons. En effet, on peut remarquer qu'une distribution spatiale de gain similaire est observée lorsqu'un modèle d'occurrence seulement basée sur le prédicteur R_2 est utilisé (*cf.* figure VIII.1).

   Sur la figure VIII.4, les plus faibles gains sont obtenus sur la côte Atlantique. Les dates analogues apportent donc déjà une grande part de l'information nécessaire dans cette région. A l'inverse, dans le Sud-Est, des gains importants sont observés. Pour cet endroit, les dates analogues sont

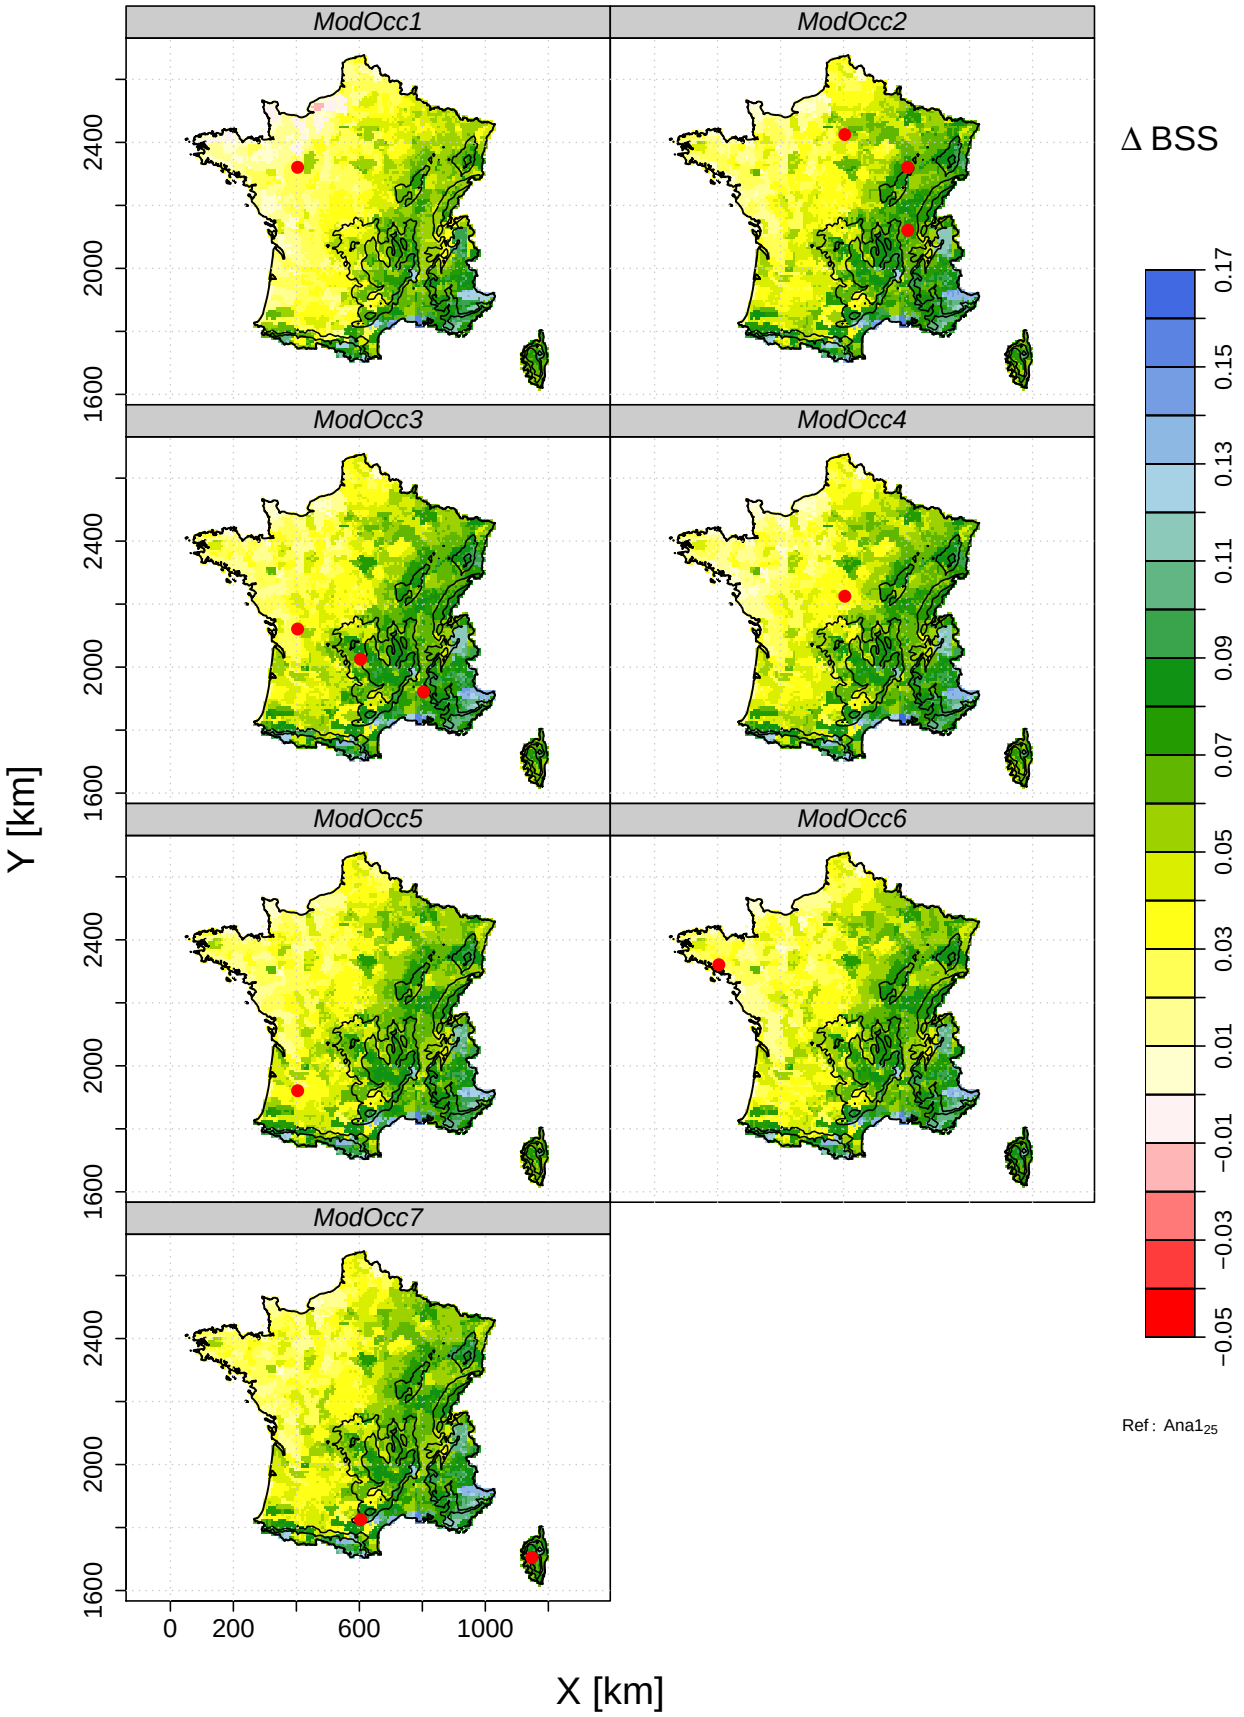

FIGURE VIII.4 – Gain en BSS obtenu sur la France par chacun des modèles d'occurrence listés dans le tableau VIII.2. Les points rouges représentent les mailles Safran pour lesquelles le modèle d'occurrence considéré est optimal.

insuffisamment informatives et il est alors intéressant de rajouter de l'information disponible au travers des prédicteurs de second ordre.

Pour la suite de cette étude, nous retenons un unique modèle d'occurrence pour l'ensemble de la France. Nous choisissons le modèle ModOcc3 qui obtient globalement les meilleures performances moyennes (environ 5,5 points de CRPSS). Comme observé sur la figure VIII.5 montrant le meilleur modèle d'occurrence parmi ceux listés dans le tableau VIII.2 pour chaque maille Safran, il s'agit du modèle obtenant les meilleures performances pour une grande partie des mailles Safran (environ 30%).

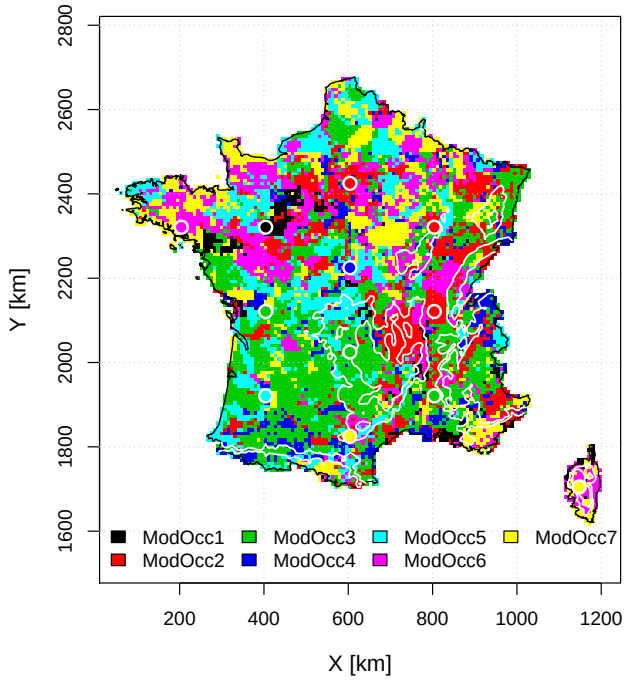

FIGURE VIII.5 – Distribution spatiale du meilleur modèle d'occurrence parmi ceux listés dans le tableau VIII.2 en chaque maille Safran. Les lignes de reliefs sont ici représentées en blanc.

3. Etude du modèle unique d'occurrence

3.1. Adaptation dans le temps

Dans cette section, nous nous attachons à étudier le comportement du modèle d'occurrence unique retenu pour la France à la section 2. Plus précisément, nous souhaitons vérifier la capacité recherchée du modèle ModOcc3 à s'adapter en fonction des prédictions. Pour chaque prédiction, le modèle MA_{100}+GLM détermine une combinaison de prédicteurs adaptée (parmi les prédicteurs R_2, H, W et *Occ-1*) sur la base d'un algorithme de sélection itérative basé sur les méthodes d'inclusion et d'exclusion (*cf.* section 2.3.3 du chapitre VI). La combinaison de prédicteurs retenue peut alors être l'une des quinze combinaisons listées dans le tableau VIII.3. Ces combinaisons sont dénommées par la suite sous les termes de *"structures régressives"* et un numéro leur est attribué : plus le numéro de la structure est élevé, plus le modèle d'occurrence est complexe, car il utilise plus de prédicteurs. Lorsqu'aucune de ces combinaisons n'a pu être retenue – car les contraintes de significativité des

coefficients n'ont pas pu être respectées – le modèle alternatif est utilisé (*cf.* section 3.2 du chapitre VI).

Tableau VIII.3 – Ensemble des structures régressives proposées par le modèle d'occurrence unique retenu pour la France à la section 2.

Structure régressive	Prédicteurs
Str. n° 1	R_2
Str. n° 2	H
Str. n° 3	W
Str. n° 4	*Occ-1*
Str. n° 5	$R_2 + H$
Str. n° 6	$R_2 + W$
Str. n° 7	R_2+*Occ-1*
Str. n° 8	$H + W$
Str. n° 9	H+*Occ-1*
Str. n° 10	W+*Occ-1*
Str. n° 11	$R_2 + H + W$
Str. n° 12	$R_2 + H$+*Occ-1*
Str. n° 13	$R_2 + W$+*Occ-1*
Str. n° 14	$H + W$+*Occ-1*
Str. n° 15	$R_2 + H + W$+*Occ-1*

La figure VIII.5.a) représente la distribution du score de Brier **journalier** obtenu par le modèle d'occurrence en fonction du nombre de prédicteurs utilisés dans la structure régressive sélectionnée pour la maille d'accroche NW. Le cas où l'ensemble des quatre prédicteurs est utilisé n'est pas robuste de part le faible nombre de prédictions pour lesquelles la structure 15 est échantillonnée. Sur la figure VIII.5.a), on remarque que les valeurs de BS journaliers sont les plus faibles pour les structures n'utilisant qu'un seul prédicteur (*i.e.* les structures 1 à 4). Plus la structure utilise de prédicteurs, plus l'erreur en BS est importante.

La figure VIII.6.b) représente la distribution des ΔBS **journaliers** obtenus par le modèle MA_{100}+GLM par rapport au modèle MA_{25} en fonction du nombre de prédicteurs utilisés par la structure régressive. Pour une prédiction i, le $\Delta\mathrm{BS}_i$ est défini comme :

$$\Delta\mathrm{BS}_i = \mathrm{BS}_{i,\mathrm{MA}_{25}} - \mathrm{BS}_{i,\mathrm{MA}_{100}+\mathrm{GLM}} \tag{VIII.2}$$

où $\mathrm{BS}_{i,\mathrm{MA}_{25}}$ et $\mathrm{BS}_{i,\mathrm{MA}_{100}+\mathrm{GLM}}$ correspondent respectivement au BS obtenus pour le modèle MA_{25} et MA_{100}+GLM. Comme le BS est toujours positif et que sa valeur optimale est égale à zéro, les cas où $\Delta\mathrm{BS}_i$ est positif indique que le modèle MA_{100}+GLM obtient une erreur en BS plus faible que celle du modèle MA_{25}. S'il est négatif, l'inverse est obtenu.

Sur la figure VIII.6.b), on remarque que les $\Delta\mathrm{BS}_i$ ne sont pas tous positifs. Le modèle combiné MA_{100}+GLM obtient une erreur en BS de prédiction plus importante pour environ 40% des cas où chaque structure régressive est appliquée. Lorsque le ΔBS est positif, on remarque que le nombre de prédicteurs utilisés n'influence pas les gains observés. En revanche, les ΔBS négatifs les plus faibles sont obtenus lorsque le nombre de prédicteurs utilisés dans la structure régressive est important.

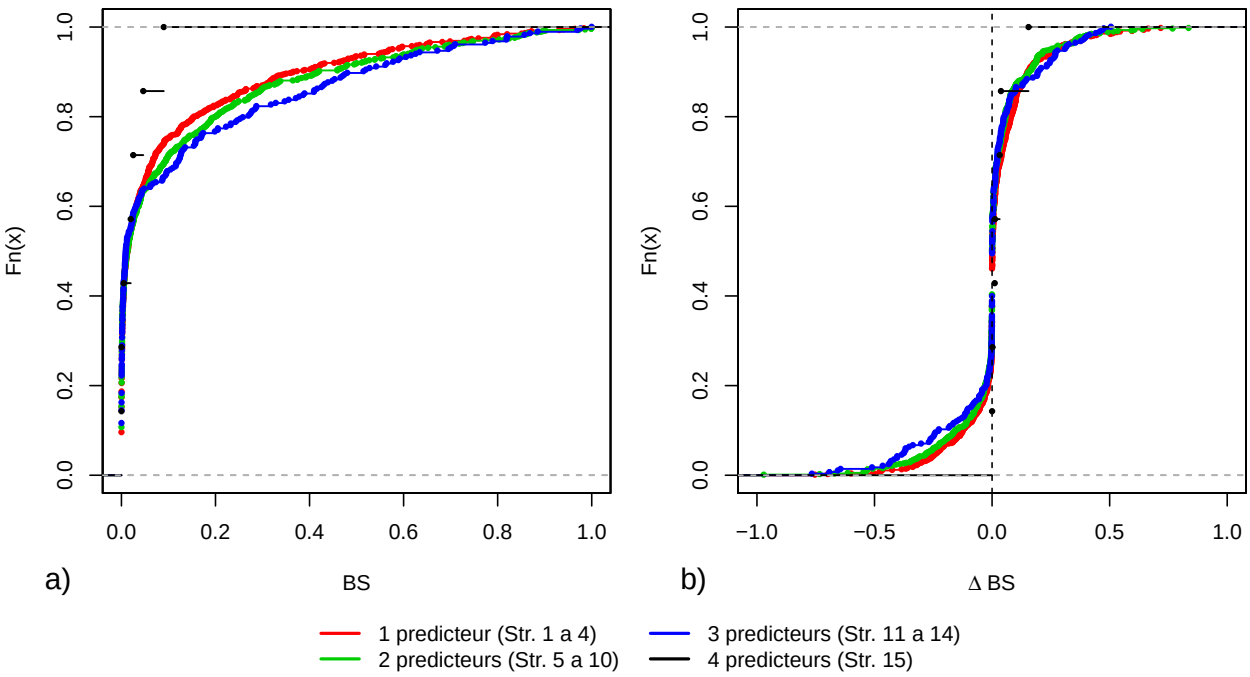

FIGURE VIII.6 – Distributions a) du score de Brier journalier BS et b) du ΔBS obtenus par le modèle MA_{100}+GLM par rapport au modèle MA_{25} en fonction du nombre de prédicteurs considérés dans les structures régressives listées dans le tableau VIII.3. Application à la maille d'accroche NW.

3.1.1. Fréquence d'échantillonnage des structures régressives

La figure VIII.7 représente les fréquences d'échantillonnage des différentes structures régressives – ainsi que celle du modèle MA_{25} – contenus dans le modèle d'occurrence unique France. La fréquence d'échantillonnage du modèle alternatif MA_{25} a été ajoutée à celles des structures régressives. De la même manière, la figure VIII.8 représente la différence d'erreur journalière moyenne en BS obtenue par chacune des structures régressives. A partir de ces deux figures, on peut déduire que :

- Parmi les structures régressives disponibles dans le modèle d'occurrence, seules quelques unes d'entre elles sont échantillonnées en moyenne plus de 10% des prédictions (figure VIII.7). Il s'agit des structures n° 1 (R_2), n° 6 ($R_2 + W$), n° 7 (R_2+*Occ-1*) et n° 13 ($R_2 + W$+*Occ-1*). Ces structures sont toutes basées sur le prédicteur R_2 et obtiennent toutes des ΔBS positifs sur l'ensemble de la France (figure VIII.8), excepté en Bretagne pour les structures n° 6 et n° 13. La structure n° 1 basée sur le prédicteur R_2 est celle qui est retenue le plus de fois sur l'ensemble du territoire, excepté en Bretagne où le modèle alternatif MA_{25} est plus de fois échantillonné (jusqu'à 40%). Pour les autres structures, l'échantillonnage est quasiment nul sur l'ensemble du territoire et ne permet pas une évaluation robuste. Par conséquent, la distribution des $\Delta\overline{BS}$ pour ces structures ne possède pas d' organisation spatiale.
- L'échantillonnage d'une structure dépend de la région considérée. Par exemple, la structure n° 1 (R_2) est plus de fois sollicitée dans le Sud-Est de la France (jusqu'à 45% des prédictions) tandis que son échantillonnage est seulement de 15% en certaines mailles situées à l'Ouest du Massif Central.
- Certaines structures peuvent être fortement sollicitées à l'échelle locale. Par exemple, la structure n° 6 ($R_2 + W$) est plus fortement sollicitée sur les plaines du Nord-Est de la France (jusqu'à 30%)

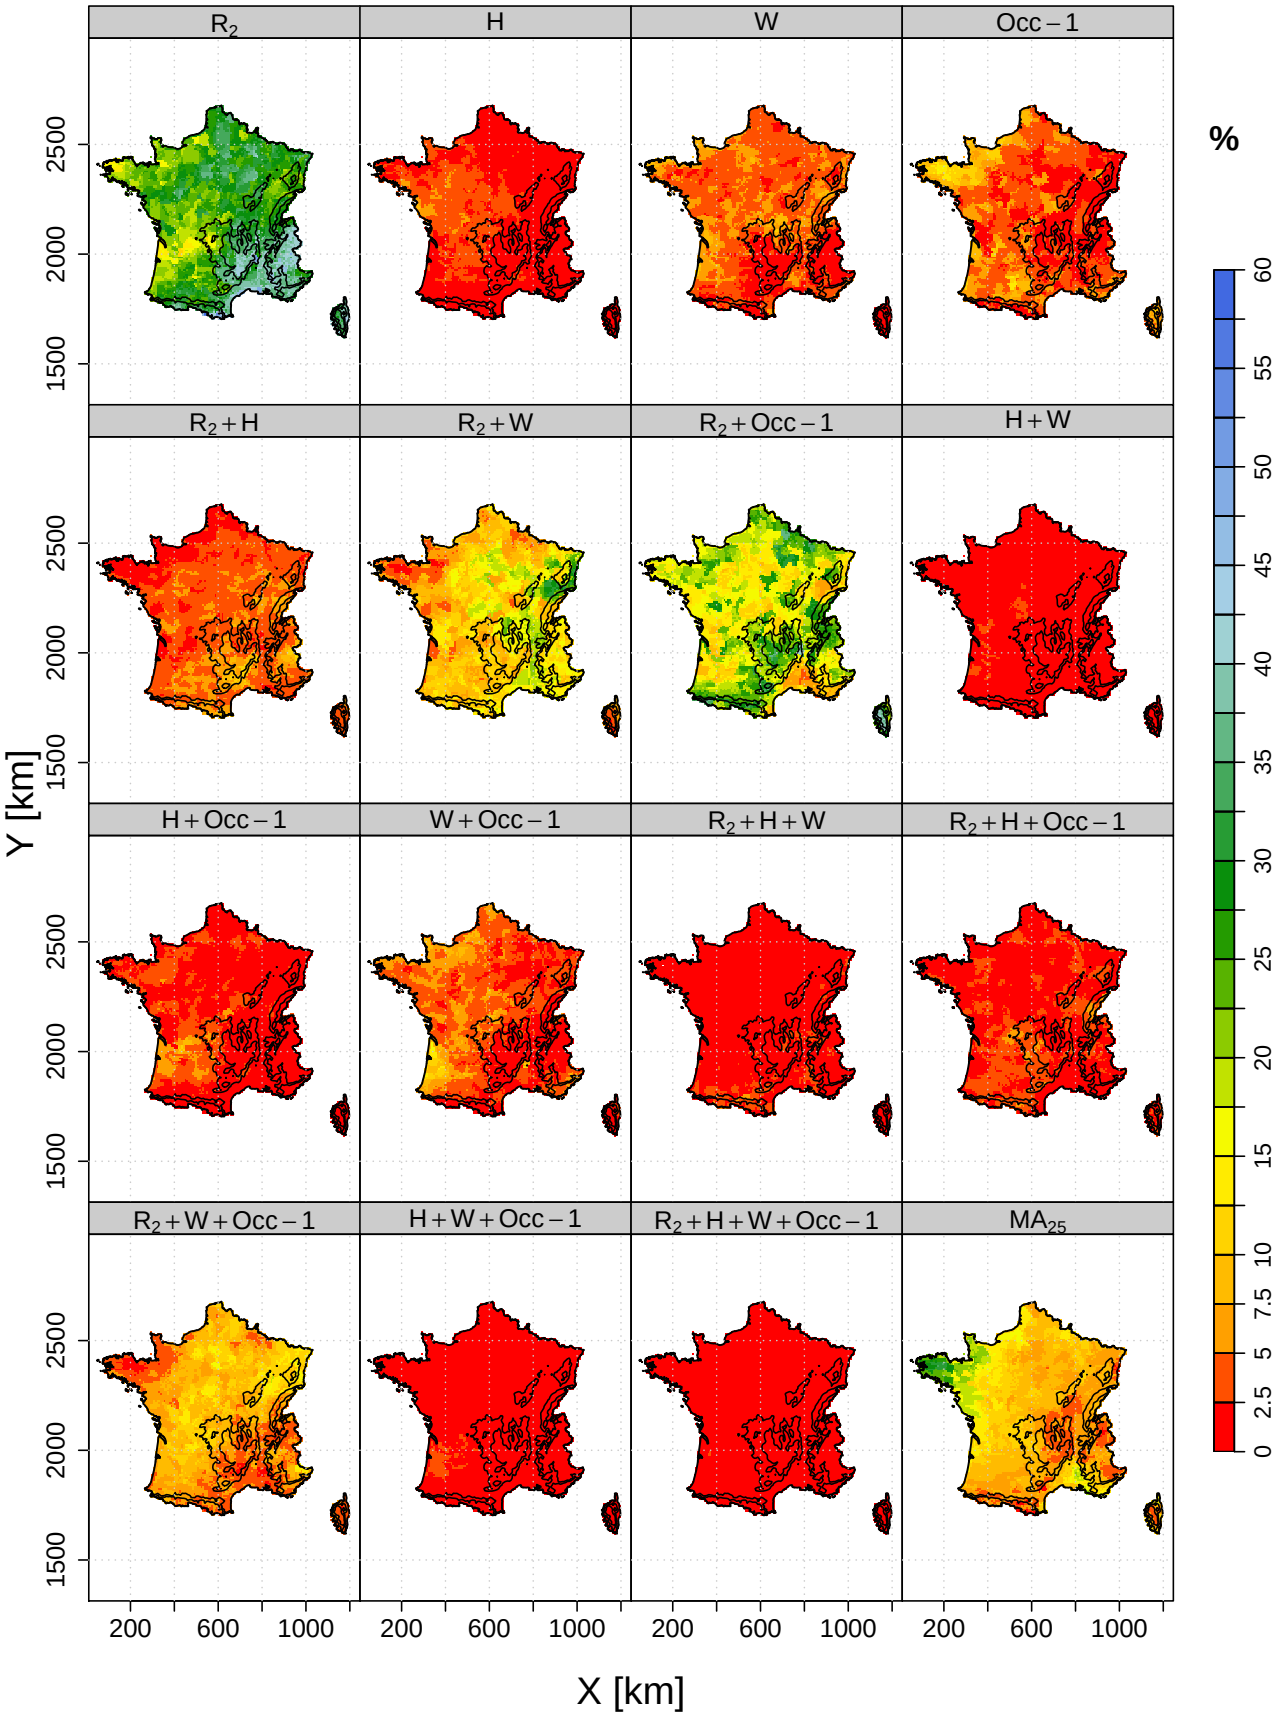

FIGURE VIII.7 – Fréquence d'échantillonnage des structures régressives et du modèle MA_{25} du modèle d'occurrence unique pour la France.

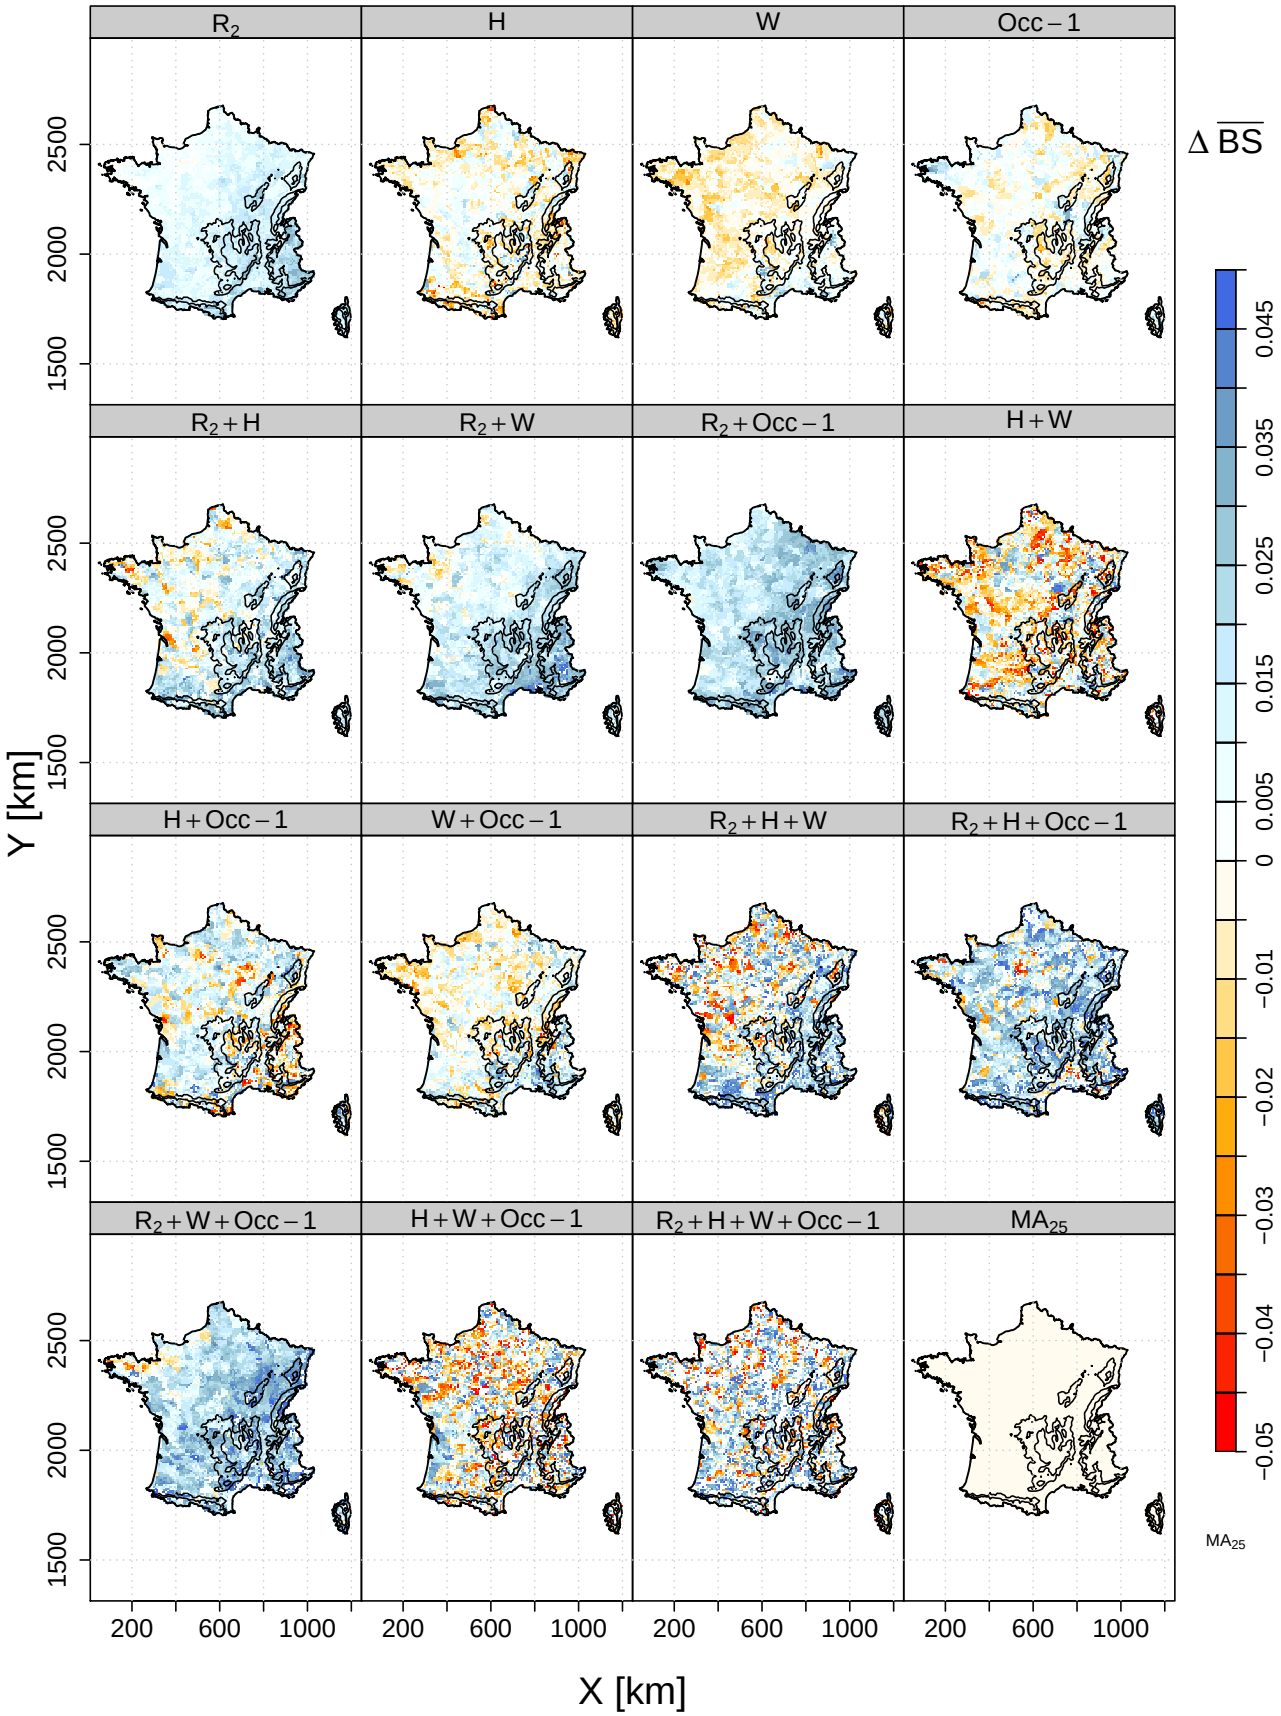

FIGURE VIII.8 – Gains et pertes moyennes en BS obtenues par les structures régressives et le modèle MA_{25} issus du modèle d'occurrence unique pour la France.

et dans la vallée du Rhône (jusqu'à 20%) alors qu'elle est sollicitée en moyenne 10% des cas pour le reste du territoire. La structure n° 7 peut elle aussi être fortement sollicitée à une échelle locale, comme par exemple le Nord des Alpes, le Massif central et les Vosges (jusqu'à 30%).

- Enfin, la fréquence d'échantillonnage du modèle alternatif MA_{25} est la plus élevée en Bretagne. Pour la maille d'accroche B située dans cette région, le pourcentage de fois ou MA_{25} est sollicité correspond à 25% des prédictions. Pour ces prédictions, la valeur moyenne de la probabilité fournie par les 100 dates analogues qu'il précipite est proche de 1, ici égale à 0,82 ; le modèle MA_{100}+GLM n'arrive pas à déterminer un modèle d'occurrence adapté car les valeurs d'occurrence de précipitations obtenues par les dates analogues sont presque toutes égales à 1. Un comportement similaire est observable pour certaines mailles du Sud-Est de la France. Par exemple, la maille d'accroche SE sollicite MA_{25} pour 12% des prédictions. Pour ces prédictions, le modèle MA_{100} prédit en moyenne 5% de chance qu'il pleuve. Une fois encore, il est difficile pour le modèle MA_{100}+GLM de déterminer une structure régressive pour la prédiction de l'occurrence du fait de la forte proportion de dates analogues sèches. Pour le reste des mailles Safran, le pourcentage de fois où le modèle MA_{25} est sollicité est plus faible.

3.1.2. Variation de l'échantillonnage dans le temps

Dans cette partie, nous discutons de la fréquence d'échantillonnage des principales structures identifiées à la section 3.1.1 en fonction des filtres temporels. Par exemple, la figure VIII.9 représente la différence en fréquence d'échantillonnage de la structure n° 1 (R_2) en fonction des saisons et des types de temps par rapport à son échantillonnage moyen. Pour un filtre temporel considéré, les mailles coloriées en bleu indiquent que la structure n° 1 (R_2) est en moyenne plus de fois sollicitée. Lorsqu'elles sont coloriées en jaune, la sollicitation de la structure régressive est moins importante. Si la structure régressive est très peu retenue (*i.e.* la fréquence d'échantillonnage est inférieure à 5%), la maille Safran est coloriée en gris. Sur la figure VIII.9, on remarque que la structure 1 (R_2) est la plus sollicitée en été sur l'ensemble du territoire (10 à 15% de prédictions en plus), mais aussi pour le TT1 (de 5 à 10% en plus) et surtout pour le TT3 (jusqu'à 30% de prédictions en plus), excepté pour quelques mailles situées dans le quart Sud-Est. Pour les TT4 et TT7, elle est aussi sur-échantillonnée au Nord du Massif Central et au Sud des Alpes. Pour les autres types de temps, la mobilisation de cette structure est plus ou moins accentuée selon la région considérée. Pour les saisons d'automne, d'hiver et de printemps ainsi que pour les TT5 et TT8 (à l'exception du Sud-Est), cette structure est sous-échantillonnée par rapport à la moyenne. Pour ces situations, le modèle d'occurrence utilise d'autres structures régressives.

Par la suite, on peut se demander à quelles structures régressives profite un sous-échantillonnage de la structure n° 1 (R_2) ou autrement dit, quelles sont les structures qui sont sur-échantillonnées lorsque la structure n° 1 est sous-échantillonnée ? Pour répondre à cette question, nous considérons pour chaque filtre temporel, l'ensemble des structures sur-échantillonnées en chaque maille. La structure pour laquelle le sur-échantillonnage est maximal est retenue et représentée pour chaque maille Safran sur la figure VIII.10. La figure VIII.10 représente donc la structure régressive pour laquelle le sur-échantillonnage est maximal. Toutefois, il est important de garder à l'esprit que cette représentation n'est qu'une vision réduite des structures sur-échantillonnées. Pour une analyse plus approfondie du sur-échantillonnage d'une structure régressive particulière, le lecteur dispose à la section 2.3 de

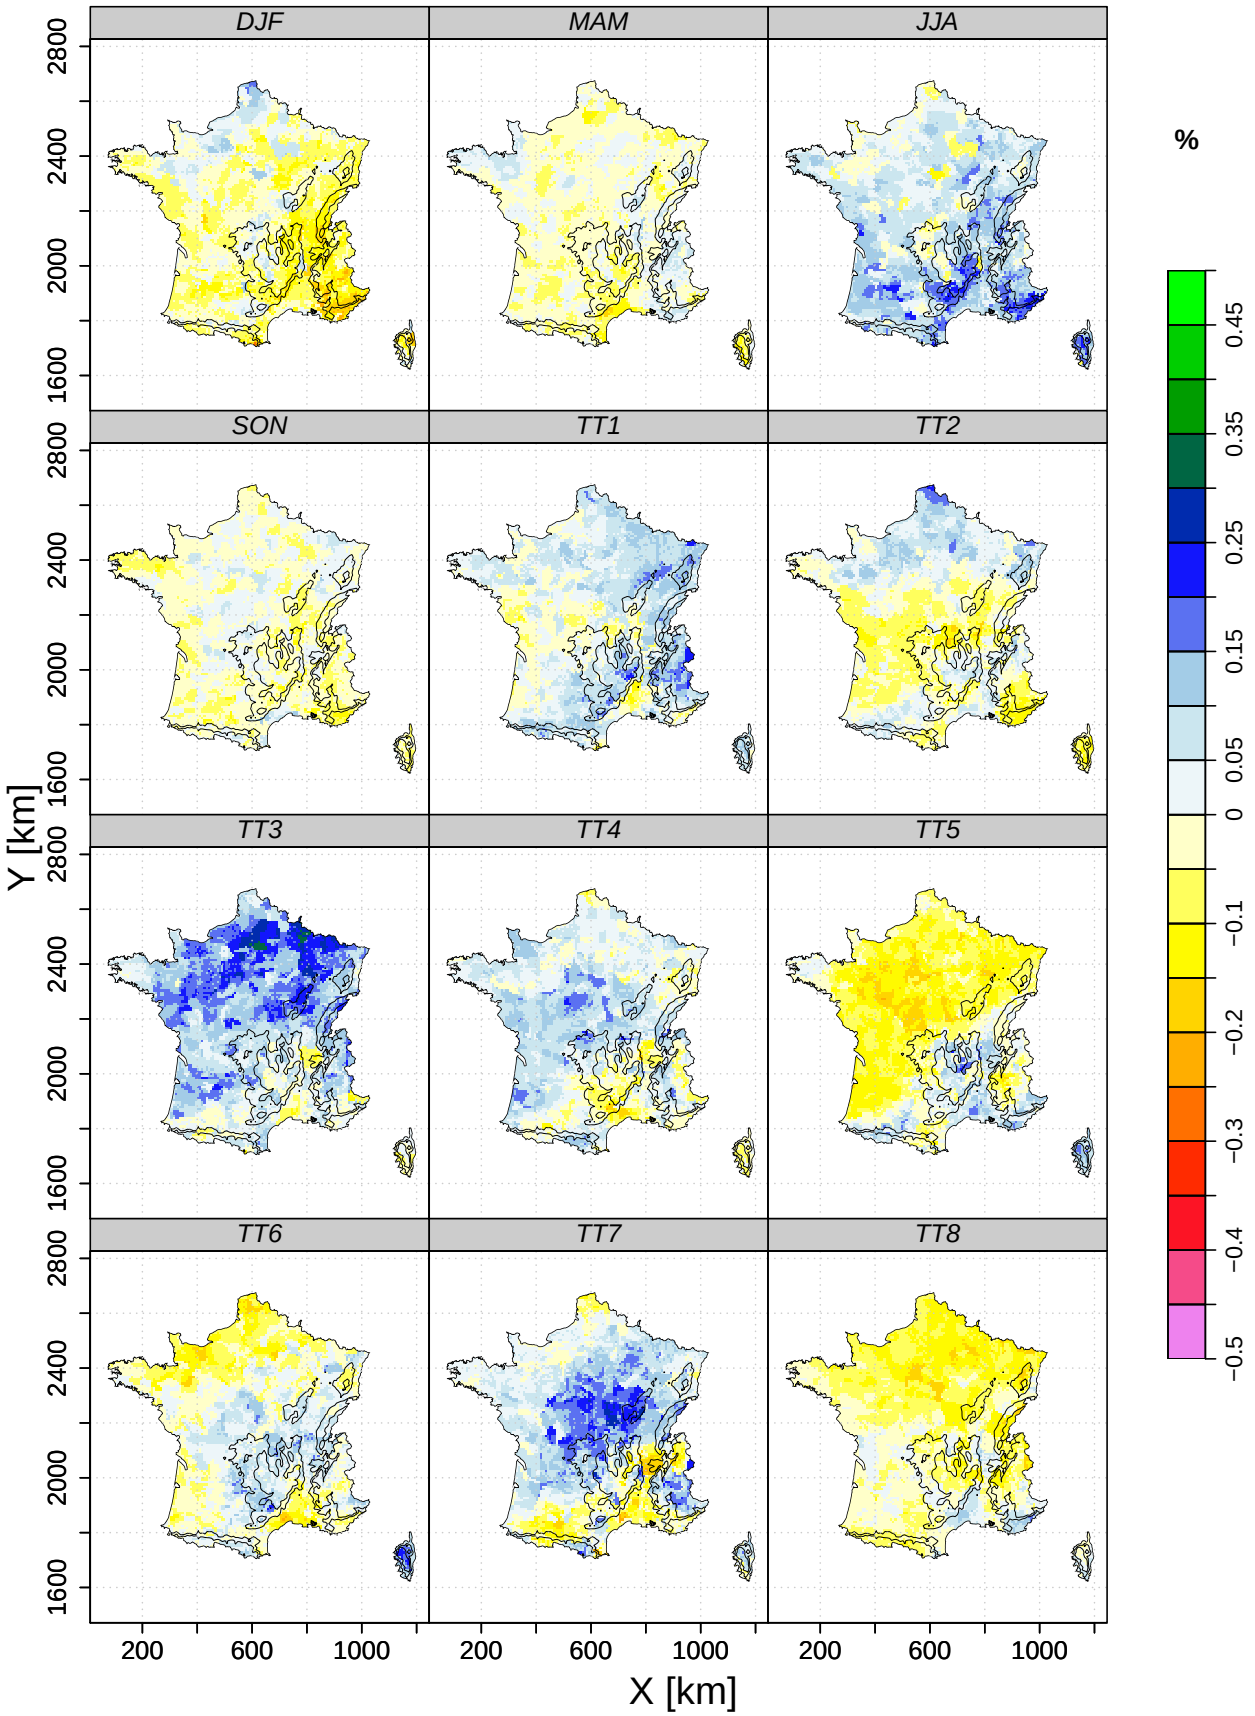

FIGURE VIII.9 – Différence d'échantillonnage de la structure n° 1 basée sur le prédicteur R_2 par rapport à son échantillonnage moyen en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

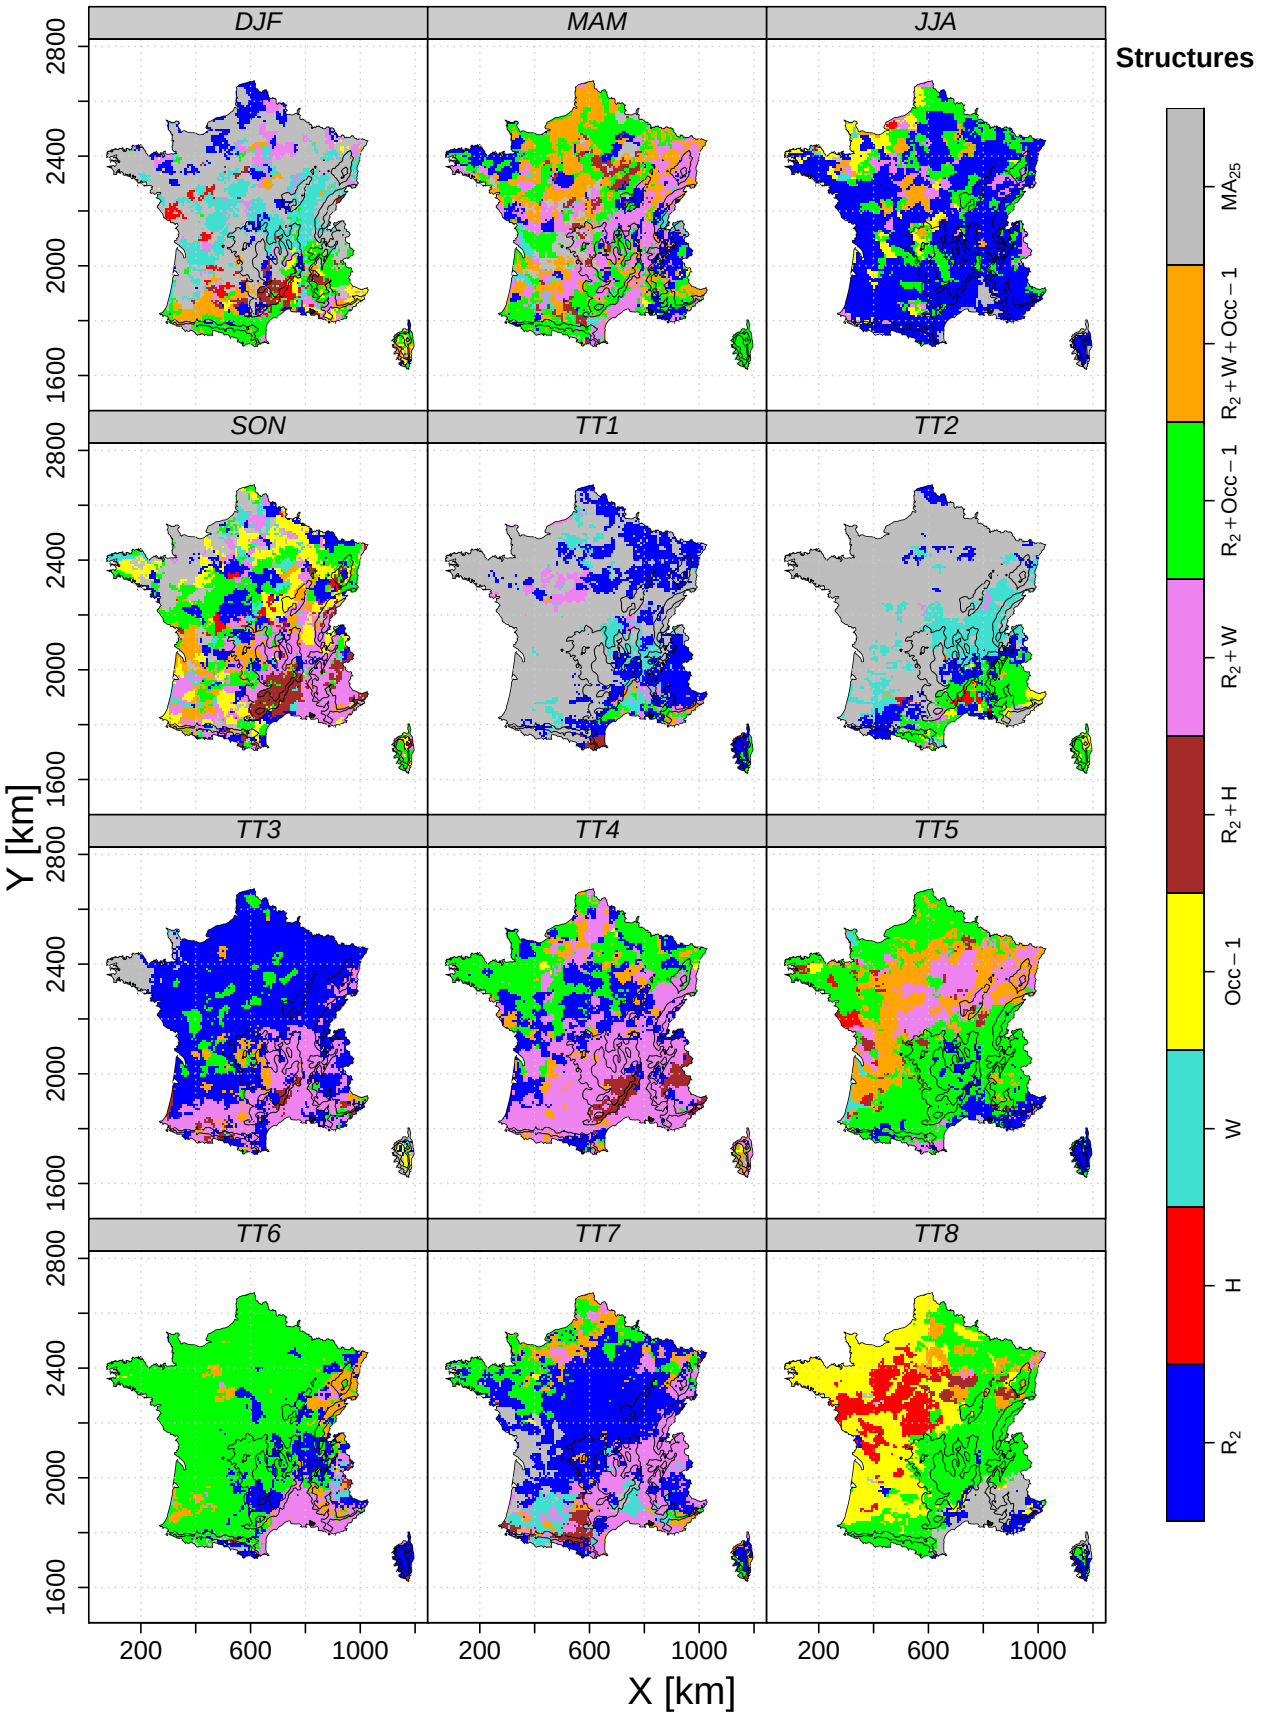

FIGURE VIII.10 – Distribution spatiale des structures régressives et du modèle MA_{25} pour lesquelles la différence d'échantillonnage avec la fréquence d'échantillonnage moyenne est maximale en fonction des saisons et des types de temps.

l'annexe D des distributions spatiales de la variation d'échantillonnage des principales structures régressives utilisées.

Comme il a été remarqué au paragraphe précédent, une forte sollicitation de la structure n° 1 est retrouvée sur la figure VIII.10 en été et pour les situations des types de temps 1, 3 et 7. En revanche, pour le type de temps 4, un sur-échantillonnage absolu plus important est observé pour d'autres structures régressives. Pour les types de temps correspondant à des flux de Sud (TT4 et TT7), la structure n° 6 ($R_2 + W$) est fortement sur-échantillonnée dans le Sud de la France. Plus localement pour le type de temps 4, la structure n° 5 ($R_2 + H$) est fortement sollicitée sur les massifs des Cévennes-Vivarais.

Pour les types de temps plutôt secs, on remarque que les structures faisant intervenir le prédicteur *Occ-1* sont plus souvent sollicitées. Par exemple, pour le TT5, les structure n° 7 (R_2+*Occ-1*) et n° 13 ($R_2 + W$+*Occ-1*) sont celles qui possèdent le plus fort sur-échantillonnage pour quasiment l'ensemble des mailles Safran. Pour le TT8, il s'agit des structures n° 4 (*Occ-1*) et n° 7 (R_2+*Occ-1*), tandis que cette dernière possède le plus fort sur-échantillonnage lors de retours d'Est (TT6) pour les mailles situées au Nord et à l'Ouest du Massif Central, et dont la précipitation moyenne observée pour ce type de temps est faible en ces endroits (figure II.7). Le prédicteur *Occ-1* est donc un indicateur des situations sèches. De plus, on remarque que pour le TT8, la structure n° 2 n'incluant que le prédicteur de cisaillement H est plus fortement sollicitée par rapport à la moyenne. Garavaglia et al. [2010] indique que pour ce type de temps, aucune circulation atmosphérique n'est clairement identifiée et aucune précipitation n'est observée. De part la faible dynamique atmosphérique obtenue pour ce type de temps, le terme d'hélicité est quasiment nul comparé aux autres types de temps et saisons (figure D.11 à l'annexe D). Ainsi, l'utilisation de l'hélicité H lorsqu'elle est nulle permet de prédire une probabilité nulle qu'il précipite.

Pour les circulations de Sud correspondant aux types de temps 4, 7 et 3, il semble nécessaire d'ajouter le prédicteur W à l'humidité relative au travers la structure n° 6. Cette structure se retrouve aussi pour le TT6 – correspondant aux situations de retours d'Est – apportant des précipitations trois fois plus importantes que la moyenne annuelle dans le Sud-Est. Plus localement pour les flux de Sud (TT4), sur les massifs des Cévennes-Vivarais, il apparaît qu'une information portant sur le cisaillement du flux d'air soit une information importante à considérer compte tenu de la forte sollicitation de la structure 5 basée sur la combinaison de prédicteurs $R_2 + H$. Ceci se retrouve par ailleurs pour la saison d'automne pour laquelle le pourcentage de situations appartenant aux circulations de Sud est le plus élevé [23% selon Garavaglia et al., 2010].

Concernant les TT1 et TT2 correspondant à des circulations d'Ouest, on remarque ici que le modèle alternatif MA_{25} est fortement sollicité par rapport à la moyenne. D'après la figure II.8, les journées appartenant à ces deux types de temps sont quasiment toutes pluvieuses sur l'ensemble du territoire, excepté dans le Sud-Est. Si les précipitations extraites des dates analogues correspondant à ces prédictions sont toutes pluvieuses, impliquant 100% de chance qu'il précipite pour la maille Safran cible, le modèle d'occurrence ne peut alors établir un lien de régression. Le modèle alternatif MA_{25} est alors retenu. Cependant, si l'on fait abstraction de la forte sollicitation du modèle MA_{25} pour ces deux types de temps, la structure 3 (W) est sur-échantillonnée pour le TT2. Cela se confirme aussi pour le type de temps 1 lorsque l'on regarde la figure D.5 en annexe D. Le prédicteur W constitue

alors un bon indicateur des fronts provenant des perturbations atlantiques. De plus, comme le type de temps 2 correspond en moyenne à 36% des situations en hiver, une distribution spatiale des structures régressives similaire est retrouvée en hiver.

En conclusion de cette partie, les différents résultats retenus sont :

- La structure n° 1 basée sur R_2 est en moyenne la plus sollicitée.
- Les prédicteurs d'occurrence *Occ-1* et de cisaillement H sont plus souvent sollicités pour les périodes sèches.
- Le prédicteur W indique les fronts provenant des perturbations Atlantiques. Autrement, pour un grand nombre de ces situations (TT1 et TT2), le modèle alternatif MA_{25} est souvent utilisé.
- La structure 6 ($R_2 + W$) est plus souvent échantillonnée pour les situations correspondant à des flux de Sud apportant des précipitations dans le Sud-Est de la France. Plus localement, l'information de cisaillement H additionnée à l'humidité relative R_2 (structure 5) est plus fortement sollicitée pour prédire l'occurrence de précipitation sur les massifs des Cévennes-Vivarais.

3.2. Cohérence spatiale des structures régressives

3.2.1. Cohérence spatiale et temporelle des structures régressives

Dans cette section, nous évaluons la capacité du modèle d'occurrence à prédire une même structure régressive lorsque ce dernier est appliqué en deux mailles Safran données. Pour une maille d'accroche, nous considérons la série temporelle listant la chronologie des structures régressives qui ont été appliquées par le modèle d'occurrence. Cette série temporelle est comparée à celle issue de chaque maille Safran. Le nombre de prédictions pour lesquelles une même structure régressive est utilisée est alors exprimé sous forme d'un pourcentage par rapport au nombre total de prédictions émises. Ce pourcentage est calculé entre chaque maille d'accroche et l'ensemble des autres mailles Safran est représenté sur la figure VIII.11. Sur cette figure, on remarque que seules quelques mailles situées dans un proche voisinage de la maille d'accroche ont un pourcentage de prédictions similaires élevé, variant entre 30 et 70%. Lorsque le modèle d'occurrence est appliqué en des mailles situées dans un rayon de 100 km de la maille d'accroche, le modèle applique la même structure régressive dans 20% des cas au minimum. En moyenne, le pourcentage minimal semble être de l'ordre de 10%. Il est de plus contraint par le relief : par exemple pour la maille SE, le pourcentage de structures utilisées similaires diminue de 35% à 25% lorsque l'on traverse le Massif Central vers le Nord-Ouest. Un raisonnement similaire peut être effectué avec la maille MC lorsque l'on traverse les Cévennes et le Vivarais vers le Sud-Est.

3.2.2. Sensibilité spatiale des coefficients

Une autre façon d'évaluer la robustesse spatiale des structures régressives est d'évaluer la sensibilité spatiale des coefficients d'une même structure régressive. Pour une structure régressive donnée et un prédicteur X_j donné de cette structure, le coefficient de régression moyen $\overline{\widehat{\beta}_{j,p,f}}$ est calculé en chaque maille Safran p et pour chaque filtre temporel f. De façon à comparer les valeurs obtenues par le coefficient moyen $\overline{\widehat{\beta}_{j,p,f}}$ entre chaque filtre temporel, nous introduisons la variable normalisée $||\overline{\widehat{\beta}_{j,p,f}}||$

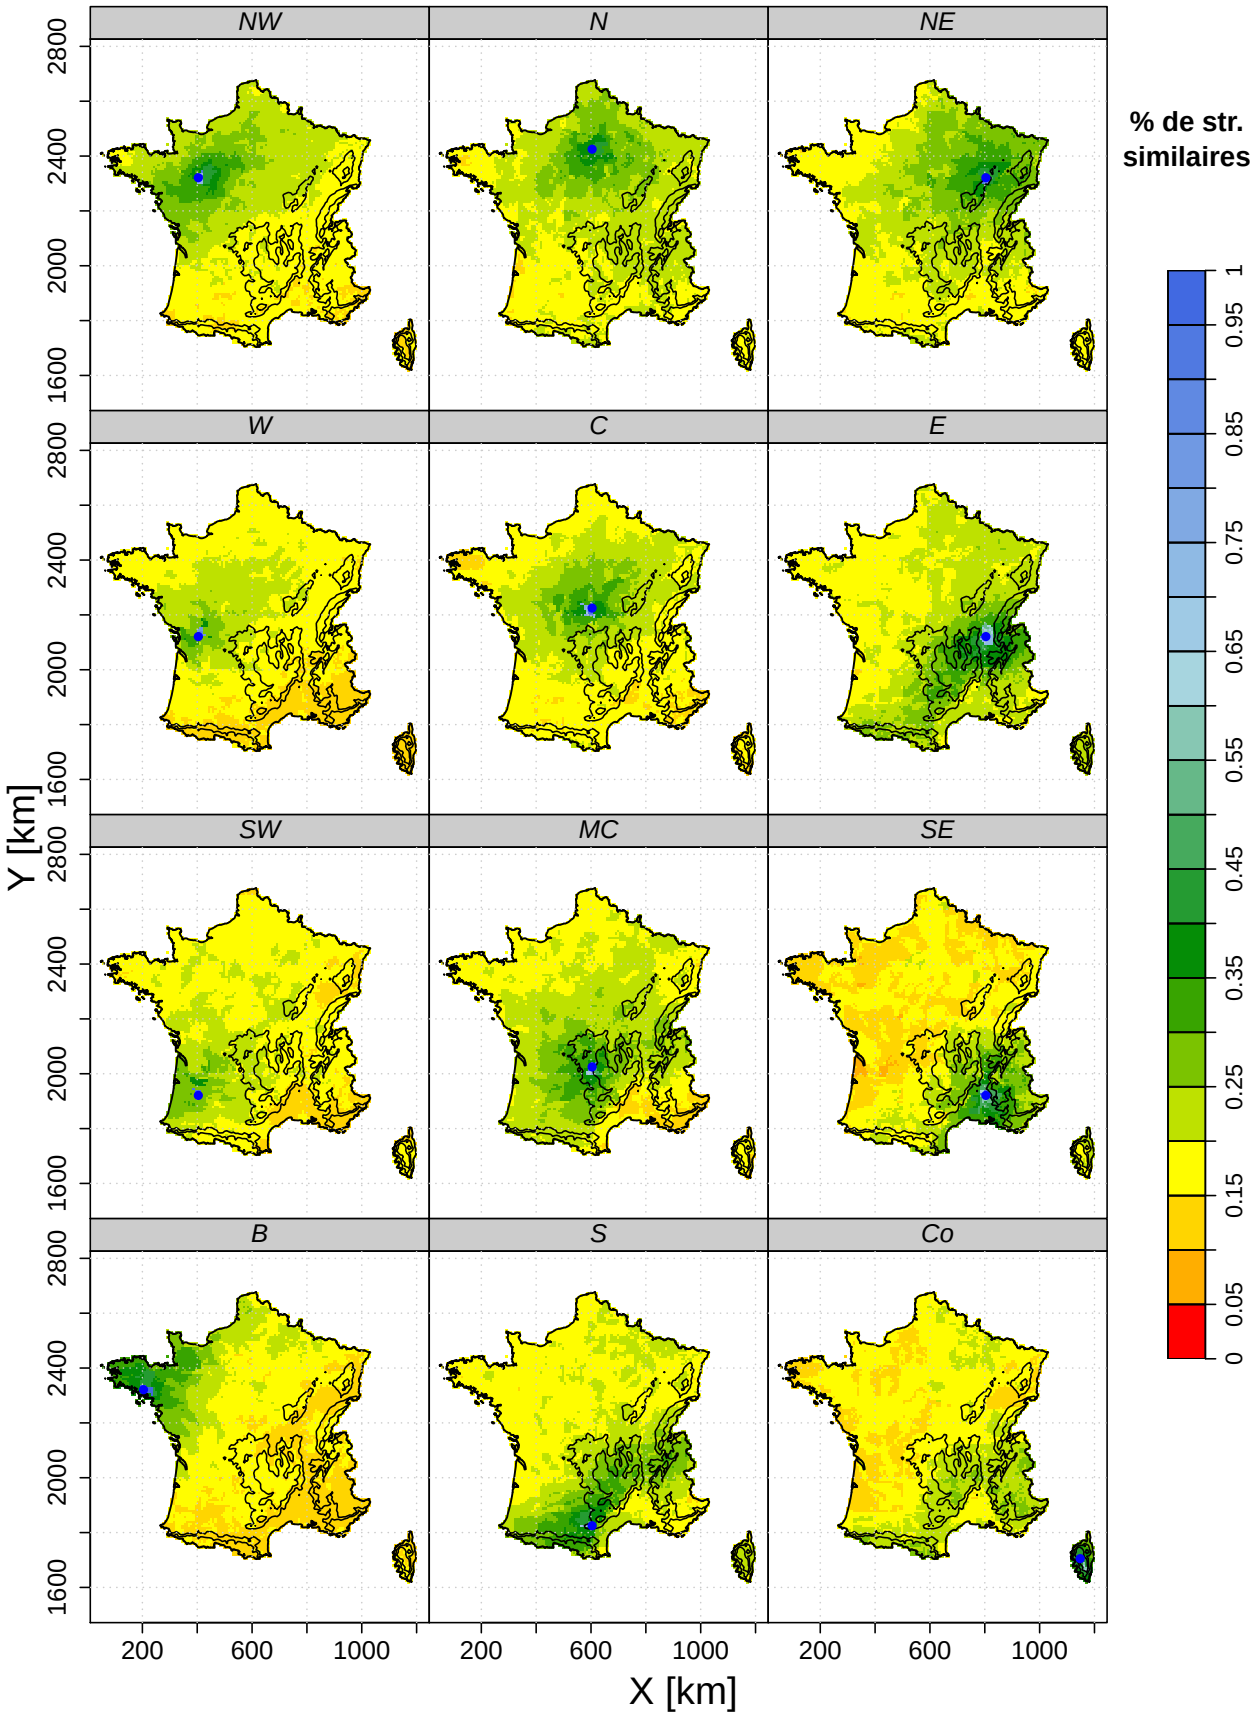

FIGURE VIII.11 – Pourcentage de jours où la structure utilisée par l'une des mailles d'accroche (représentée en bleu sur les cartes) est similaire à celles utilisées par les autres mailles Safran.

telle que :

$$\begin{aligned} ||\overline{\widehat{\beta}_{j,p,f}}|| &= \frac{\overline{\widehat{\beta}_{j,p,f}}}{N_j(\overline{\widehat{\beta}_{j,p,f}})} \\ N_j(\overline{\widehat{\beta}_{j,p,f}}) &= max\left\{abs\left(\overline{\widehat{\beta}_{j,p,f}}\right)\right\} \end{aligned} \tag{VIII.3}$$

où $N_j(\overline{\widehat{\beta}_{j,p,f}})$ correspond à la norme utilisée. Elle est égale au maximum des valeurs absolues de $\overline{\widehat{\beta}_{j,p,f}}$ obtenues sur l'ensemble des filtres temporels et des mailles Safran.

A titre d'illustration, le coefficient de régression moyen normalisé du prédicteur R_2 de la structure n° 1 – correspondant à la structure la plus utilisée pour la prédiction de l'occurrence – est illustré ici. La figure VIII.12 représente la distribution spatiale de ce coefficient normalisé pour les différents filtres temporels. De manière générale, le coefficient est plus important à l'Est (où il varie de 0,5 à 1) qu'à l'Ouest (où il varie de 0,3 à 0,5). Au printemps, en été et pour les types de temps 4, 6 et 7, la valeur moyenne est proche de 0,6 tandis qu'elle atteint 0,48 pour l'hiver et le TT2. Même si cette valeur varie entre les saisons et les types de temps, la variation spatiale du coefficient reste similaire et graduelle lorsque l'on se déplace de l'Est à l'Ouest. Cette variation dans l'espace que l'on retrouve à chacune des situations traduit de la robustesse du lien entre l'occurrence des précipitations et le prédicteur R_2.

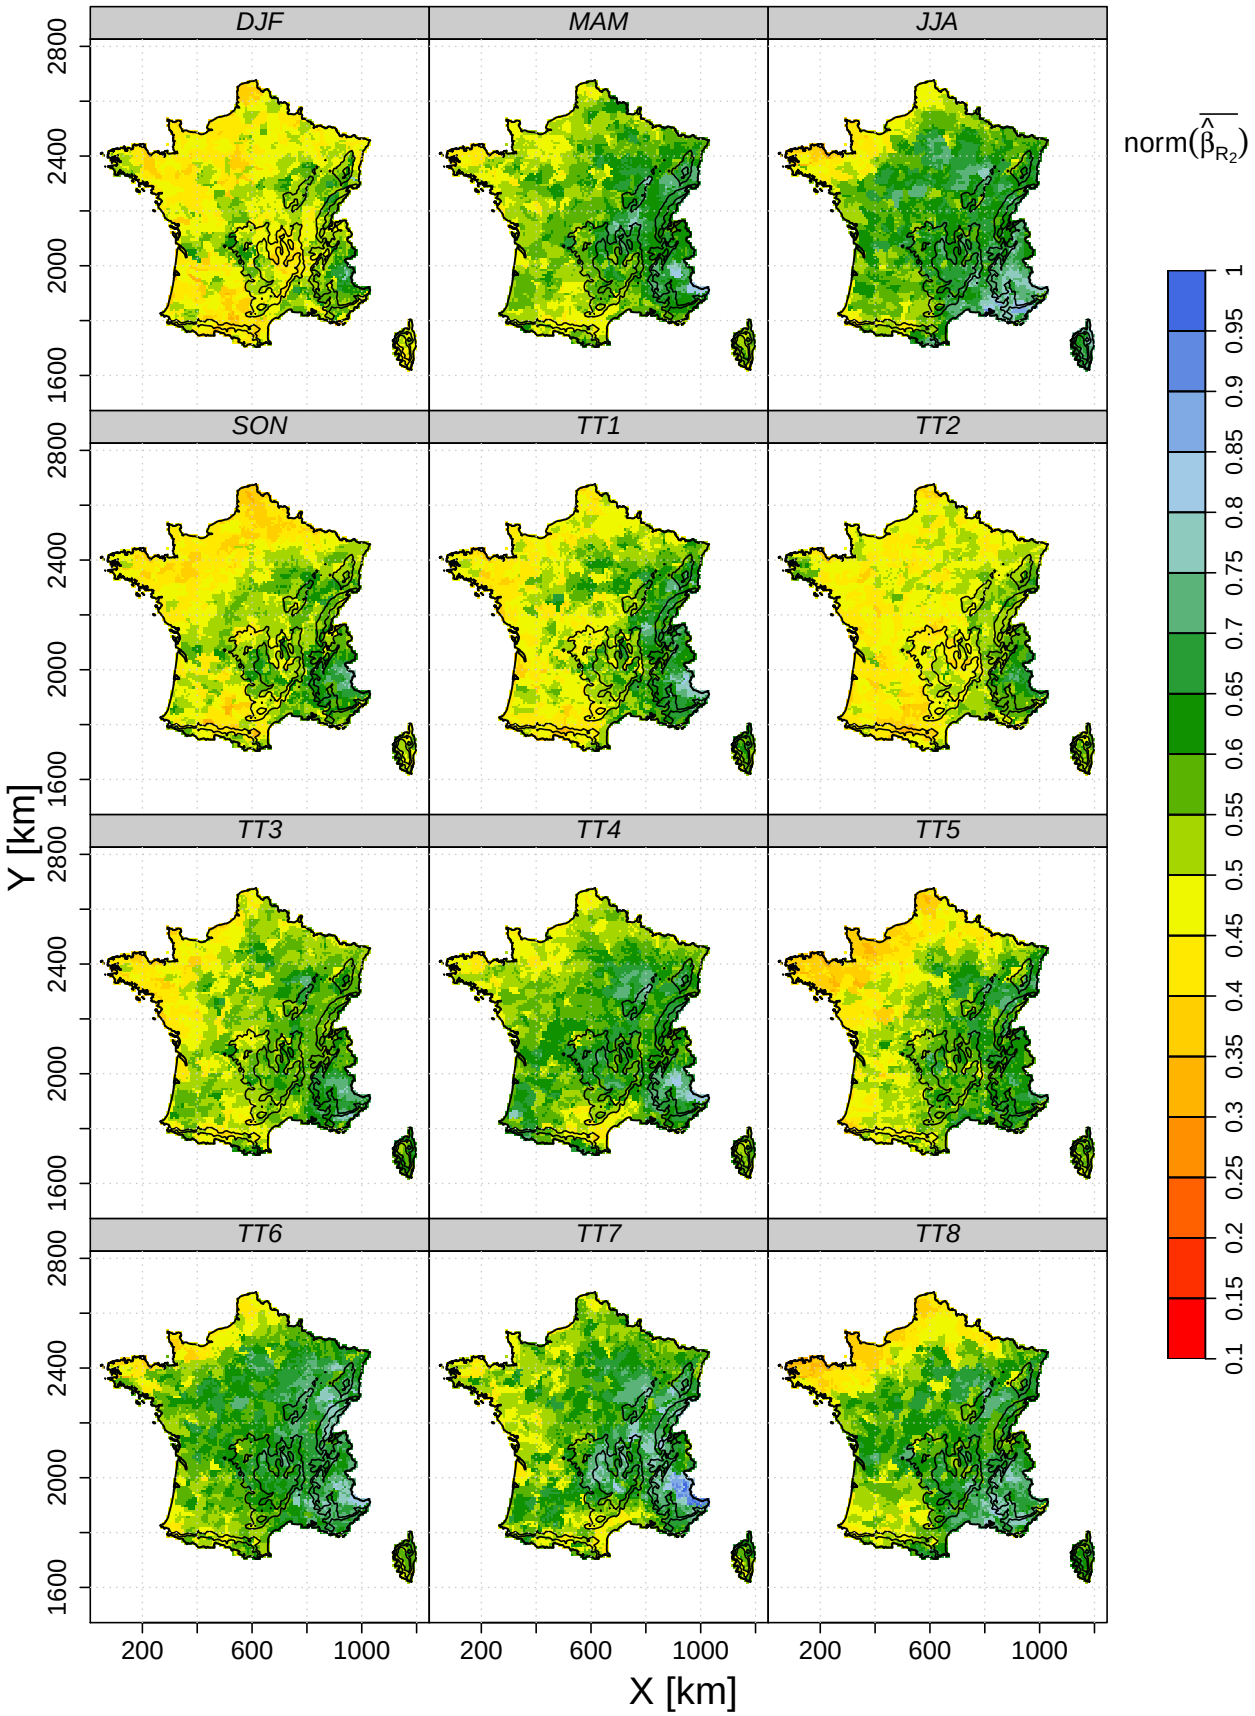

FIGURE VIII.12 – Distribution spatiale des coefficients moyens normalisés du prédicteur R_2 de la structure régressive n° 1.

Chapitre IX

Détermination d'un modèle régressif unique de quantité des précipitations

Dans ce chapitre, nous souhaitons déterminer un jeu de prédicteurs adapté pour la mise à jour de la distribution des précipitations. Le modèle correspondant est utilisé en complément du modèle d'occurrence unique retenu pour la France au chapitre VIII et utilisé pour la mise à jour de l'occurrence. Similairement au chapitre VIII, ce chapitre se décompose en trois parties : le pouvoir prédictif de chacun des prédicteurs retenus au chapitre VII est évalué pour la prédiction de la quantité des précipitations (section 1). Nous explorons ensuite plusieurs jeux de prédicteurs de façon à identifier le panier optimal apportant la meilleure performance moyenne (section 2). Le modèle de quantité optimisé est finalement évalué selon les saisons et les types de temps (section 3). A chacune de ces étapes, le critère permettant d'évaluer la performance moyenne du modèle MA_{100}+GLM est le CRPSS. Par la suite, les performances sont aussi comparées à celles de notre modèle de référence, *i.e.* le modèle MA_{25}.

1. Pouvoir prédictif de chacun des prédicteurs

Les figures IX.1 et IX.2 représente la différence en CRPSS obtenue par le modèle MA_{100}+GLM par rapport au modèle MA_{25} lorsque chaque prédicteur est pris séparément. Le ΔCRPSS est défini comme :

$$\Delta\text{CRPSS} = \text{CRPSS} - \text{CRPSS}_{Ref} \tag{IX.1}$$

où CRPSS est la performance en CRPSS obtenue par le modèle MA_{100}+GLM et CRPSS_{Ref} la performance obtenue par le modèle de référence, *i.e.* le modèle MA_{25}. On notera que comme le CRPS évalue pour chaque prédiction l'ensemble de la distribution émise, les performances du modèle

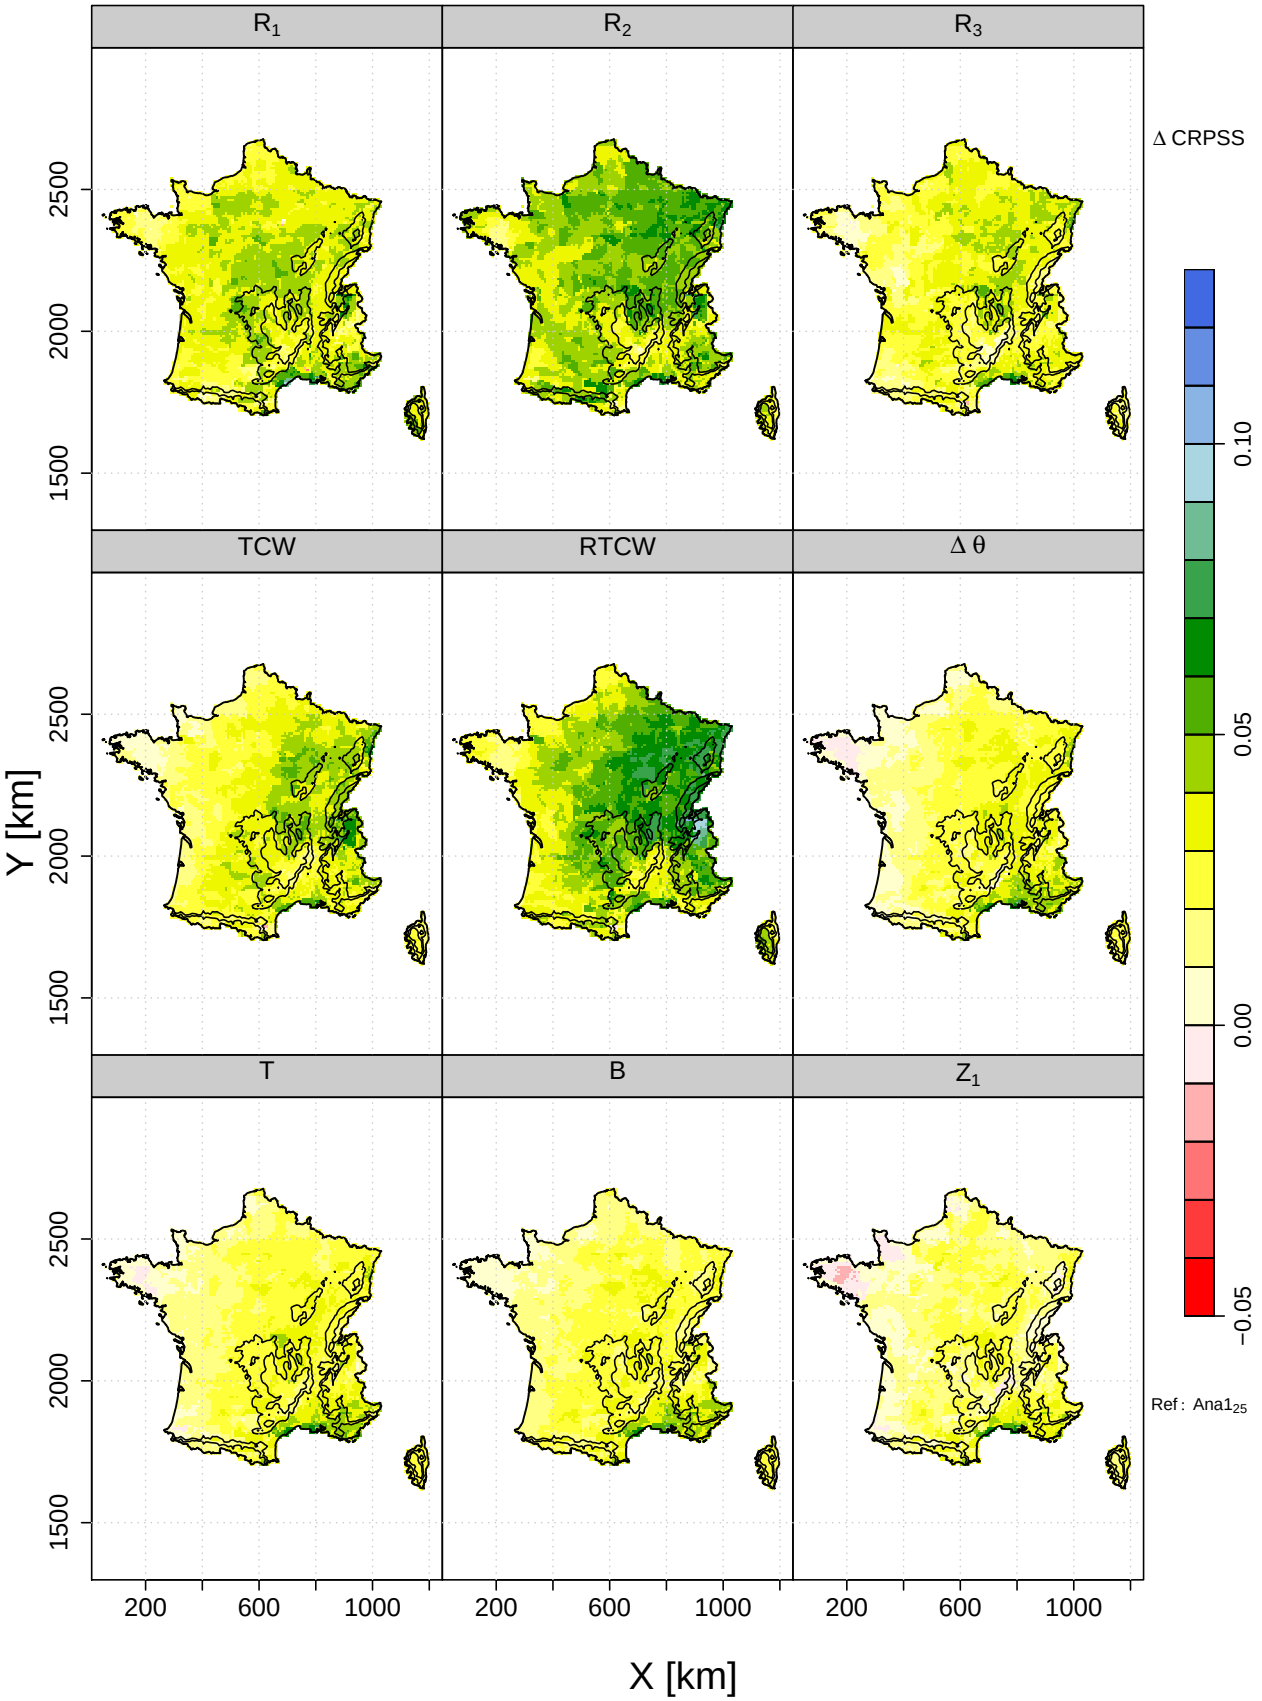

FIGURE IX.1 – Distribution spatiale du ΔCRPSS obtenue entre un modèle combiné MA_{100}+GLM uniprédicteur (prédicteurs R_1, R_2, R_3, TCW, $RTCW$, $\Delta\theta$, T, B et Z_1) et le modèle MA_{25} de référence.

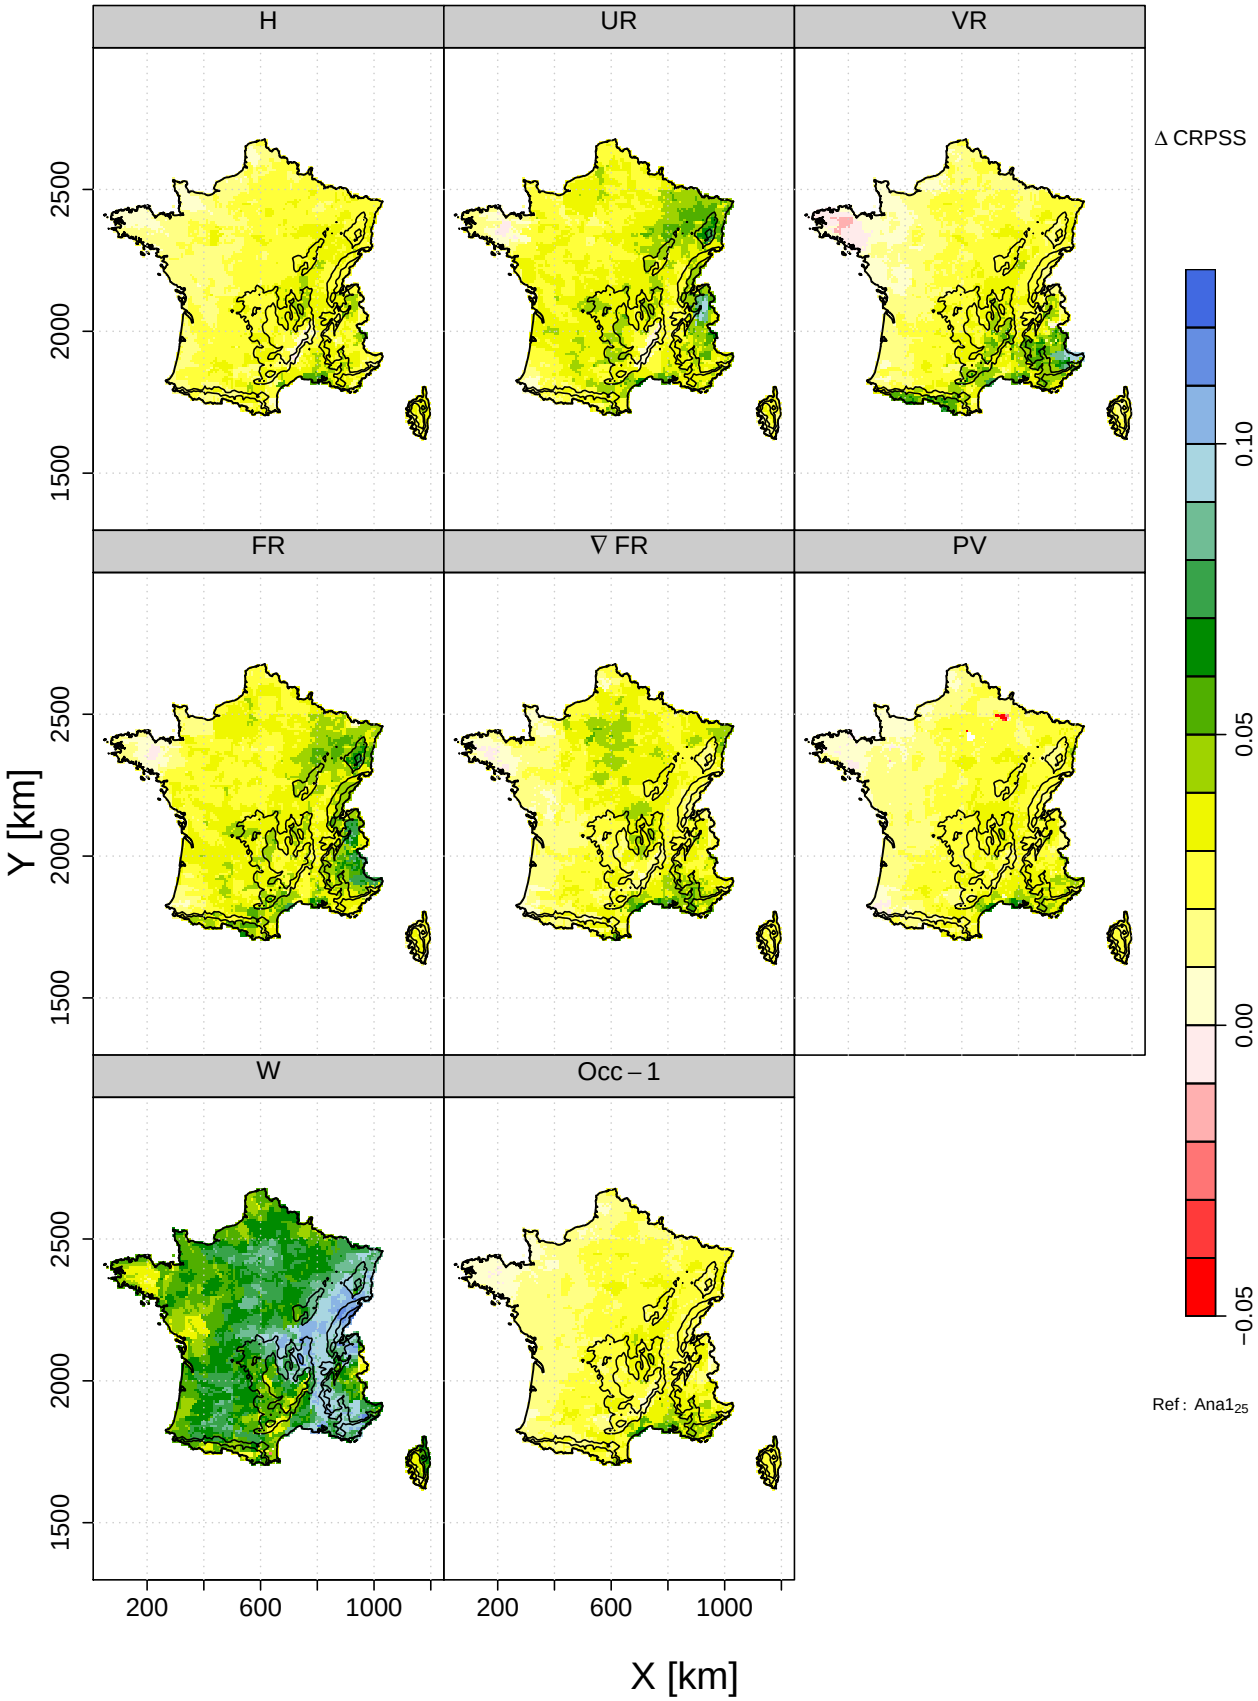

FIGURE IX.2 – Distribution spatiale du ΔCRPSS obtenue entre un modèle combiné MA_{100}+GLM uniprédicteur (prédicteurs H, UR, VR, FR, ∇FR, PV, W et *Occ-1*) et le modèle MA_{25} de référence.

de quantité MA_{100}+GLM présentées dans ce chapitre dépendent du modèle d'occurrence retenu au chapitre VIII.

A l'inverse des résultats obtenus à la section 1 du chapitre VIII, les variables testées pour la prédiction de la quantité de précipitation obtiennent toutes des gains sur l'ensemble de la France, excepté en Bretagne où les variables Z_1 et VR obtiennent des pertes. Parmi ces dernières, la vitesse verticale W à 700 hPa est la plus explicative des variables. Le gain observé est supérieur à 4 points de CRPSS pour une grande majorité des mailles Safran. De plus, des gains proches de 10 points de CRPSS sont obtenus sur l'ensemble de la vallée du Rhône et de la Saône, de la Loire amont et de l'Allier ainsi que les massifs du Jura, des Vosges et le Nord des Alpes. Seules quelques mailles localisées en Bretagne obtiennent des valeurs de gains aux alentours de 3 points de CRPSS.

Parmi les variables d'humidité, R_2 et $RTCW$ sont celles qui obtiennent les meilleurs performances. Des gains supérieurs à 4 points de CRPSS sont obtenus sur un bon quart Nord-Est de la France. Le gain obtenu par la variable $RTCW$ est plus important en certains massifs comme les Vosges et le Nord des Alpes que celui obtenu par R_2. A l'inverse, les gains observés pour R_2 sont plus importants sur la côte Atlantique. Ils semblent répartis de façon plus homogène sur le territoire français.

Les variables de flux d'humidité obtiennent un gain en CRPSS plus faible, de l'ordre de 2 points sur l'ensemble de la France avec des gains plus importants en certaines régions de l'Est de la France. Les meilleurs gains observés pour UR atteignent cependant 5 points sur le Nord-Est et jusqu'à 9 points sur le Nord des Alpes. Des gains importants d'environ 4 points de CRPSS obtenus par VR sont localisés dans le Sud-Est de la France et plus spécifiquement sur les reliefs du Sud des Alpes, de l'Est du Massif Central et des Pyrénées. Pour la prédiction de la quantité, les régions obtenant les gains les plus importants pour FR regroupent celles obtenues pour UR (situées dans le Nord-Est de la France) et VR (situées dans le Sud-Est de la France). Cependant, contrairement à la prédiction de l'occurrence (figure VIII.2), aucune augmentation du gain en CRPSS n'est vraiment remarquée lorsque le prédicteur FR est utilisé au lieu de UR ou de VR.

Les autres prédicteurs – *i.e.* $\Delta\theta$, T, B, Z_1, H, ∇FR, PV et *Occ-1* – obtiennent une distribution spatiale des gains similaire. Pour l'ensemble des mailles Safran, le gain se situe entre 0 et 2 points de CRPSS. Seules quelques mailles localisées sur le pourtour Méditerranéen obtiennent des gains proches de 5 points de CRPSS. Le meilleur de ces prédicteurs est globalement ∇FR car il permet d'obtenir des gains proches de 5 points en île de France et en Alsace. A l'inverse, Z_1 obtient les gains les plus faibles, certains étant même négatifs en Bretagne.

Comme l'ensemble des prédicteurs testés s'avère informatif de la quantité précipitée, la sélection d'un jeu de prédicteurs potentiels pour la détermination d'un modèle de quantité unique pour la France s'appuie aussi sur les résultats déterminés par l'étude des corrélations à la partie 3. Le prédicteur W est retenu car il est sans conteste le plus informatif de la hauteur précipitée. Parmi les prédicteurs d'humidité, le prédicteur R_2 est retenu : pour des valeurs de gains similaires, ses performances s'avèrent mieux réparties sur le territoire que celles obtenues par $RTCW$. Aucune des variables de flux d'humidité n'est conservée de part leur corrélation avec le terme d'humidité R_2. Comme les variables restantes sont peu corrélées entre elles, le jeu de prédicteurs potentiels est finalement constitué des prédicteurs R_2, $\Delta\theta$, T, B, Z_1, H, ∇FR, PV, W et *Occ-1* pour la détermination d'un modèle de quantité unique pour la France.

2. Optimisation du modèle de quantité

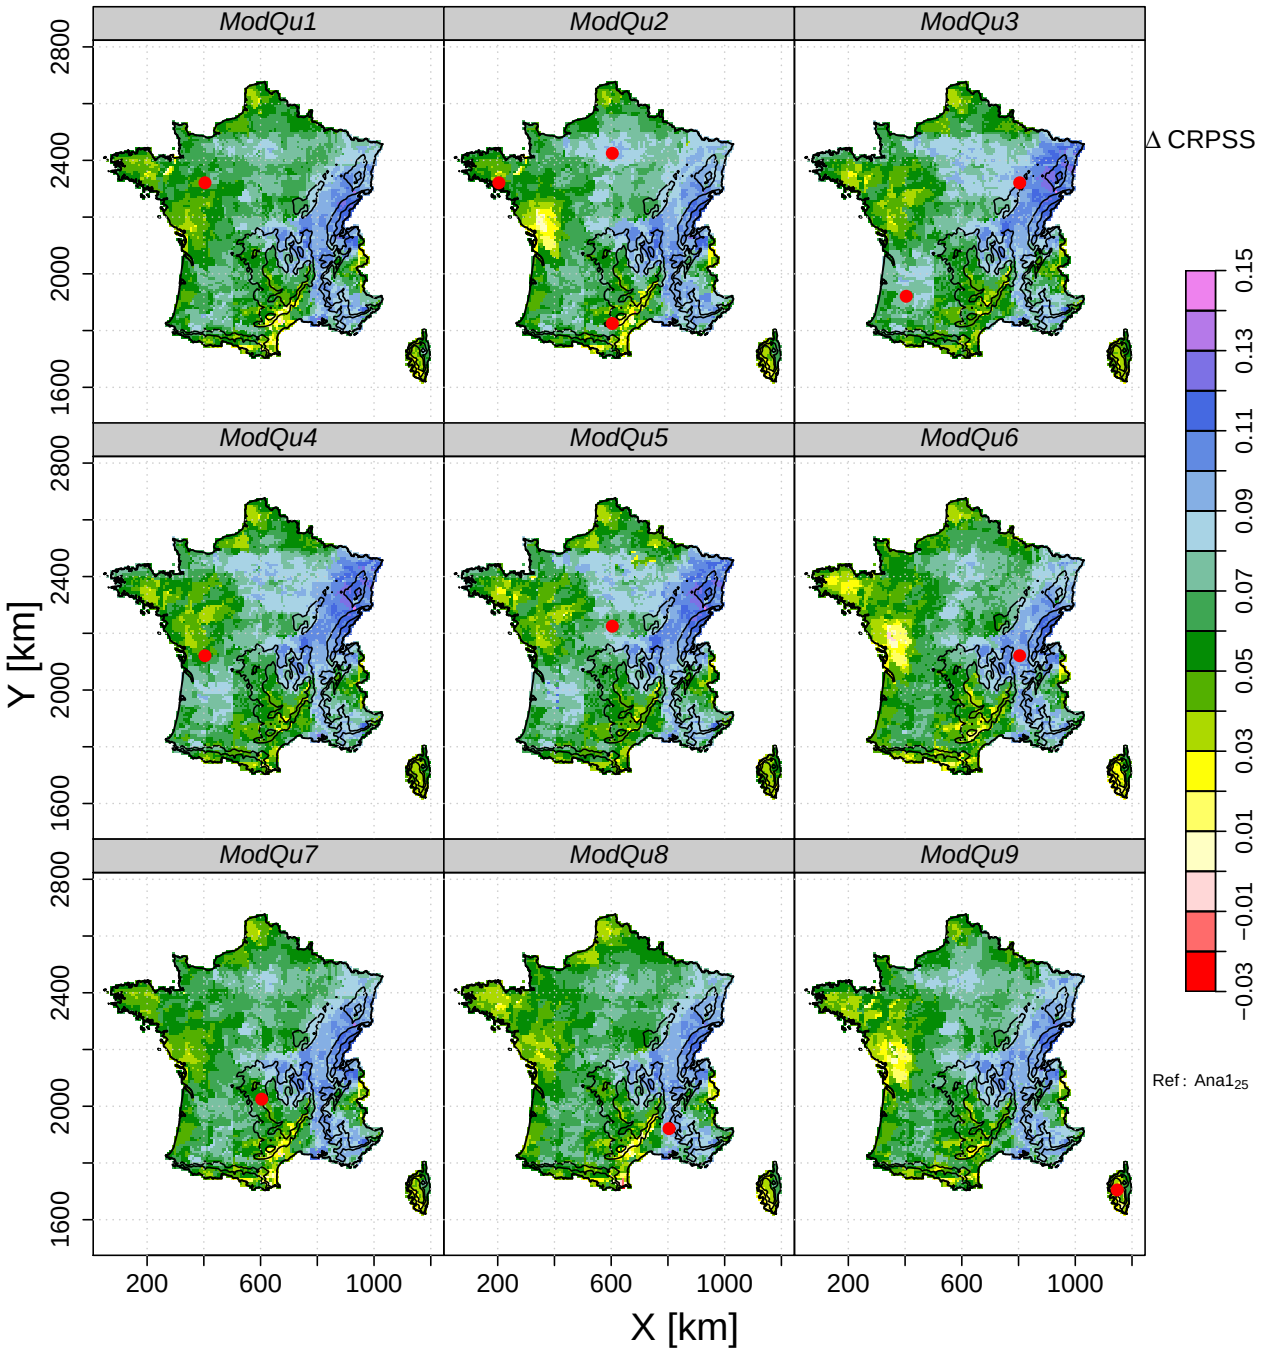

FIGURE IX.3 – Distribution spatiale du ΔCRPSS par chacun des modèles MA_{100}+GLM listés dans le tableau IX.1 et le modèle MA_{25} de référence. Les points rouge représentent les mailles Safran pour lesquelles le modèle de quantité considéré est optimal.

La méthodologie adoptée pour la détermination d'un modèle de quantité unique pour la France est similaire à celle employée pour le modèle d'occurrence unique (*cf.* section 2 du chapitre VIII). A partir de tests préliminaires menés sur les 12 mailles d'accroche Safran, nous avons déterminé que le nombre optimal de prédicteurs variait entre 2 et 6. En considérant le prédicteur W comme étant le plus informatif, nous avons décidé de déterminer la meilleure combinaison de quatre prédicteurs

incluant W pour chacune des mailles d'accroche Safran. Neuf configurations de modèle de quantité ont été trouvées. Elles sont listées dans le tableau IX.1.

Parmi ces modèles, on remarque que la température T à 700 hPa est la variable la plus retenue (10 mailles sur les 12). Lorsque la variable T n'est pas utilisée (ModQu6 et ModQu8), on retrouve les prédicteurs B et $\Delta\theta$ qui sont dérivés la température. En second lieu, la variable hélicité H est retenue pour la moitié des mailles. La variable ∇FR est la troisième variable le plus de fois sélectionnée (5 fois sur 12) suivie ensuite de R_2 (4 fois sur 12). Les autres prédicteurs (*i.e.* $\Delta\theta$, B, PV, Z_1 et *Occ-1*) sont quand à eux moins fréquemment retenus (au maximum 3 modèles sur 12).

Tableau IX.1 – Combinaisons optimales de quatre prédicteurs pour chaque maille d'accroche pour la prédiction de la quantité de précipitation ainsi que le gain moyen observé en CRPSS correspondant.

Dénominations	Combinaisons	Maille d'accroche	$\overline{\Delta\text{CRPSS}}$
ModQu1	$T + B + H + W$	NW	0,067
ModQu2	$T + H + \nabla FR + W$	N,S,B	0,069
ModQu3	$R_2 + T + W + Occ\text{-}1$	NE,SW	0,070
ModQu4	$R_2 + \Delta\theta + T + W$	W	0,070
ModQu5	$R_2 + T + PV + W$	C	0,070
ModQu6	$\Delta\theta + B + \nabla FR + W$	E	0,064
ModQu7	$T + H + PV + W$	MC	0,067
ModQu8	$\Delta\theta + H + W + Occ\text{-}1$	SE	0,064
ModQu9	$T + Z_1 + \nabla FR + W$	Co	0,066

La figure IX.3 présente le gain en CRPSS obtenu pour chaque modèle décrit dans le tableau IX.1. Pour tous les modèles, la distribution spatiale des gains est similaire à celle obtenue lorsque seule la variable W est utilisée (*cf.* figure IX.2). Les gains les plus importants sont observés à l'Est de la France avec des valeurs pouvant être supérieures à 10 points de CRPSS plus particulièrement sur le Nord-Est. Ces gains diminuent graduellement lorsque l'on se déplace vers l'Ouest. Sur le pourtour Atlantique, les gains varient entre 3 et 6 points. Toutefois, certaines différences apparaissent entre les modèles : les modèles 2, 6 et 9 obtiennent de faibles gains (pouvant être parfois nul) de la Bretagne à la Gironde. D'après le tableau IX.1, ces modèles possèdent tous le prédicteur ∇FR. Ceci est cohérent avec le pouvoir prédictif du prédicteur ∇FR qui est parmi les plus faibles en cette région.

A l'inverse, les modèles retenant l'humidité R_2 (les modèles 3, 4 et 5) semblent apporter les meilleurs gains en CRPSS dans le Nord-Est de la France. Par ailleurs, ces modèles obtiennent le meilleur gain moyen égal à 7 points de CRPSS (tableau IX.1).

Les modèles listés dans le tableau IX.1 nous donnent un aperçu des prédicteurs les plus utilisés. Par suite, nous avons décidé que le modèle retenu *in fine* pour la prédiction de la quantité serait un nouveau modèle ModQu10 basé sur la combinaison de prédicteurs $R_2 + T + H + W$ pour les raisons suivantes :

- W est le prédicteur obtenant le pouvoir prédictif le plus important (*cf.* section 1).

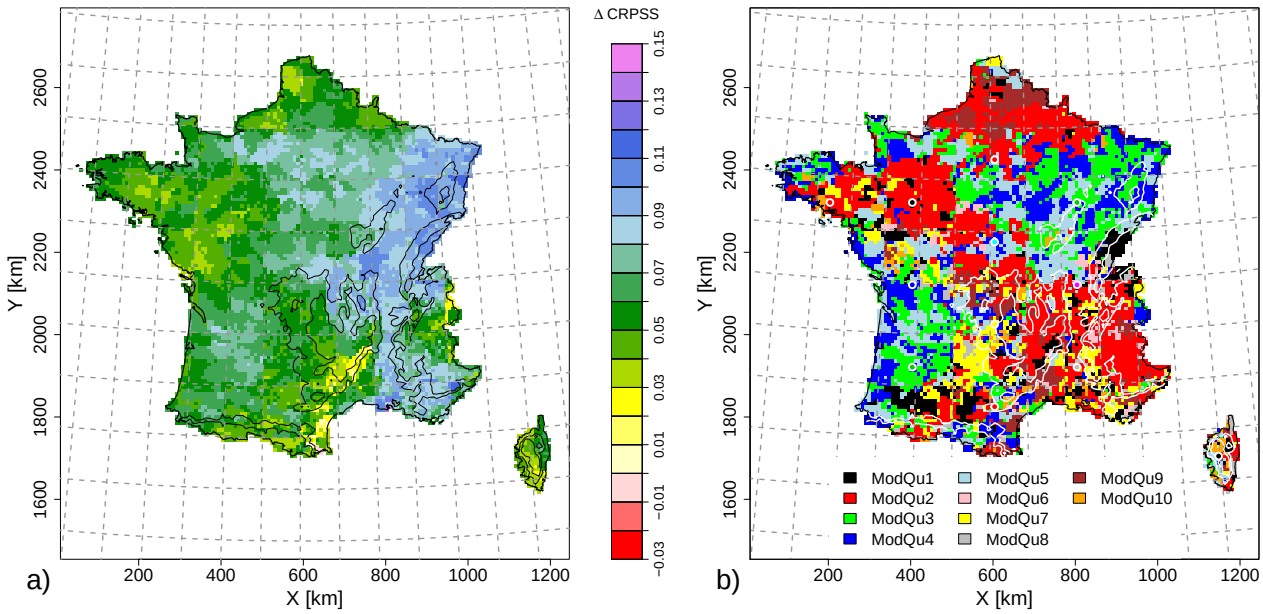

FIGURE IX.4 – a) Gain de performance en CRPSS obtenu par le modèle ModQu10. b) Distribution spatiale des meilleurs modèles de quantité parmi les 10 testés pour chaque maille sur la France. Les lignes de reliefs sont ici représentées en blanc.

- Sur la base des douze mailles d'accroche, les prédicteurs T et H sont les prédicteurs les plus fréquemment retenus parmi les différents modèles "optimaux" (respectivement dix et six fois sur douze) pour les douze mailles d'accroche.
- Le prédicteur R_2 permet d'intégrer une variable d'humidité. C'est par ailleurs le second prédicteur obtenant le meilleur pouvoir prédictif (*cf.* section 1). De plus, il est retenu par les trois modèles de quantité qui obtiennent les meilleures performances (*i.e.* les modèles ModQu3, ModQu4 et ModQu5 listés dans le tableau IX.1).

Pour ce nouveau modèle ModQu10, le gain de performance en CRPSS (IX.4.a) est similaire à ceux obtenus à la figure IX.3. Sa valeur moyenne égale à 6,5 points n'est pas parmi les plus importantes observées dans le tableau IX.1 et le nombre de mailles pour lesquelles ce modèle s'avère le meilleur des dix modèles testés est faible (figure IX.4.b). Toutefois, à titre de comparaison, ce gain reste supérieur de 3 points de CRPSS au gain moyen obtenu par le modèle MA à deux niveaux d'analogie utilisé dans CHARDON et al. [2014]. Enfin, les résultats obtenus avec ce modèle se sont révélés plus intéressants que ceux obtenus avec des modèles plus "performants" dans le tableau IX.1.

3. Etude du modèle de quantité unique

3.1. Adaptation dans le temps

3.1.1. Fréquence d'échantillonnage des structures régressives

Similairement au modèle d'occurrence unique décrit à la section 3 de la partie VIII, le modèle de quantité unique possède 15 structures régressives listées dans le tableau IX.2. La fréquence d'échantillonnage de chacune de ces structures régressives est représentée sur la figure IX.5. Pour chaque structure régressive, les erreurs de prédiction journalières retrouvées pour MA_{100}+GLM et

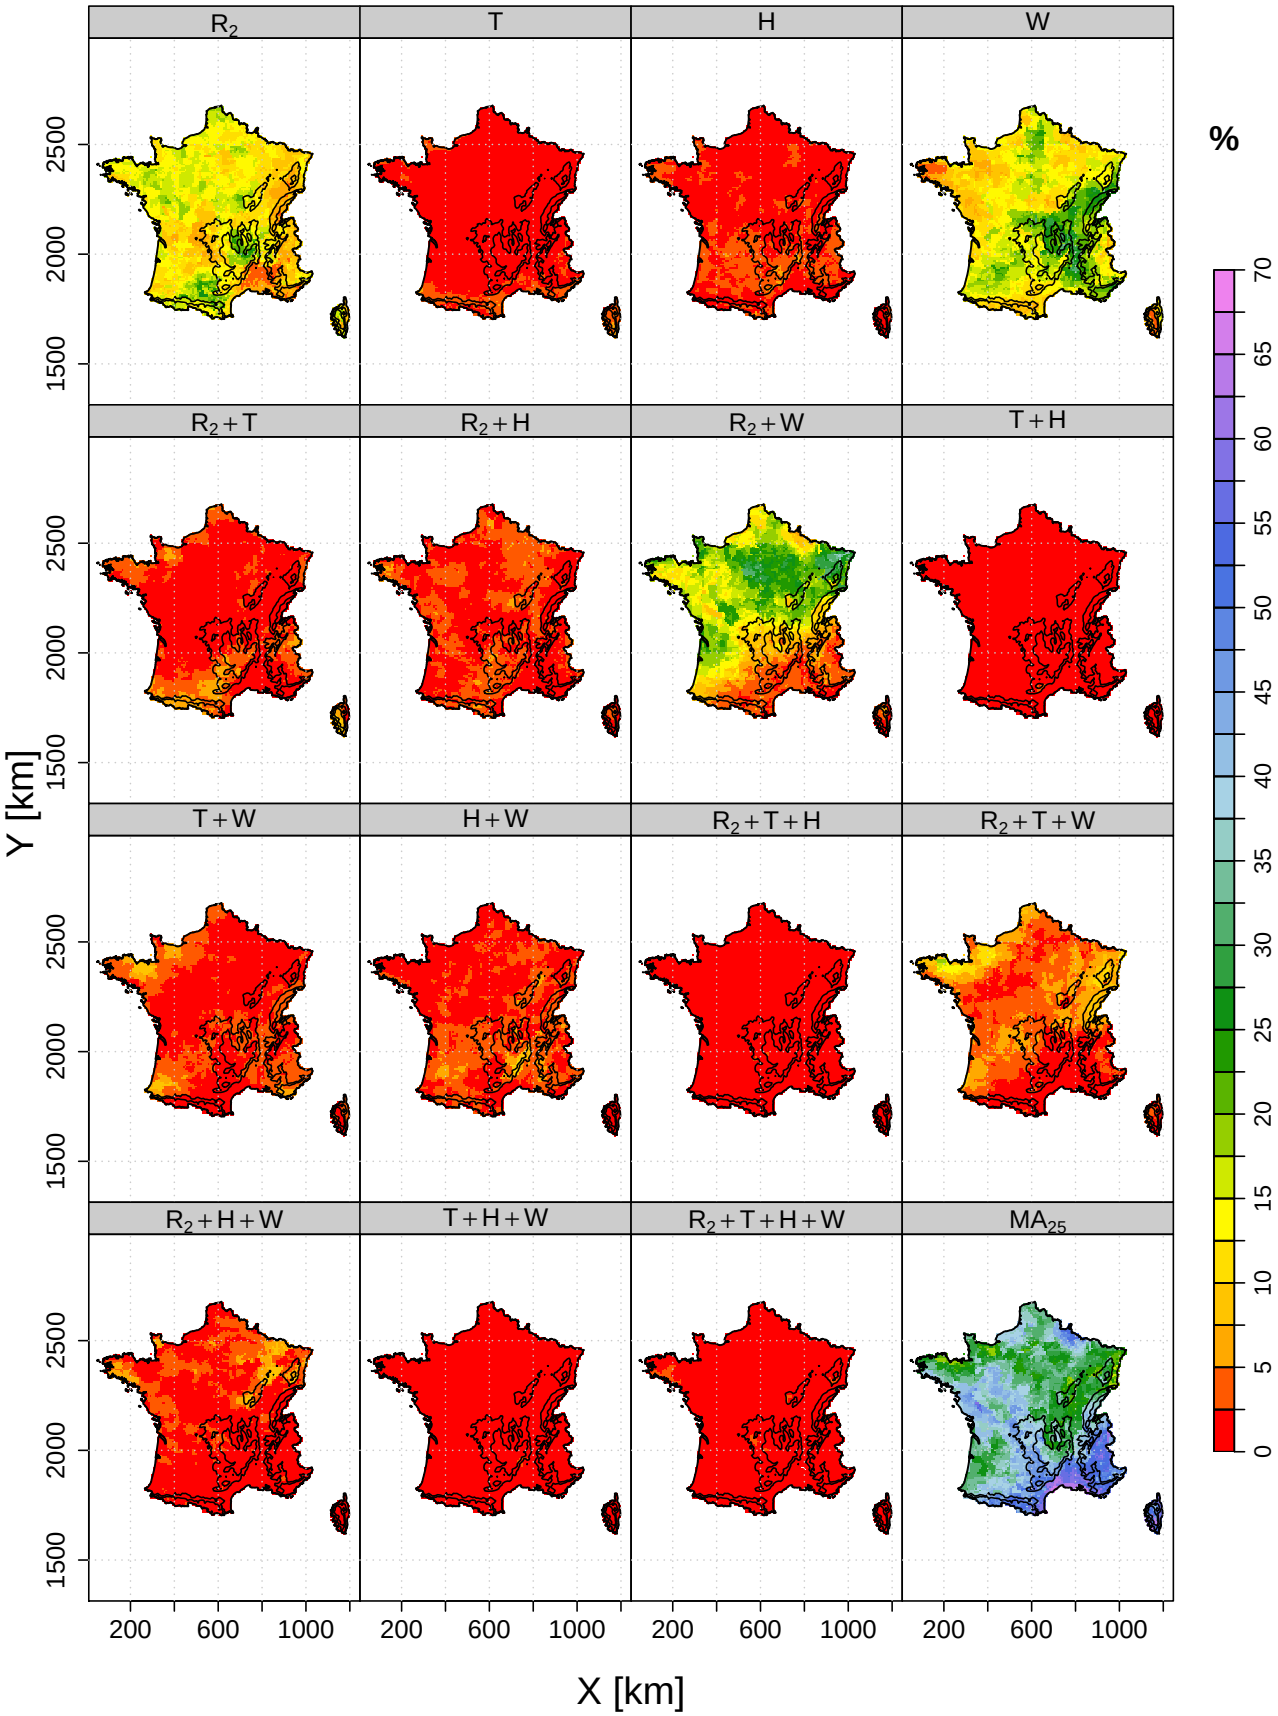

FIGURE IX.5 – Fréquences d'échantillonnage des structures régressives et du modèle MA_{25} du modèle de quantité unique pour la France (fréquences moyennes sur l'ensemble de la période 1982–2001). Les mailles blanches indiquent que la structure régressive concernée n'a jamais été utilisée.

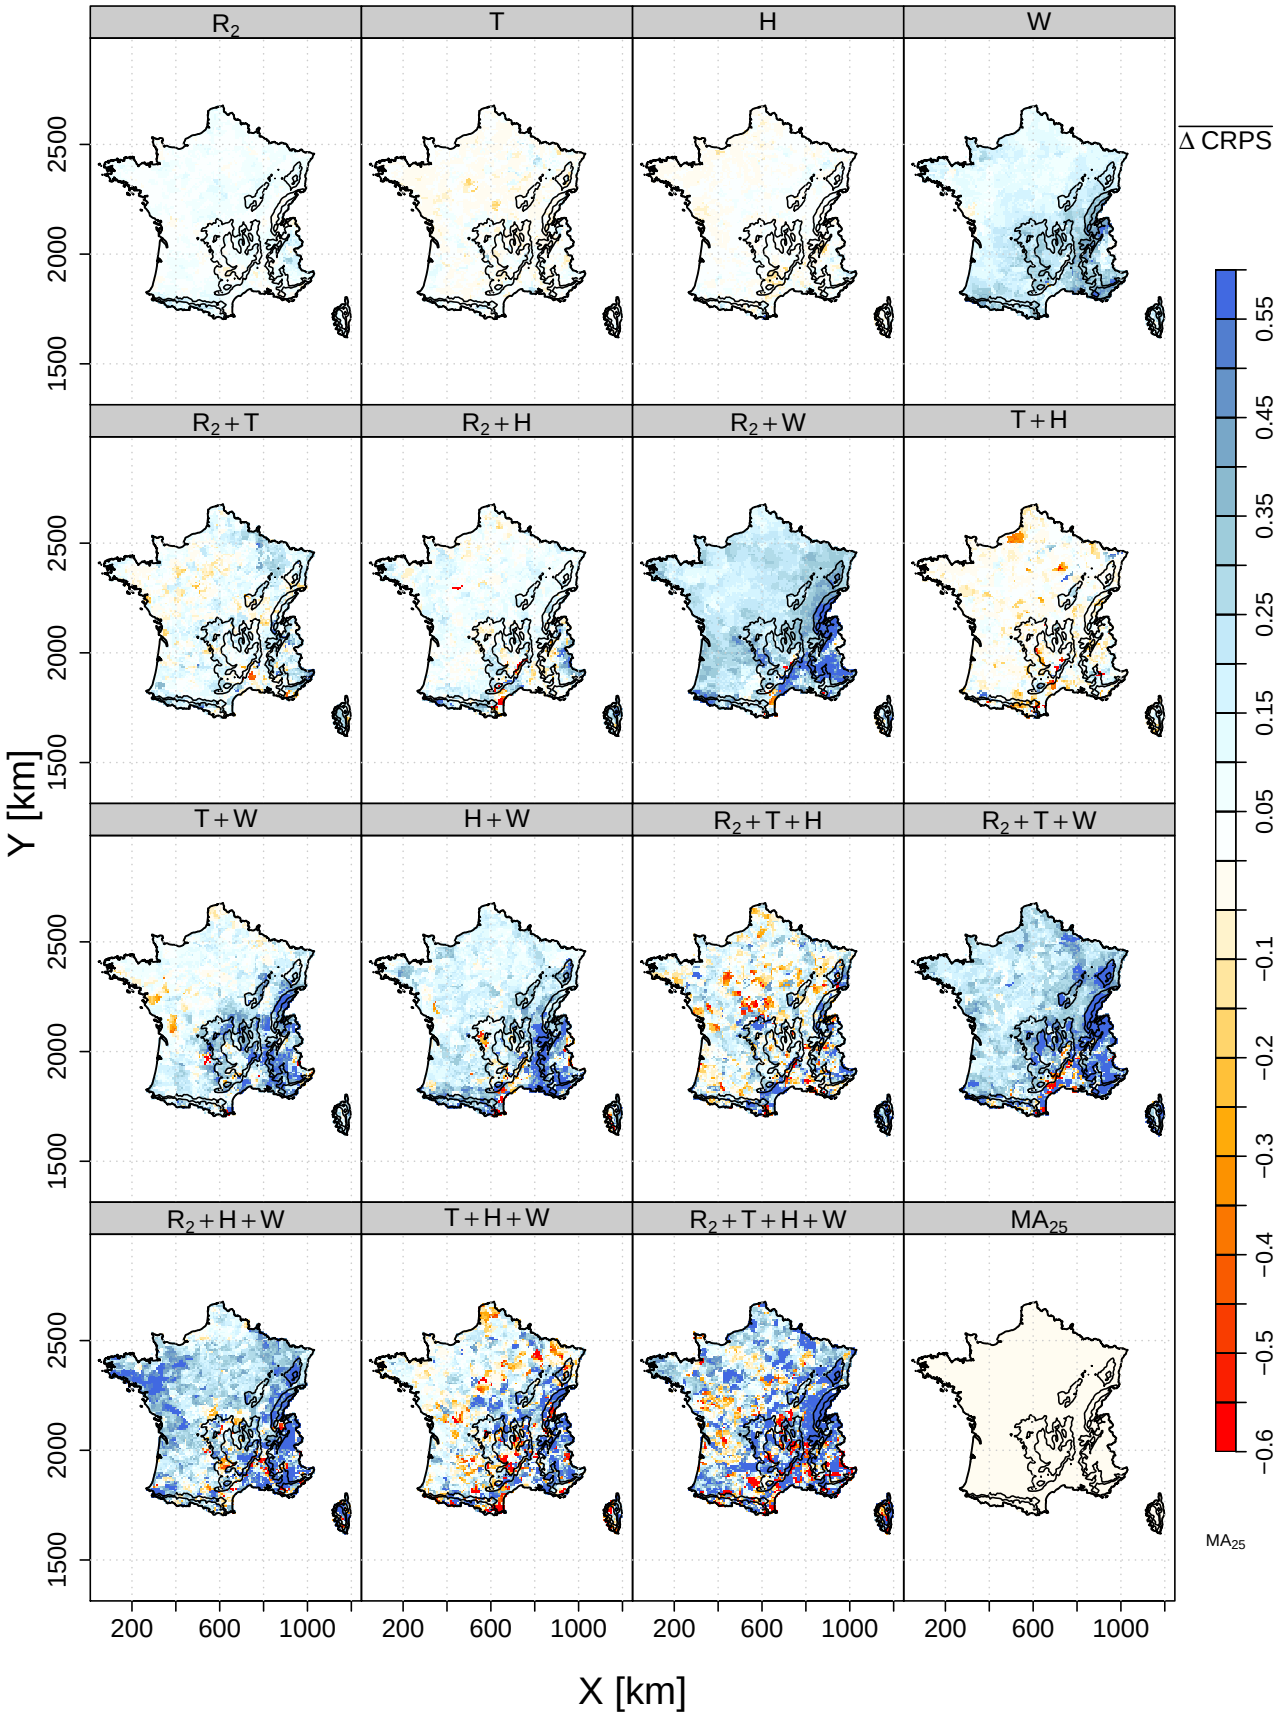

FIGURE IX.6 – Différence moyenne des erreurs en CRPS obtenues entre les modèles MA_{100}+GLM et MA_{25} par les structures régressives et du modèle MA_{25} du modèle de quantité unique pour la France.

Tableau IX.2 – Ensemble des structures régressives proposées par le modèle de quantité unique France.

Structure régressive	Prédicteurs
Str. n° 1	R_2
Str. n° 2	T
Str. n° 3	H
Str. n° 4	W
Str. n° 5	$R_2 + T$
Str. n° 6	$R_2 + H$
Str. n° 7	$R_2 + W$
Str. n° 8	$T + H$
Str. n° 9	$T + W$
Str. n° 10	$H + W$
Str. n° 11	$R_2 + T + H$
Str. n° 12	$R_2 + T + W$
Str. n° 13	$R_2 + H + W$
Str. n° 14	$T + H + W$
Str. n° 15	$R_2 + T + H + W$

MA_{25} peuvent être comparées par le $\Delta\mathrm{CRPS}_i$ journalier défini comme :

$$\Delta\mathrm{CRPS}_i = \mathrm{CRPS}_{i,\mathrm{MA}_{25}} - \mathrm{CRPS}_{i,\mathrm{MA}_{100}+\mathrm{GLM}} \tag{IX.2}$$

où $\mathrm{CRPS}_{i,\mathrm{MA}_{25}}$ et $\mathrm{CRPS}_{i,\mathrm{GLM}_{100}+\mathrm{GLM}}$ correspondent respectivement au CRPS obtenus pour le modèle MA_{25} et MA_{100}+GLM pour une prédiction i donnée. Une valeur positive de $\Delta\mathrm{CRPS}_i$ indique que l'erreur de prédiction effectuée par MA_{100}+GLM est plus faible que celle de MA_{25}, tandis qu'une valeur négative indique une erreur plus importante. Le $\overline{\Delta\mathrm{CRPS}}$ moyen journalier est représenté sur la figure IX.6 en fonction de chaque structure régressive.

A partir des figures IX.5 et IX.6, des résultats similaires à ceux observés à la section 3 du chapitre VIII sont obtenus :

- Seules les structures n° 1 (R_2), n° 4 (W) et n° 7 ($R_2 + W$) sont échantillonnées plus de 10% des prédictions sur le territoire.
- L'échantillonnage d'une des trois structures citées dépend de la région considérée. Par exemple, la structure n° 4 (W) est échantillonnée jusqu'à 30% des prédictions dans les vallées du Rhône, de la Saône, et la partie amont des bassins de la Loire et de l'Allier. Sur le reste du territoire, son échantillonnage est plus faible, entre 5 et 15%. Pour la structure n° 1 (R_2), l'échantillonnage est globalement compris entre 10 et 20% des prédictions. Il est plus faible dans le Sud-Est (environ 5%) et légèrement plus important dans le Nord-Est et au Sud-Ouest du Massif Central. La structure n° 7 ($R_2 + W$) quant à elle est fortement échantillonnée (jusqu'à 35%) sur la partie Nord de la France. Dans le Sud et particulièrement le Sud-Est, son échantillonnage est proche de 0%.
- D'autres structures régressives peuvent être échantillonnées à plus petite échelle. Par exemple, la structure n° 12 ($R_2 + T + W$) est sollicitée plus de 10% des prédictions en certains endroits de la Bretagne et des Vosges. Plus localement, il arrive que les structures n° 5 ($R_2 + T$), n° 9 ($T + W$), n° 10 ($H + W$) et n° 13 ($R_2 + H + W$) soient échantillonnées plus de 5% des prédictions.

- Quelque soit la structure parmi celles les plus échantillonnées, l'erreur journalière moyenne de prédiction est toujours plus faible pour le modèle MA_{100}+GLM, car les valeurs de $\overline{\Delta CRPS}$ sont toutes positives (figure IX.6).
- Finalement, le modèle MA_{25} alternatif est en moyenne le plus fortement échantillonné avec une fréquence proche de 40% pour une large partie des mailles Safran. Cette fréquence devient très importante lorsque l'on se déplace dans le Sud-Est de la France, où les valeurs atteignent 65%. Pour cette région, il n'est donc pas possible d'établir un modèle de régression pour la quantité. Ceci est dû au fait qu'une graande partie des dates analogues sont sèches. L'information permettant d'identifier un modèle de régression sur la quantité est donc manquante. C'est le cas en particulier de la région du Sud-Est où la fréquence des jours secs est particulièrement importante (*cf.* figure II.8). Par exemple, pour la maille SE, le modèle MA_{25} est sollicité 51% des prédictions. Pour ces dernières, la probabilité moyenne qu'il précipite délivrée par les dates analogues est relativement faible, égale à 0,14.

3.1.2. Variation de l'échantillonnage dans le temps

Dans cette section, nous illustrons la capacité du modèle de quantité à sélectionner préférentiellement une ou plusieurs structures régressives spécifiques en fonction des saisons ou des situations synoptiques. Par exemple, les figures IX.7 et IX.8 représentent respectivement la différence d'échantillonnage de la structure régressive n° 4 (W) et n° 10 ($H+W$) par rapport à leurs fréquences d'échantillonnage globales moyennes respectives observées à la figure IX.5. Pour un filtre temporel donné, les mailles coloriées en bleues indiquent que la structure régressive considérée a été sur-échantillonnée. Elles sont coloriées en jaune lorsqu'il s'agit d'un sous-échantillonnage. La couleur grise indique que l'échantillonnage de la structure pour le filtre temporel considéré est quasiment nul (*i.e.* inférieur à 5%).

A partir des figures IX.7 et IX.8, on remarque que :

- L'échantillonnage d'une structure régressive varie en fonction du filtre temporel considéré. Par exemple, la structure n° 4 (W) est sur-échantillonnée sur l'ensemble du territoire pour les types de temps correspondant à des flux de Sud et au printemps.
- Le sur-échantillonnage de la structure dépend de la région considérée. Par exemple, pour le TT7, la structure n° 4 est sur-échantillonnée jusqu'à +30% en certaines mailles du Sud de la France. Pour d'autres filtres temporels comme l'automne, les TT1, TT3 et TT5, son sur-échantillonnage est seulement limité à certaines régions. Sur la figure IX.8, la structure n° 10 ($H+W$) est globalement peu échantillonnée pour l'ensemble des filtres temporels (moins de 5% des prédictions). Toutefois, pour le TT7, la structure n° 10 est fortement sur-échantillonnée (jusqu'à +25%) localement sur les massifs des Cévènnes-Vivarais.

La figure IX.9 représente pour chaque filtre temporel, les structures régressives pour lesquelles le sur-échantillonnage est maximal en fonction des mailles Safran. Similairement à la figure VIII.10, nous insistons sur le fait que la figure IX.9 n'est qu'une vision limitée des structures régressives qui sont sur-échantillonnées. Les valeurs exactes des sur/sous-échantillonnages sont présentées pour l'ensemble des structures régressives principalement utilisées dans la section 3.2 de l'annexe D. La figure IX.9 permet néanmoins de faire ressortir de façon synthétique quelques résultats intéressants. Il apparaît que :

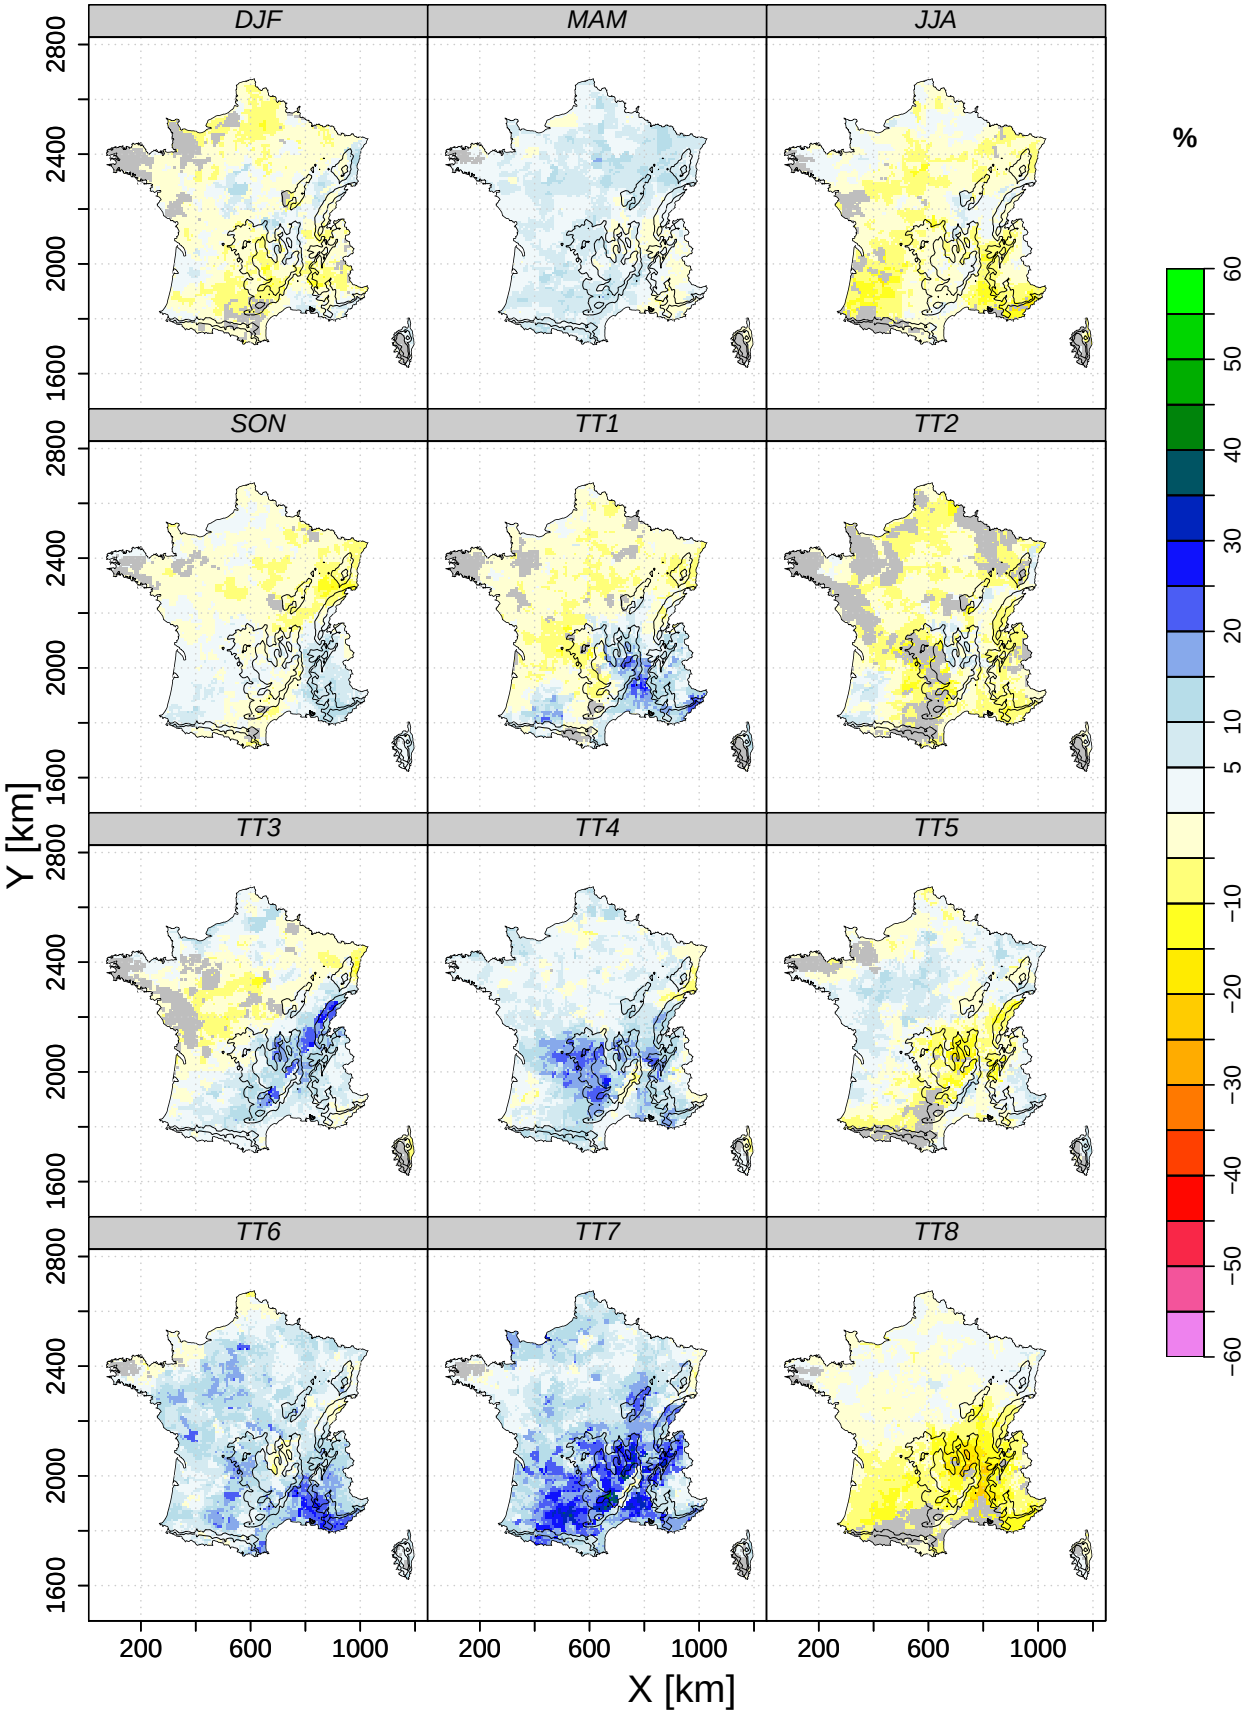

FIGURE IX.7 – Différence de fréquence d'échantillonnage de la structure 4 (seulement basée sur W) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

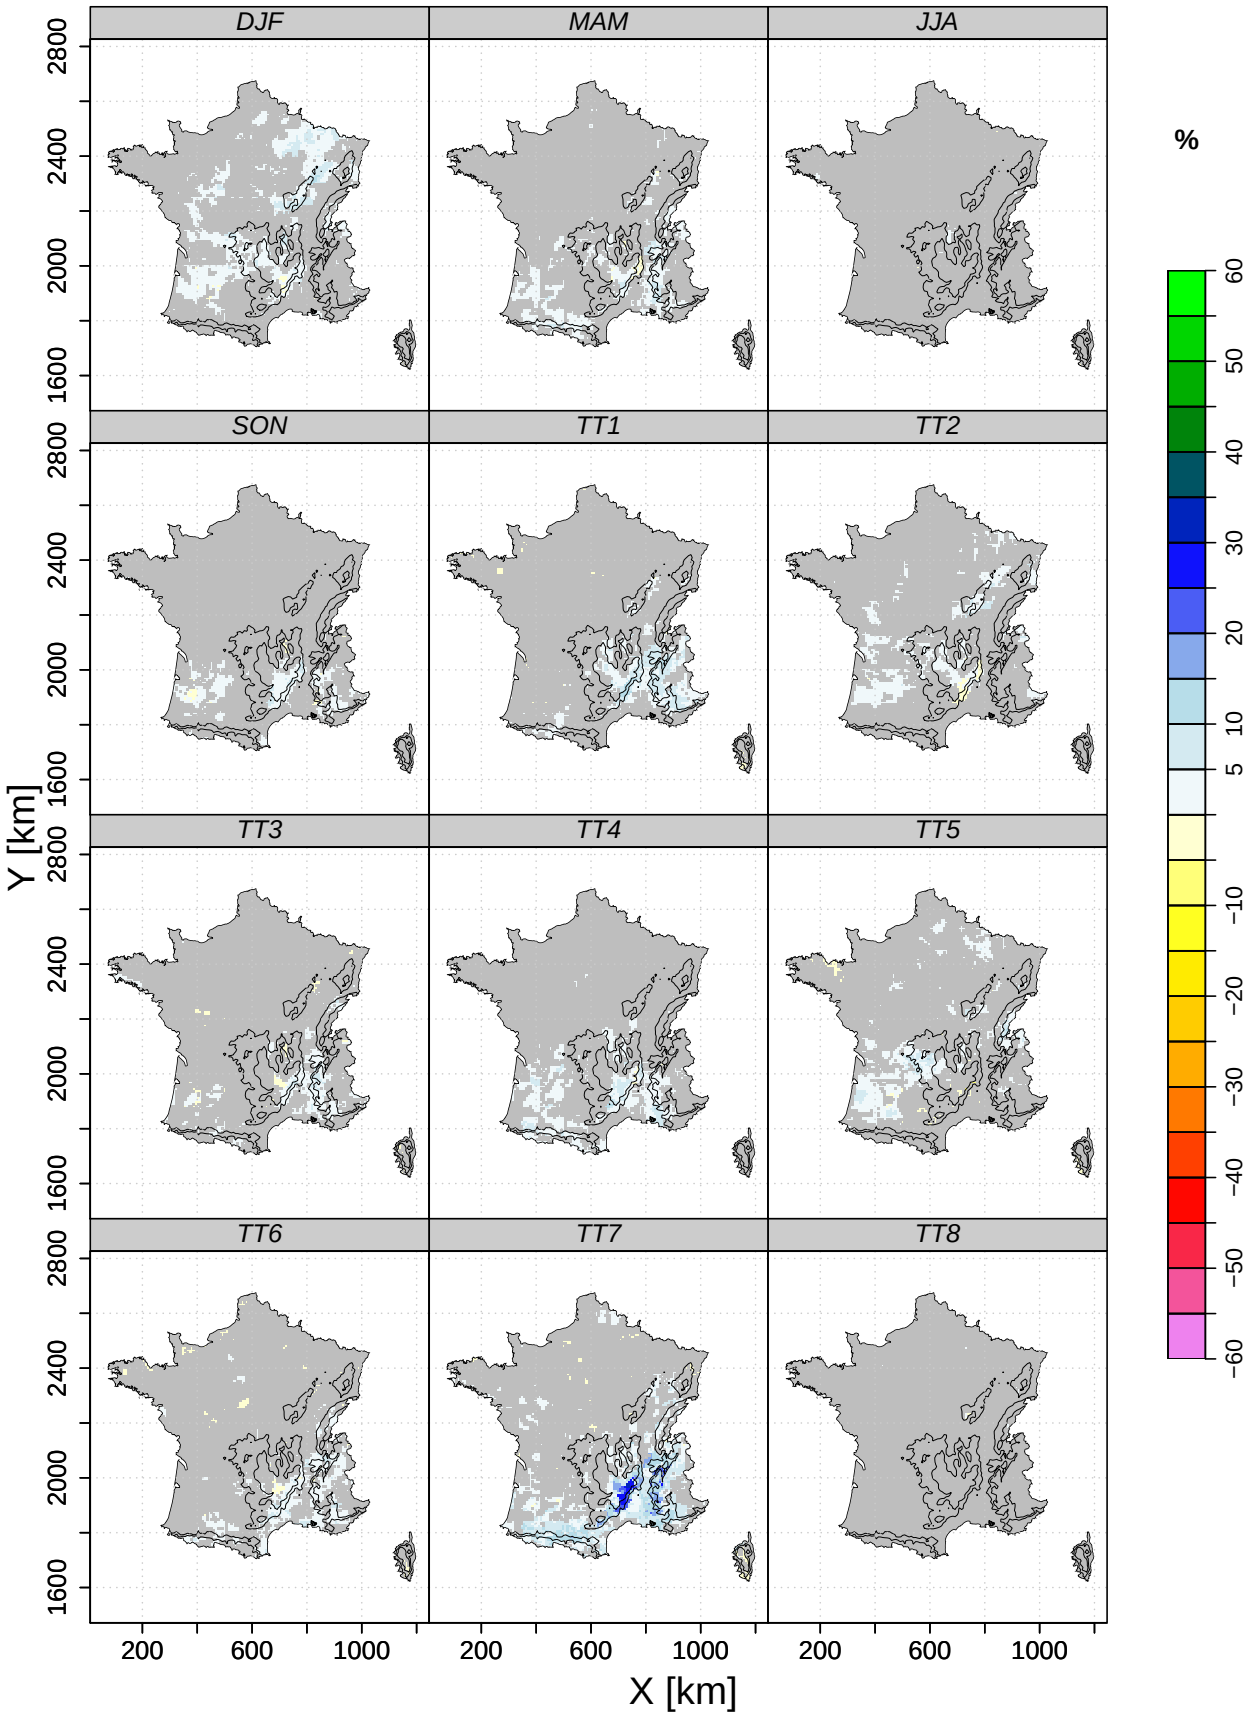

FIGURE IX.8 – Différence de fréquence d'échantillonnage de la structure 10 ($H+W$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

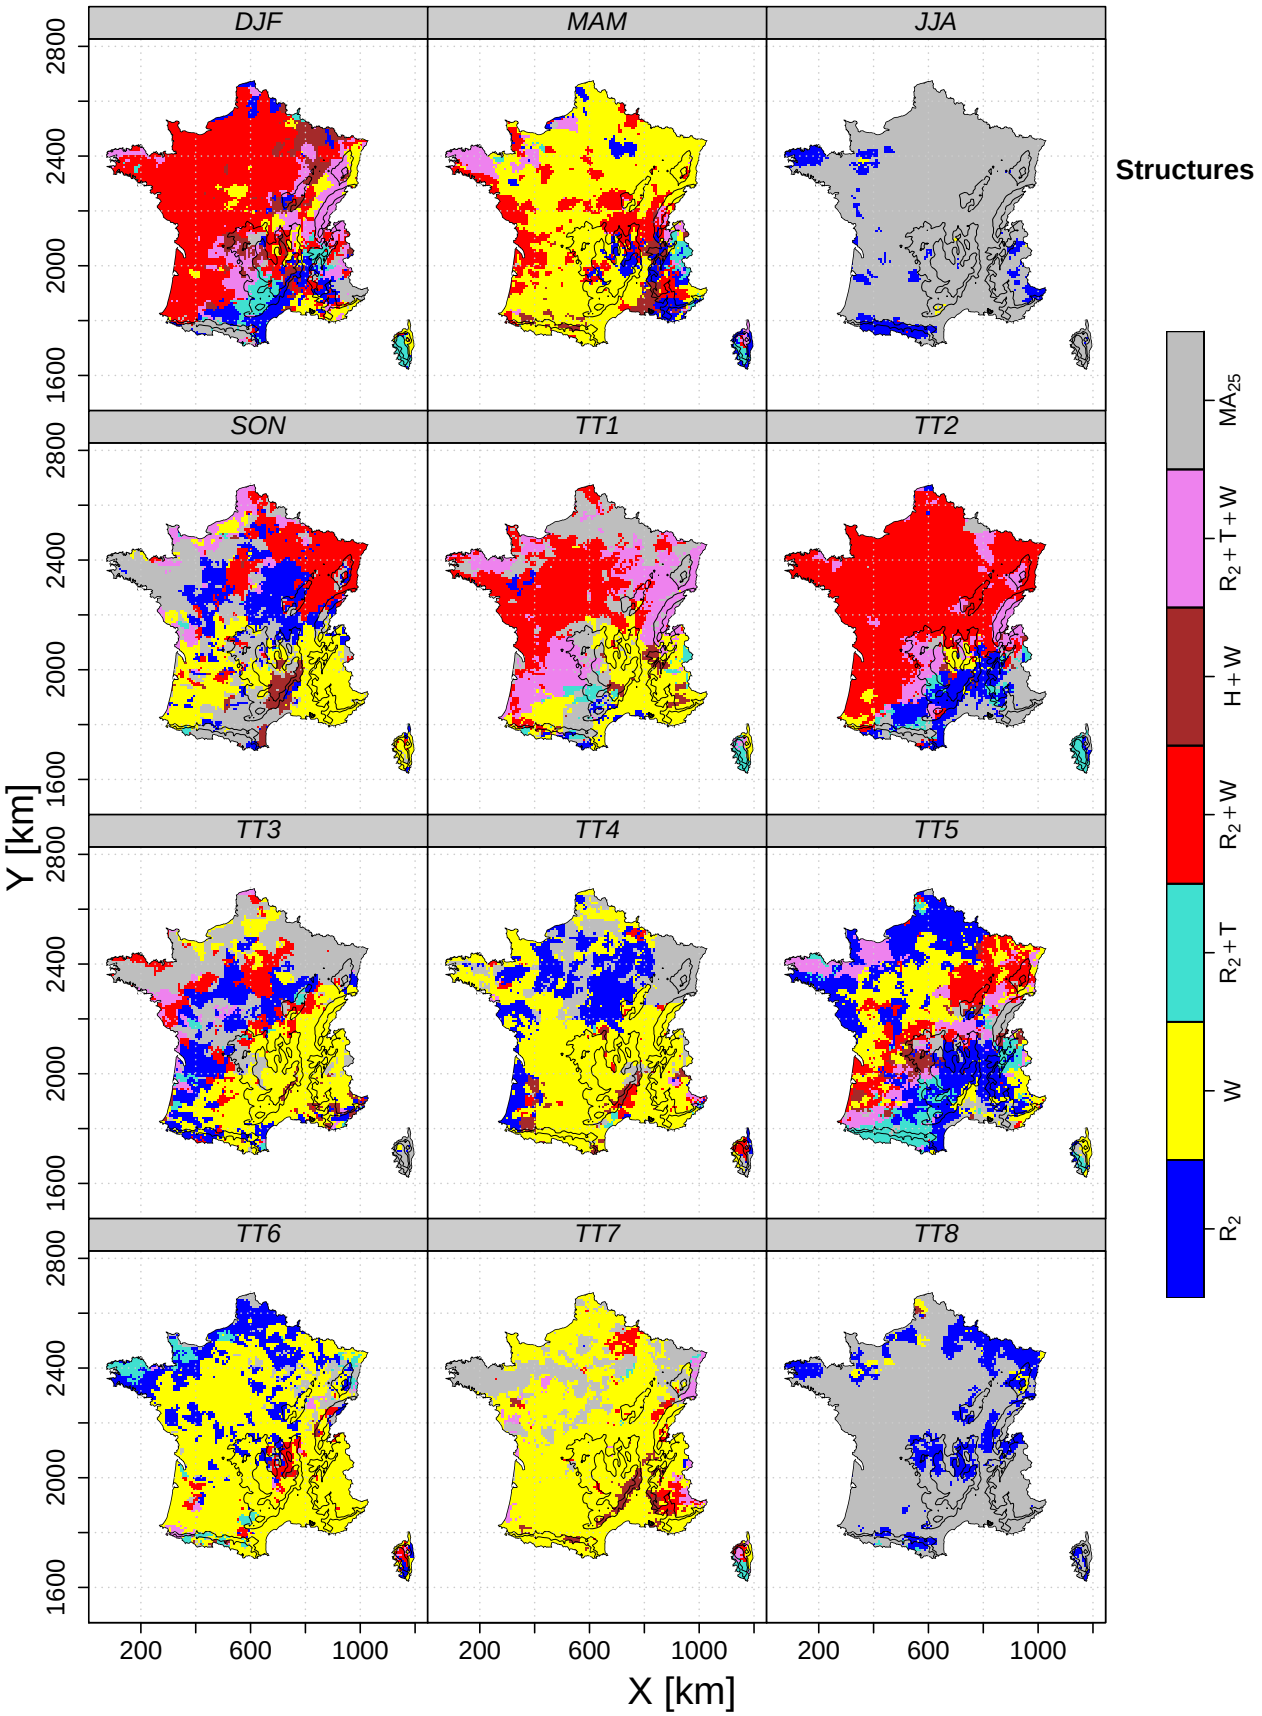

FIGURE IX.9 – Distribution spatiale des structures régressives pour lesquelles la différence d'échantillonnage est maximale en fonction des saisons et des types de temps.

- Dans le cas de flux de Sud (TT4, TT6 et TT7) et pour le printemps, la structure n° 4 (W) s'avère être celle dont le sur-échantillonnage est le plus important sur l'ensemble du territoire (excepté quelques mailles situées dans le nord pour le TT4 et le TT6).
- Dans le cas de flux d'Ouest (ici les TT1 et TT2), les structures comportant la combinaison des deux prédicteurs R_2 et W (*i.e.* les structures n° 7 et n° 12) sont celles dont le sur-échantillonnage est le plus important.
- Le sur-échantillonnage de la structure n° 1 seulement basée sur le prédicteur R_2 est le plus important pour les endroits et les filtres temporels où aucune précipitation n'est observée (*cf.* figure II.7). Par exemple pour le TT2 et dans le Sud-Est où très peu de précipitations sont obtenues, le sur-échantillonnage maximal est obtenu pour la structure n° 1. Ce résultat peut être de plus illustré dans le Nord de la France pour le TT4, le TT5 et le TT6, mais aussi pour les situations d'été et de TT8 (*cf.* figure D.13 de l'annexe D).
- Pour les situations très sèches (*i.e.* l'été et le TT8), le modèle alternatif MA_{25} est celui dont le sur-échantillonnage est le plus important. Cela s'explique de nouveau par le nombre important de dates analogues sèches retenues pour les prédictions appartenant à ces situations.
- La structure n° 10 ($H+W$) présente un sur-échantillonnage important pour le TT7 et dans une moindre mesure pour le TT4 sur la région très spécifique des Cévènnes-Vivarais. Ce résultat est en accord avec plusieurs études comme celles effectuées par Godart [2009] ou encore Kirshbaum & Durran [2005] qui ont montré que le cisaillement était un paramètre important pour la génération de précipitations orographiques organisées en bande souvent retrouvées dans cette région et pour ces types de circulation.

3.2. Cohérence spatiale des structures régressives

3.2.1. Cohérence spatiale de l'échantillonnage des structures

Dans cette section, nous évaluons la capacité du modèle de quantité à identifier une même structure régressive lorsque ce dernier est appliqué en deux mailles Safran données. Pour une maille d'accroche, nous considérons la série temporelle listant la chronologie des structures régressives qui ont été appliquées par le modèle de quantité. Cette série temporelle est comparée à celle issue de chaque maille Safran. Le nombre de prédictions pour lesquelles une même structure régressive est utilisée est alors exprimé sous forme d'un pourcentage par rapport au nombre total de prédictions émises. Ce pourcentage est calculé entre chaque maille d'accroche et l'ensemble des autres mailles Safran. Il est représenté sur la figure IX.10.

On remarque que les mailles incluses dans un rayon d'environ 100 km de la maille d'accroche ont un pourcentage de structures similaires utilisées qui est au moins supérieur à 30%. De même que l'analyse similaire effectuée pour le modèle d'occurrence (*cf.* section 3.2.1 du chapitre VIII), le pourcentage de structures similaires utilisées est là-encore contraint par le relief.

3.2.2. Cohérence spatiale des coefficients de la régression

La figure IX.11 représente la distribution spatiale du coefficient de régression moyen normalisé (*cf.* équation VIII.3) du prédicteur W de la structure régressive 4. Ce coefficient varie entre -1 et 0,05 entre les différentes situations temporelles. Pour chacune de ces situations, ce coefficient varie

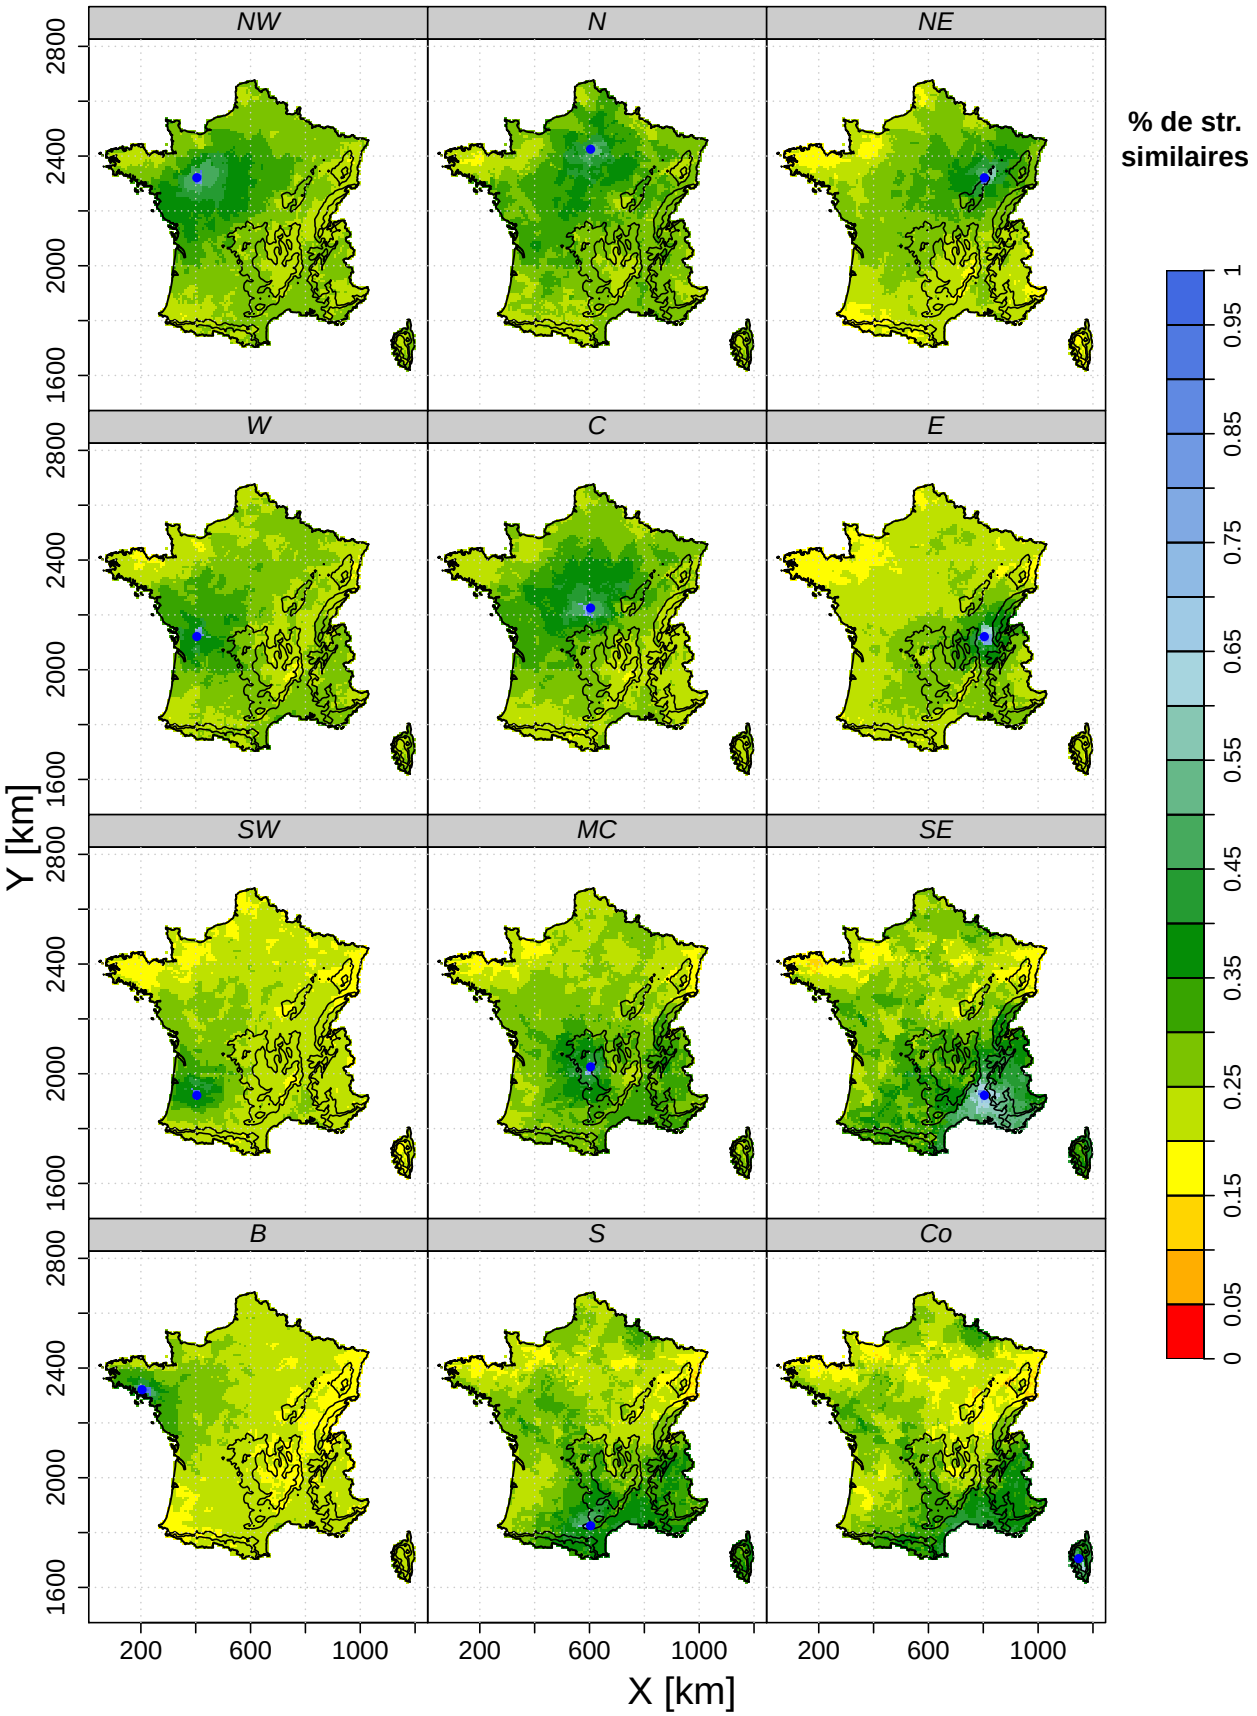

FIGURE IX.10 – Pourcentage de fois où la structure utilisée par l'une des mailles d'accroche (représentée en bleu sur les cartes) est similaire à celles utilisées par les autres mailles Safran.

graduellement de la manière suivante : les valeurs les plus fortes sont observées sur l'ensemble des reliefs (de -0,4 à -0,2) tandis que les valeurs observées en plaine sont plus faibles et diminuent lorsque l'on se déplace vers l'Ouest (jusqu'à -1 pour le TT8). Qui plus est, les situations ou saisons les plus sèches (*i.e.* été et TT8) voient généralement des valeurs de coefficients les plus faibles, tandis qu'elles sont plus importantes lors de situations plus humides telles qu'au TT7 ou au TT6 dans le Sud-Est.

La variation graduelle du coefficient normalisé observée à l'échelle du territoire et en fonction des filtres temporels considérés traduit une certaine robustesse des coefficients de la structure régressive considérée.

L'utilisation concomitante de mêmes structures régressives en différentes mailles voisines, de même que la cohérence spatiale des coefficients estimés en différentes mailles pour ces structures traduit aussi une certaine robustesse des liens d'échelle utilisés pour prédire les précipitations locales.

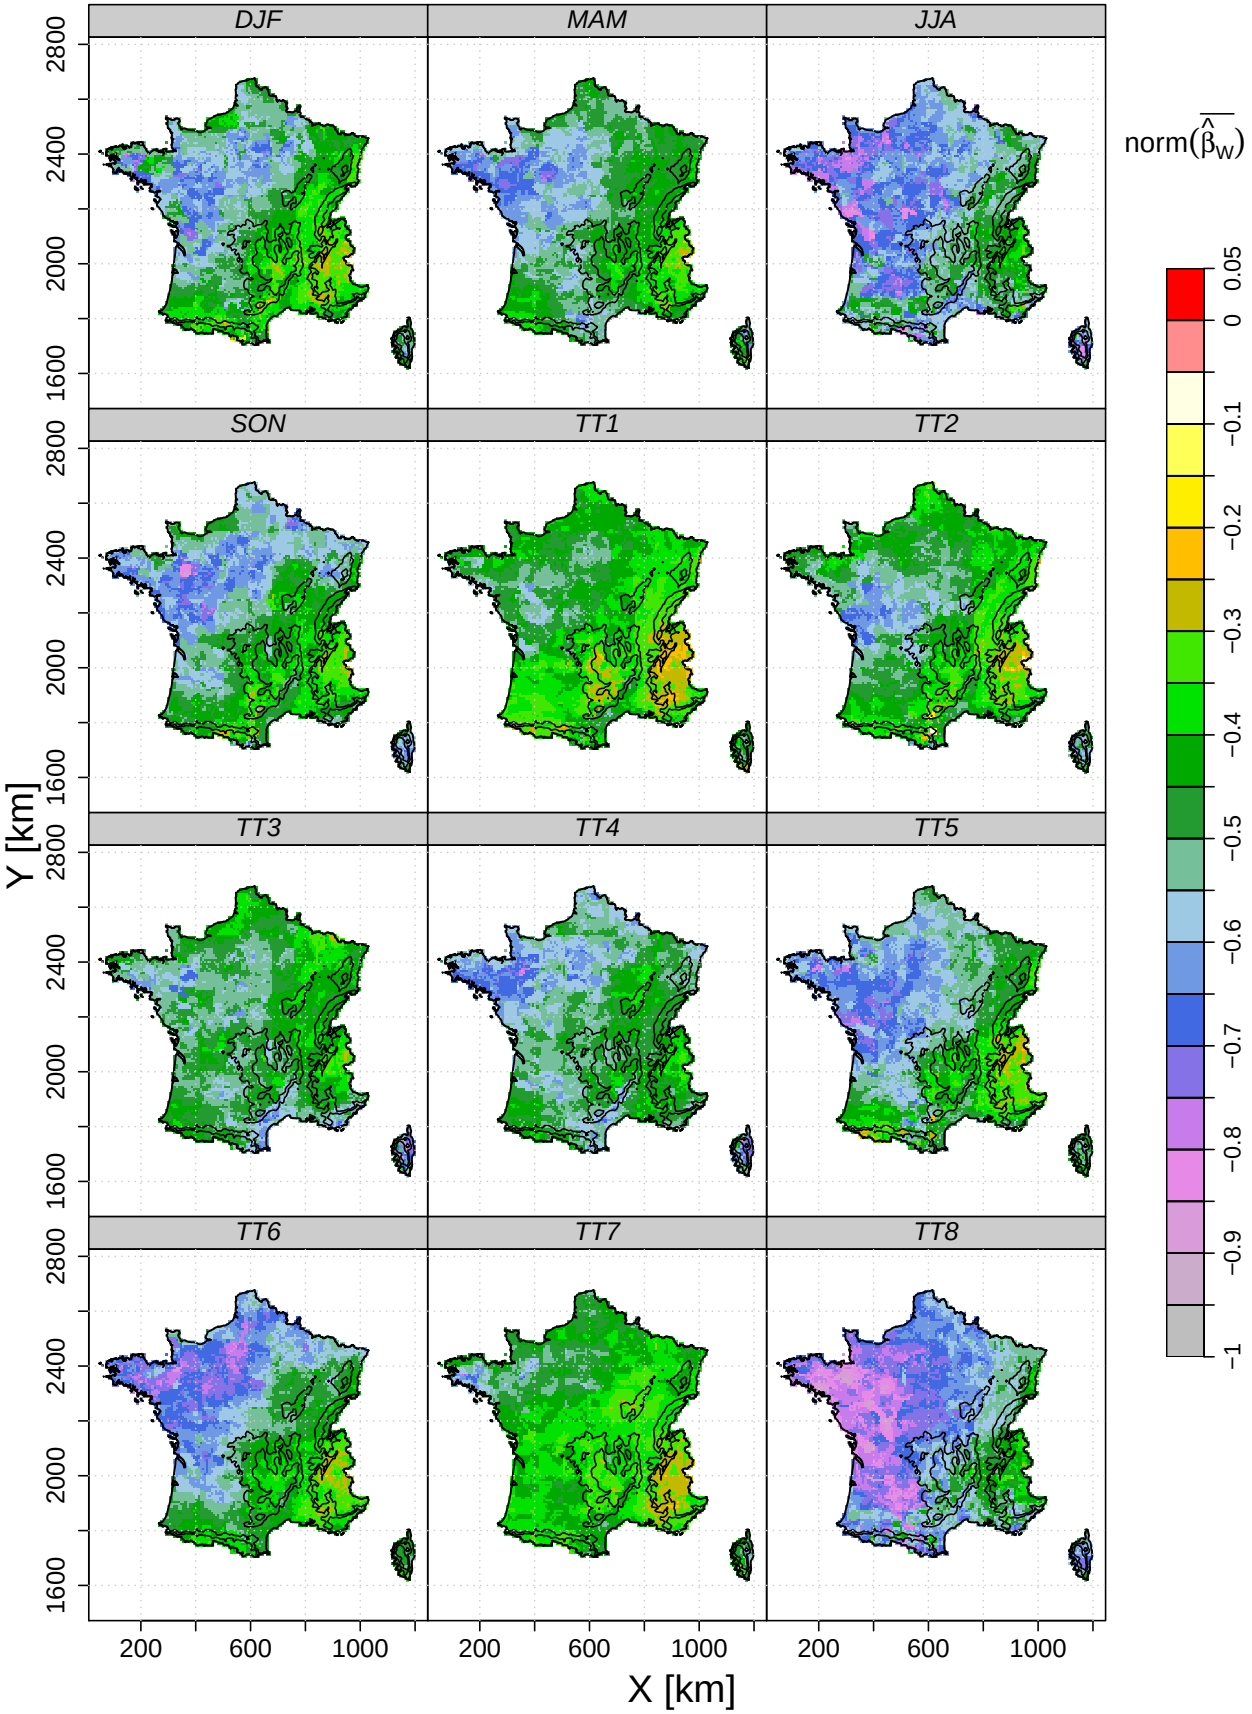

FIGURE IX.11 – Distribution spatiale des coefficients moyens normalisés du prédicteur W de la structure régressive n° 4.

Chapitre X

Intérêt des mises à jour de l'occurrence et de la quantité : combinaison et contribution

---

Dans les deux chapitres précédents, nous avons déterminé deux jeux de prédicteurs pour prédire l'occurrence et la quantité des précipitations. Pour chacun des deux jeux déterminés, nous avons mis en évidence d'une part, (i) les structures régressives les plus utilisées, et d'autre part (ii), les situations synoptiques ou les saisons pour lesquelles l'utilisation de ces structures était la plus favorisée.

Dans ce chapitre, nous nous concentrons sur le fonctionnement du modèle combiné MA_{100}+GLM. Pour une prédiction donnée, le modèle MA_{100}+GLM met à jour, lorsque les contraintes de significativité des coefficients sont satisfaites, la probabilité d'occurrence et/ou la distribution de la quantité de précipitations du modèle MA_{100}. Lorsqu'un modèle de régression n'a pas pu être retenu pour l'une de ces variables, le modèle alternatif MA_{25} est utilisé pour la prédiction de cette dernière. Ceci nous amène à considérer quatre assemblages à partir des modèles d'occurrence et de quantité, comme détaillé à la section VI.3.

Cas 1 : Aucune MAJ (NoMAJ). Le modèle d'occurrence et le modèle de quantité n'ont pas pu être retenus. Dans ce cas, aucune mise à jour de la distribution des précipitations est effectuée. La distribution prédite est égale à la distribution prédite par le modèle MA_{25}.

Cas 2 : Mise à jour de l'occurrence (MAJOcc). Le modèle d'occurrence est retenu tandis que le modèle de quantité n'a pas pu l'être. La distribution prédite résulte de la seule mise à jour de la probabilité qu'il précipite et de l'estimation de la distribution des précipitations positives analogues prédite par le modèle MA_{25}.

Cas 3 : Mise à jour de la quantité (MAJQu). Le modèle d'occurrence n'est pas retenu alors que le modèle de quantité est conservé. La distribution prédite découle de la probabilité qu'il

précipite du modèle MA_{25} et de la distribution des précipitations positives prédite par le modèle de régression logarithmique. Seule la distribution des précipitations positives est alors mise à jour.

Cas 4 : MAJ de l'ensemble de la distribution (MAJall). Le modèle d'occurrence et le modèle de quantité sont retenus. La distribution prédite résulte alors de la mise à jour de la probabilité qu'il précipite et de la distribution des précipitations positives délivrées par les modèles d'occurrence et de quantité.

Dans ce chapitre, nous décrivons d'abord quelles sont les fréquences respectives d'échantillonnage de ces quatre assemblages. Nous estimons ensuite la contribution de chacune des mises à jour respectives (*i.e.* de la probabilité d'occurrence et de la quantité) vis-à-vis de l'augmentation de performance.

1. Caractérisation des quatre assemblages

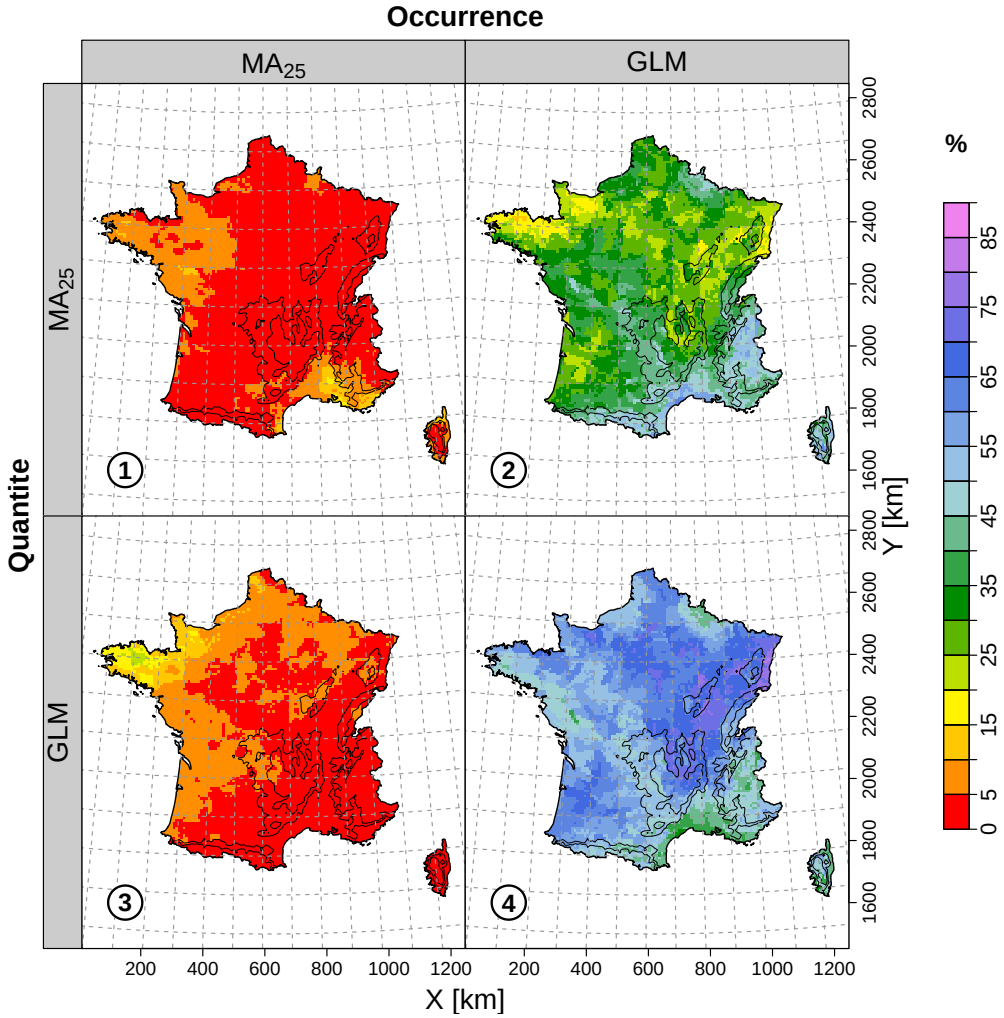

FIGURE X.1 – Distribution spatiale de l'échantillonnage des quatre assemblages possibles pour la combinaison des modèles d'occurrence et de quantité.

La figure X.1 représente la fréquence d'échantillonnage des quatre assemblages possibles. La figure X.2.a) représente l'anomalie de pluie moyenne estimée pour un assemblage donné sur la base de l'ensemble des journées pour lesquels l'assemblage considéré a été utilisé. Elle est exprimée comme le quotient de la pluie moyenne observée pour ces jours sur la pluie moyenne totale (figure X.2.a). Si

pour une maille donnée et un assemblage donné, l'anomalie est inférieure à 1, les prédictions émises à partir de cet assemblage correspondent alors à des journées pour lesquelles les précipitations observées sont inférieures à la moyenne. A l'inverse, pour des anomalies de précipitation supérieures à 1, les journées correspondantes sont alors majoritairement plus pluvieuses que la moyenne. La figure X.2.b) représente la fréquence des jours secs correspondant à chacun des quatre assemblages.

En premier lieu, la figure X.1 nous permet de dire que :

- Les assemblages les plus échantillonnés correspondent à ceux pour lesquels une mise à jour de la probabilité d'occurrence est effectuée. La somme des fréquences d'échantillonnage des cas 2 et 4 représente au minimum 70% des prédictions (non montré dans cette thèse). Le cas 4 est le plus échantillonné sur l'ensemble du territoire (entre 45% et 80%), excepté dans le Sud-Est de la France où le cas 2 obtient une valeur d'échantillonnage plus élevée.
- Le cas 1, où aucune mise à jour est effectuée, est globalement peu échantillonné (au maximum 10% des prédictions). Cela montre l'intérêt fréquent de mettre à jour la distribution prédictive émise.
- Le cas 3, où seule la mise à jour de la quantité est effectuée, est aussi peu fréquent (moins de 10% des prédictions), excepté en Bretagne où un échantillonnage variant entre 10 et 25% peut être observé.

La figure X.2 apporte des éléments de réponse pour expliquer les échantillonnages observés à la figure X.1 :

- Pour les prédictions où une mise à jour a été effectuée à la fois sur l'occurrence et sur la quantité des précipitations (cas 4), les journées correspondantes obtiennent une précipitation variant autour de la précipitation moyenne annuelle (figure X.2.b). La fréquence de jours secs est inférieure à 55% sur l'ensemble du territoire. Pour ces prédictions, la présence de dates analogues sèches d'une part, et d'un nombre suffisant de dates analogues humides d'autre part, permet au modèle MA_{100}+GLM de proposer un modèle de régression à la fois pour l'occurrence et pour la quantité.
- Les prédictions où seule la quantité est mise à jour (cas 3) correspondent à des journées très humides. En effet, la précipitation moyenne est au minimum deux fois plus importante que la précipitation moyenne annuelle (figure X.2.a). De plus, la fréquence de jours secs (figure X.2.b) est proche de 0 (excepté dans le Sud-Est, où un très faible échantillonnage du cas 3 inférieur à 0,5% ne permet pas d'émettre des conclusions). Pour ces prédictions, les dates analogues issues du modèle MA_{100} sont quasiment toutes humides. Elles permettent seulement de mettre à jour la distribution de la quantité de précipitation.
- Les prédictions dont seule l'occurrence des précipitations a été mise à jour (cas 2) correspondent à des journées plutôt sèches. La précipitation moyenne de ces journées est en effet inférieure à la précipitation moyenne annuelle pour l'ensemble du territoire (figure X.2.a). La fréquence des jours secs est comprise entre 45% en Bretagne et 80% dans le Sud-Est, ce qui est plus élevé que pour le cas 4. Le nombre de dates analogues humides est dans ce cas trop faible pour permettre de déterminer convenablement une régression pour la quantité, et la probabilité d'occurrence est seulement mise à jour.

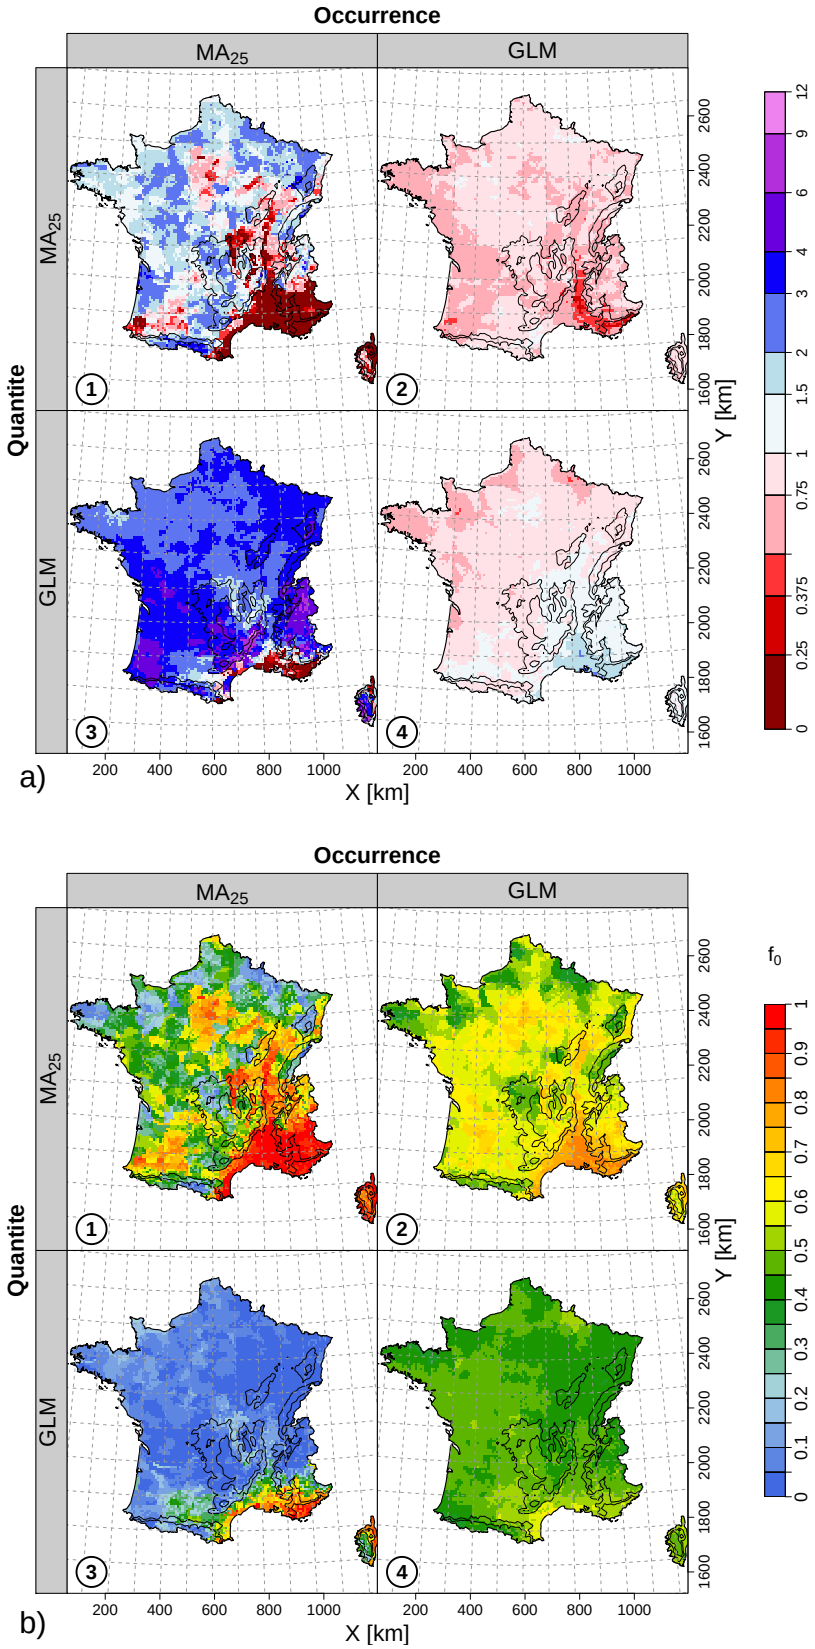

FIGURE X.2 – a) Distribution spatiale du quotient des pluies moyennes observées pour un assemblage considéré sur la pluie moyenne totale et b) distribution de la fréquence des jours secs pour chacun des quatre assemblages. 1) NoMAJ, 2) MAJOcc, 3) MAJQu et 4) MAJall.

- Enfin, le cas 1 – où aucune mise à jour est effectuée – est faiblement échantillonné sur l'ensemble du territoire (moins de 5%), excepté dans le Sud-Est de la France et en Bretagne où l'échantillonnage peut atteindre 15%. Pour ces prédictions, les dates analogues correspondent toutes à des journées sèches. Comme nous l'avons déjà énoncé à la section 3.1.2 du chapitre VIII et à la section 3.1.2 du chapitre IX, le nombre important de dates analogues sèches pour ces prédictions interdit la détermination d'un modèle de régression pour l'occurrence ainsi que pour la quantité. Le modèle MA_{25} est alors utilisé. C'est ce qu'on observe par exemple dans le Sud-Est de la France où la précipitation moyenne est très faible et la fréquence des jours secs est proche de 1.

  Cependant, le modèle MA_{25} est aussi mobilisé dans d'autres configurations. Dans ces cas, étrangement, les dates analogues sont toutes humides. Un modèle d'occurrence ne peut pas être déterminé de part la forte proportion de valeurs d'occurrence égales à 1. Pour ces prédictions, un modèle de quantité est recherché par le modèle MA_{100}+GLM au travers de l'algorithme de sélection itérative (*cf.* section 2.3.3 du chapitre VI). Cependant, il apparaît que pour ces situations, la fonction `step()` (package `R – {stats}`) utilisée pour la sélection itérative des prédicteurs est mise en défaut car elle n'arrive pas à converger. Dans ce cas, nous avions imposé l'utilisation du modèle alternatif MA_{25}. Pour cette raison, de fortes valeurs de ratio de précipitations moyennes (figure X.2.a) et de faibles fréquences de jours secs (figure X.2.b) sont rencontrées sur l'ensemble du territoire (excepté le Sud-Est). Par suite, l'algorithme de sélection de la structure régressive retenue a été modifié : pour chaque jour de prédiction, l'ensemble des quinze structures régressives listées dans le tableau IX.2 a été testé pour la prédiction de la quantité de précipitation. La structure régressive retenue *in fine* correspond à celle qui est la plus pertinente selon le critère BIC (*i.e.* celle obtenant le BIC le plus faible) et respectant les conditions de significativité des coefficients définies à la section 3.2 du chapitre VI. Si aucune structure régressive ne respecte les conditions de significativité, le modèle MA_{25} est utilisé comme lien d'échelle alternatif pour la prédiction de la quantité de précipitation. Une procédure de sélection similaire a aussi été mise en place pour la prédiction de la probabilité d'occurrence. L'utilisation de ce nouvel algorithme de sélection a permis de mettre à jour les résultats présentés aux figures IX.5, IX.6, IX.7, IX.8, IX.9, IX.10, X.1 et X.2. Ces dernières sont disponibles à l'annexe D.4 [1].

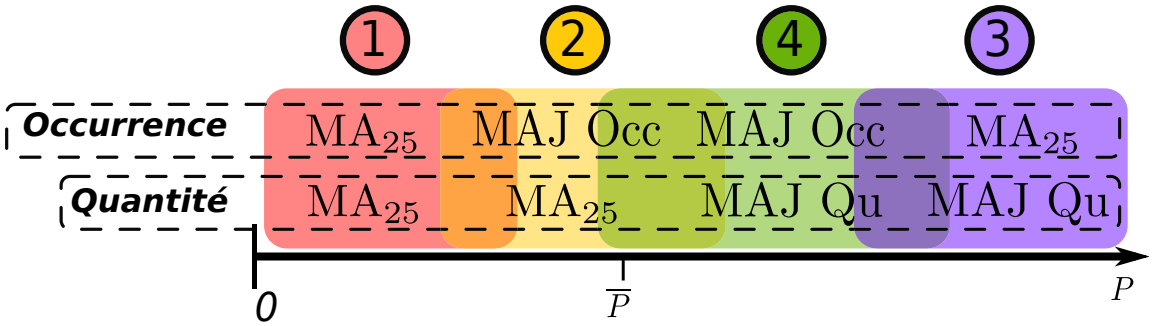

FIGURE X.3 – Schéma représentant la stratégie d'assemblage du modèle combiné MA_{100}+GLM en fonction de la quantité de précipitation.

Pour représenter la stratégie d'assemblage des modèles d'occurrence, de quantité et du modèle alternatif MA_{25}, le schéma X.3 représente la manière dont la précipitation est prédite en fonction

1. L'ensemble des calculs incluant cette nouvelle stratégie de sélection de la structure régressive a été effectué entre la soumission du manuscrit de thèse aux membres du jury et la soutenance de thèse.

du cumul de précipitation observé pour une journée. Pour les jours très secs pour lesquels les dates analogues sont quasiment toutes sèches, le modèle combiné privilégie l'utilisation du modèle MA_{25}. Lorsqu'une faible probabilité qu'il précipite est émise par MA_{100}, le modèle MA_{100}+GLM met seulement à jour l'occurrence. Pour des jours où la précipitation observée est en moyenne égale à la précipitation moyenne annuelle, le modèle met à jour l'ensemble de la distribution. Pour finir, pour les situations où les dates analogues sont quasiment toutes humides, seule la quantité de précipitation est mise à jour, conduisant alors en moyenne à des précipitations intenses.

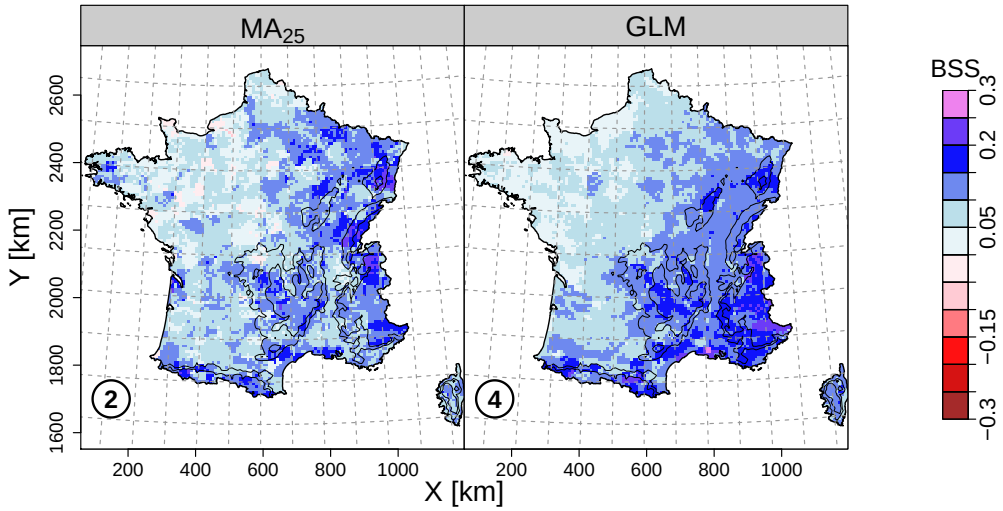

FIGURE X.4 – Gain relatif du score de Brier BS (équivalent à un BSS en prenant pour référence le modèle MA_{25}) entre le modèle combine MA_{100}+GLM et le modèle MA_{25} pour les cas 2 et 4 où l'occurrence de précipitation a pu être mise à jour. 2) MAJOcc, 4) MAJall.

Pour les deux cas où l'occurrence des précipitations a pu être mise à jour (correspondant aux cas 2 et 4), la figure X.4 montre le gain relatif du score de Brier par rapport au modèle MA_{25} – ce qui revient à calculer le BSS obtenu par le modèle MA_{100}+GLM en considérant comme référence le modèle MA_{25}. Dans les deux cas, un gain est observé en toute maille Safran. Le gain en BS varie dans la même gamme de valeurs (entre 0,05 et 0,25) pour les deux cas 2 et 4, toutefois, il est légèrement plus important dans le Sud-Est de la France dans les cas où la quantité est aussi mise à jour (cas 4).

La figure X.5 présente le gain relatif en CRPS – équivalent au CRPSS obtenu par le modèle MA_{100}+GLM en considérant pour référence le modèle MA_{25}. On remarque que des gains sont observés dès lors qu'une mise à jour, de l'occurrence ou de la quantité, est effectuée, excepté dans le Sud-Est pour le cas 4, pour lequel il a été montré que cette évaluation n'était pas pertinente de part le très faible échantillonnage du cas 4 dans le Sud-Est. Les gains très importants sont obtenus pour les jours où seule la quantité a été mise à jour (de 10 à 30%). Ils sont encore très importants quand cette mise à jour est combinée à une mise à jour de l'occurrence (entre 0 et 15%) et dans une moindre mesure lorsque seule l'occurrence est mise à jour. Cela justifie l'introduction d'une information synoptique supplémentaire pour permettre une meilleure prédiction locale des précipitations.

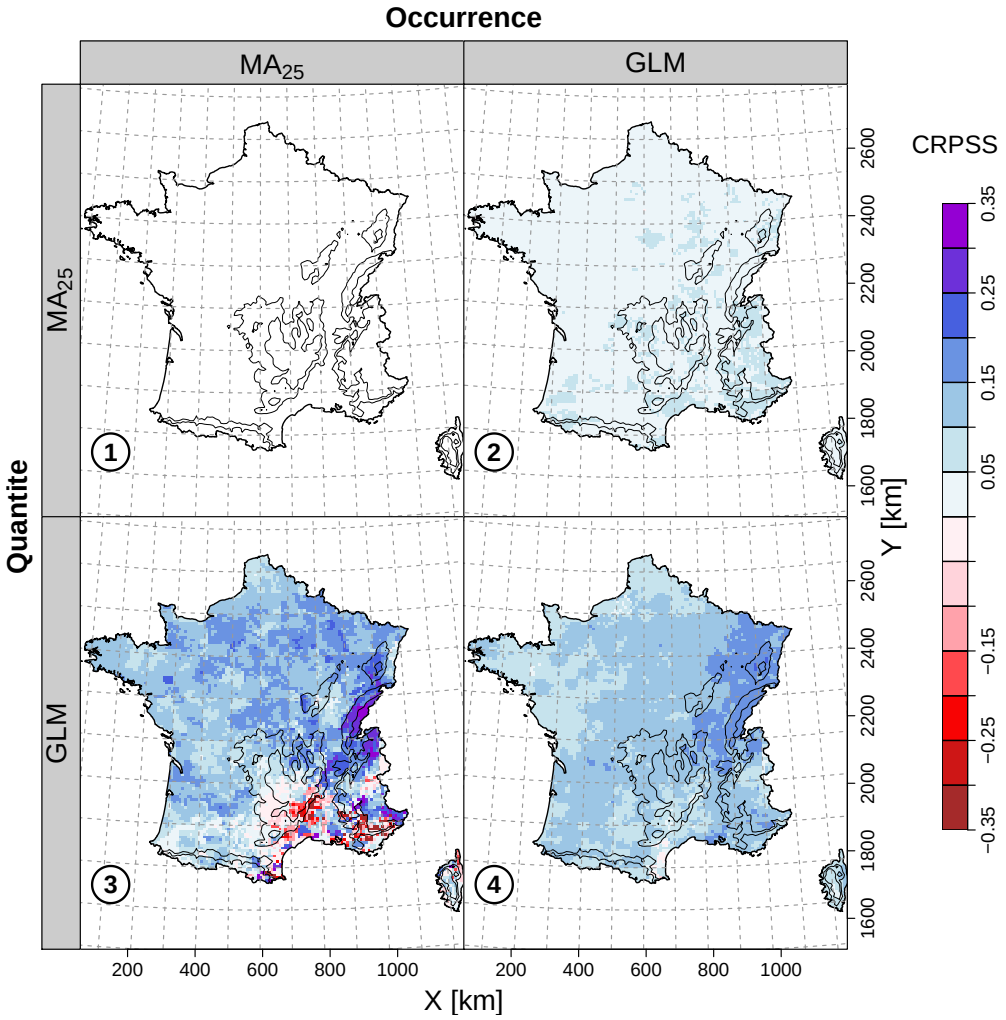

FIGURE X.5 – Gain relatif en CRPS (équivalent à un CRPSS en prenant pour référence le modèle MA_{25}) . 1) NoMAJ, 2) MAJOcc, 3) MAJQu 4) MAJall.

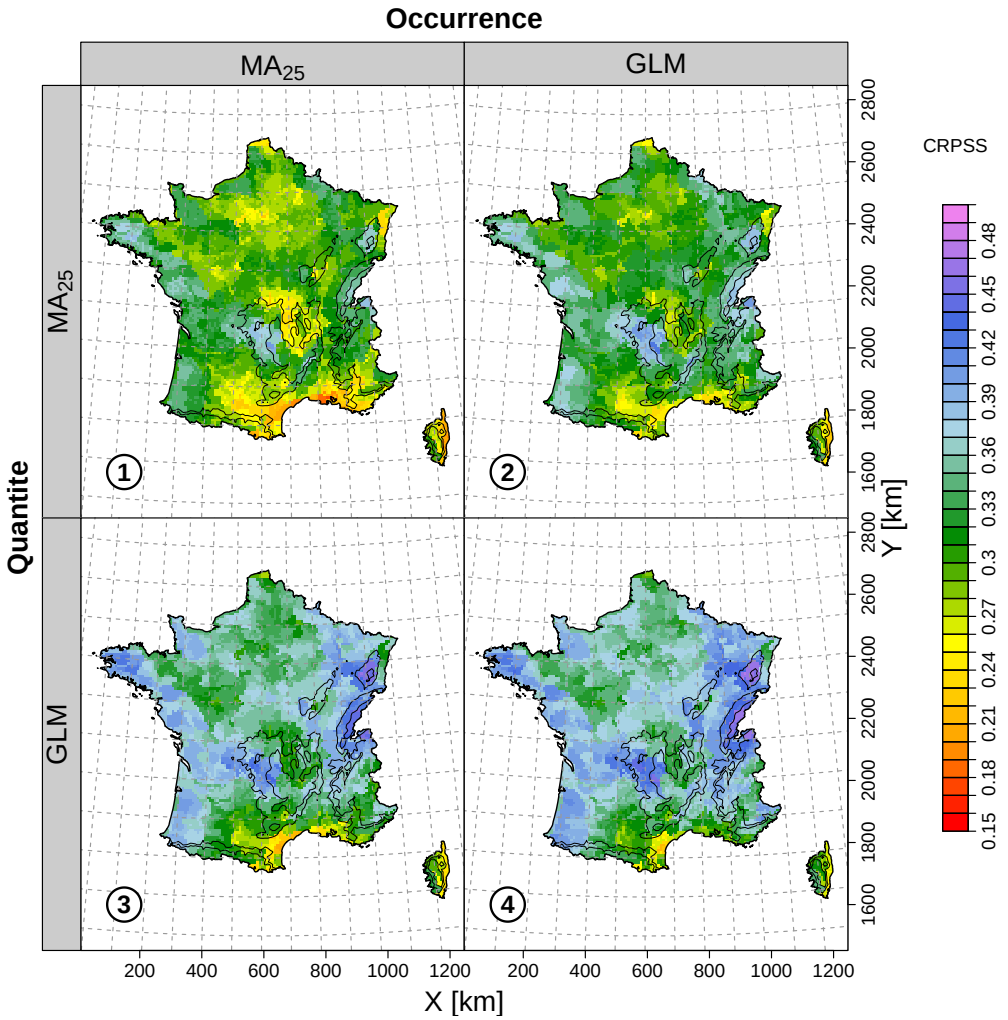

FIGURE X.6 – CRPSS obtenus lorsque 1) le modèle MA_{25} est utilisé, 2) seule l'occurrence est mise à jour dans le modèle MA_{100}+GLM, 3) seule la quantité est mise à jour dans le modèle MA_{100}+GLM et 4) l'occurrence et la quantité sont toutes les deux mises à jour.

2. Contribution à l'augmentation du gain de performance

Les résultats précédents illustrent les intérêts relatifs des différentes mises à jour. Cependant, l'analyse est bruitée par le fait que les différents assemblages sont par construction appliqués sur des ensembles différents de prédictions. Pour mieux cerner l'intérêt de chaque composante de la mise à jour, nous nous demandons ici quelle est la part de performance en CRPSS du modèle MA_{100}+GLM expliquée par la mise à jour de l'occurrence et/ou celle de la quantité. Quatre simulations sont alors considérées :

- **Simulation 1** : Le modèle alternatif MA_{25} est appliqué pour la prédiction des précipitations en toute maille de la France. Cette simulation correspond au modèle MA_{25} évalué au chapitre III.
- **Simulation 2** : Le modèle MA_{100}+GLM est utilisé pour la prédiction de l'occurrence. Le modèle alternatif MA_{25} est utilisé pour la prédiction de la quantité de précipitation.
- **Simulation 3** : Le modèle alternatif MA_{25} est utilisé pour la prédiction de l'occurrence de précipitation. Le modèle MA_{100}+GLM est utilisé pour la prédiction de la quantité.

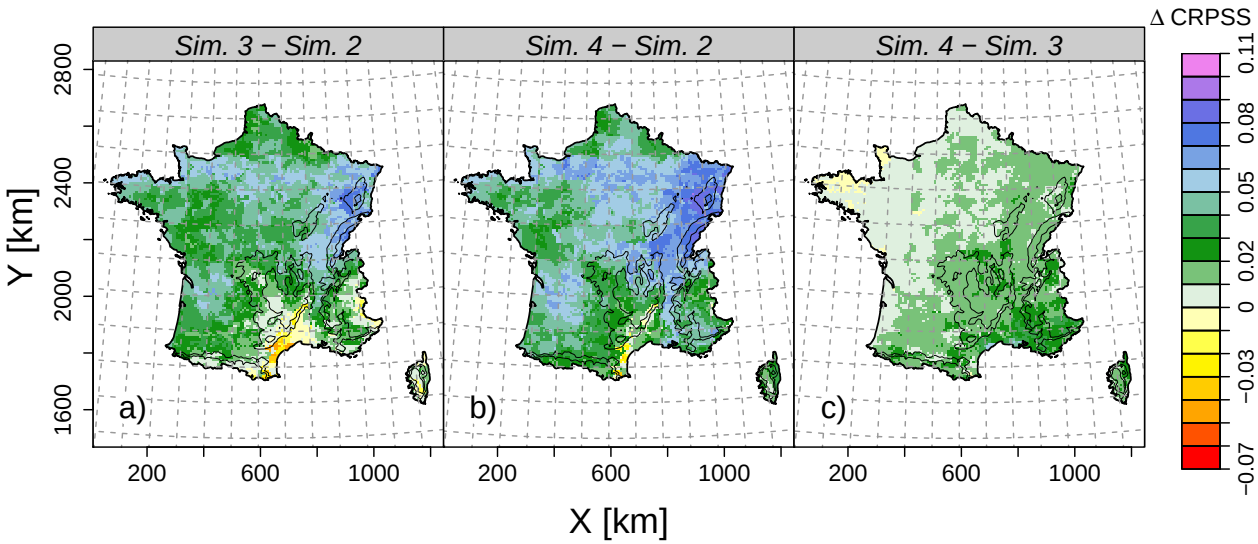

FIGURE X.7 – ΔCRPSS correspondant à la différence de performance en CRPSS a) entre le modèle combiné où seule la quantité est mise à jour et le modèle où seule l'occurrence est mise à jour, b) entre le modèle où l'ensemble de la distribution est mise à jour et le modèle où seule l'occurrence est mise à jour et c) entre le modèle où l'ensemble de la distribution est mise à jour et le modèle où seule la quantité est mise à jour.

- **Simulation 4** : Le modèle MA_{100}+GLM est utilisé pour la prédiction de l'occurrence et de la quantité de précipitation. Cette simulation correspond alors au modèle MA_{100}+GLM évalué à la section 1.

La figure X.6 représente les performances en CRPSS calculées pour ces quatre simulations. Pour mémoire, les performances obtenues pour la simulation 1 correspondent à celles représentées à la figure III.6.a) tandis que les performances obtenues par la simulation 4 correspondent à celles représentées sur la figure IX.4.a).

La distribution spatiale des performances en CRPSS lorsque seule l'occurrence est mise à jour (simulation 2) est similaire à celle obtenue par le modèle MA_{25} (simulation 1 de la figure X.6). Les performances observées lorsque seule la quantité est mise à jour (simulation 3) sont quant à elles proches de celles obtenues lorsque l'ensemble de la distribution est mise à jour (simulation 4). Ainsi, la mise à jour de la quantité apparaît comme étant la plus bénéfique des performances obtenues par le modèle MA_{100}+GLM. Cela est de plus illustré au travers de la figure X.7.a) qui présente la différence de CRPSS entre plusieurs paires de simulation. Globalement, la performance en CRPSS est plus importante sur l'ensemble de la France lorsque seule la quantité est mise à jour par rapport à l'occurrence. Cependant, pour certaines mailles situées dans le Sud de la France, les performances en CRPSS obtenues sont plus importantes lorsque seule l'occurrence est mise à jour (figure X.7.a). Pour cette région particulière, il apparaît même que la mise à jour à la fois de la quantité et de l'occurrence dégrade légèrement de 1 point le CRPSS (figure X.7.b). La mise à jour de la quantité s'avère donc en moyenne pénalisante. Pour mémoire, cette région correspond à la région pour laquelle le gain de performance en CRPSS était le plus faible pour le modèle de quantité (*cf.* figure IX.3 du chapitre IX, ModQu10). Dans une moindre mesure, un comportement similaire peut être observé en Bretagne à la figure X.7.c) où de très faibles pertes peuvent être observées lorsque les mises à jour de l'occurrence et de la quantité (simulation 4) sont effectuées par rapport à une mise à jour seule de la quantité

(simulation 3). De même, la Bretagne correspond à la région pour laquelle le gain de performance en BSS est le plus faible pour le modèle d'occurrence (*cf.* figure VIII.4 du chapitre VIII, ModOcc3).

Ces résultats sont évidemment très conditionnés par le choix des modèles retenus pour la mise à jour de la probabilité d'occurrence et de la quantité. Ce choix a été effectué parmi plusieurs modèles identifiés comme les meilleurs pour différentes mailles du territoire. Il est possible que les pertes constatées dans le Sud-Est et en Bretagne soient réduites voire même remplacées par des gains pour de meilleurs modèles adaptés à ces régions.

Synthèse

La corrélation entre prédicteurs de grande échelle diffère-t-elle lorsque les prédicteurs sont extraits des dates analogues ?
De manière générale, la corrélation entre deux prédicteurs est conservée lorsqu'elle est estimée à partir des dates analogues. Néanmoins, pour une majorité des couples de prédicteurs testés, le niveau de corrélation positive (ou de corrélation négative) observé est légèrement moins important que celui obtenu lorsque la corrélation est calculée de façon globale. L'extraction des valeurs de prédicteurs par les dates analogues n'échantillonne qu'une partie des jours inclus dans une fenêtre de $\pm$ 30 jours et réduit ainsi les effets de saisonnalité pouvant exister entre prédicteurs. A l'inverse, très peu de prédicteurs obtiennent une corrélation plus forte. Globalement, la sélection d'un jeu de prédicteurs non corrélés pour l'application d'un modèle combiné semble pouvoir se satisfaire d'une étude de la corrélation moyenne.

Quels sont les prédicteurs de second niveau pour la prédiction des précipitations en France ?
Dans une première analyse, nous avons exploré l'intérêt de prédicteurs uniques pour la mise à jour de la prédiction émise pour un modèle analogue basé sur les hauteurs de géopotentiels Z_{1000} et Z_{500}. Concernant l'occurrence des précipitations, il est apparu que seuls les prédicteurs d'humidité permettent d'améliorer en tout point du territoire la performance du modèle analogue. Par suite, il s'est avéré que la combinaison d'une information d'humidité (*i.e.* humidité relative à 700 hPa) et d'une information de persistance (*i.e.* l'occurrence de précipitation de la veille) s'avère majoritairement intéressante.

Pour la hauteur précipitée, tous les prédicteurs testés permettent d'augmenter les performances en CRPSS du modèle analogue. Sur l'ensemble du territoire, le prédicteur de vitesse verticale W est apparu comme étant le plus explicatif de la quantité de précipitation, suivi de l'humidité relative R_2.

Pour la prédiction de l'occurrence et de la quantité de précipitation, les gains de performances observés par rapport au modèle MA_{25} augmentent lorsque l'on se déplace de l'Ouest à l'Est de la France. L'information de second niveau est plus intéressante dans les terres et sur le pourtour méditerranéen que sur la côte Atlantique, région pour laquelle les précipitations sont déjà relativement bien expliquées par les géopotentiels.

Existe-t-il une dépendance entre prédicteurs et situations de grande échelle ?
Une évaluation de la fréquence d'échantillonnage des structures régressives utilisées en fonction des saisons et d'une classification en type de temps a mis en évidence qu'il existait une dépendance entre la structure et la situation considérée. Pour l'occurrence par exemple, dans le cas de situations atmosphériques pour lesquelles aucune précipitation n'est attendue, un prédicteur de persistance s'avère adapté. Dans le cas de flux d'Ouest, la combinaison de l'humidité relative et de la vitesse verticale constitue un bon indicateur de la quantité de précipitations.

Une dépendance à la région considérée peut parfois être observée. Par exemple, lors de situations correspondant à des flux atmosphériques originaires du Sud, le prédicteur hélicité, caractéristique du cisaillement, est fortement sollicité que ce soit pour l'occurrence ou la quantité de précipitation.

Quels sont les avantages de combiner un modèle GLM avec un modèle Analog ?
La combinaison d'un GLM avec un modèle MA permet d'adapter, pour chaque prédiction, le lien d'échelle à la fois dans le temps, mais aussi dans l'espace sur la base des dates analogues. Le lien d'échelle semble robuste dans l'espace de par l'utilisation concomitante fréquente de mêmes structures régressives et la forte cohérence spatiale obtenue pour les coefficients des régressions.

L'utilisation d'un modèle combiné apporte de plus un gain moyen en CRPSS égal à 6,5 points sur la France, ce qui représente 3 points de plus par rapport à un modèle analogue hiérarchique où le second niveau d'analogie est effectué de façon figée sur un terme d'humidité. Ceci montre l'intérêt d'adapter dans le temps le lien d'échelle par la recherche d'une combinaison de prédicteurs adaptés à la situation à prédire.

Les mises à jour de la probabilité d'occurrence et de la quantité de précipitation sont-elles importantes ?
A l'échelle du territoire français, il est apparu qu'une mise à jour de la quantité apporte des gains en CRPSS plus importants que celle effectuée sur la probabilité d'occurrence. Toutefois, la mise à jour de cette dernière n'est pas à négliger car son utilité s'avère très importante en certaines régions comme le Sud de la France. Globalement, la sollicitation d'un modèle d'occurrence et d'un modèle de quantité dépend du niveau moyen de précipitation attendue. Si la précipitation attendue est très faible, ou en d'autres termes, si la majeure partie des dates analogues sont sèches, le modèle d'occurrence et le modèle de quantité seront peu voir jamais sollicités. Pour ces deux prédictands, le modèle MA_{25} est utilisé comme modèle de prédiction alternatif. Le modèle d'occurrence ne sera pas non plus sollicité si la précipitation moyenne attendue est importante, ce qui est souvent le cas lorsque toutes les dates analogues sont précipitantes. Pour ces situations, le modèle de quantité pourra en revanche être sollicité. Le modèle d'occurrence et le modèle de quantité sont généralement tous deux sollicités lorsque les précipitations attendues sont modérées et pour lesquelles une partie seulement des dates analogues prédisent des précipitations.

CONCLUSION & PERSPECTIVES

En bref...

Dans ce travail de thèse, nous avons exploré différentes questions liées à la possibilité de générer sur de vastes territoires des scénarios de précipitations spatialement cohérents, qui puissent expliquer au mieux les précipitations observées à différentes échelles d'espace. Nous synthétisons ici les principaux résultats de nos analyses et proposons quelques pistes de recherche pour des travaux ultérieurs.

1. Prédiction de scénarios pluviométriques spatialement cohérents

Dans plusieurs études, il a été montré que les prédicteurs optimaux d'un modèle MA, et par suite les dates analogues, étaient dépendants de l'endroit géographique considéré pour la prédiction [Timbal & McAvaney, 2001 ; Wetterhall et al., 2006]. Lorsque les prédicteurs sont fixés, plusieurs domaines d'analogies peuvent conduire à des performances équivalentes [Radanovics et al., 2013], alors que ces domaines diffèrent très légèrement entre deux sites voisins. Ainsi, un domaine d'analogie optimisé pour un site donné pourrait conduire à une performance quasi-optimale lorsqu'il est utilisé pour la prédiction des précipitations en des sites voisins.

Dans une première partie de cette thèse, nous avons évalué la capacité à appliquer un jeu de dates analogues en d'autres endroits que celui pour lequel ces dates ont été optimisées, *i.e.* leur transposabilité spatiale. Les principales conclusions peuvent être résumées ainsi :

- Un fort niveau de similarité entre les dates analogues optimales n'est pas nécessaire pour la transposabilité spatiale d'un modèle MA.
- Lorsque les dates analogues sont identifiées sur la base des hauteurs de géopotentiel, la transposabilité spatiale des dates analogues est grande et des performances de prédiction quasi-optimales peuvent être obtenues en des mailles parfois distantes de 500 km. Tout comme les Alpes [Bontron, 2004], le Massif Central constitue une barrière topographique limitant cette transposabilité.
- Un biais non négligeable de la moyenne inter-annuelle peut être retrouvé lorsque le modèle MA est utilisé pour la génération de scénarios de précipitations. Ce résultat est dû à un échantillonnage hétérogène des situations analogues passées contenues dans l'archive historique. Ce biais peut être amplifié lorsque des dates analogues sont transposées. Toutefois, comme plusieurs jeux de dates analogues permettent d'obtenir des performances similaires, on peut imaginer qu'il soit possible d'identifier un jeu de dates qui conduise à la fois à l'obtention de bonnes performances de prédiction et d'un biais faible, ou *a minima* plus faible que celui obtenu ici.
- Le raffinement d'un modèle MA est potentiellement nuisible à la bonne transposabilité spatiale des dates analogues. Lorsqu'un second niveau d'analogie basé sur un prédicteur d'humidité est ajouté, les performances de prédiction sont certes augmentées, mais la transposabilité est réduite. Toutefois, le gain de performance apporté par l'ajout de la seconde variable d'analogie est supérieur à la perte engendrée lors de la transposition. Ceci est visible jusqu'à 400 km à partir de la maille pour laquelle les modèles MA transposés ont été optimisés.

2. Prédiction de précipitations agrégées à l'échelle d'un territoire donné

Les cadres d'analyse expérimental puis simulatoire mis en place dans cette thèse nous ont permis d'évaluer la sensibilité des performances d'un modèle MA unique pour la France lorsque l'on souhaite prédire des précipitations agrégées sur des territoires de plus en plus vastes. Les expériences effectuées ont permis de retrouver les résultats de Gangopadhyay et al. [2005] et Mezghani & Hingray [2009], *i.e.* les performances de prédiction augmentent avec le niveau d'agrégation spatiale. L'agrégation permet de faire ressortir le signal pluviométrique régional lié à la grande échelle, en lissant les bruits résultant de réponses pluviométriques plus locales. Nos expériences ont permis aussi de compléter les résultats obtenus dans ces travaux antérieurs et d'en revisiter la portée. Ainsi :

- La vitesse d'augmentation de la performance avec l'agrégation spatiale est dépendante de la corrélation spatiale des précipitations journalières. La performance augmente plus vite avec l'agrégation quand la corrélation spatiale est faible.
- Lorsqu'un unique lien d'échelle est utilisé pour prédire les précipitations, la performance n'augmente *a priori* pas indéfiniment avec l'agrégation. C'est en particulier le cas lorsque la précipitation agrégée inclut des précipitations locales originaires de processus atmosphériques différents de ceux représentés par la MDES. La performance locale de la MDES pour ces précipitations peut être dégradée. Pour la prédiction de la précipitation agrégée, la performance résulte alors d'un compromis entre l'effet bénéfique de l'agrégation, qui permet de mieux révéler le signal régional des précipitations, et la faible performance de prédiction pour des précipitations locales météorologiquement hétérogènes. L'évolution de la performance avec l'agrégation dépend des poids relatifs de ces deux éléments. On peut penser que l'effet bénéfique de l'agrégation domine souvent pour les premiers niveaux d'agrégation et que ce soit l'inverse pour des niveaux d'agrégation importants. On peut donc s'attendre à un optimum de performance pour une échelle d'agrégation spatiale donnée lorsque l'effet bénéfique de l'agrégation n'arrive plus à dépasser la conséquence néfaste d'une faible performance de prédiction des précipitations voisines.

A partir des résultats issus des deux premières parties de ces travaux de recherche, nous pouvons répondre à quelques contraintes opérationnelles concernant la génération de scénarios de précipitations spatialement cohérents. Dans le cas d'études hydrologiques portant sur des territoires relativement vastes, une faible transposabilité spatiale peut être limitante, et un compromis entre performance locale et transposabilité spatiale devient nécessaire. Dans ce cas, l'utilisation d'un modèle MA basique et moins performant est peut être préférable pour disposer d'une meilleure transposabilité. Si l'on veut privilégier la performance locale, il est sans doute nécessaire, de considérer quatre ou cinq modèles MA pour couvrir le territoire météropolitain. Au vu des résultats obtenus dans cette thèse, chacun de ces modèles pourrait aisément être optimisé et appliqué pour couvrir de grands hydrosystèmes tels que les principaux fleuves français. La cohérence spatiale requise pour les analyses hydrologiques subséquentes à l'échelle des bassins versants serait donc ainsi assurée.

Dans un contexte de prédiction en lien avec le changement climatique, la régionalisation est généralement coûteuse en temps de calcul du fait 1) du grand nombre d'expériences climatiques à considérer et 2) de la longueur importante des périodes de simulation correspondantes. Ensuite, certains phénomènes tels que les sécheresses ont une envergure nationale et nécessitent des scénarios cohérents à l'échelle du territoire. Dans ce cas, une plus faible performance de prédiction locale peut être vrai-

semblablement tolérée, de façon à pouvoir utiliser un modèle unique pour la France. La stratégie proposée par [*e.g.* Timbal et al., 2003 ; Boé & Terray, 2008] semble pertinente à cet égard.

3. Possibilité de raffiner la prédiction locale par l'ajout de prédicteurs supplémentaires

Nous avons montré dans l'étude de la transposabilité spatiale qu'un gain apporté par l'ajout d'une seconde variable d'analogie réduit la bonne transposabilité spatiale du modèle MA. Nous nous sommes alors demandés s'il était possible d'augmenter localement les performances du modèle MA tout en conservant sur un vaste territoire la cohérence spatiale des scénarios de précipitations générés. La stratégie que nous proposons est de raffiner la prédiction locale en chacun des sites du territoire visé en mettant à jour la distribution de probabilité des précipitations obtenue avec les scénarios analogues. En pratique la mise à jour s'effectue à l'aide de deux sous-modèles, l'un pour la probabilité d'occurrence des précipitations, l'autre pour la quantité précipitée. Ces deux sous modèles prennent chacun la forme d'une régression linéaire généralisée. Les valeurs des prédictands et des prédicteurs nécessaires à l'établissement des régressions sont extraites des dates analogues retenues par le modèle MA. Pour chacun des prédictands, la mise à jour se fait donc avec un modèle de régression sur noyau, le noyau étant défini par les différentes dates analogues au jour cible visé. L'intérêt de cette approche consiste à pouvoir mettre à jour à la fois la probabilité d'occurrence et la quantité de précipitations par la sélection d'un jeu de prédicteurs adaptés pour chaque prédiction et/ou site cible. Ce modèle MA+GLM nous a permis de mettre en évidence que :

- Pour prédire la probabilité d'occurrence, les variables d'humidité relative et d'occurrence de la veille constituent de bons prédicteurs. L'hélicité et la vitesse verticale se révèlent aussi très informatives pour certains types de situations. Pour la quantité, la vitesse verticale et l'humidité relative se sont révélées être, en moyenne, les meilleurs prédicteurs. L'hélicité et la température sont aussi souvent mobilisées.
- L'adaptation journalière du lien d'échelle semble robuste dans l'espace, que ce soit au niveau des prédicteurs utilisés mais aussi au niveau des coefficients estimés dans les régressions. Ceci se traduit par une organisation spatiale marquée des structures régressives utilisées conditionnée par les reliefs.
- Une augmentation moyenne de la performance égale à 6,5 points de CRPSS est obtenue par le modèle MA+GLM. Elle est supérieure de 3 points à celle obtenue avec un modèle basé sur deux niveaux d'analogie (au regard de la circulation atmosphérique, puis de l'humidité relative). Ceci met en lumière l'intérêt d'un modèle adaptatif dans le temps et dans l'espace.

Quelques perspectives... ?

Certaines questions abordées dans cette thèse n'ont toutefois pas été entièrement explorées et il serait nécessaire de mener des recherches plus approfondies. En particulier :

La génération de scénarios de précipitations spatialement cohérents

- La transposabilité spatiale du modèle MA s'est avérée être sensible à la saison et au type de circulation atmosphérique considéré. Lorsque l'évaluation est conditionnée à la situation atmosphérique, il semblerait que la transposabilité soit sensible à l'origine des flux. Une identification plus robuste du domaine d'analogie (*e.g.* pour un ensemble de mailles Safran réparties sur une région donnée) pourrait peut être permettre de confirmer cette hypothèse.
- La mise en place d'un modèle combiné MA+GLM a permis de montrer qu'il était possible d'accroître localement les performances de prédiction. Dans nos travaux, la distribution prédite des précipitations en chaque maille est mise à jour sur la base de dates analogues optimisées localement. Par conséquent, les aspects de cohérence spatiale des scénarios générés n'ont pas été traités. Un même jeu de dates analogues, optimisées pour la France et assurant ainsi la cohérence spatiale des scénarios générés, pourrait être utilisé pour explorer la capacité d'un modèle MA+GLM à prédire les précipitations en chaque maille. Il serait intéressant d'évaluer si le gain de performance apporté par un modèle MA+GLM permet de compenser la perte de performance induite par un modèle MA unique pour la France. Par ailleurs, l'utilisation d'un même jeu de dates analogues pourrait augmenter la robustesse spatiale des prédicteurs échantillonnés pour la régression linéaire généralisée.
- Sur la base de l'étude publiée [Chardon et al., 2014], un travail similaire pourrait être d'évaluer la perte de performance lorsqu'un modèle MA+GLM, optimisé localement pour la prédiction des précipitations en une maille donnée, est appliqué à l'échelle du territoire français, *i.e.* sa transposabilité spatiale. S'il s'avère que des pertes de performance similaires sont obtenues lorsqu'un modèle MA+GLM et un modèle MA optimisés localement sont transposés, cela indiquerait qu'une même transposabilité spatiale est obtenue pour les modèles MA+GLM et MA, avec potentiellement de meilleures performances pour le modèle MA+GLM.
- La mise en place d'un modèle combiné MA+GLM a permis de montrer qu'il était possible d'accroître localement les performances de prédiction. En revanche, nous n'avons pas eu le temps de traiter les aspects de cohérence spatiale des scénarios générés. La mise en place d'un modèle de régression linéaire généralisée sur la base des dates analogues permet d'émettre une distribution prédictive pour chaque site du territoire. Sur la base de cette dernière, différents scénarios de précipitations locales peuvent être déduits. La mise à jour de la distribution prédictive obtenue avec le modèle combiné ne fournit cependant pas d'information sur les structures de corrélation spatiales entre sites. La génération de champs de précipitations cohérents dans l'espace, permettant de prendre en compte les mises à jour locales des distributions et de produire un scénario spatial réaliste, est un challenge ardu, similaire (si ce n'est plus difficile) à celui de la génération stochastique de champs spatiaux. Il est donc éminemment complexe. Il nécessite probablement d'adjoindre une étape de post-traitement statistique spatial au modèle MA+GLM [*e.g.* Clark

et al., 2004].

Application pour des scénarios futurs

- La transposabilité spatiale des dates analogues a ici été évaluée pour le pas de temps journalier. Pour certaines applications, dont celles liées au changement climatique, il est possible que la résolution journalière ne soit pas la résolution temporelle la plus importante à considérer. On pourrait alors s'interroger sur le comportement de la transposabilité spatiale lorsque le modèle MA est appliqué pour la prédiction de précipitations cumulées sur des pas de temps plus grands, *i.e.* l'échelle mensuelle, saisonnière ou annuelle.
- Nous avons ciblé une partie de nos analyses sur la transposabilité spatiale des dates analogues. Dès lors que le modèle doit être appliqué pour la génération de scénarios futurs se pose aussi la question importante de la transposabilité temporelle du modèle. L'application en climat futur repose en effet sur l'hypothèse que les liens d'échelle identifiés sur les décennies récentes sont toujours valables pour un contexte climatique donné. Ce qui est loin d'être acquis. Evaluer la transposabilité temporelle du modèle utilisé est évidemment une nécessité pour ce type d'analyse. Cette évaluation n'est pas évidente. Elle est souvent effectuée en évaluant la performance du modèle à reproduire les observations sur une période non utilisée pour la calibration du modèle. Cependant, l'évaluation en transposabilité temporelle est souvent polluée par l'hétérogénéité des données observées [Lafaysse, 2011]. Dans ce contexte, une optimisation des domaines d'analogie effectuée sur une sélection d' années échantillonnées de façon systématique (*e.g.* une année sur deux) permettrait de s'affranchir des problèmes liés à l'hétérogénéité des archives [Ben Daoud, 2010]. L'évaluation en transposabilité temporelle est par ailleurs aussi limitée du fait en particulier que le climat de la période d'évaluation est généralement très proche de celui de la période de calibration, beaucoup plus proche en tous les cas que des climats attendus pour les décennies futures. Cette question est définitivement aussi une question importante à explorer par la suite.

Enfin, ces travaux laissent place à de nouvelles perspectives, à savoir :

Des scénarios multivariés pour des échelles continentales ?

- La transposabilité spatiale des dates analogues a été évaluée à l'échelle de la France. Similairement, l'utilisation de ré-analyses couvrant de plus vastes domaines [*e.g.* Maurer et al., 2002, pour l'Amérique du Nord ; Liebmann & Allured, 2005, pour l'Amérique du Sud ; Xie et al., 2007, pour l'Asie ; Haylock et al., 2008, pour l'Europe] permettrait d'évaluer la transposabilité spatiale des dates analogues à l'échelle d'un continent. Les questions qui se posent dans ce contexte sont : si l'on souhaitait générer avec le modèle MA des scénarios spatialement cohérents à l'échelle d'un sous-continent, quel serait la perte de performance locale par rapport à un modèle optimal ? Si cette perte est trop importante, quelle stratégie alternative devrions-nous adopter ?
- L'utilisation des dates analogues permet de satisfaire la cohérence spatiale des scénarios de précipitation, mais aussi leur cohérence physique. Le modèle MA peut alors être appliqué pour la prédiction de plusieurs variables météorologiques locales sur un territoire donné. Une étude

similaire évaluant la transposabilité spatiale des dates analogues pour la prédiction de plusieurs variables pourrait être développée. Dans ce contexte, des travaux de thèse sont actuellement effectués par D. Raynaud (LTHE, 2013–2016) dans le cadre du projet européen COMPLEX – Knowledge Based Climate Mitigation Systems for a Low Carbon Economy [1].

Mieux comprendre les facteurs atmosphériques explicatifs des précipitations

- Le modèle MA+GLM a permis de montrer que certains prédicteurs étaient plus facilement échantillonnés pour certaines situations atmosphériques. Ce modèle pourrait alors être appliqué pour la détermination de prédicteurs clés à l'origine des précipitations observées pour certains évènements spécifiques. Il serait intéressant de voir en quoi les prédicteurs identifiés permettraient de conforter ou d'éclairer les analyses cognitives que l'on pourrait imaginer sur certains types d'évènements particuliers.
- Nous avons montré que certaines combinaisons de prédicteurs étaient plus souvent échantillonnées que d'autres. Ces prédicteurs (*i.e.* la température, l'humidité relative et la vitesse verticale) sont cohérents avec ceux déterminés par les études antérieures [Bontron, 2004 ; Ben Daoud, 2010]. Le rôle joué par d'autres variables explicatives telle que l'hélicité a aussi été mis en évidence pour certaines régions et/ou situations synoptiques. Ces prédicteurs comptent parmi ceux qui ont – sous les contraintes de nos expériences – permis d'obtenir la meilleure performance sur l'ensemble des jours de prédiction. Ils sont donc informatifs pour la majeure partie des prédictions et la plupart des sites considérés. Pour des situations spécifiques et donc moins fréquentes, et/ou des sites isolés, il est fortement envisageable que des prédicteurs "secondaires" soient toutefois très explicatifs. Notre étude n'a cependant pas permis de le mettre en évidence. Cela nécessiterait alors de ne plus travailler à l'échelle globale, mais de zoomer sur ces cas spécifiques, représentant une perspective intéressante d'un point de vue cognitif et opérationnel pour l'augmentation des performances de prédictions.

Vers un modèle de prédiction complètement adaptatif

Les études que nous avons menées dans cette thèse se basent toutes sur un domaine d'analogie optimisé globalement sur la base de l'ensemble des prédictions. Il résulte donc d'un compromis entre l'ensemble des situations synoptiques rencontrées. Or, Wetterhall et al. [2006] montrent que le domaine d'analogie optimal diffère en fonction de la saison considérée. Bontron [2004] observe même qu'un gain de performance peut être obtenu lorsqu'une fenêtre d'analogie est optimisée pour des types de temps préalablement définis. Le domaine d'analogie pourrait alors être optimisé par type de temps. Toutefois, l'inconvénient d'une classification par type de temps concerne les définitions des frontières entre les différentes classes qui sont forcément arbitraires et toujours sujettes à insatisfactions. A l'image de ce que nous avons fait pour le modèle de mise à jour de la prédiction qui s'adapte en fonction de la journée cible, il serait intéressant d'explorer la possibilité d'adapter le domaine d' analogie à la journée cible.

1. www.complex.ac.uk

RÉFÉRENCES BIBLIOGRAPHIQUES

Abaurrea, J. & Asn, J. [**2005**]. "Forecasting local daily precipitation patterns in a climate change scenario". *Climate Research.* Vol. 28. no. 3, p. 183–197. doi : 10.3354/cr028183.

Abdellatif, M., Atherton, W. & Alkhaddar, R. [**2012**]. "Climate change impacts on the extreme rainfall for selected sites in North Western England". *Open Journal of Modern Hydrology.* Vol. 2. no. 3, p. 49–58.

Ailliot, P., Allard, D., Monbet, V. & Naveau, P. [**2014**]. "Stochastic weather generators : an overview of weather type models". *submitted.*

Akaike, H. [**1974**]. "A new look at the statistical model identification". *IEEE Transactions on Automatic Control.* Vol. 19. no. 6, p. 716–723. doi : 10.1109/TAC.1974.1100705.

Beckmann, B.-R. & Buishand, A. T. [**2002**]. "Statistical downscaling relationships for precipitation in the Netherlands and North Germany". *International Journal of Climatology.* Vol. 22. no. 1, p. 15–32. doi : 10.1002/joc.718.

Bedia, J., Herrera, S., Martín, D. S., Koutsias, N. & Gutiérrez, J. M. [**2013**]. "Robust projections of Fire Weather Index in the Mediterranean using statistical downscaling". *Climatic Change.* Vol. 120. no. 1-2, p. 229–247. doi : 10.1007/s10584-013-0787-3.

Ben Daoud, A. [**2010**]. "Améliorations et développements d'une méthode de prévision probabiliste des pluies par analogie. Application à la prévision hydrologique sur les grands bassins fluviaux de la Saône et de la Seine." Thèse de doctorat. Grenoble : Université de Grenoble, p. 340. url : https://tel.archives-ouvertes.fr/tel-00483080.

Ben Daoud, A., Sauquet, E., Lang, M., Obled, C. & Bontron, G. [**2009**]. "Precipitation forecasting through an analog sorting technique : state of the art and further investigations". *Houille Blanche.* Vol. 6, p. 60–65. doi : 10.1051/lhb/2009079.

Ben Daoud, A., Sauquet, E., Lang, M., Bontron, G. & Obled, C. [**2011**]. "Precipitation forecasting through an analog sorting technique : a comparative study". *Advances in Geosciences.* Vol. 29, p. 103–107. doi : 10.5194/adgeo-29-103-2011.

Beuchat, X., Schaefli, B., Soutter, M. & Mermoud, A. [**2012**]. "A robust framework for probabilistic precipitations downscaling from an ensemble of climate predictions applied to Switzerland". *Journal of Geophysical Research : Atmospheres.* Vol. 117. no. D3. doi : 10.1029/2011JD016449.

Beven, K. [**2006**]. "A manifesto for the equifinality thesis". *Journal of Hydrology.* Vol. 320. no. 1, p. 18–36. doi : 10.1016/j.jhydrol.2005.07.007.

Boé, J. & Terray, L. [**2008**]. "A weather-type approach to analyzing winter precipitation in France : Twentieth-century trends and the role of anthropogenic forcing". *Journal of Climate.* Vol. 21. no. 13, p. 3118–3133. doi : 10.1175/2007JCLI1796.1.

Bontron, G. [**2004**]. "Prévision quantitative des précipitations : adaptation probabiliste par recherche d'analogues". Thèse de doctorat. Grenoble : Institut National Polytechnique de Grenoble, p. 262. url : http://www.theses.fr/2004INPG0001.

Bontron, G. & Obled, C. [**2005**]. "A probabilistic adaptation of meteorological model outputs to hydrological forecasting". *Houille Blanche-Revue Internationale de l'Eau.* no. 1, p. 23–28. issn : 0018-6368.

Brier, G. W. [**1950**]. "Verification of forecasts expressed in terms of probability". *Monthly Weather Review.* Vol. 78. no. 1-3. doi : http://dx.doi.org/10.1175/1520-0493(1950)078<0001:VOFEIT>2.0.CO;2.

Bröcker, J. & Smith, L. A. [**2007**]. "Scoring probabilistic forecasts : the importance of being proper". *Weather and Forecasting.* Vol. 22. no. 2, p. 382–388. doi : 10.1175/WAF966.1.

Brown, T. A. [**1974**]. "Admissible scoring systems for continuous distributions". Manuscript P-5235. 1700 Main St., Santa Monica, CA 90407-2138 : The Rand Corporation.

Burger, G. & Chen, Y. [**2005**]. "Regression-based downscaling of spatial variability for hydrologic applications". *Journal of Hydrology.* Vol. 311. no. 1-4, p. 299–317. doi : 10.1016/j.jhydrol.2005.01.025.

Candille, G. & Talagrand, O. [**2005**]. "Evaluation of probabilistic prediction systems for a scalar variable". *Journal of the Royal Meteorological Society.* P. 1–20. doi : 10.1256/qj.04.71.

Cavazos, T. & Hewiston, B. C. [**2005**]. "Performance of NCEP–NCAR reanalysis variables in statistical downscaling of daily precipitation". *Climate Research.* Vol. 28. no. 2. doi : 10.3354/cr028095.

Chardon, J., Hingray, B., Favre, A.-C., Autin, P., Gailhard, J., Zin, I. & Obled, C. [**2014**]. "Spatial similarity and transferability of analog dates for precipitation downscaling over France". *Journal of Climate.* Vol. 27. no. 13, p. 5056–5074. doi : 10.1175/JCLI-D-13-00464.1.

Christensen, J. H. & Christensen, O. B [**2007**]. "A summary of the PRUDENCE model projections of changes in European climate by the end of this century". *Climatic Change.* Vol. 81. no. 1, p. 7–30. doi : 10.1007/s10584-006-9210-7.

Chun, K. P., Wheater, H. S., Nazemi, A. & Khaliq, M. N. [**2013**]. "Precipitation downscaling in Canadian Prairie Provinces using the LARS-WG and GLM approaches". *Canadian Water Resources Journal.* Vol. 38. no. 4, p. 311–332. doi : 10.1080/07011784.2013.830368.

Clark, M. P., Gangopadhyay, S., Brandon, D., Werner, K., Hay, L., Rajagopalan, B. & Yates, D. [**2004**]. "A resampling procedure for generating conditioned daily weather sequences". *Water Resources Research.* Vol. 40. no. 4, W04304. doi : 10.1029/2003WR002747.

Coe, R. & Stern, R. D. [**1982**]. "Fitting models to daily rainfall data". *Journal of Applied Meteorology.* Vol. 21. no. 7, p. 1024–1031. doi : 10.1175/1520-0450(1982)021<1024:FMTDRD>2.0.CO;2.

Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M. A., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A. C. M., Berg, L. van de, Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A. J., Haimberger, L., Healy, S. B., Hersbach, H., Hólm, E. V., Isaksen, L., Kållberg, P., Köhler, M., Matricardi, M., McNally, A. P., Monge-Sanz, B. M., Morcrette, J.-J., Park, B.-K., Peubey, C., Rosnay, P. de, Tavolato, C., Thépaut, J.-N. & Vitart, F. [**2011**]. "The ERA-Interim reanalysis : configuration and performance of the data assimilation system". *Quaterly Journal of the Royal Meteorological Society.* Vol. 137. no. 656, p. 553–597. doi : 10.1002/qj.828.

Doswell, C.A. [**1987**]. "The distinction between large-scale and mesoscale contribution to severe convection : A case study example". *Weather and Forecasting.* Vol. 2. no. 1, p. 3–16. doi : 10.1175/1520-0434(1987)002<0003:TDBLSA>2.0.CO;2.

Duband, D. [**1970**]. "Reconnaissance dynamique de la forme des situations météorologiques. Application à la prévision quantitative des précipitations." Thèse de doctorat. Faculté des sciences de Paris.

Dubrovský, M. [**1997**]. "Creating daily weather series with use of the weather generator". *Environmetrics.* Vol. 8. no. 5, p. 409–424. doi : 10.1002/(SICI)1099-095X(199709/10)8:5<409::AID-ENV261>3.0.CO;2-0.

Durand, Y. & Brun, E. [**1993**]. "A meteorological estimation of relevant parameters for snow models". *Annals of Glaciology.* Vol. 18, p. 65–71.

Durand, Y., Laternser, M., Giraud, G., Etchevers, P., Lesaffre, B. & Mérindol, L. [**2009**]. "Reanalysis of 44 Yr of climate in the French Alps (1958–2002) : Methodology, model validation, climatology, and trends for air temperature and precipitation". *Journal of Applied Meteorology and Climatology.* Vol. 48. no. 3, p. 429–449. doi : 10.1175/2008JAMC1808.1.

Evin, G. & Favre, A.-C. [**2013**]. "Further developments of a transient Poisson-cluster model for rainfall". *Stochastic Environmental Research and Risk Assessment.* Vol. 27. no. 4, p. 831–847. doi : 10.1007/s00477-012-0612-y.

Fernandez, J. & Saenz, J. [**2003**]. "Improved field reconstruction with the analog method : searching the CCA space". *Climate Research.* Vol. 24. no. 3, p. 199–213. doi : 10.3354/cr024199.

Fowler, H. J., Blenkinsop, S. & Tebaldi, C. [**2007**]. "Linking climate change modelling to impacts studies : recent advances in downscaling techniques for hydrological modelling". *International Journal of Climatology.* Vol. 27. no. 12, p. 1547–1578. doi : 10.1002/joc.1556.

Frei, C., Christensen, J. H., Deque, M., Jacob, D., Jones, R. G. & Vidale, P. L. [**2003**]. "Daily precipitation statistics in regional climate models : Evaluation and intercomparison for the European Alps". *Journal of Geophysical Research.* Vol. 108. no. D3, p. 4124. doi : 10.1029/2002JD002287.

Frost, A. J., Charles, S. P., Timbal, B., Chiew, F. H. S., Mehrotra, R., Nguyen, K. C., Chandler, R. E., McGregor, J. L., Fu, G., Kirono, D. G. C., Fernandez, E. & Kent, D. M. [**2011**]. "A comparison of multi-site daily rainfall downscaling techniques under Australian conditions". *Journal of Hydrology.* Vol. 408. no. 1-2, p. 1–18. doi : 10.1016/j.jhydrol.2011.06.021.

Gandin, L. S. [**1965**]. "Objective analysis of meteorological fields".

Gangopadhyay, S., Clark, M., Werner, K., Brandon, D. & Rajagopalan, B. [**2004**]. "Effects of spatial and temporal aggregation on the accuracy of statistically downscaled precipitation estimates in the upper Colorado River basin". *Journal of Hydrometeorology.* Vol. 5. no. 6, p. 1192–1206. doi : 10.1175/JHM-391.1.

Gangopadhyay, S., Clark, M. & Rajagopalan, B. [**2005**]. "Statistical downscaling using K-nearest neighbors". *Water Resources Research.* Vol. 41. no. 2. doi : 10.1029/2004WR003444.

Garavaglia, F., Gailhard, J., Paquet, E., Lang, M., Garçon, R. & Bernardara, P. [**2010**]. "Introducing a rainfall compound distribution model based on weather patterns sub-sampling". *Hydrology and Earth System Sciences.* Vol. 14. no. 6, p. 951–964. doi : 10.5194/hess-14-951-2010.

Giorgi, F. & Mearns, L. O. [**1991**]. "Approaches to the simulation of regional climate change - A review". *Reviews of Geophysics.* Vol. 29. no. 2, 191–216. doi : 10.1029/90RG02636.

Gneiting, T. & Raftery, A. E. [**2007**]. "Strictly proper scoring rules, prediction, and estimation". *Journal of the American Statistical Association.* Vol. 102. no. 477, p. 359–378. doi : 10.1198/016214506000001437.

Gneiting, T., Raftery, A. E., Westveld, A. H. & Goldman, T. [**2005**]. "Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation". *Monthly Weather Review.* Vol. 133. no. 5, p. 1098–1118. doi : doi:10.1175/MWR2904.1.

Godart, A. [**2009**]. "Les précipitations orographiques organisées en bandes dans la région Cévennes-Vivarais. Caractérisation et contribution au régime pluviométrique". Thèse de doctorat. Université Joseph-Fourier, p. 336. url : https://tel.archives-ouvertes.fr/tel-00431254.

Guilbaud, S. [**1997**]. "Prévision quantitative des précipitations journalières par une méthode statistico-dynamique de recherche d'analogues - Application à des bassins du Pourtour Méditerranéen". Thèse de doctorat. Grenoble : Institut National Polytechnique de Grenoble, p. 386. url : http://www.theses.fr/1997INPG0134.

Hannachi, A., Jolliffe, I. T. & Stephenson, D. B. [**2007**]. "Empirical orthogonal functions and related techniques in atmospheric science : A review". *International Journal of Climatology.* Vol. 27. no. 9, p. 1119–1152. doi : 10.1002/joc.1499.

Haylock, M. R, Hofstra, N., Tank, A. M. G. Klein, Klok, E. J, Jones, P. D & New, M. [**2008**]. "A European daily high-resolution gridded data set of surface temperature and precipitation for 1950-2006". *Journal of Geophysical Research-Atmospheres.* Vol. 113. no. D20. doi : 10.1029/2008JD010201.

Hersbach, H. [**2000**]. "Decomposition of the Continuous Ranked Probability Score for ensemble prediction systems". *Weather and Forecasting.* Vol. 15. no. 5, p. 559–570.

Hertig, E., Seubert, S., Paxian, A., Vogt, G., Paeth, H. & Jacobeit, J. [**2013**]. "Statistical modelling of extreme precipitation indices for the Mediterranean area under future climate change". *International Journal of Climatology.* P. 1132–1156. doi : 10.1002/joc.3751.

Hewitson, B. & Crane, R. [**1996**]. "Climate downscaling : techniques and application". *Climate Research.* Vol. 07. no. 2, p. 85–95. doi : 10.3354/cr007085.

Hingray, B. & Saïd, M. [**2014**]. "Partitioning internal variability and model uncertainty components in a multimember multimodel ensemble of climate projections". *Journal of Climate.* Vol. 27. no. 17, p. 6779–6798. doi : 10.1175/JCLI-D-13-00629.1.

Hingray, B., Picouet, C. & Musy, A. [**2009**]. "Hydrologie 2 - Une science pour l'ingénieur". PPUR Presses Polytechniques et Universitaires Romandes, p. 600. isbn : 9782880747985.

Hingray, B., Hendrickx, F., Bourqui, M., Creutin, J.-D., François, B., Gailhard, J., Lafaysse, M., Lemoine, N., Mathevet, T., Mezghani, A. & Monteil, C. [**2013**]. "RIWER2030 : Climats régionaux et incertitudes, ressource en eau et gestion associée de 1860 à 2100". Projet ANR VMCS 2009-2012 - Rapport Final, 60p. + Annexes.

Horton, P. [**2012**]. "Improvements and global optimization of the analogue method for statistical precipitations forecasting." Thèse de doctorat. Lausanne : Université de Lausanne, Faculté des géosciences et de l'environnement. url : `http://www3.unil.ch/wpmu/risk/pascal-horton-improvements-and-global-optimization-of-the-analogue-method-for-statistical-precipitations-forecasting/`.

Huth, R. [**1999**]. "Statistical downscaling in central Europe : evaluation of methods and potential predictors". *Climate Research*. Vol. 13. no. 2, p. 91–101. doi : `10.3354/cr013091`.

Ibarra-Berastegi, G., Saénz, J., Ezcurra, A., Elías, A., Argandoña, J. Diaz & Errasti, I. [**2011**]. "Downscaling of surface moisture flux and precipitation in the Ebro Valley (Spain) using analogues and analogues followed by random forests and multiple linear regression". *Hydrology and Earth System Sciences*. Vol. 15. no. 6, p. 1895–1907. doi : `10.5194/hess-15-1895-2011`.

Imbert, A. & Benestad, R. E. [**2005**]. "An improvement of analog model strategy for more reliable local climate change scenarios". *Theoretical and Applied Climatology*. Vol. 82. no. 3-4, p. 245–255.

Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O. B., Bouwer, L. M., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsmann, A., Martin, E., Meijgaard, E., Moseley, C., Pfeifer, S., Preuschmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.-F., Teichmann, C., Valentini, R., Vautard, R., Weber, B. & Yiou, P. [**2014**]. "EURO-CORDEX : new high-resolution climate change projections for European impact research". *Regional Environmental Change*. Vol. 14. no. 2, p. 563–578. doi : `10.1007/s10113-013-0499-2`.

Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K. C., Ropelewski, C., Wang, J., Leetmaa, A., Reynolds, R., Jenne, R. & Joseph, D. [**1996**]. "The NCEP/NCAR 40-year reanalysis project". *Bulletin of the American Meteorological Society*. Vol. 77. no. 3, p. 437–471. doi : `10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2`.

Karl, T. R., Wang, W.-C., Schlesinger, M. E., Knight, R. W. & Portman, D. [**1990**]. "A method of relating General Circulation Model simulated climate to the observed local climate. Part I : Seasonal Statistics". *Journal of Climate*. Vol. 3. no. 10, p. 1053–1079. doi : `10.1175/1520-0442(1990)003<1053:AMORGC>2.0.CO;2`.

Keller, D. E., Fischer, A. M., Frei, C., Liniger, M. A., Appenzeller, C. & Knutti, R. [**2014**]. "Stochastic modelling of spatially and temporally consistent daily precipitation time-series over complex topography". *Hydrology and Earth System Sciences Discussion*. Vol. 11. no. 7, p. 8737–8777. doi : `10.5194/hessd-11-8737-2014`.

Kenabatho, P. K., McIntyre, N. R., Chandler, R. E. & Wheater, H. S. [**2012**]. "Stochastic simulation of rainfall in the semi-arid Limpopo basin, Botswana". *International Journal of Climatology*. Vol. 32. no. 7, p. 1113–1127. doi : `10.1002/joc.2323`.

Kirshbaum, D. J. & Durran, D. R. [**2005**]. "Atmospheric factors governing banded orographic convection". *Journal of the Atmospheric Sciences*. Vol. 62. no. 10, p. 3758–3774. doi : `10.1175/JAS3568.1`.

Lafaysse, M. [**2011**]. "Changement climatique et régime hydrologique d'un bassin alpin. Génération de scénarios sur la Haute-Durance, méthodologie d'évaluation et incertitudes associées". Thèse de doctorat. Université de Toulouse, Université Toulouse III - Paul Sabatier, p. 311. url : `http://thesesups.ups-tlse.fr/1679/`.

Lafaysse, M., Hingray, B., Mezghani, A., Gailhard, J. & Terray, L. [**2014**]. "Internal variability and model uncertainty components in future hydrometeorological projections : The Alpine Durance basin". *Water Resources Research.* Vol. 50. no. 4, p. 3317–3341. doi : 10.1002/2013WR014897.

Lall, U. & Sharma, A. [**1996**]. "A nearest neighbor bootstrap for resampling hydrologic time series". *Water Resources Research.* Vol. 32. no. 3, p. 679–693. doi : 10.1029/95WR02966.

Liebmann, B. & Allured, D. [**2005**]. "Daily precipitation grids for South America". *Bulletin of the American Meteorological Society.* Vol. 86. no. 11, p. 1567–1570. doi : 10.1175/BAMS-86-1567.

Lorenz, E. N. [**1969**]. "Atmospheric predictability as revealed naturaally occuring analogues". *Journal of the Atmospheric Sciences.* Vol. 26. no. 4, p. 636–646. doi : 10.1175/1520-0469(1969)26<636:APARBN>2.0.CO;2.

Malardel, S. [**2005**]. "Fondamentaux de Météorologie". Cépaduès. Toulouse. isbn : 2.85428.631.6.

Maraun, D., Wetterhall, F., Ireson, A. M., Chandler, R. E., Kendon, E. J., Widmann, M., Brienen, S., Rust, H. W., Sauter, T., Themessl, M., Venema, V. K. C., Chun, K. P., Goodess, C. M., Jones, R. G., 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.* Vol. 48,RG3003. doi : 201010.1029/2009RG000314.

Marty, R. [**2010**]. "Prévision hydrologique d'ensemble adaptée aux bassins à crue rapide". Thèse de doctorat. Grenoble : Université de Grenoble, p. 327. url : https://tel.archives-ouvertes.fr/tel-00480713/.

Marty, R., Zin, I., Obled, C., Bontron, G. & Djerboua, A. [**2012**]. "Toward real-time daily PQPF by an analog sorting approach : Application to flash-flood catchments". *Journal of Applied Meteorology and Climatology.* Vol. 51. no. 3, p. 505–520. doi : 10.1175/JAMC-D-11-011.1.

Mathes, A., Friederichs, P. & Hense, A. [**2008**]. "Towards a quality control of precipitation data". *Meteorologische Zeitschrift.* Vol. 17. no. 6, p. 733–749. doi : 10.1127/0941-2948/2008/0347.

Matheson, J. E. & Winkler, R. L. [**1976**]. "Scoring rules for continuous probability distributions". *Management Science.* Vol. 22. no. 10, p. 1087–1096. doi : 10.1287/mnsc.22.10.1087.

Maurer, E. P., Wood, A. W., Adam, J. C., Lettenmaier, D. P. & Nijssen, B. [**2002**]. "A long-term hydrologically based dataset of land surface fluxes and states for the conterminous United States". *Journal of Climate.* Vol. 15. no. 22, p. 3237–3251. doi : 10.1175/1520-0442(2002)015<3237:ALTHBD>2.0.CO;2.

McCullagh, P. & Nelder, J. A. [**1989**]. "Generalized Linear Models, Second Edition". Boca Raton : Chapman & Hall/CRC. isbn : 9780412317606.

Mezghani, A. [**2009**]. "Génération multi-sites de variables météorologiques horaires en zone alpine. Application à la simulation de scénarios de crues du Rhône supérieur suisse." Thèse de doctorat. Lausanne : Ecole Polytechnique Fédérale de Lausanne, p. 186. url : http://doc.rero.ch/record/12178?ln=fr.

Mezghani, A. & Hingray, B. [**2009**]. "A combined downscaling-disaggregation weather generator for stochastic generation of multisite hourly weather variables over complex terrain : development and multi-sacle validation for the Upper Rhone River basin". *Journal of Hydrology.* Vol. 377. no. 3-4, p. 245–260.

Mezghani, A., Hingray, B. & Lafaysse, M. [**2012**]. "Atmospheric predictors for daily precipitation prediction over France". 25ème Colloque de l'Association Internationale de Climatologie, Grenoble, Fr.. Vol. 14.

Moss, R. H., Edmonds, J. A., Hibbard, K. A., Manning, M. R., Rose, S. K., van Vuuren, D. P., Carter, T. R., Emori, S., Kainuma, M., Kram, T., Meehl, G. A., Mitchell, J. F. B., Nakicenovic, N., Riahi, K., Smith, S. J., Stouffer, R. J., Thomson, A. M., Weyant, J. P. & Wilbanks, T. J. [**2010**]. "The next generation of scenarios for climate change research and assessment". *Nature.* Vol. 463. no. 7282, p. 747–756. doi : 10.1038/nature08823.

Murphy, A. H. [**1973**]. "A new vector partition of the probability score". *Journal of Applied Meteorology and Climatology.* Vol. 12, p. 595–600. doi : 10.1175/1520-0450(1973)012<0595:ANVPOT>2.0.CO;2.

Murphy, A. H. [**1986**]. "A new decomposition of the Brier score : Formulation and interpretation". *Monthly Weather Review.* Vol. 114. no. 12, p. 2671–2673. doi : 10.1175/1520-0493(1986)114<2671:ANDOTB>2.0.CO;2.

Myoung, B. & Nielsen-Gammon, J. W. [**2010**]. "Sensitivity of monthly convective precipitation to environmental conditions". *Journal of Climate.* Vol. 23. no. 1, p. 166–188. doi : 10.1175/2009JCLI2792.1.

Nelder, J. A. & Wedderburn, R. W. M. [**1972**]. "Generalized Linear Models". *Journal of the Royal Statistical Society. Series A (General).* Vol. 135. no. 3, p. 370–384.

Obled, C., Bontron, G. & Garçon, R. [**2003**]. "Quantitative precipitation forecasts : a statistical adaptation of model outputs through an analogues sorting approach". *Atmospheric Research.* Vol. 63. no. 3-4, p. 303–324. doi : 10.1016/S0169-8095(02)00038-8.

Olsson, J., Uvo, C. B. & Jinno, K. [**2001**]. "Statistical atmospheric downscaling of short-term extreme rainfall by neural networks". *Physics and Chemistry of the Earth, Part B : Hydrology, Oceans and Atmosphere.* Vol. 26. no. 9, p. 695–700. doi : 10.1016/S1464-1909(01)00071-5.

Page, C., Terray, L. & Boe, J. [**2009**]. "DSCLIM : A software to downscale climate scenarios at regional scale using a weather-typing based statistical methodology". Rap. tech. CERFACS.

Preisendorfer, R. W. & Mobley, C. D. [**1988**]. "Principal component analysis in meteorology and oceanography". Elsevier. isbn : 9780444430144.

Quintana-Segui, P., Moigne, P. Le, Durand, Y., Martin, E., Habets, F., Baillon, M., Canellas, C., Franchisteguy, L. & Morel, S. [**2008**]. "Analysis of near-surface atmospheric variables : Validation of the SAFRAN analysis over France". *Journal of Applied Meteorology and Climatology.* Vol. 47, p. 92–107. doi : 10.1175/2007JAMC1636.1.

Radanovics, S., Vidal, J.-P., Sauquet, E., Ben Daoud, A. & Bontron, G. [**2013**]. "Optimising predictor domains for spatially coherent precipitation downscaling". *Hydrology and Earth System Sciences.* Vol. 17. no. 10, p. 4189–4208. doi : 10.5194/hess-17-4189-2013.

Ribalaygua, J., Torres, L., Pórtoles, J., Monjo, R., Gaitán, E. & Pino, M. R. [**2013**]. "Description and validation of a two-step analogue/regression downscaling method". *Theoretical and Applied Climatology.* Vol. 114. no. 1-2, p. 253–269. doi : 10.1007/s00704-013-0836-x.

Richardson, C. W. [**1981**]. "Stochastic simulation of daily precipitation, temperature, and solar radiation". *Water Resources Research.* Vol. 17. no. 1, p. 182–190. doi : 10.1029/WR017i001p00182.

Rudolph, J. V. & Friedrich, K. [**2014**]. "Dynamic and thermodynamic predictors of vertical structure in radar-observed regional precipitation". *Journal of Climate.* Vol. 27. no. 5, p. 2143–2158. doi : 10.1175/JCLI-D-13-00239.1.

Salathe, E. P. [**2003**]. "Comparison of various precipitation downscaling methods for the simulation of streamflow in a rainshadow river basin". *International Journal of Climatology.* Vol. 23. no. 8, p. 887–901. doi : 10.1002/joc.922.

Schoof, J. T., Pryor, S. & Surprenant, J. [**2010**]. "Development of daily precipitation projections for the United States based on probabilistic downscaling". *Journal of Geophysical Research : Atmospheres.* Vol. 115. no. D13. doi : 10.1029/2009JD013030.

Seity, Y., Brousseau, P., Malardel, S., Hello, G., Bénard, P., Bouttier, F., Lac, C. & Masson, V. [**2011**]. "The AROME-France convective-scale operational model". *Monthly Weather Review.* Vol. 139. no. 3, p. 976–991. eprint : 10.1175/2010MWR3425.1.

Showalter, A. K. [**1953**]. "A stability index for thunderstorm forecasting". *Bulletin of the American Meteorological Society.* Vol. 34, p. 250–252.

Stein, C. M. [**1981**]. "Estimation of the mean of a multivariate normal distribution". *The Annals of Statistics.* Vol. 9. no. 6, p. 1135–1151. doi : 10.1214/aos/1176345632.

Stern, R. D. & Coe, R. [**1984**]. "A model fitting analysis of daily rainfall data". *Journal of the Royal Statistical Society. Series A (General).* Vol. 147. no. 1, p. 1. doi : 10.2307/2981736.

Taylor, E. K. [**2001**]. "Summarizing multiple aspects of model performance in a single diagram". *Journal of Geophysical Research.* Vol. 106. no. D7, PP. 7183–7192. doi : 200110.1029/2000JD900719.

Teweless, J. & Wobus, H. [**1954**]. "Verification of prognosis charts". *Bulletin of the American Meteorological Society.* Vol. 35. no. 10, p. 2599–2617.

THÉVENOT, N. [**2004**]. "Prévision quantitative des précipitations : Adaptation par une méthode d'Analogie de la prévision d'ensemble du CEPMMT". Mémoire de Master 2 - recherche. Terre, Univers, Environnement - Océan, Atmosphère, Hydrologie.

TIMBAL, B. & MCAVANEY, B. J. [**2001**]. "An analogue-based method to downscale surface air temperature : application for Australia". *Climate Dynamics.* Vol. 17. no. 12, p. 947–963. doi : 10.1007/s003820100156.

TIMBAL, B., DUFOUR, A. & MCAVANEY, B. [**2003**]. "An estimate of future climate change for western France using a statistical downscaling technique". *Climate Dynamics.* Vol. 20. no. 7-8, p. 807–823. doi : 10.1007/s00382-002-0298-9.

TIMBAL, B., FERNANDEZ, E. & LI, Z. [**2009**]. "Generalization of a statistical downscaling model to provide local climate change projections for Australia". *Environmental Modelling & Software.* Vol. 24. no. 3, p. 341–358. doi : 10.1016/j.envsoft.2008.07.007.

TREMBLAY, V. [**2012**]. "Multicolinéarité et sélection de variables dans un contexte de prévision : application à la prévision du volume de la crue printannière." Rap. tech. Québec : Université Laval.

UPPALA, S. M., KALLBERG, P. W., SIMMONS, A. J., ANDRAE, U., BECHTOLD, V. D., FIORINO, M., GIBSON, J. K., HASELER, J., HERNANDEZ, A., KELLY, G. A., LI, X., ONOGI, K., SAARINEN, S., SOKKA, N., ALLAN, R. P., ANDERSSON, E., ARPE, K., BALMASEDA, M. A., BELJAARS, A. C. M., BERG, L. Van De, BIDLOT, J., BORMANN, N., CAIRES, S., CHEVALLIER, F., DETHOF, A., DRAGOSAVAC, M., FISHER, M., FUENTES, M., HAGEMANN, S., HOLM, E., HOSKINS, B. J., ISAKSEN, L., JANSSEN, PAEM, JENNE, R., MCNALLY, A. P., MAHFOUF, J. F., MORCRETTE, J. J., RAYNER, N. A., SAUNDERS, R. W., SIMON, P., STERL, A., TRENBERTH, K. E., UNTCH, A., VASILJEVIC, D., VITERBO, P. & WOOLLEN, J. [**2005**]. "The ERA-40 re-analysis". *Quaterly Journal of the Royal Meteorological Society.* Vol. 131. no. 612, Part b, p. 2961–3012. doi : 10.1256/qj.04.176.

VAN DER LINDEN, P. & MITCHELL, J. F. B. [**2009**]. "ENSEMBLES : Climate change and its impacts : Summary of research and results from the ENSEMBLES project". Rap. tech. Met Office Hadley Centre, FitzRoy Road, Exeter EX1 3PB, UK., Met Office Hadley Centre, 160pp.

VIDAL, J.-P., MARTIN, E., FRANCHISTEGUY, L., BAILLON, M. & SOUBEYROUX, J.-M. [**2010**]. "A 50-year high-resolution atmospheric reanalysis over France with the Safran system". *International Journal of Climatology.* Vol. 30. no. 11, p. 1627–1644. doi : 10.1002/joc.2003.

VON STORCH, H. [**1999**]. "On the use of 'Inflation' in statistical downscaling". *Journal of Climate.* Vol. 12. no. 12, p. 3505.

VON STORCH, H. & ZWIERS, F. W. [**2001**]. "Statistical analysis in climate research". Cambridge University Press. isbn : 9780521012300.

VRAC, M., MARBAIX, P., PAILLARD, D. & NAVEAU, P. [**2007**]. "Non-linear statistical downscaling of present and LGM precipitation and temperatures over Europe". *Climate of the Past.* Vol. 3. no. 4, p. 669–682. doi : 10.5194/cp-3-669-2007.

WETTERHALL, F., HALLDIN, S. & XU, C.-Y. [**2005**]. "Statistical precipitation downscaling in central Sweden with the analogue method". *Journal of Hydrology.* Vol. 306. no. 1-4, p. 174 –190. doi : 10.1016/j.jhydrol.2004.09.008.

WETTERHALL, F., BÁRDOSSY, A., CHEN, D., HALLDIN, S. & XU, C-Y. [**2006**]. "Daily precipitation-downscaling techniques in three Chinese regions". *Water Resources Research.* Vol. 42. no. 11. doi : 10.1029/2005WR004573.

WILBY, R. L. & WIGLEY, T. M. L. [**2000**]. "Precipitation predictors for downscaling : Observed and general circulation model relationships". *International Journal of Climatology.* Vol. 20. no. 6, p. 641–661. doi : 10.1002/(SICI)1097-0088(200005)20:6<641::AID-JOC501>3.0.CO;2-1.

WILBY, R. L., HAY, L. E. & LEAVESLEY, G. H. [**1999**]. "A comparison of downscaled and raw GCM output : implications for climate change scenarios in the San Juan River basin, Colorado". *Journal of Hydrology.* Vol. 225. no. 1-2, p. 67–91. doi : 10.1016/S0022-1694(99)00136-5.

Wilby, R. L., Tomlinson, O. J. & Dawson, C. W. [**2003**]. "Multi-site simulation of precipitation by conditional resampling". *Climate Research.* Vol. 23. no. 3, p. 183–194.

Wilks, D. S. [**2012**]. "Stochastic weather generators for climate-change downscaling, part II : multivariable and spatially coherent multisite downscaling". *Wiley Interdisciplinary Reviews : Climate Change.* Vol. 3. no. 3, p. 267–278. doi : 10.1002/wcc.167.

Wilks, D. S. & Wilby, R. L. [**1999**]. "The weather generation game : a review of stochastic weather models". *Progress in Physical Geography.* Vol. 23. no. 3, p. 329 –357. doi : 10.1177/030913339902300302.

Woodcock, F. [**1980**]. "On the use of Analogs to improve regression forecasts". *Monthly Weather Review.* Vol. 108. no. 3, p. 292–297. doi : 10.1175/1520-0493(1980)108<0292:OTUOAT>2.0.CO;2.

Xie, P., Yatagai, A., Chen, M., Hayasaka, T., Fukushima, Y., Liu, C. & Yang, S. [**2007**]. "A gauge-based analysis of daily precipitation over East Asia". *Journal of Hydrometeorology.* Vol. 8. no. 3, p. 607–626. doi : 10.1175/JHM583.1.

Zalachori, I., Ramos, M.-H., Garçon, R., Mathevet, T. & Gailhard, J. [**2012**]. "Statistical processing of forecasts for hydrological ensemble prediction : a comparative study of different bias correction strategies". *Advances in Science and Research.* Vol. 8, p. 135–141. doi : 10.5194/asr-8-135-2012.

–

ANNEXES

Annexe A

Le modèle Analog de référence

1. Nombre optimal de dates analogues

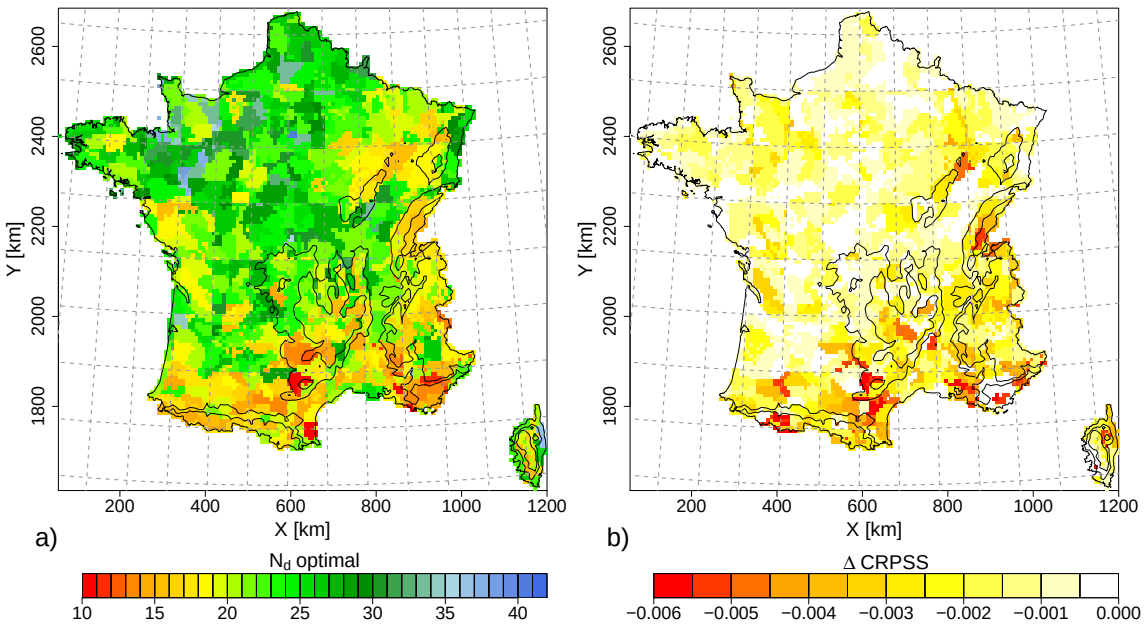

Figure A.1 – a) Nombre de dates analogues optimal à retenir en fonction de la maille Safran considérée pour l'optimisation du modèle MA. b) Perte en CRPSS entre un modèle MA retenant 25 dates analogues et un modèle MA optimal.

La figure A.1.a) représente le nombre de dates analogues optimal pour l'obtention des meilleures performances de prédiction en chaque maille Safran. Pour celles situées sur la partie Nord-Ouest de la France, le nombre de dates analogues optimal est proche de 25. Pour les autres régions telles que le Sud et la partie Est de la France, le nombre de dates analogues optimal varie entre 15 et 25. Dans les travaux de Bontron [2004], ce nombre variait plutôt entre 30 et 35. La différence obtenue

ici pourrait toutefois provenir du fait qu'entre ces deux études, la ré-analyse de grande échelle, les précipitations et le nombre d'analogues candidates (déterminé par la période de calibration et le filtre saisonnier) ne sont pas les mêmes. Par suite, nous avons décidé de retenir un nombre N_d de dates analogues égal à 25, car il s'agit du nombre pour lequel la meilleure performance moyenne en CRPSS est obtenue.

La figure A.1.b) représente la perte de performance entre un modèle Analog localement optimisé retenant 25 dates analogues et le même modèle Analog avec un nombre de dates optimal en chaque maille Safran. Sur cette figure, la perte de performance est au maximum d'un demi point de CRPSS pour une minorité de mailles situées dans le Sud-Est, ce qui est relativement faible.

2. Sensibilité de l'optimisation de la fenêtre d'analogie à une transformation de la variable d'intérêt

La figure A.2 représente le biais obtenu (*cf.* équation III.11) par un modèle MA dont l'optimisation a été effectuée sur la racine carrée des précipitations. La figure A.3 représente ce biais en fonction des saisons.

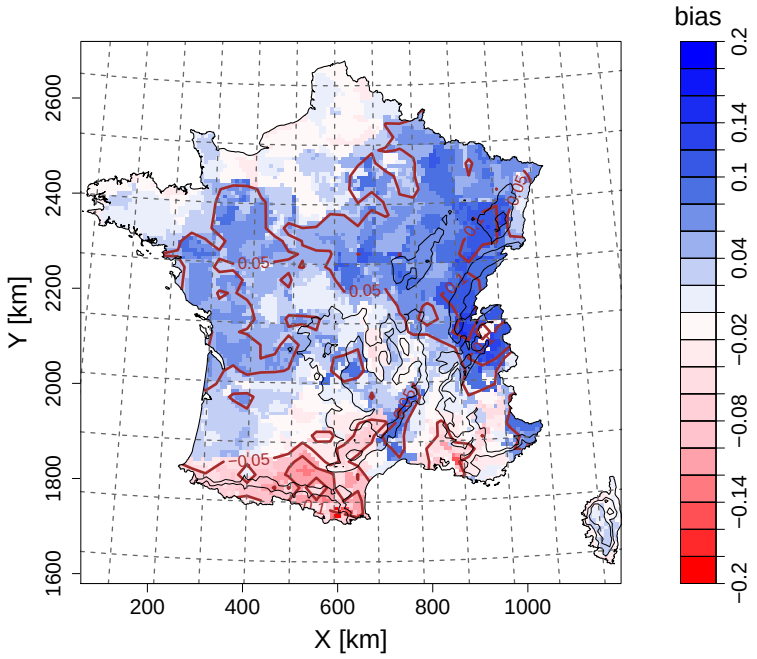

FIGURE A.2 – Biais relatif obtenu lorsque la fenêtre d'analogie des modèles MA est optimisée sur la racine carrée des précipitations.

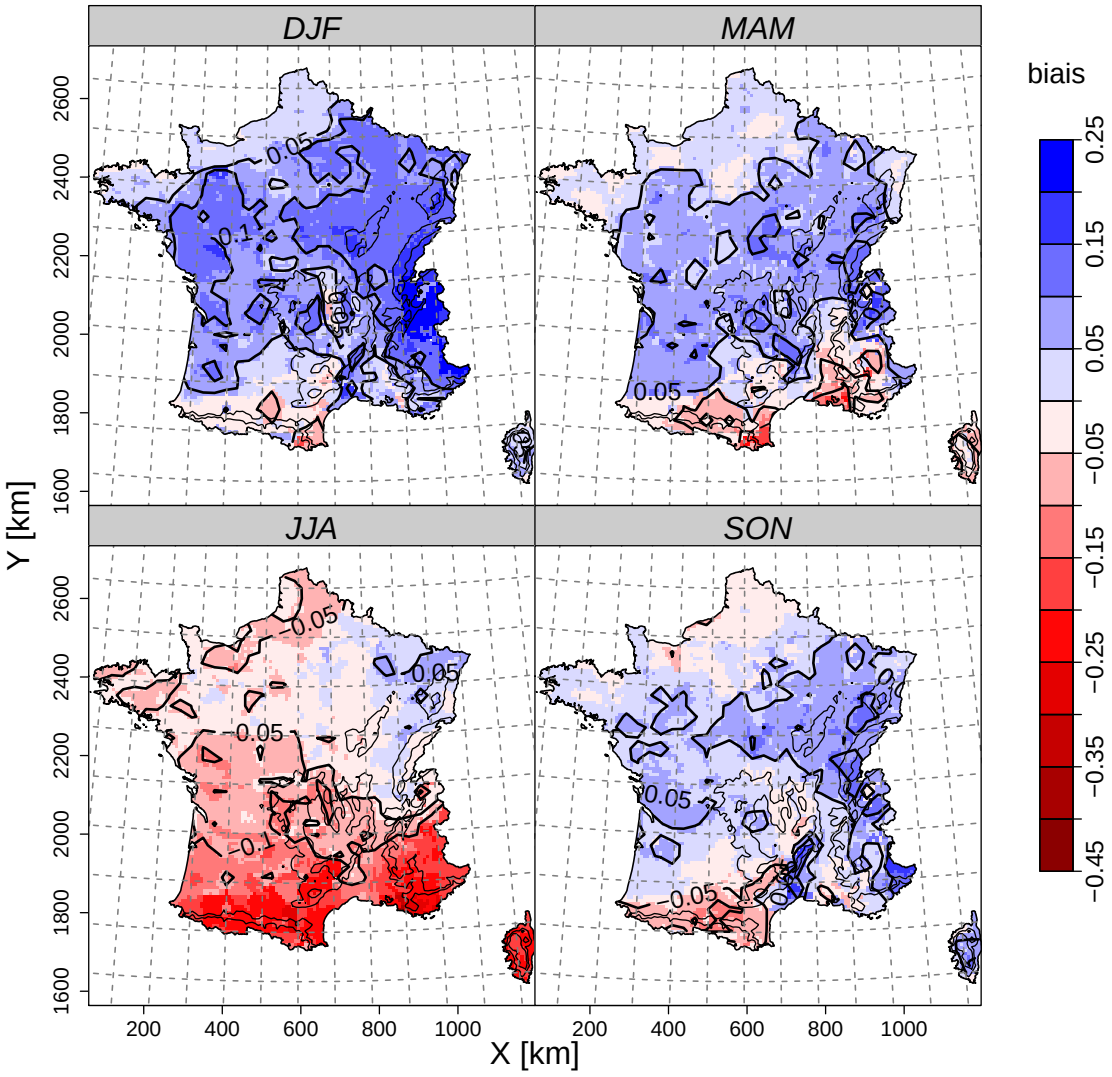

FIGURE A.3 – Biais relatifs saisonniers obtenus lorsque la fenêtre d'analogie des modèles MA est optimisée sur la racine carrée des précipitations.

Annexe B

Transposabilité des dates analogues en fonctions des types de temps

Les figures B.1 à B.8 représente la perte de performance en CRPSS lorsque le modèle MA de chacune des mailles d'accroche (*cf.* figure IV.1) est transposé sur l'ensemble de la France pour les types de temps allant du TT1 au TT8.

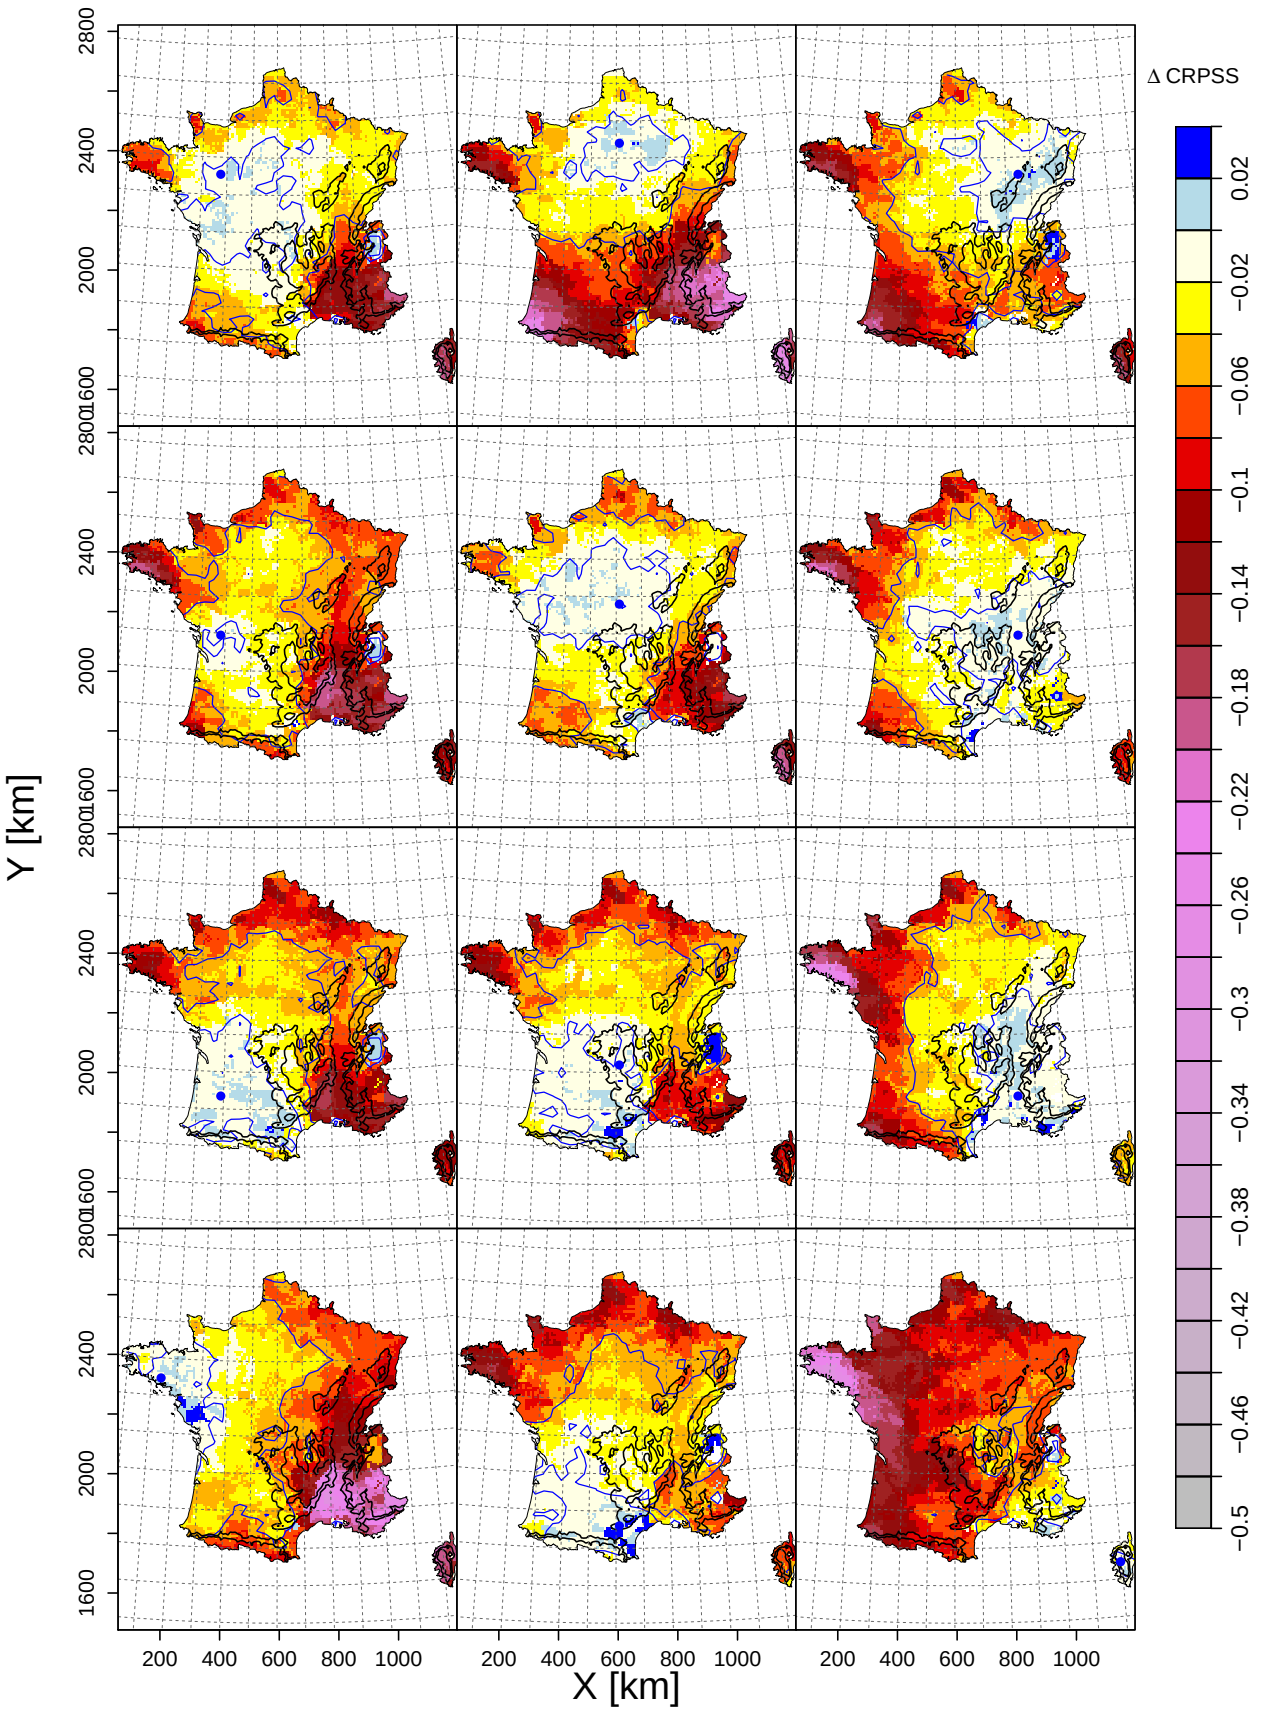

FIGURE B.1 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT1.

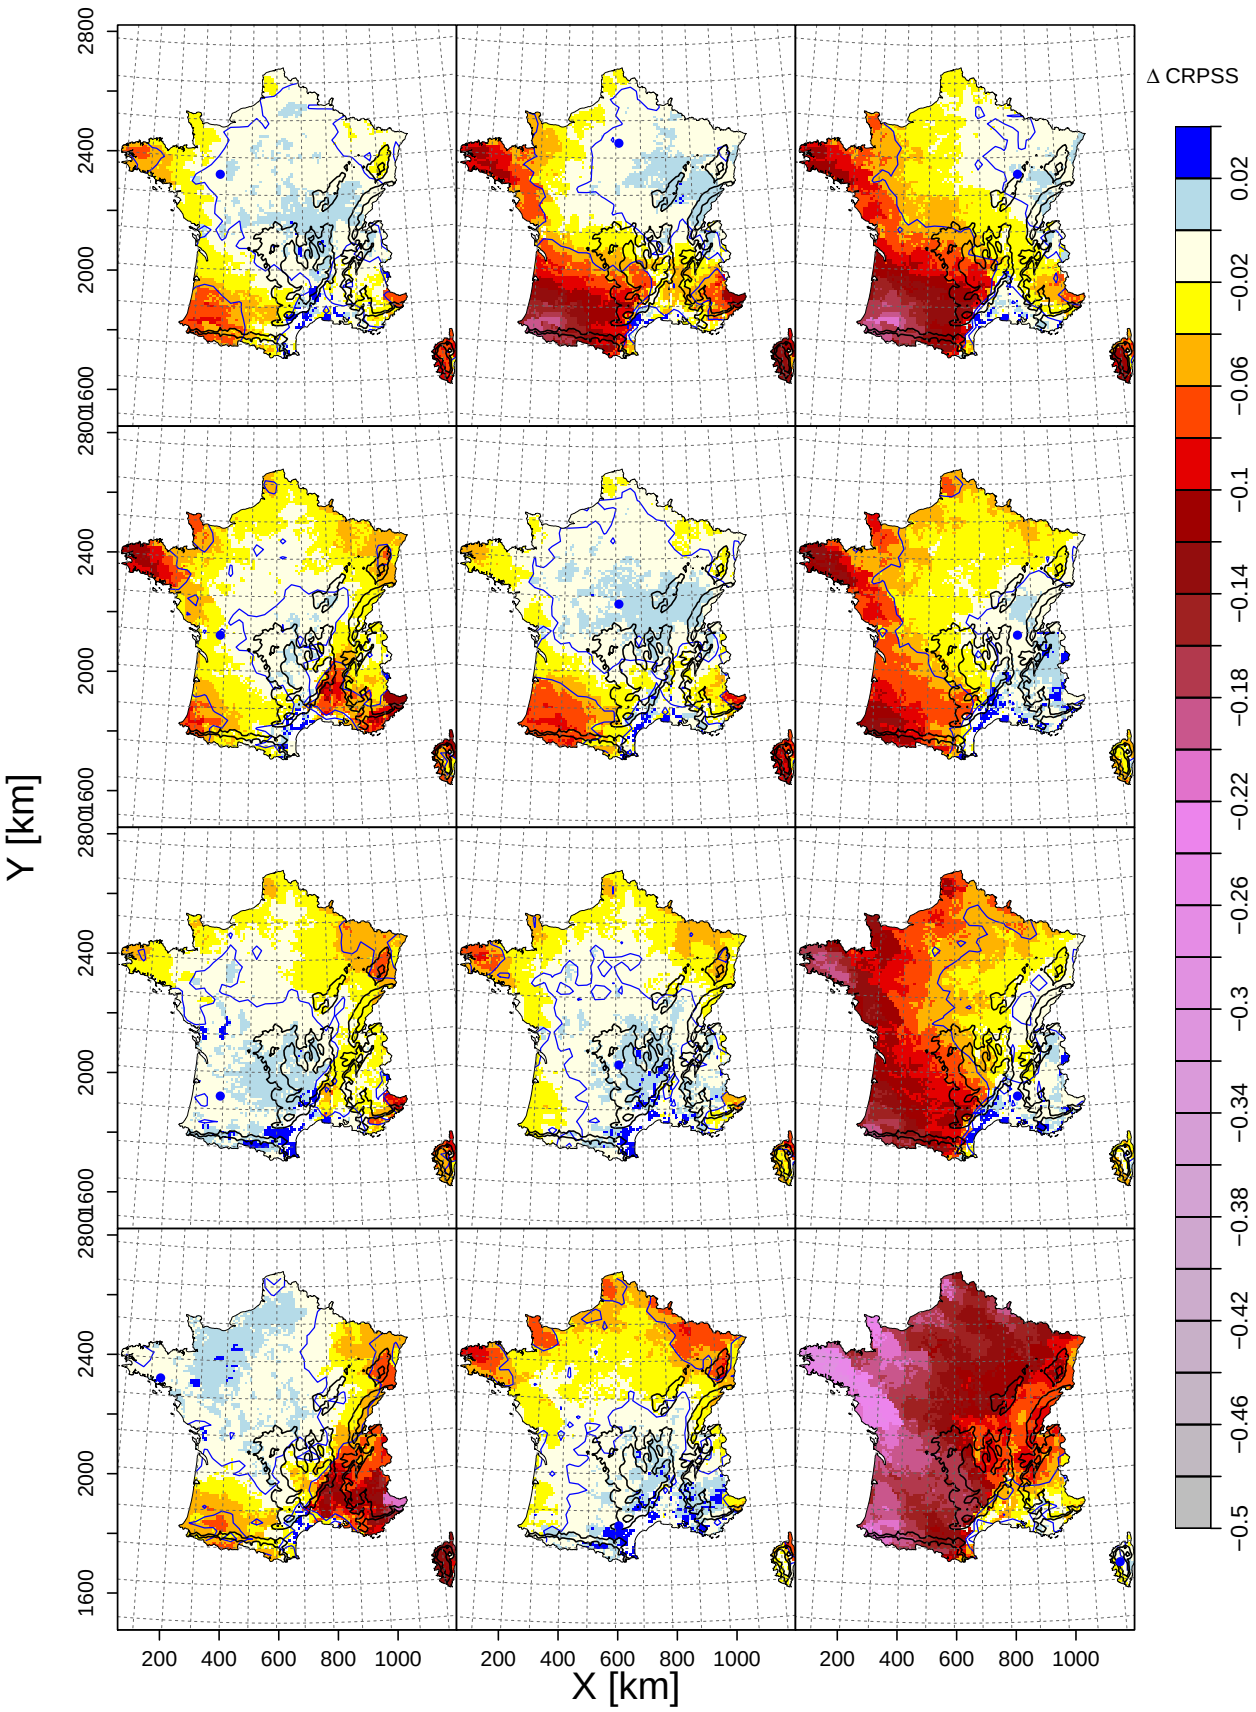

FIGURE B.2 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT2.

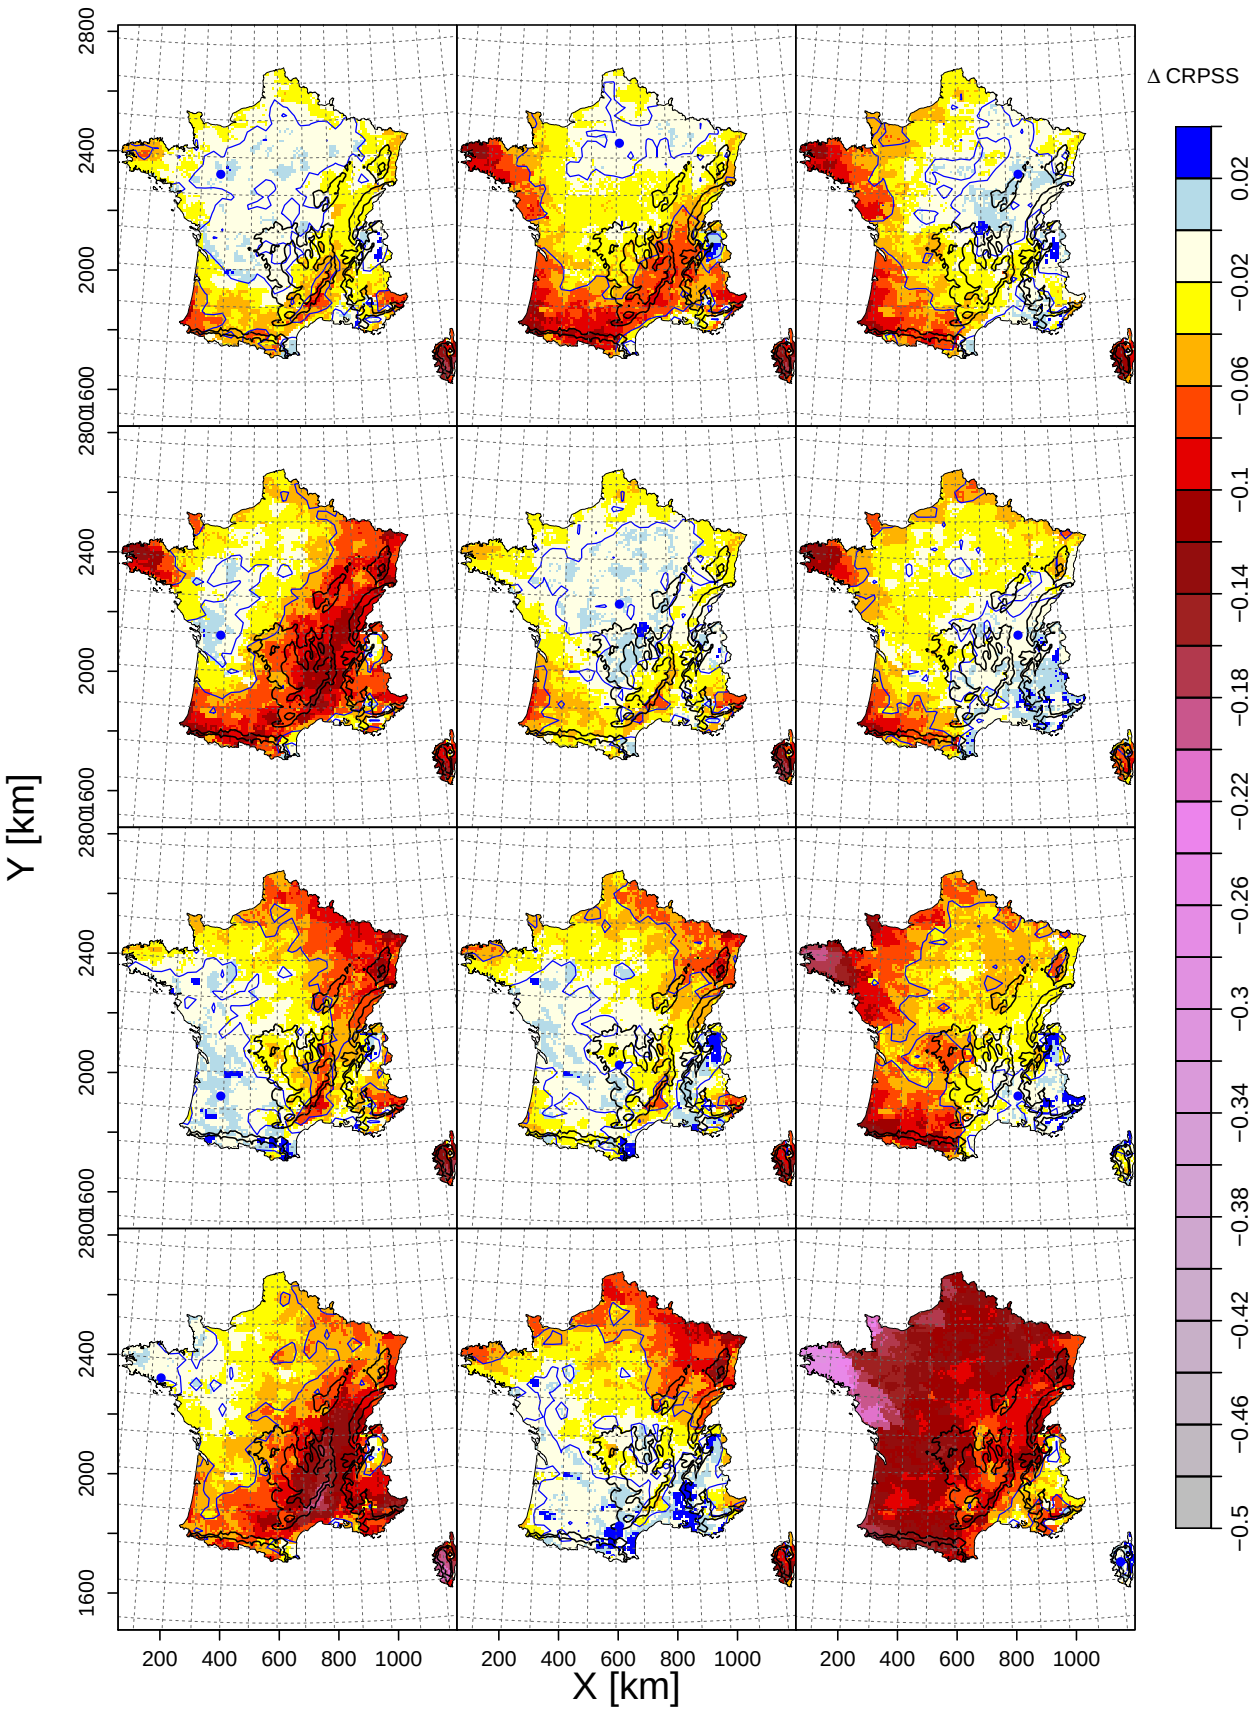

FIGURE B.3 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT3.

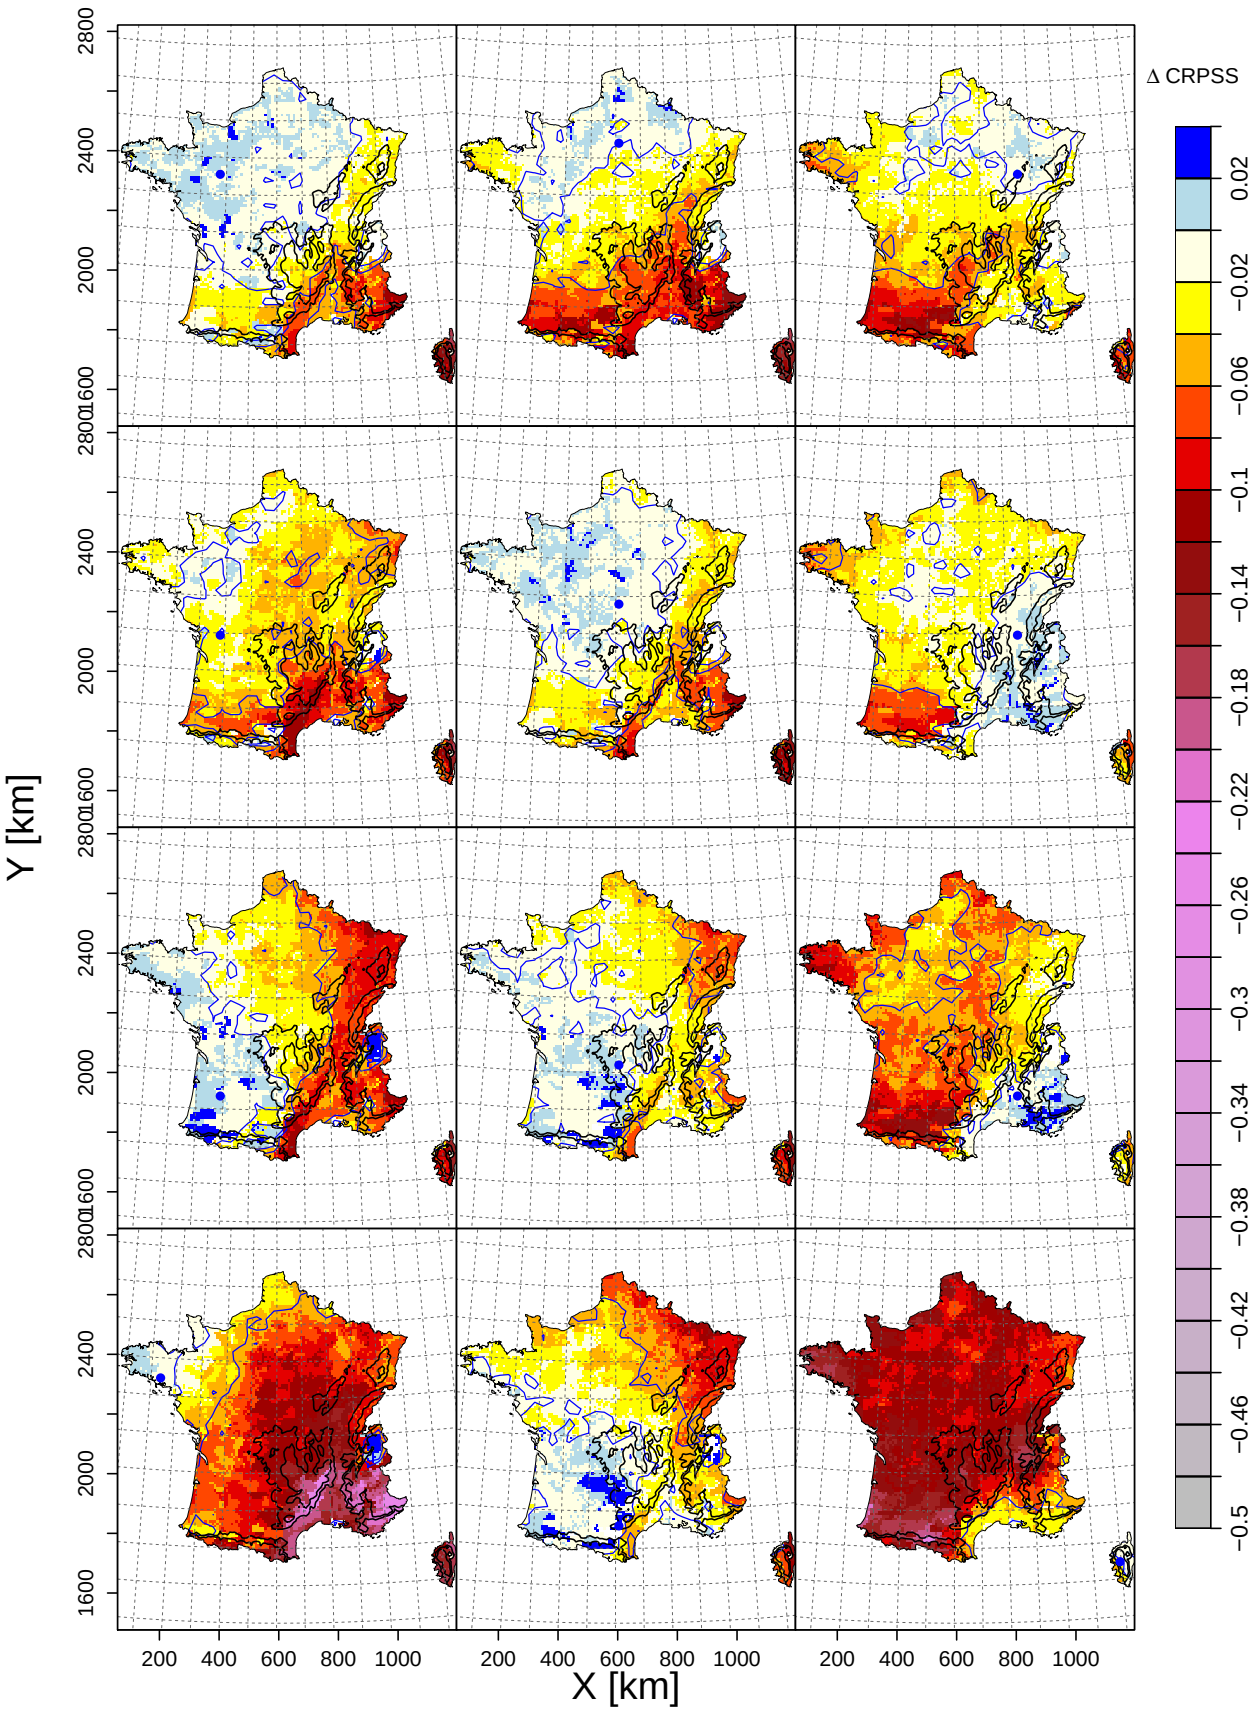

FIGURE B.4 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT4.

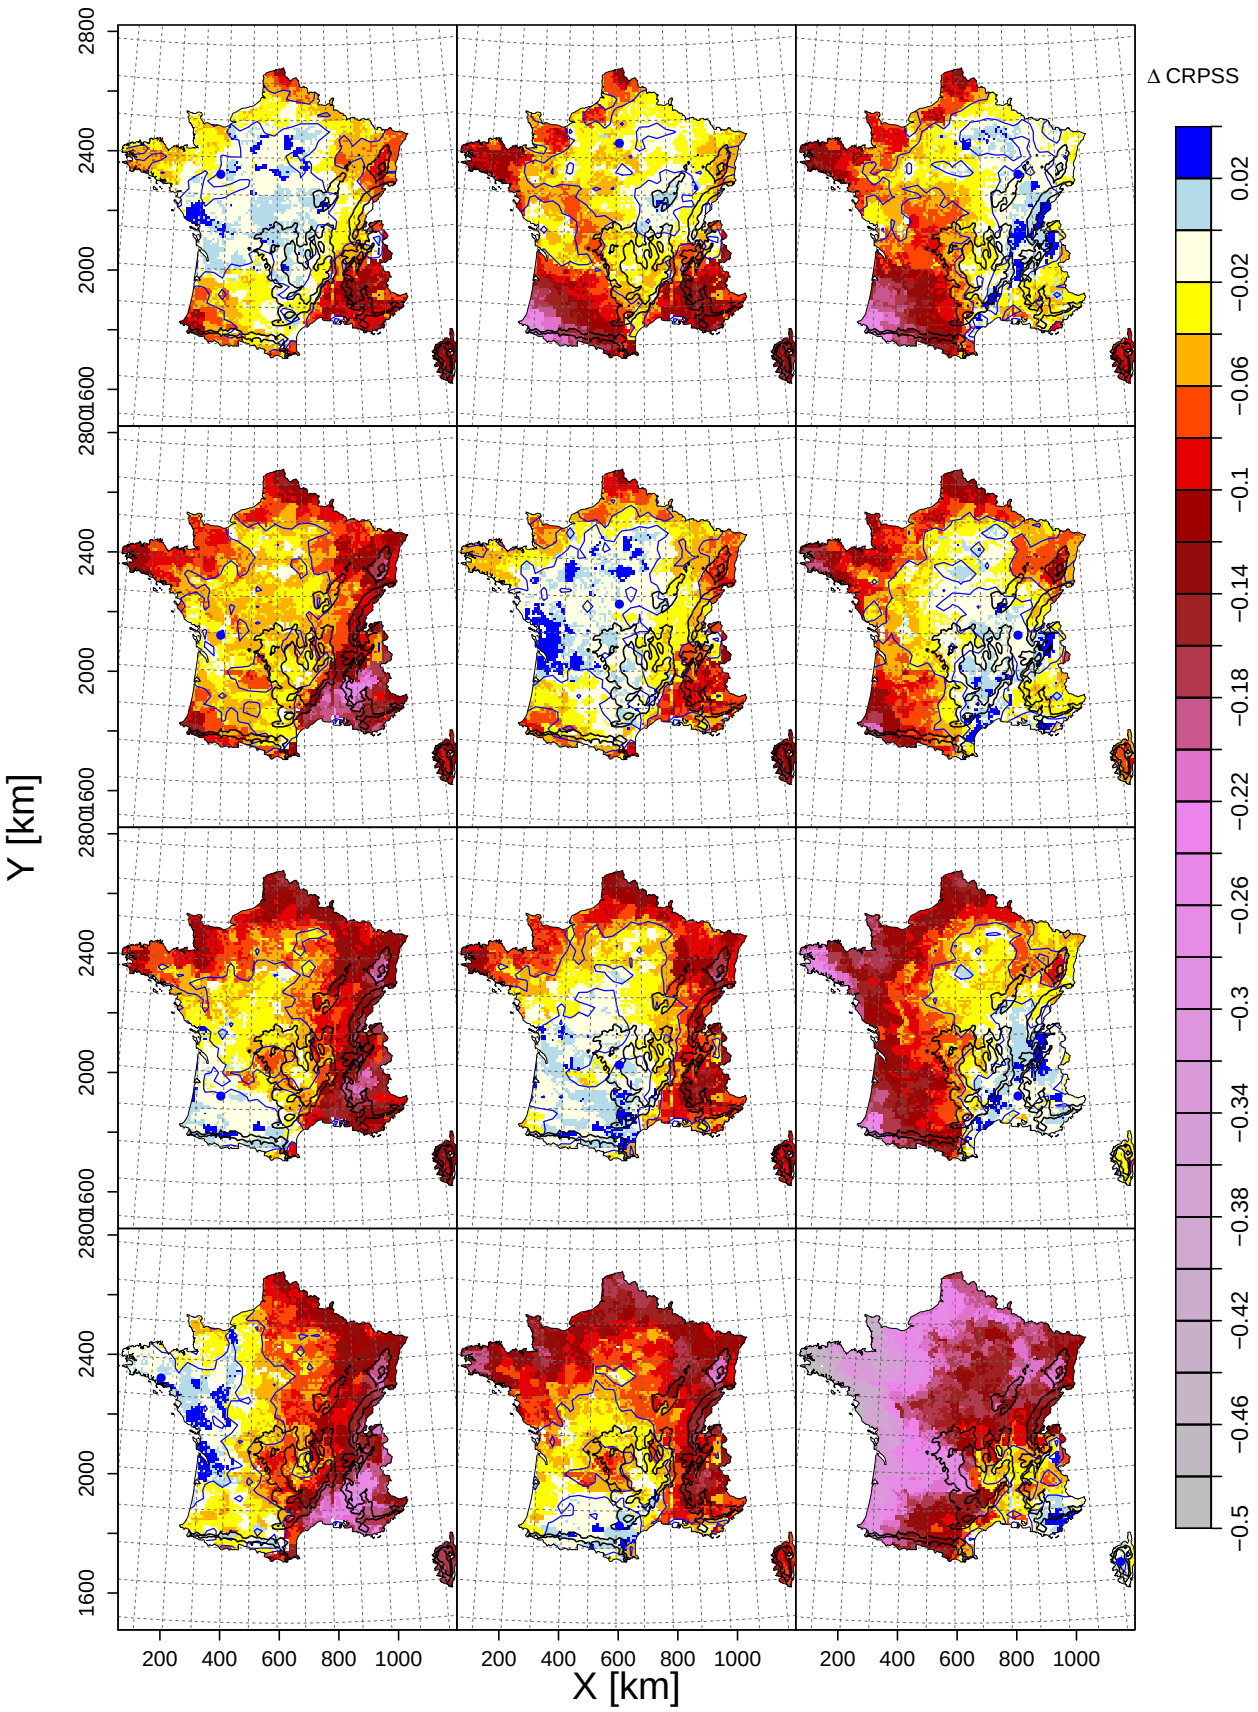

FIGURE B.5 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT5.

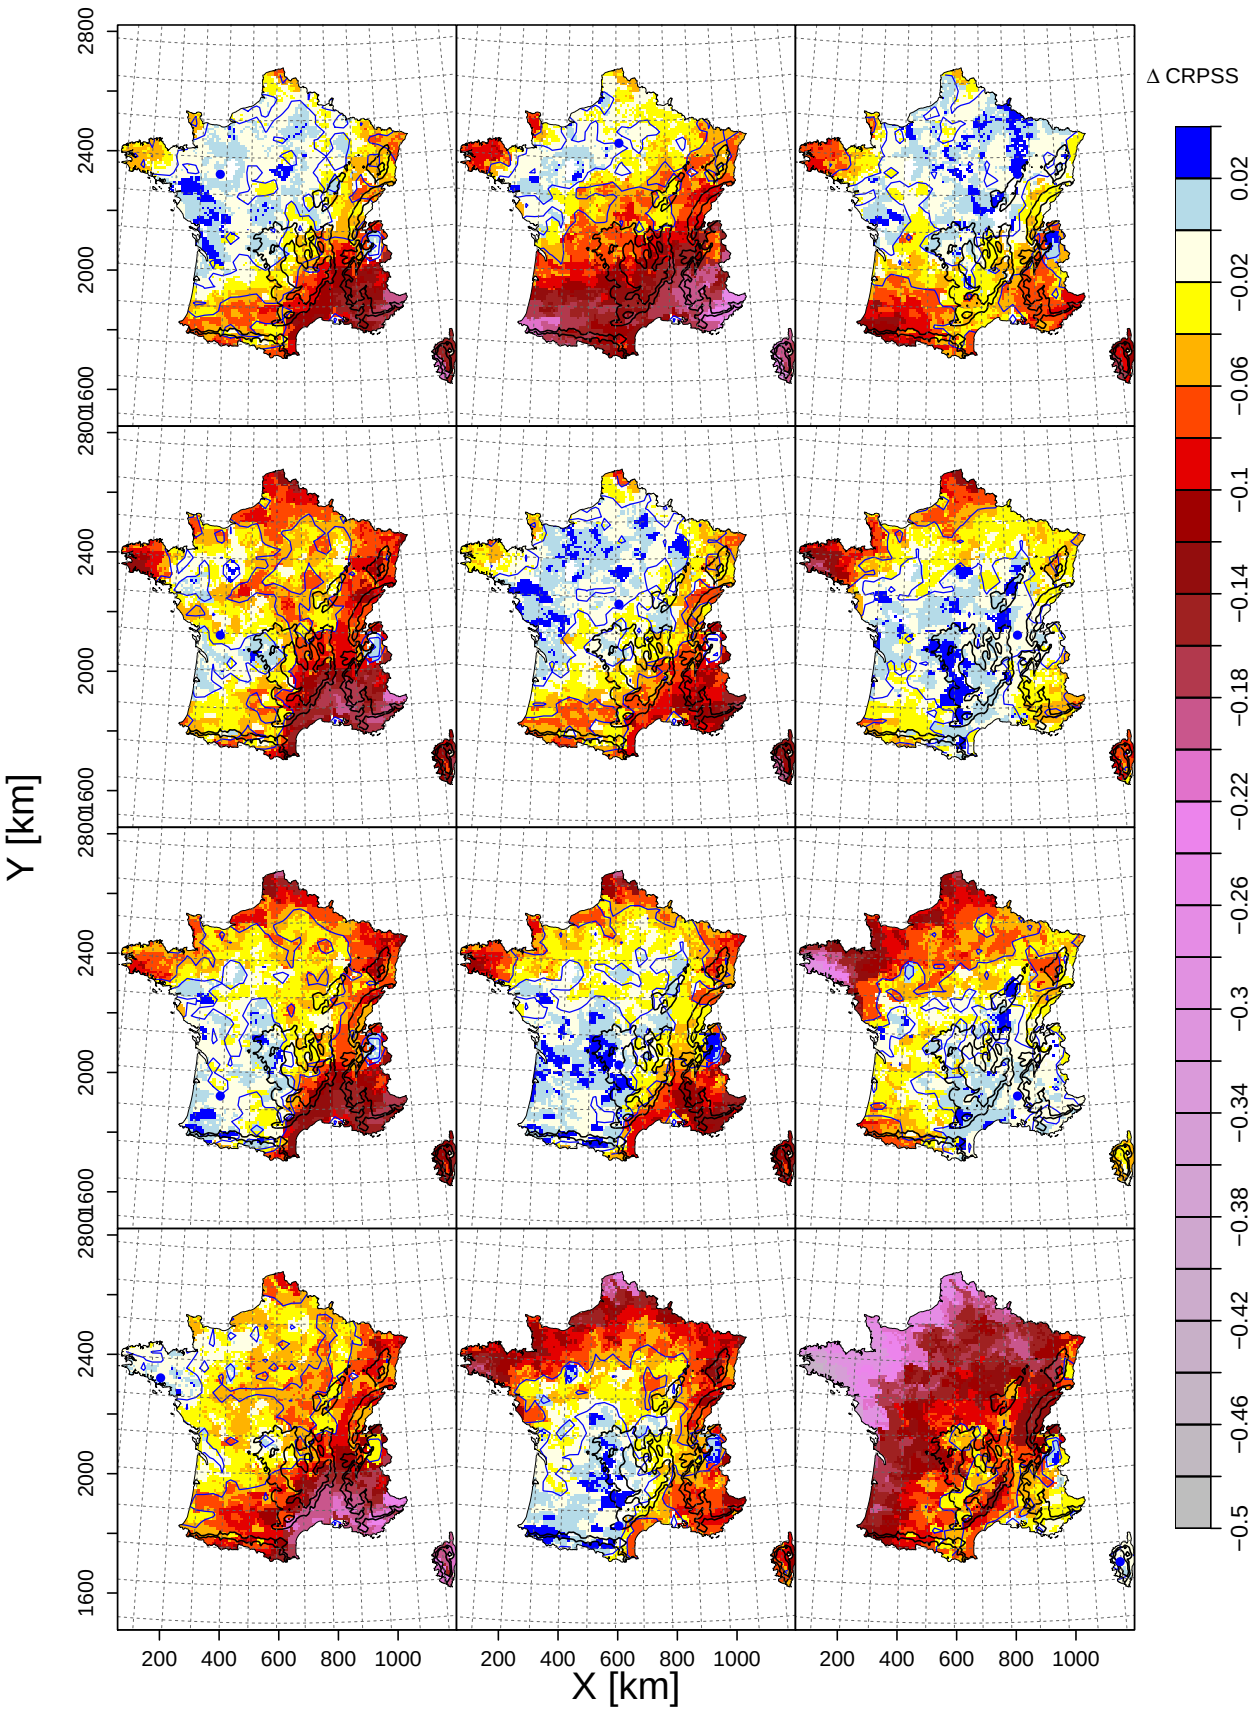

FIGURE B.6 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT6.

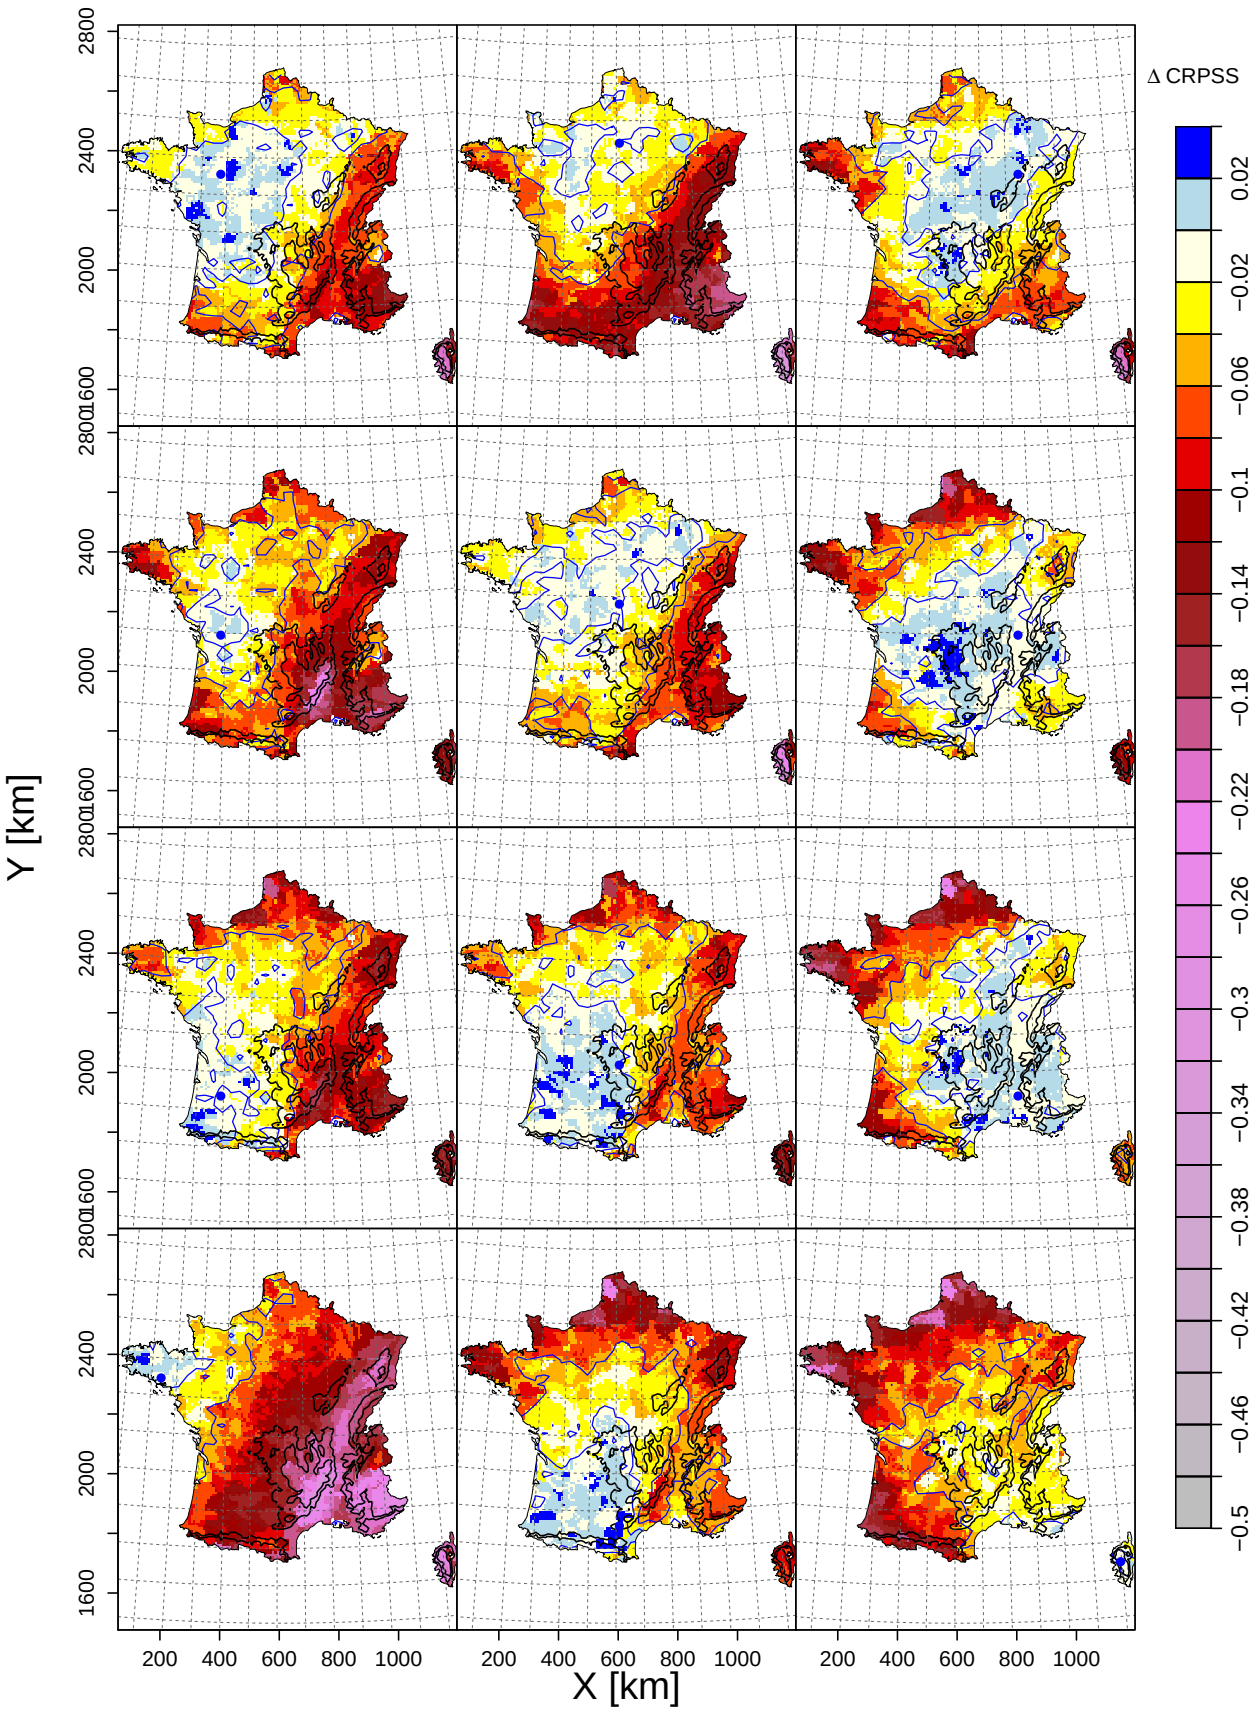

FIGURE B.7 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT7.

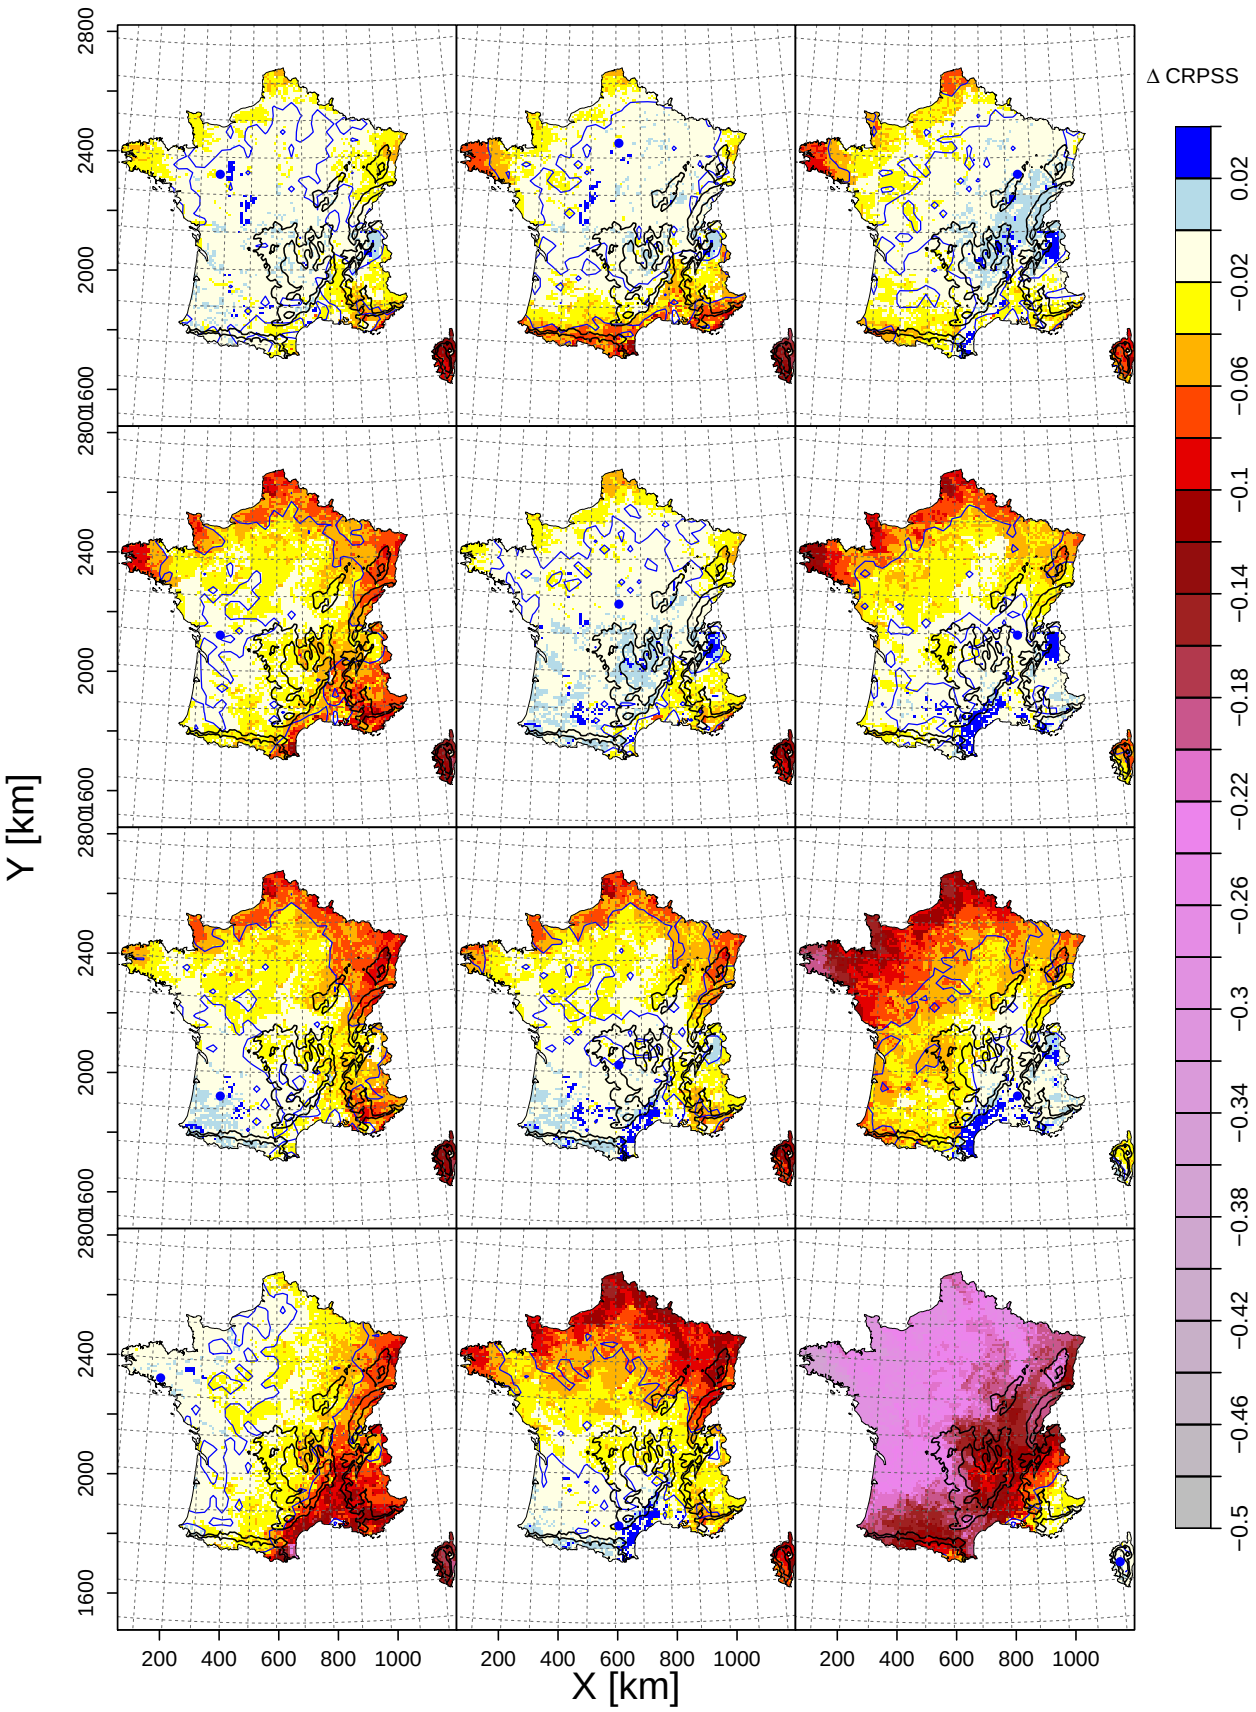

FIGURE B.8 – Transposabilité spatiale de chaque modèle MA optimisé pour chaque maille d'accroche pour le TT8.

Annexe C

Simulation d'une MDES

1. Performance en CRPS moyen lorsque les dispersions de l'erreur et des scénarios régionaux sont égales à celle du signal régional du predictand

Si l'écart-type σ_Δ de l'erreur moyenne régionale Δ_i et l'écart-type σ_H des scénarios générés $\widehat{\mathrm{M}}_{Y_i}$ sont égaux à l'écart-type du signal régional M_{Y_i} à prédire, le système de prédiction $\mathcal{P}$ n'apporte aucune valeur ajoutée par rapport à un système de prédiction climatologique $\mathcal{P}_\varphi$. Pour une prédiction i, la distribution émise $F_{\widehat{M}_{Y_i}}$ des scénarios régionaux émis est représentée par la loi normale $\mathcal{N}(\mu_{Y_i}+\delta_i, \sigma_H^2)$. Le $\overline{\mathrm{CRPS}}$ obtenu par un système $\mathcal{P}$ prédisant la variable M_{Y_i} peut être écrit comme suit :

$$\begin{aligned}\overline{\mathrm{CRPS}}\left(\mathcal{P}, \mathrm{M}_Y\right) &= \mathbb{E}\left[\mathrm{CRPS}\left(F_{\widehat{\mathrm{M}}_{Y_i}}(\mu_{Y_i}), \mu_{Y_i}\right)\right] \\ &= \mathbb{E}\left[\mathrm{CRPS}\left(\mathcal{N}(\mu_{Y_i}+\delta_i, \sigma_H^2), \mu_{Y_i}\right)\right]\end{aligned} \tag{C.1}$$

En retranchant de chaque côté l'erreur régionale δ_i, le $\overline{\mathrm{CRPS}}$ devient :

$$\begin{aligned}\overline{\mathrm{CRPS}}\left(\mathcal{P}, \mathrm{M}_Y\right) &= \mathbb{E}\left[\mathrm{CRPS}\left(\mathcal{N}(0, \sigma_H^2), -\delta_i\right)\right] \\ &= \mathbb{E}\left[\mathrm{CRPS}\left(\mathcal{N}(0, 1), -\delta_i\right)\right]\end{aligned} \tag{C.2}$$

Comme M_{Y_i} et Δ_i suivent tous les deux la même distribution normale lorsque σ_H et σ_Δ sont égaux à 1, le $\overline{\mathrm{CRPS}}$ peut alors s'écrire pour un nombre suffisant de M prédictions :

$$\begin{aligned}\overline{\mathrm{CRPS}}\left(\mathcal{P}, R_Y\right) &\simeq \mathbb{E}\left[\mathrm{CRPS}\left(\mathcal{N}(0,1), \mu_{Y_i}\right)\right] \\ &\simeq \mathbb{E}\left[\mathrm{CRPS}\left(F_{\widehat{\mathrm{M}}_{Y_i}}(\mu_{Y_i}), \mu_{Y_i}\right)\right] \\ &\simeq \overline{\mathrm{CRPS}}\left(\mathcal{P}_\varphi, \mathrm{M}_Y\right) = \overline{\mathrm{U}}\end{aligned} \tag{C.3}$$

où $\mathcal{P}_\varphi$ représente un système de prédiction basé sur la climatologie de M_{Y_i}.

2. Expression du CRPS dans le cas d'un système de prédiction fiable

Gneiting et al. [2005] ont montré que le CRPS pour une distribution émise suivant une loi normale de moyenne μ et de variance σ^2 pouvait s'écrire :

$$\begin{aligned}\mathrm{CRPS}(\mathcal{N}(\mu, \sigma^2), y) = \sigma \Bigg[&\frac{y-\mu}{\sigma}\left\{2\Psi\left(\frac{y-\mu}{\sigma}\right) - 1\right\} \\ &+ 2\psi\left(\frac{y-\mu}{\sigma}\right) - \frac{1}{\sqrt{\pi}}\Bigg]\end{aligned} \tag{C.4}$$

Où Ψ et ψ correspondent respectivement à la cdf et la pdf d'une distribution normale standard. y est la réalisation du predictand Y et $(y-\mu)/\sigma$ représente l'erreur moyenne normalisée de la prédiction.

Dans notre étude, μ correspond à la somme de deux variables distribuées normalement M_{Y_i} et Δ_i définies aux équations V.3 et V.10. Comme notre système $\mathcal{P}$ est considéré fiable, σ_Δ est égal à σ_H (*cf.* section 3.2.2 du chapitre V). En remplaçant y par μ_{Y_i}, μ par $\mu_{Y_i} + \delta_i$ et σ par σ_Δ dans l'équation C.4 et par le calcul de l'espérance, le $\overline{\mathrm{CRPS}}$ peut être exprimé en trois termes :

$$\overline{\mathrm{CRPS}} = \sigma_\Delta \ \{A + B + C\} \tag{C.5}$$

Avec

$$\begin{aligned}A &= \mathbb{E}\left[\ \frac{-\delta_i}{\sigma_\Delta}\left\{2\Psi\left(\frac{-\delta_i}{\sigma_\Delta}\right) - 1\ \right\}\right] \\ B &= \mathbb{E}\left[\ 2\psi\left(\frac{-\delta_i}{\sigma_\Delta}\right)\right] \\ C &= -\frac{1}{\sqrt{\pi}}\end{aligned} \tag{C.6}$$

Comme la variable $-\Delta_i$ suit une distribution normale de moyenne 0, et que $\Psi\left(-\delta_i/\sigma_\Delta\right) = 1 - \Psi\left(\delta_i/\sigma_\Delta\right)$, le terme A devient égal à :

$$A = 2\mathbb{E}\left[\ \frac{\delta_i}{\sigma_\Delta} \cdot \Psi\left(\frac{\delta_i}{\sigma_\Delta}\right)\right] \tag{C.7}$$

Selon le lemme de Stein [Stein, 1981], si F est une fonction pour laquelle les deux espérances $\mathbb{E}\left[F(x)(x-\mu)\right]$ et $\mathbb{E}\left[F'(x)\right]$ existent, alors

$$\mathbb{E}\left[F(x)(x-\mu)\right] = \sigma^2 \mathbb{E}\left[F'(x)\right] \tag{C.8}$$

où x est une réalisation d'une variable X normalement distribuée de moyenne μ et de variance σ^2. En remplaçant F par Ψ, F' par ψ et X par la variable Δ_i/σ_Δ de moyenne 0 et de variance 1, l'équation C.8 devient

$$\mathbb{E}\left[\Psi\left(\frac{\delta_i}{\sigma_\Delta}\right) \cdot \frac{\delta_i}{\sigma_\Delta}\right] = \mathbb{E}\left[\psi(\frac{\delta_i}{\sigma_\Delta})\right] \tag{C.9}$$

En introduisant l'égalité de l'équation C.9 dans l'équation C.7, A devient égal à B et le $\overline{\text{CRPS}}$ est alors égal à :

$$\overline{\text{CRPS}} = \sigma_\Delta \ \{D + C\} \tag{C.10}$$

Avec,

$$D = 4\mathbb{E}\left[\psi(\frac{\delta_i}{\sigma_\Delta})\right] \tag{C.11}$$

Pour une variable X suivant une loi normale standard, la valeur de l'espérance dans l'équation C.11 est calculée grâce à l'intégrale de Gauss,

$$\begin{aligned} \mathbb{E}\left[\psi(X)\right] &= \frac{1}{2\pi}\int_{-\infty}^{+\infty} \exp(-u^2)du \\ &= \frac{1}{2\sqrt{\pi}} \end{aligned} \tag{C.12}$$

Le terme D devient égal à $2/\sqrt{\pi}$ et l'espérance du CRPS pour un système de prédiction $\mathcal{P}$ fiable prédisant une loi normale devient finalement :

$$\overline{\text{CRPS}} = \frac{\sigma_\Delta}{\sqrt{\pi}} = \frac{\sigma_H}{\sqrt{\pi}} \tag{C.13}$$

Annexe $\mathcal{D}$

Compléments d'évaluation sur le modèle combiné

1. Influence de la multi-colinéarité des prédicteurs sur l'estimation des coefficients de la régression

Dans le cas d'une régression linéaire multiple, le vecteur des coefficients $\widehat{\boldsymbol{\beta}}$ peut être estimé par $(\mathbf{X}^{\mathrm{T}}\mathbf{X})^{-1}\mathbf{X}^{\mathrm{T}}Y$. Dans ce cas, le calcul de l'inverse de $\mathbf{X}^{\mathrm{T}}\mathbf{X}$ s'effectue grâce au déterminant et à la matrice des cofacteurs $\mathbf{C}$ de $\mathbf{X}^{\mathrm{T}}\mathbf{X}$ comme :

$$(\mathbf{X}^{\mathrm{T}}\mathbf{X})^{-1} = \frac{1}{\det(\mathbf{X}^{\mathrm{T}}\mathbf{X})}\mathbf{C} \tag{D.1}$$

Or le déterminant est égal à :

$$\det(\mathbf{X}^{\mathrm{T}}\mathbf{X}) = \prod_{k=1}^{K+1} \lambda_k \tag{D.2}$$

où λ_k est la k^{ème} valeur propre de $\mathbf{X}^{\mathrm{T}}\mathbf{X}$ et $\lambda_1 > \lambda_2 > \lambda_3 > \ldots > \lambda_{K+1}$, K correspondant au nombre de prédicteurs. La résolution de l'équation D.1 est possible si et seulement si l'ensemble des valeurs propres λ_k sont différentes de 0. Si une des valeurs propres est égale à 0, on dit qu'il y a multicolinéarité exacte et le calcul de $\widehat{\beta}$ n'est pas possible. En pratique, les prédicteurs sont plus ou moins colinéaires. Dans le cas d'une forte multicolinéarité, les valeurs de λ_k, et par suite celle de $\det(\mathbf{X}^{\mathrm{T}}\mathbf{X})$, seront proches de 0. Par conséquent, les valeurs de $(\mathbf{X}^{\mathrm{T}}\mathbf{X})^{-1}$ varient fortement et les coefficients du vecteur $\widehat{\beta}$ deviennent alors très sensibles à une petite variation de Y.

Pour une illustration de l'influence de la multi-colinéarité des prédicteurs, le lecteur pourra se référer aux travaux de Tremblay [2012, pp. 8–13].

2. Modèle d'occurrence

2.1. Pouvoir prédictif des prédicteurs

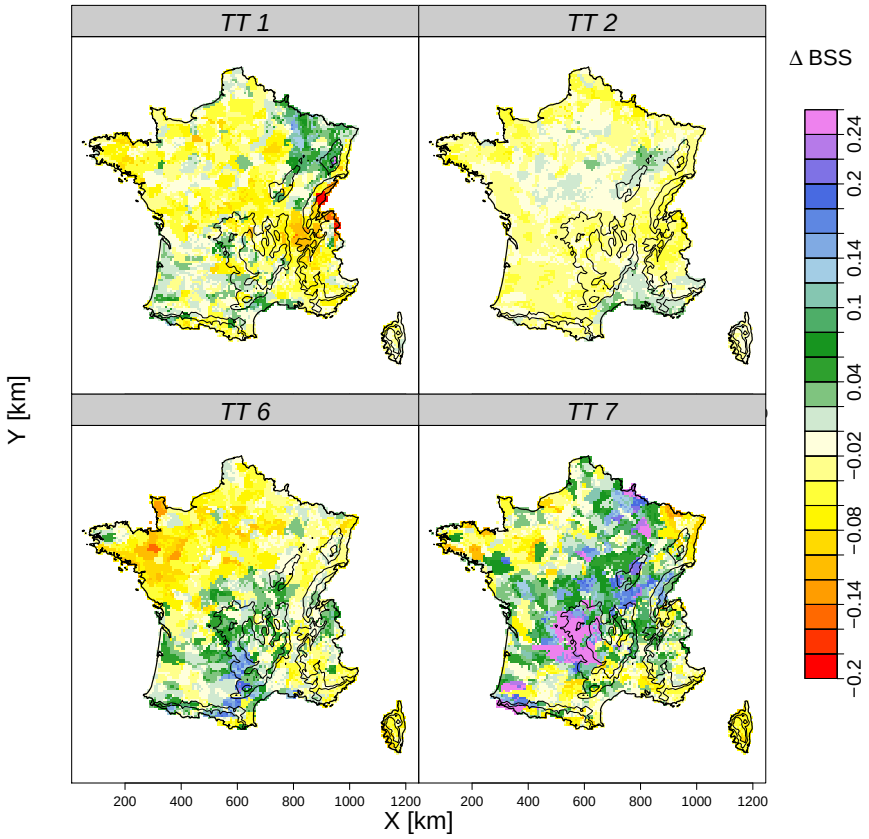

FIGURE D.1 – Gains en BSS obtenus par le modèle d'occurrence seulement basé sur le prédicteur Z_1 pour les types de temps 1, 2, 6 et 7.

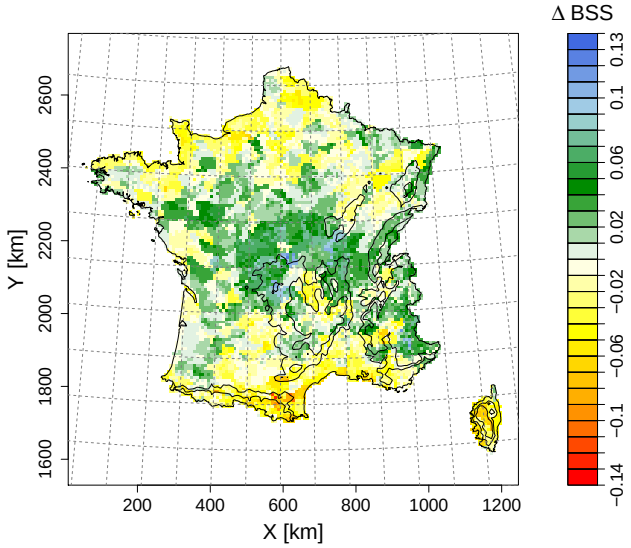

FIGURE D.2 – Gains en BSS obtenus par le modèle d'occurrence seulement basé sur le prédicteur H pour le type de temps 6.

2.2. Illustration de la multi-colinéarité des prédicteurs

De façon à vérifier la présence de relations multi-colinéaires entre les prédicteurs retenus à la section 3 du chapitre VII, nous avons utilisé le critère d'inflation de la variance (ou Variance Inflation Factor - VIF). Pour le $j^{\text{ème}}$ prédicteur X_j, le critère VIF_j est défini comme :

$$\text{VIF}_j = \frac{1}{1 - R_j^2} \tag{D.3}$$

où R_j^2 est égal au coefficient de détermination de X_j régressé par rapport aux autres prédicteurs. Plus le prédicteur X_j est expliqué par les autres prédicteurs, plus la valeur de R_j^2 tend vers 1, plus la valeur du VIF_j est importante. Par conséquent, une forte valeur du VIF indique une forte multicolinéarité et inversement. Notons toutefois que la valeur du coefficient de détermination R_j^2 ne peut qu'augmenter lorsqu'un prédicteur est rajouté. Le critère VIF s'avère donc sensible à la taille du modèle.

Dans notre cas, nous avons évalué la multicolinéarité en calculant les valeurs de VIF obtenus entre chaque prédicteur X_j et les autres prédicteurs dont les valeurs sont extraites à partir des dates analogues pour chaque prédiction. Le prédicteur obtenant le VIF le plus important est alors celui qui peut être le mieux exprimé par les autres prédicteurs.

D'après Tremblay [2012], les seuils utilisés pour attester de la multicolinéarité diffèrent en fonction des auteurs. Ils varient entre 4 et 30. La figure D.3 représente, pour la maille d'accroche NW, les distributions des VIF maximaux journaliers pour deux simulations : 1) une première simulation où le modèle de régression pour l'occurrence dispose de l'ensemble des neufs prédicteurs potentiels et 2) une seconde simulation où le modèle de régression dispose du jeu optimisé de prédicteurs pour la prédiction de l'occurrence à la section 2 du chapitre VIII. Dans le premier cas, presque 15% des prédictions obtiennent un VIF maximal supérieur à 4, tandis que le second cas conduit à une absence de mutlicolinéarité pour presque toutes les prédictions.

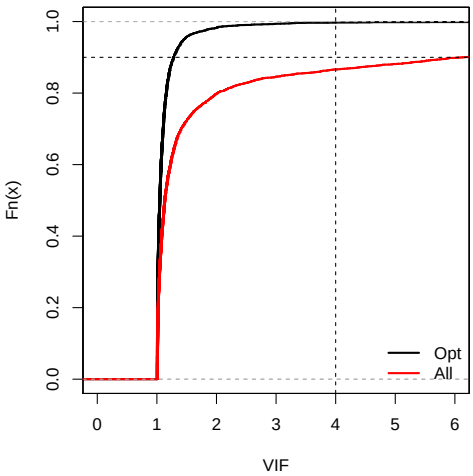

Figure D.3 – Distribution des valeurs maximales des VIF obtenues pour un modèle d'occurrence faisant intervenir l'ensemble des prédicteurs potentiels retenus à la section 1 du chapitre VIII (ligne rouge) et pour le modèle d'occurrence optimisé à la section 2 du chapitre VIII (ligne noire) appliqués à la maille d'accroche NW.

2.3. Fréquence d'échantillonnage des structures régressives

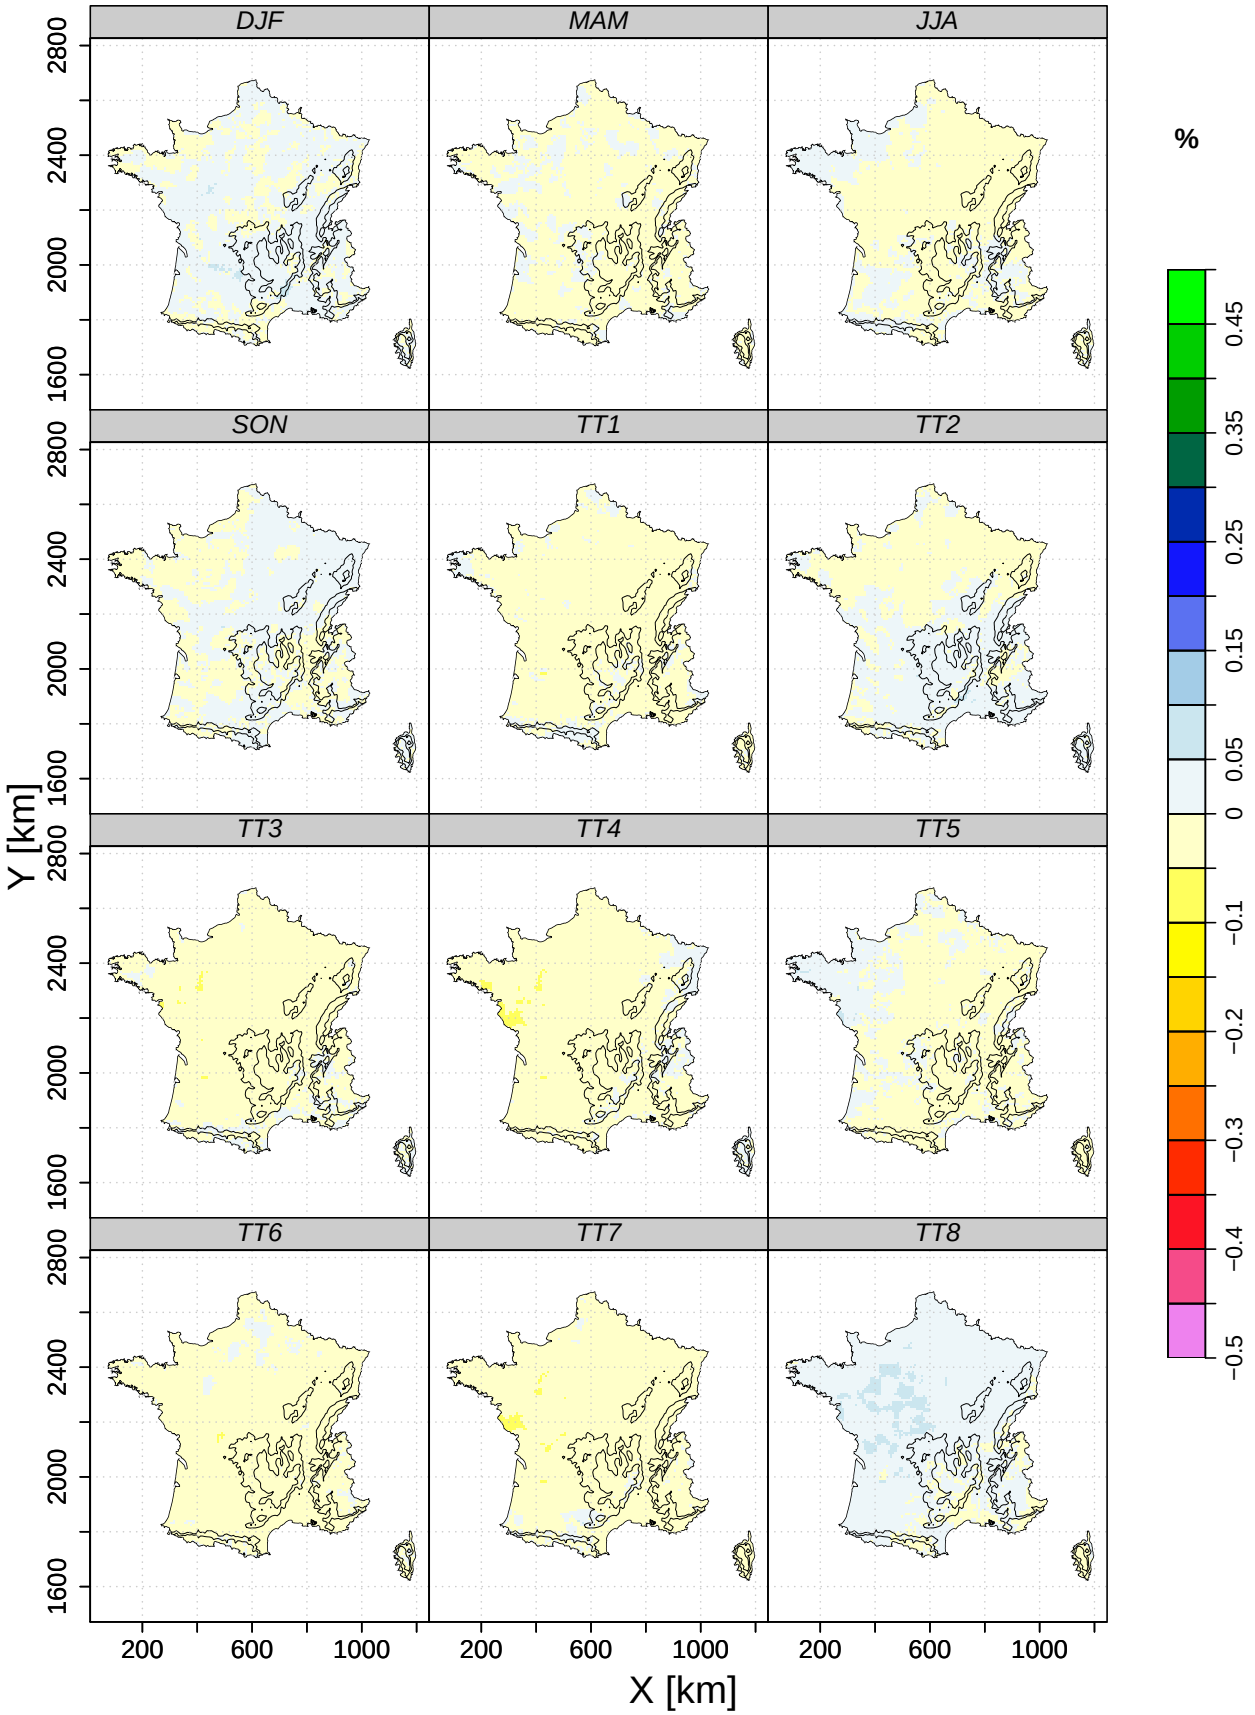

FIGURE D.4 – Différence d'échantillonnage de la structure n° 2 basée sur le prédicteur H en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

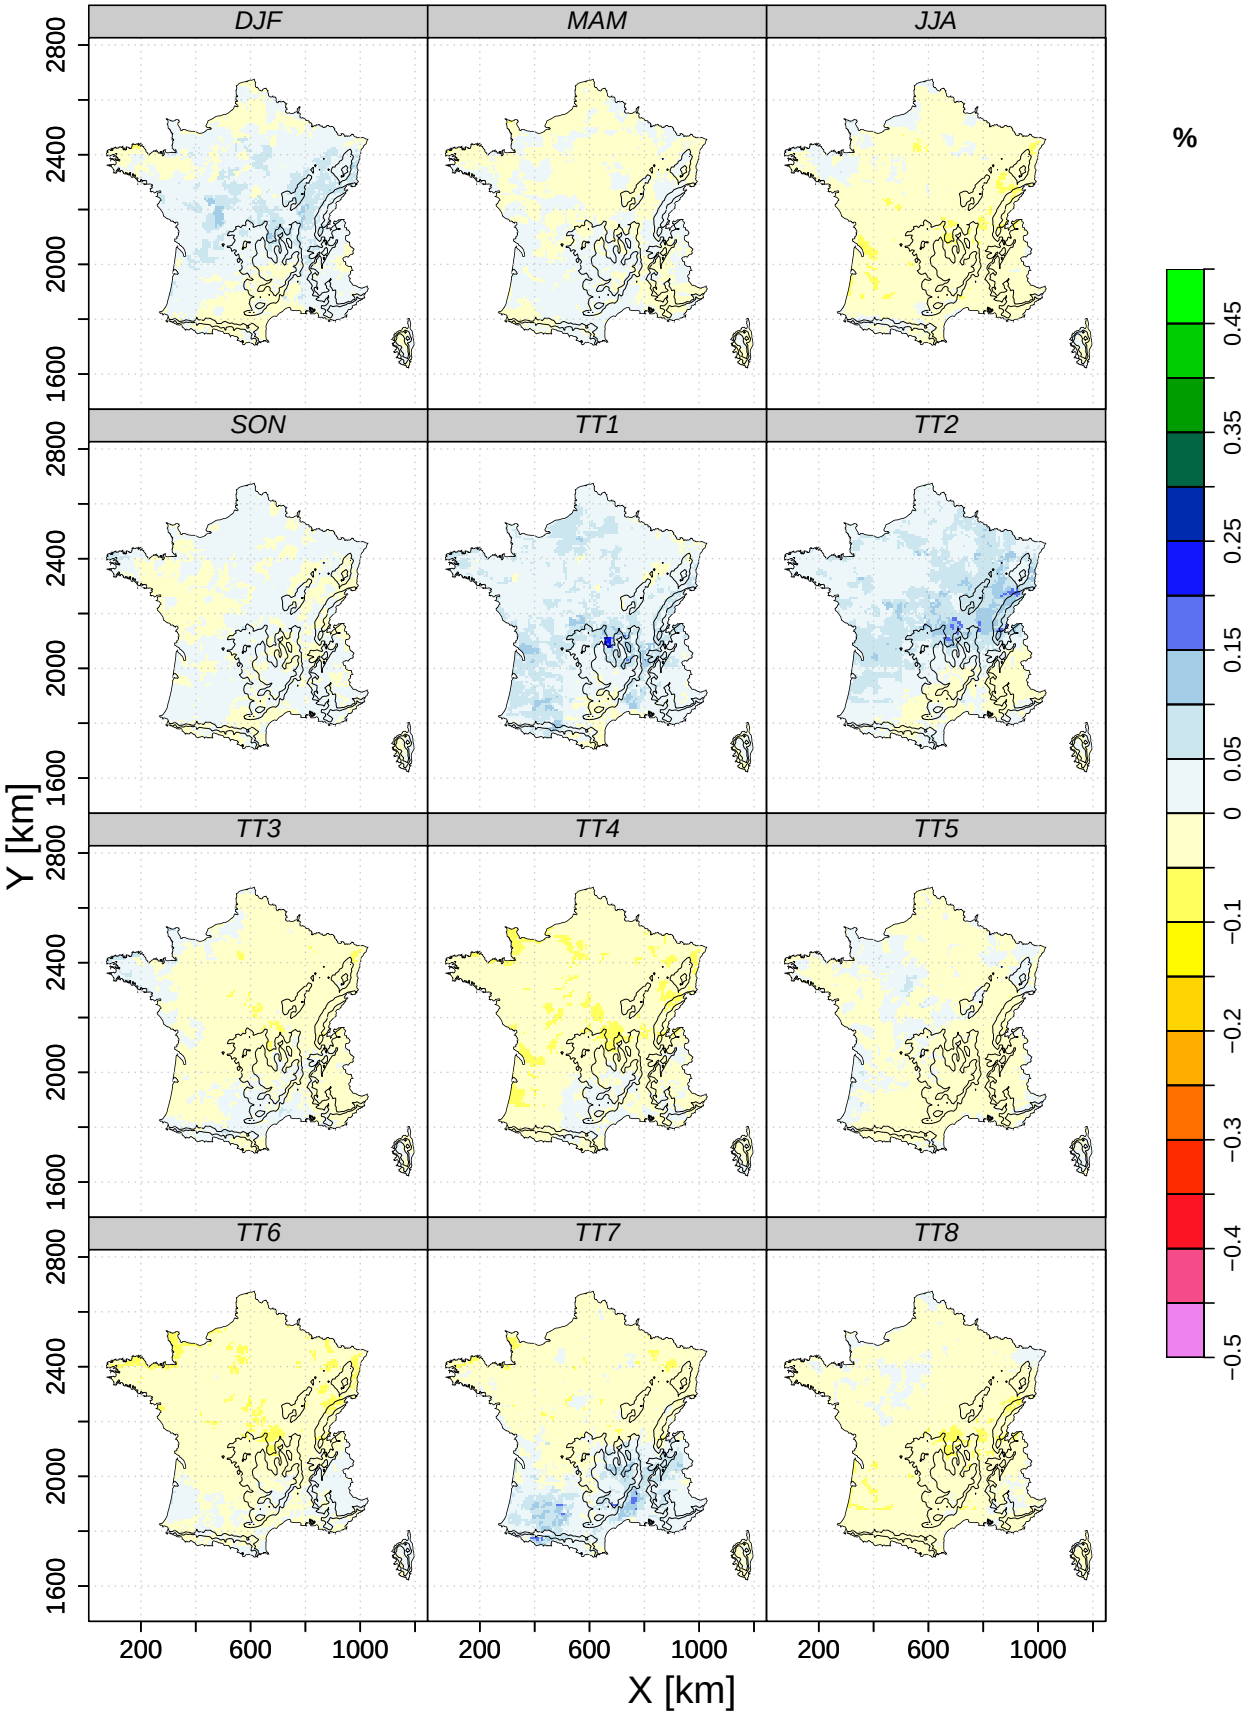

FIGURE D.5 – Différence d'échantillonnage de la structure n° 3 basée sur le prédicteur W en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

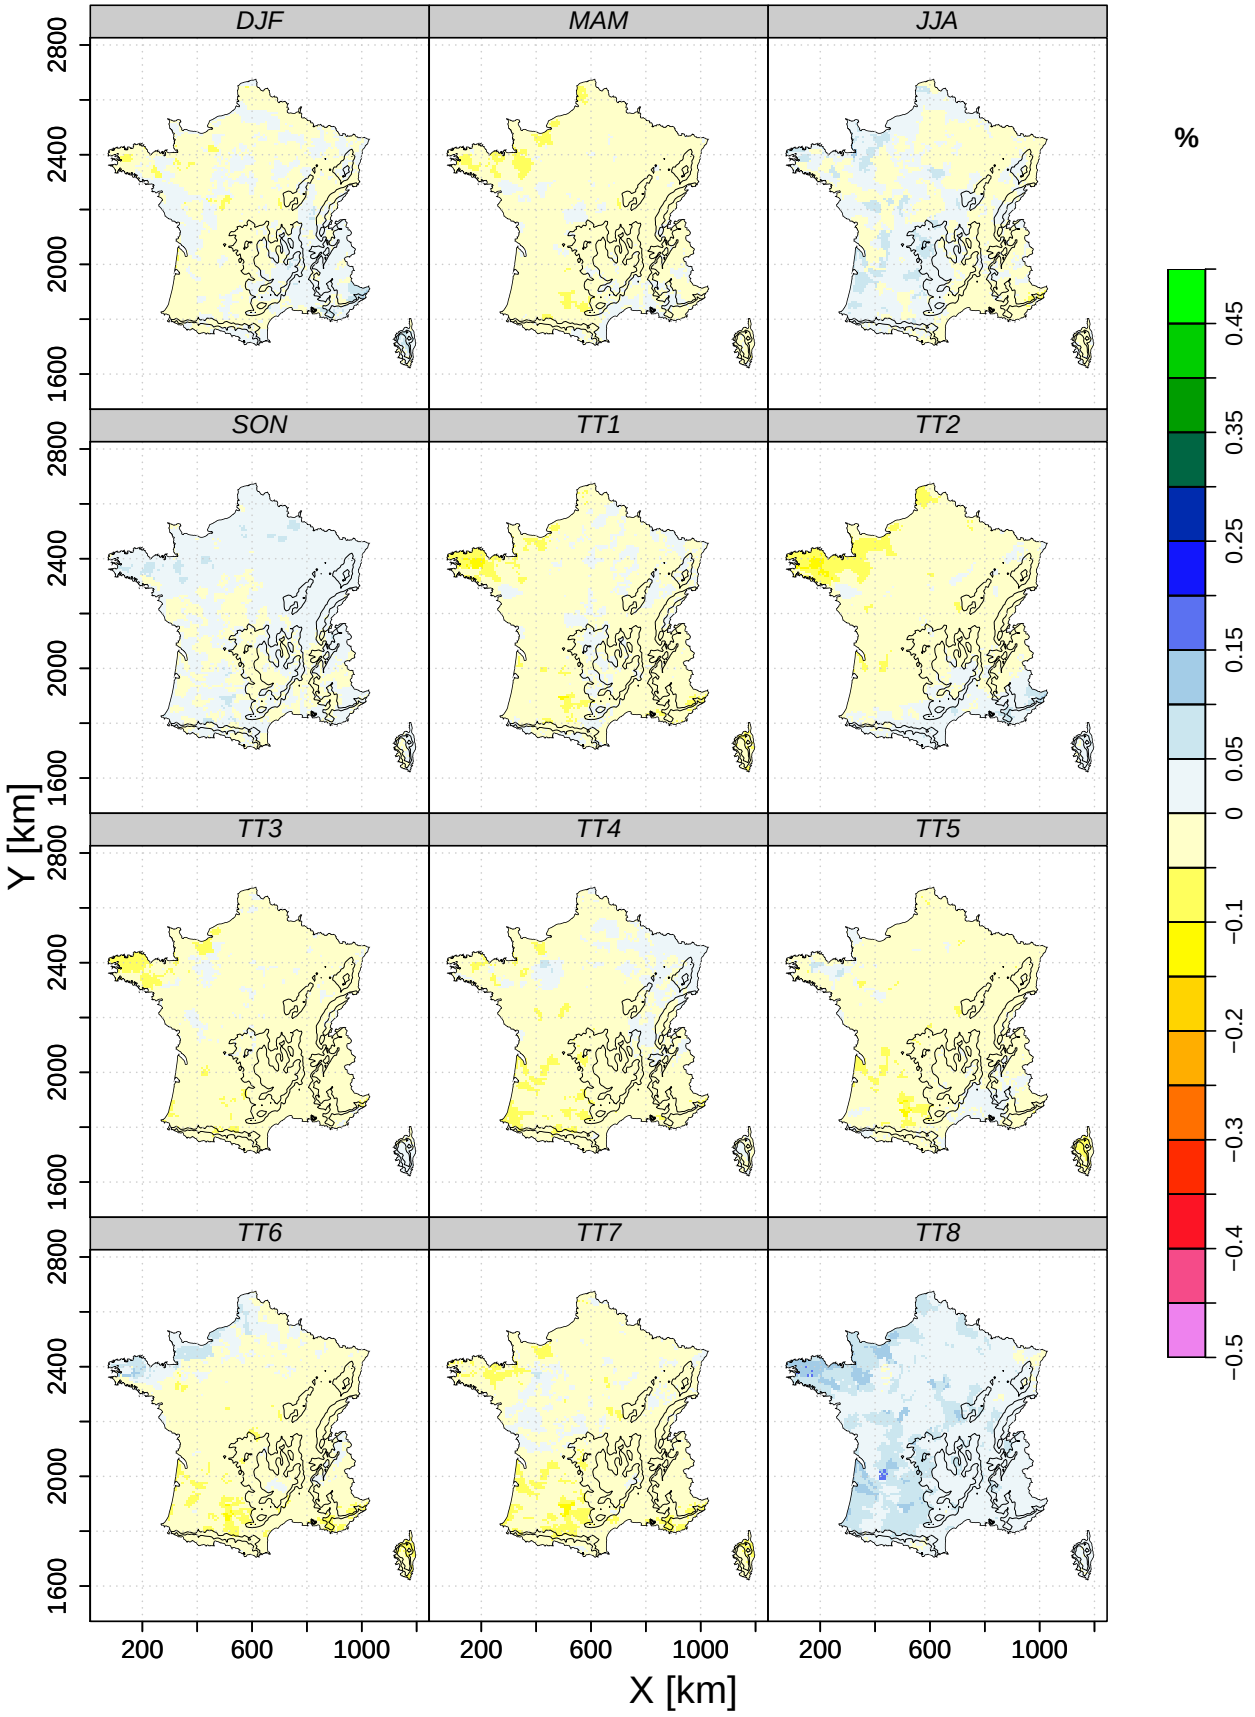

FIGURE D.6 – Différence d'échantillonnage de la structure n° 4 basée sur le prédicteur Occ-1 en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

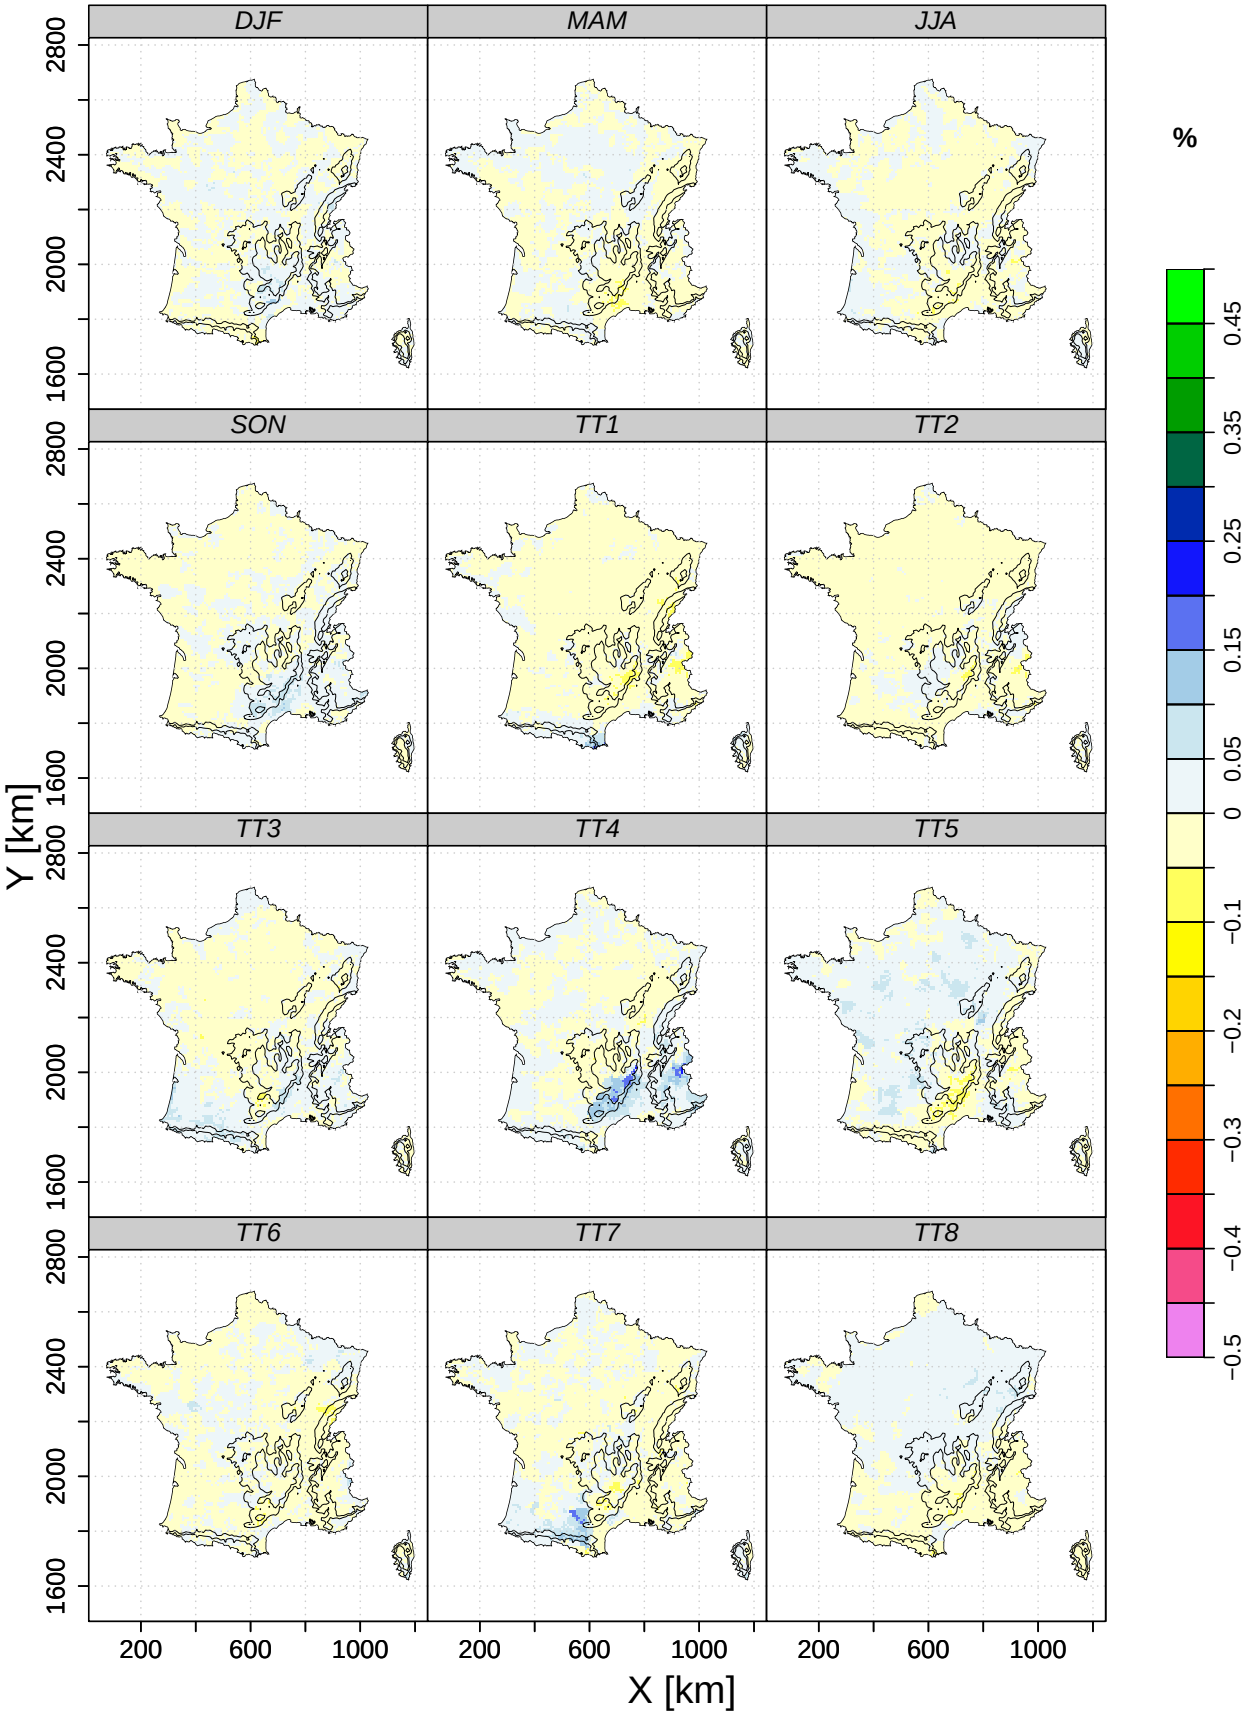

FIGURE D.7 – Différence d'échantillonnage de la structure n° 5 basée sur le prédicteur R_2 + H en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

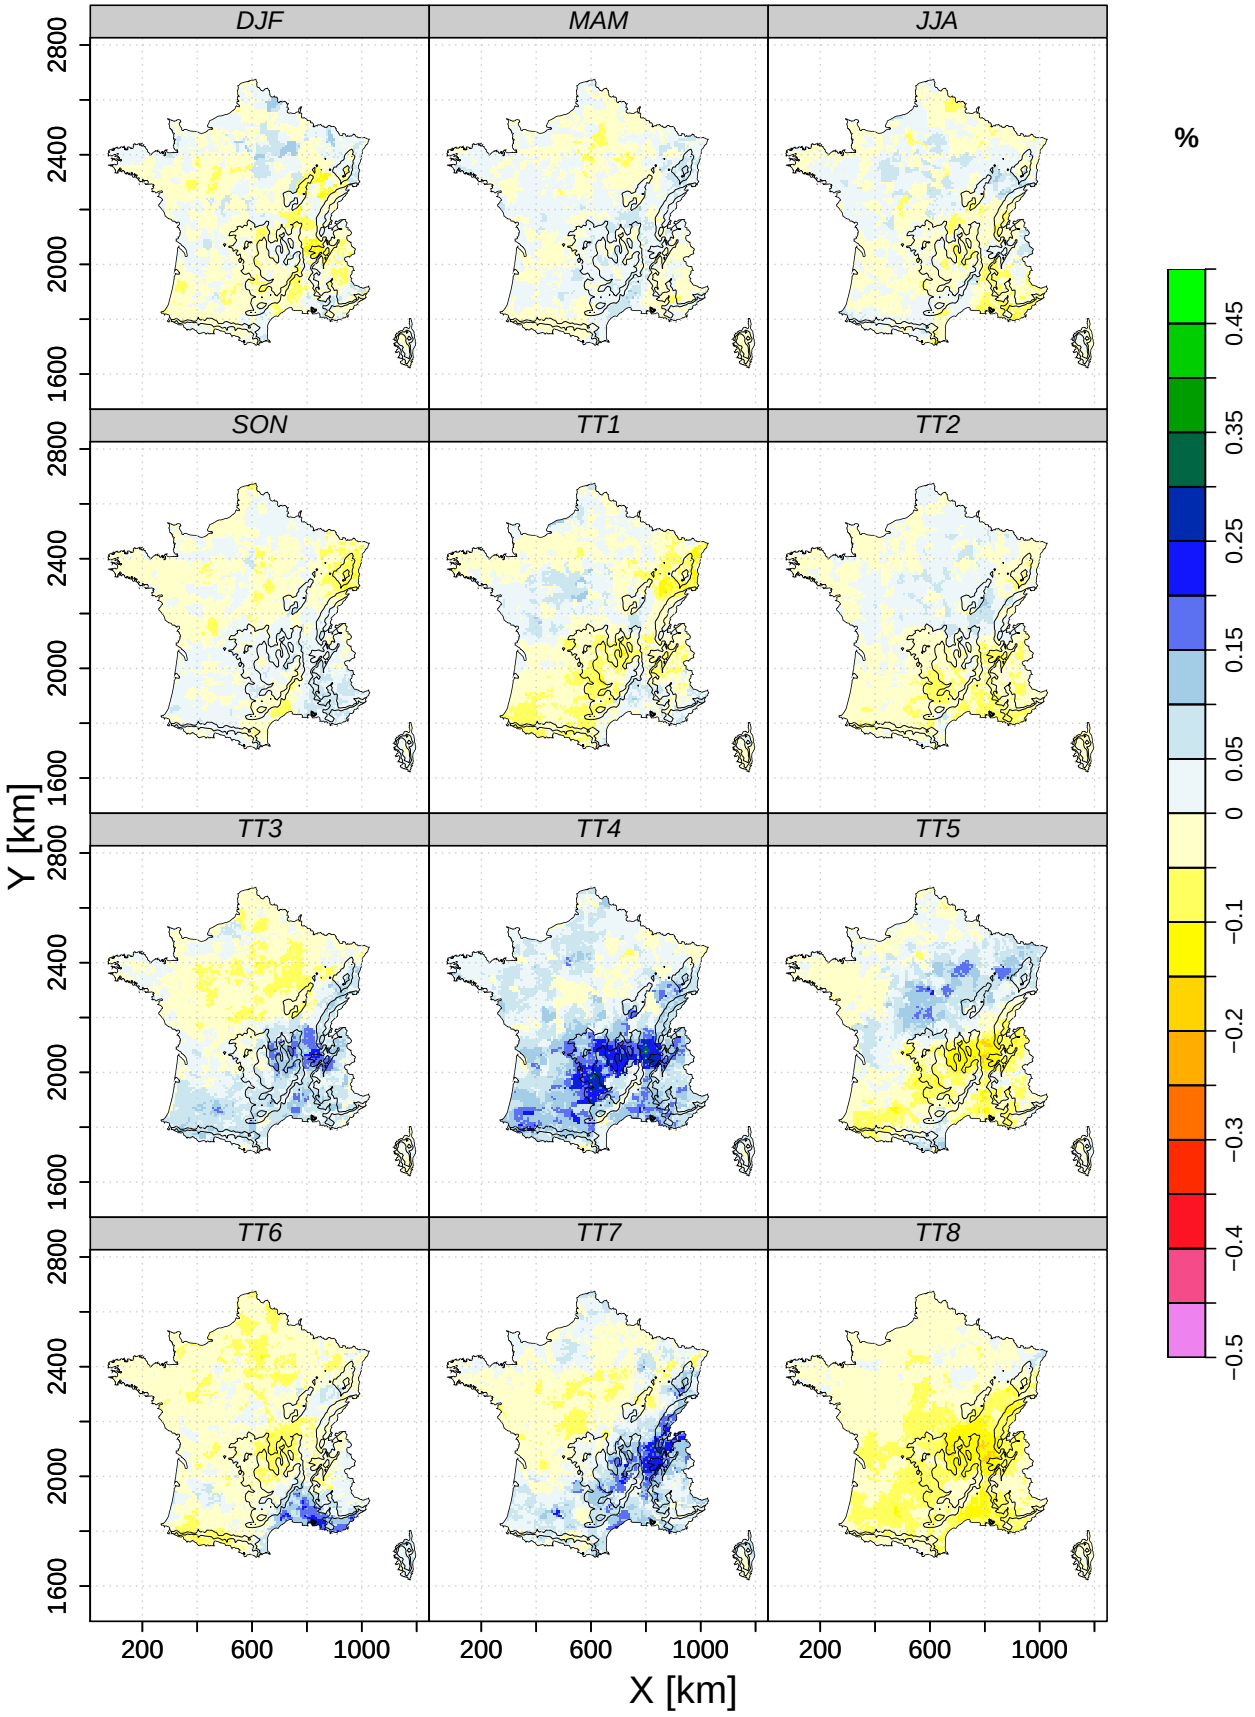

FIGURE D.8 – Différence d'échantillonnage de la structure n° 6 basée sur le prédicteur R_2 + W en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

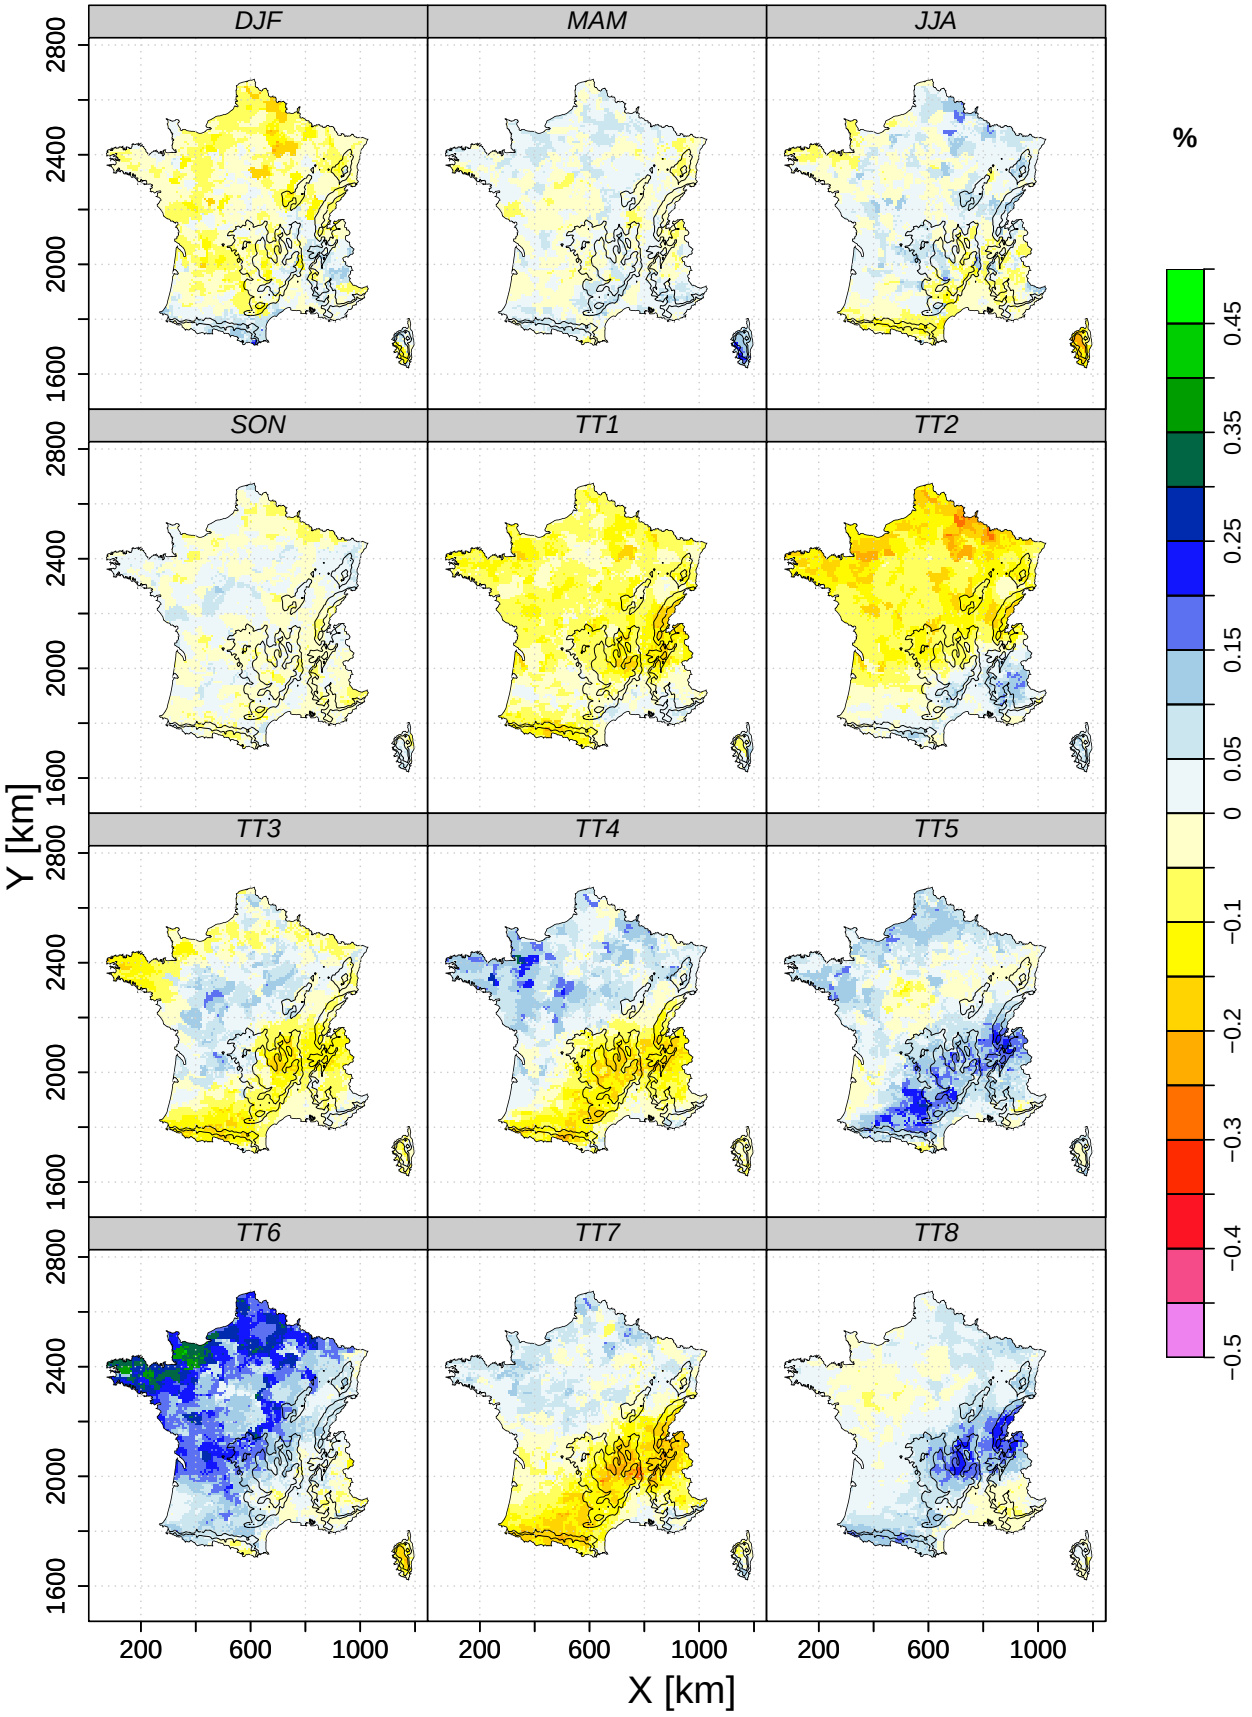

FIGURE D.9 – Différence d'échantillonnage de la structure n° 7 basée sur le prédicteur R_2 + Occ-1 en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

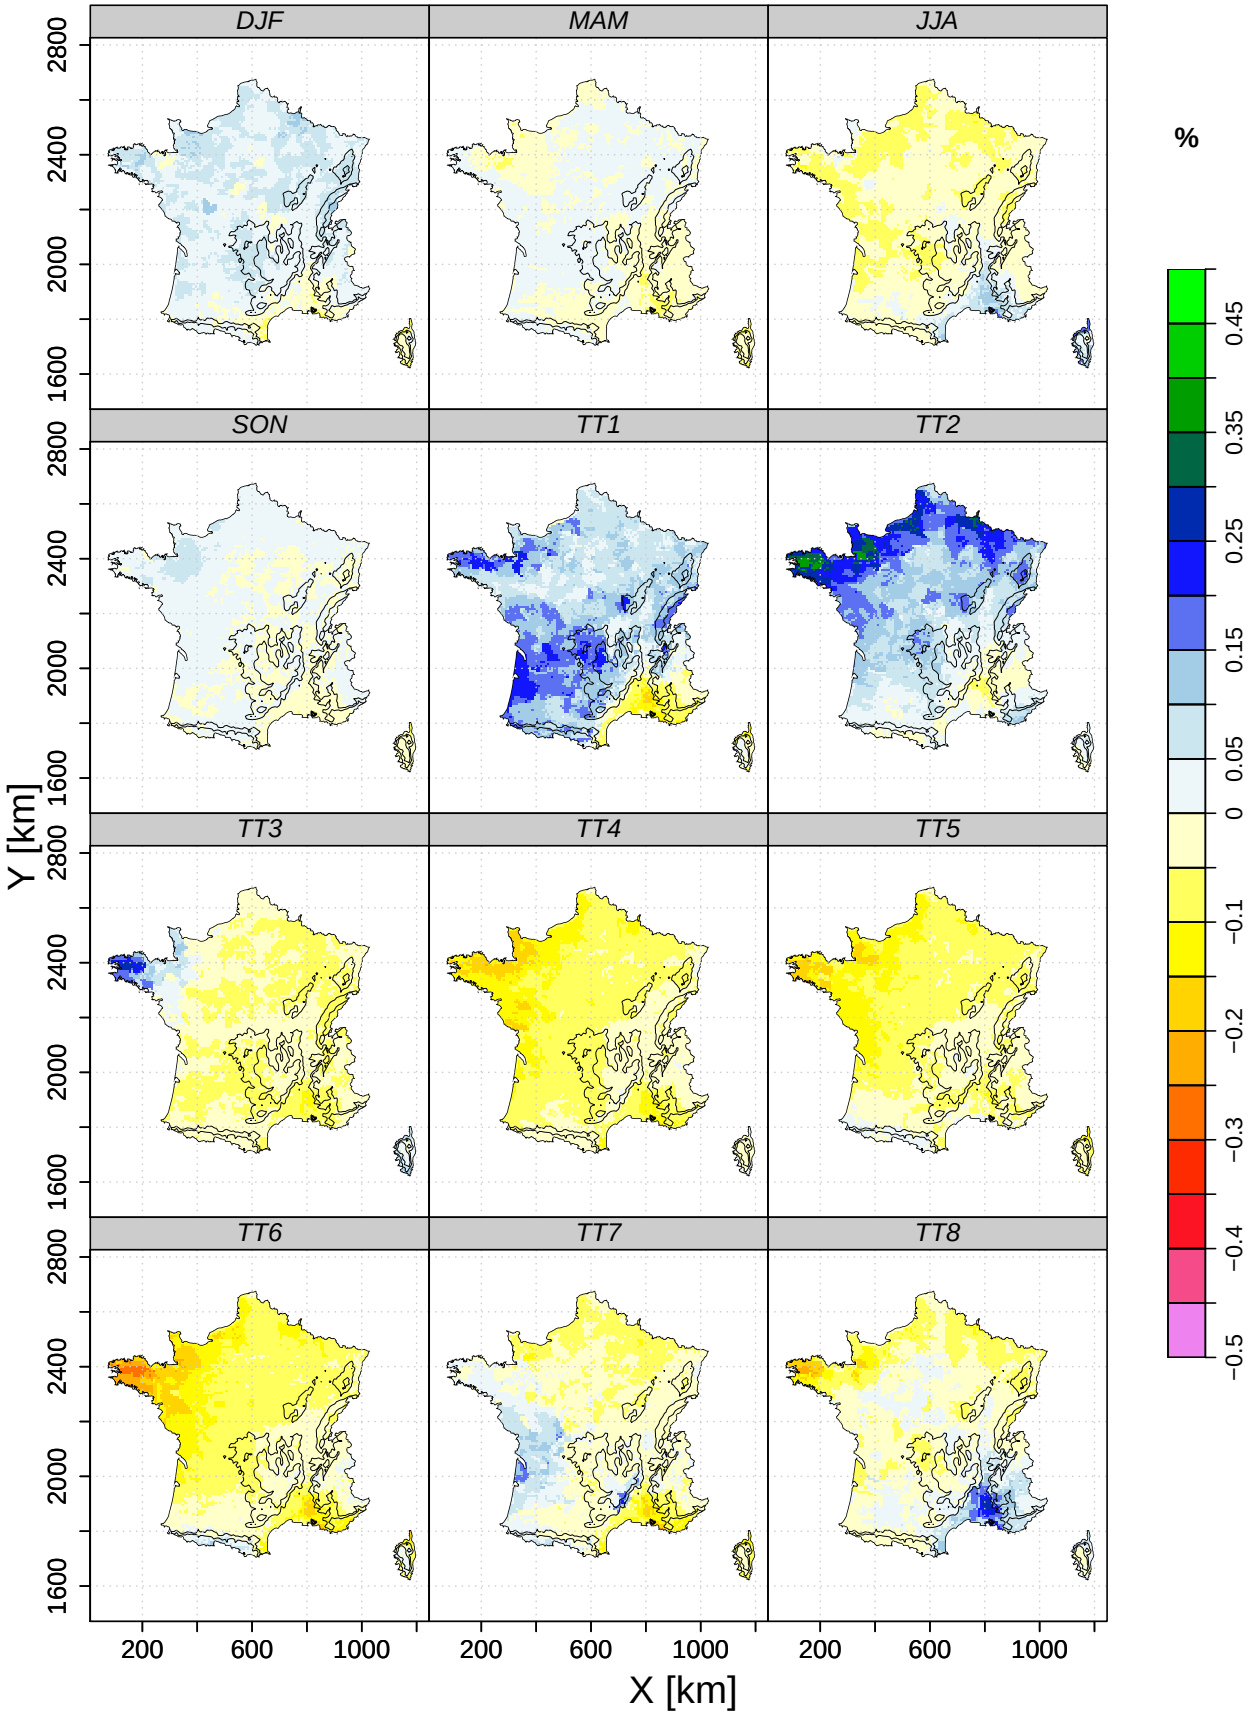

FIGURE D.10 – Différence d'échantillonnage du modèle alternatif MA_{25} en fonction des saisons et des types de temps. Les mailles pour lesquelles la fréquence d'échantillonnage est inférieure à 5% ont été représentées en gris.

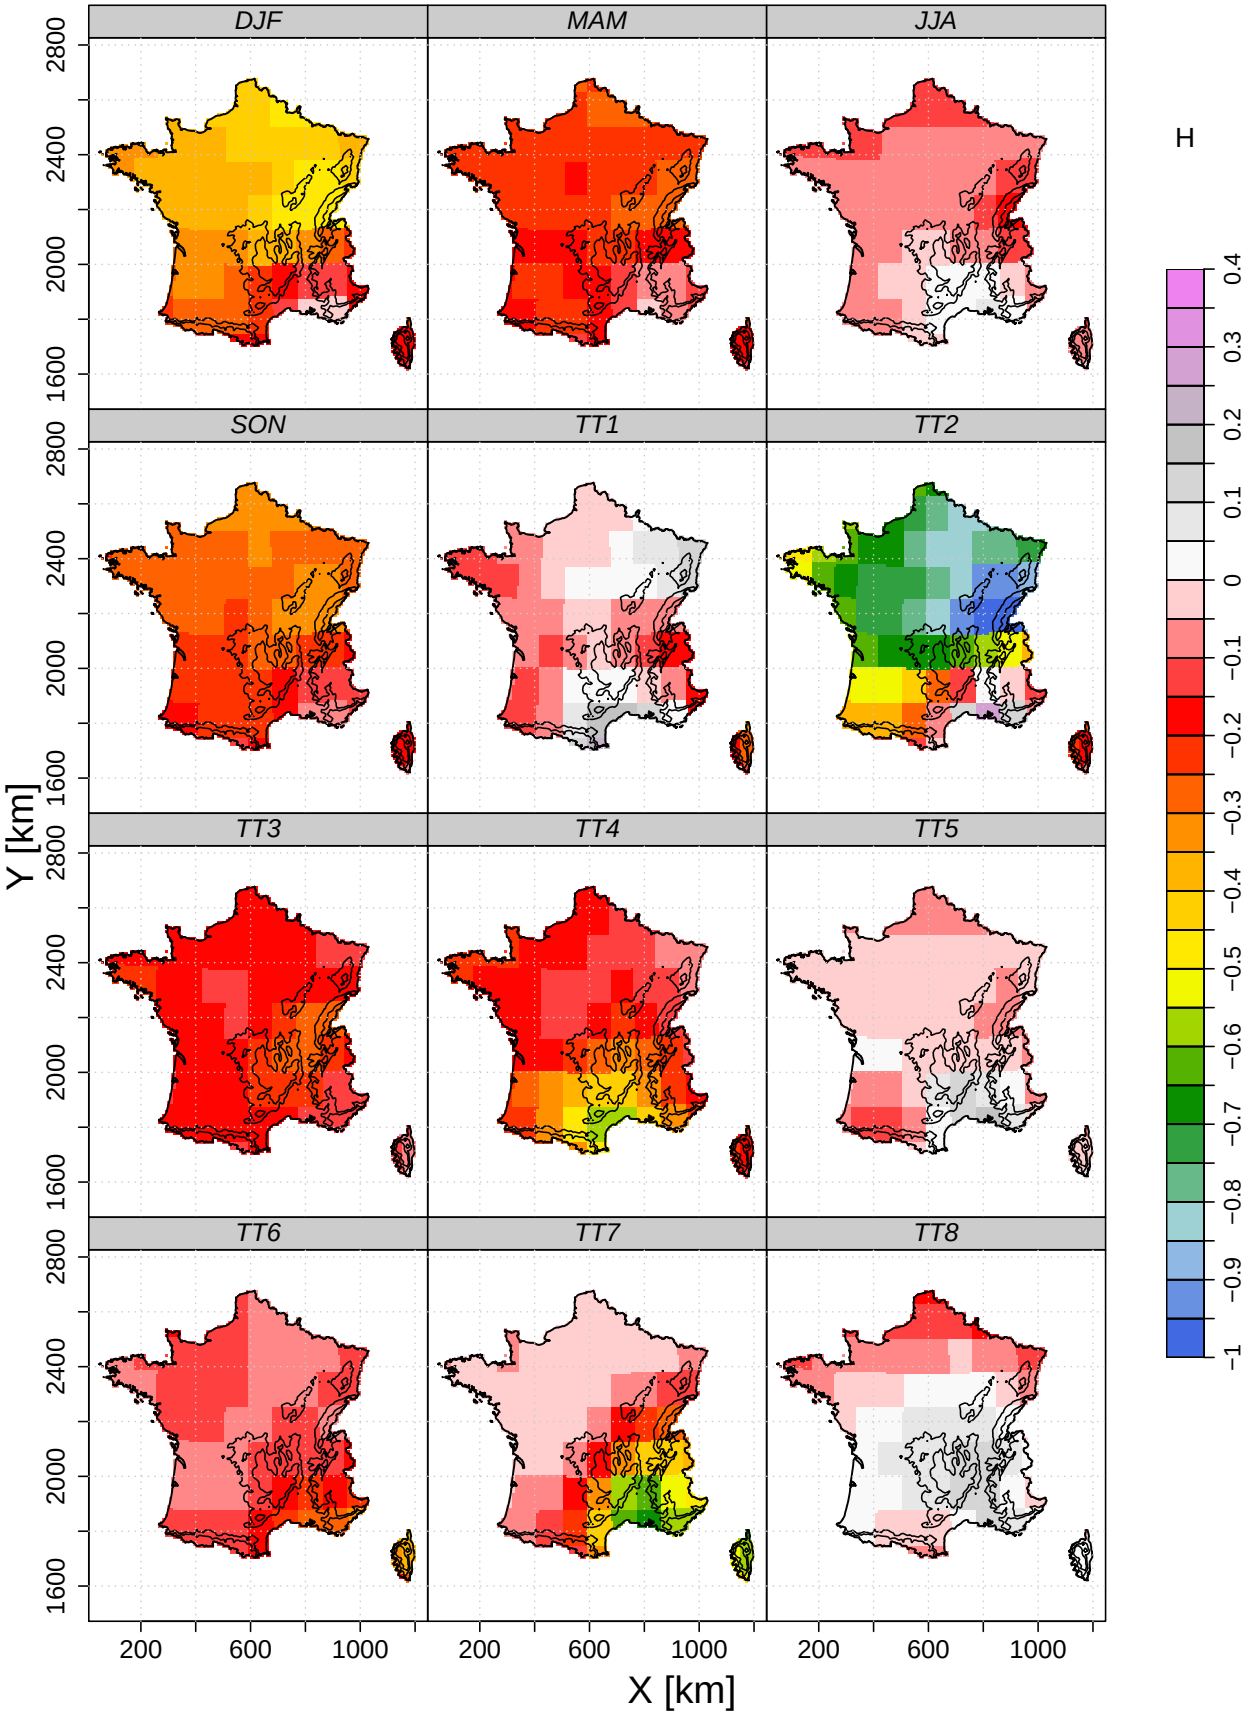

FIGURE D.11 – Valeur moyenne du prédicteur d'hélicité H en fonction des saisons et des types de temps.

3. Modèle de quantité

3.1. Erreur du modèle de quantité en fonction de la complexité de la structure régressive

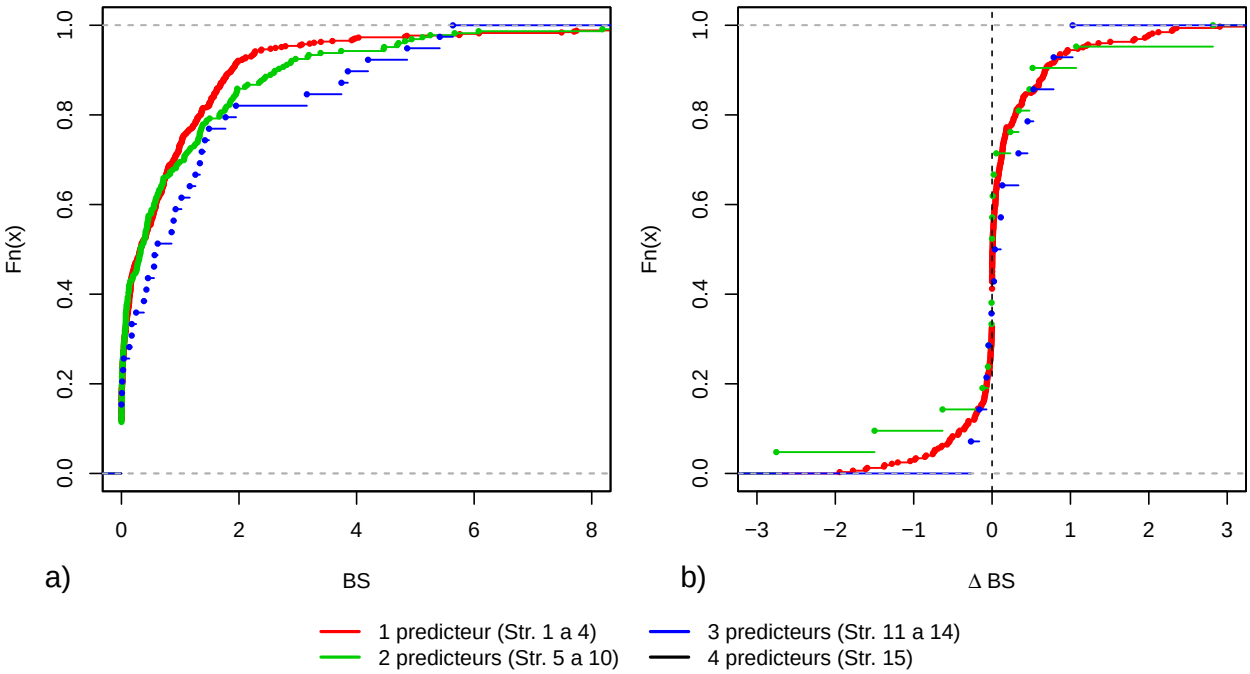

FIGURE D.12 – Distributions a) du CRPS et b) de la différence des erreurs en CRPS obtenus par MA_{100}+GLM par rapport au modèle MA_{25} en fonction des structures régressives listées dans le tableau IX.2. Application à la maille Safran NW.

3.2. Echantillonnage des structures régressives

Les figures D.13 à D.21 représentent les différences de fréquences d'échantillonnage des structures 1, 3, 5, 6, 7, 9, 12, 13 du modèle de quantité retenu par rapport à leurs fréquences d'échantillonnage respectives moyennes (figure IX.5).

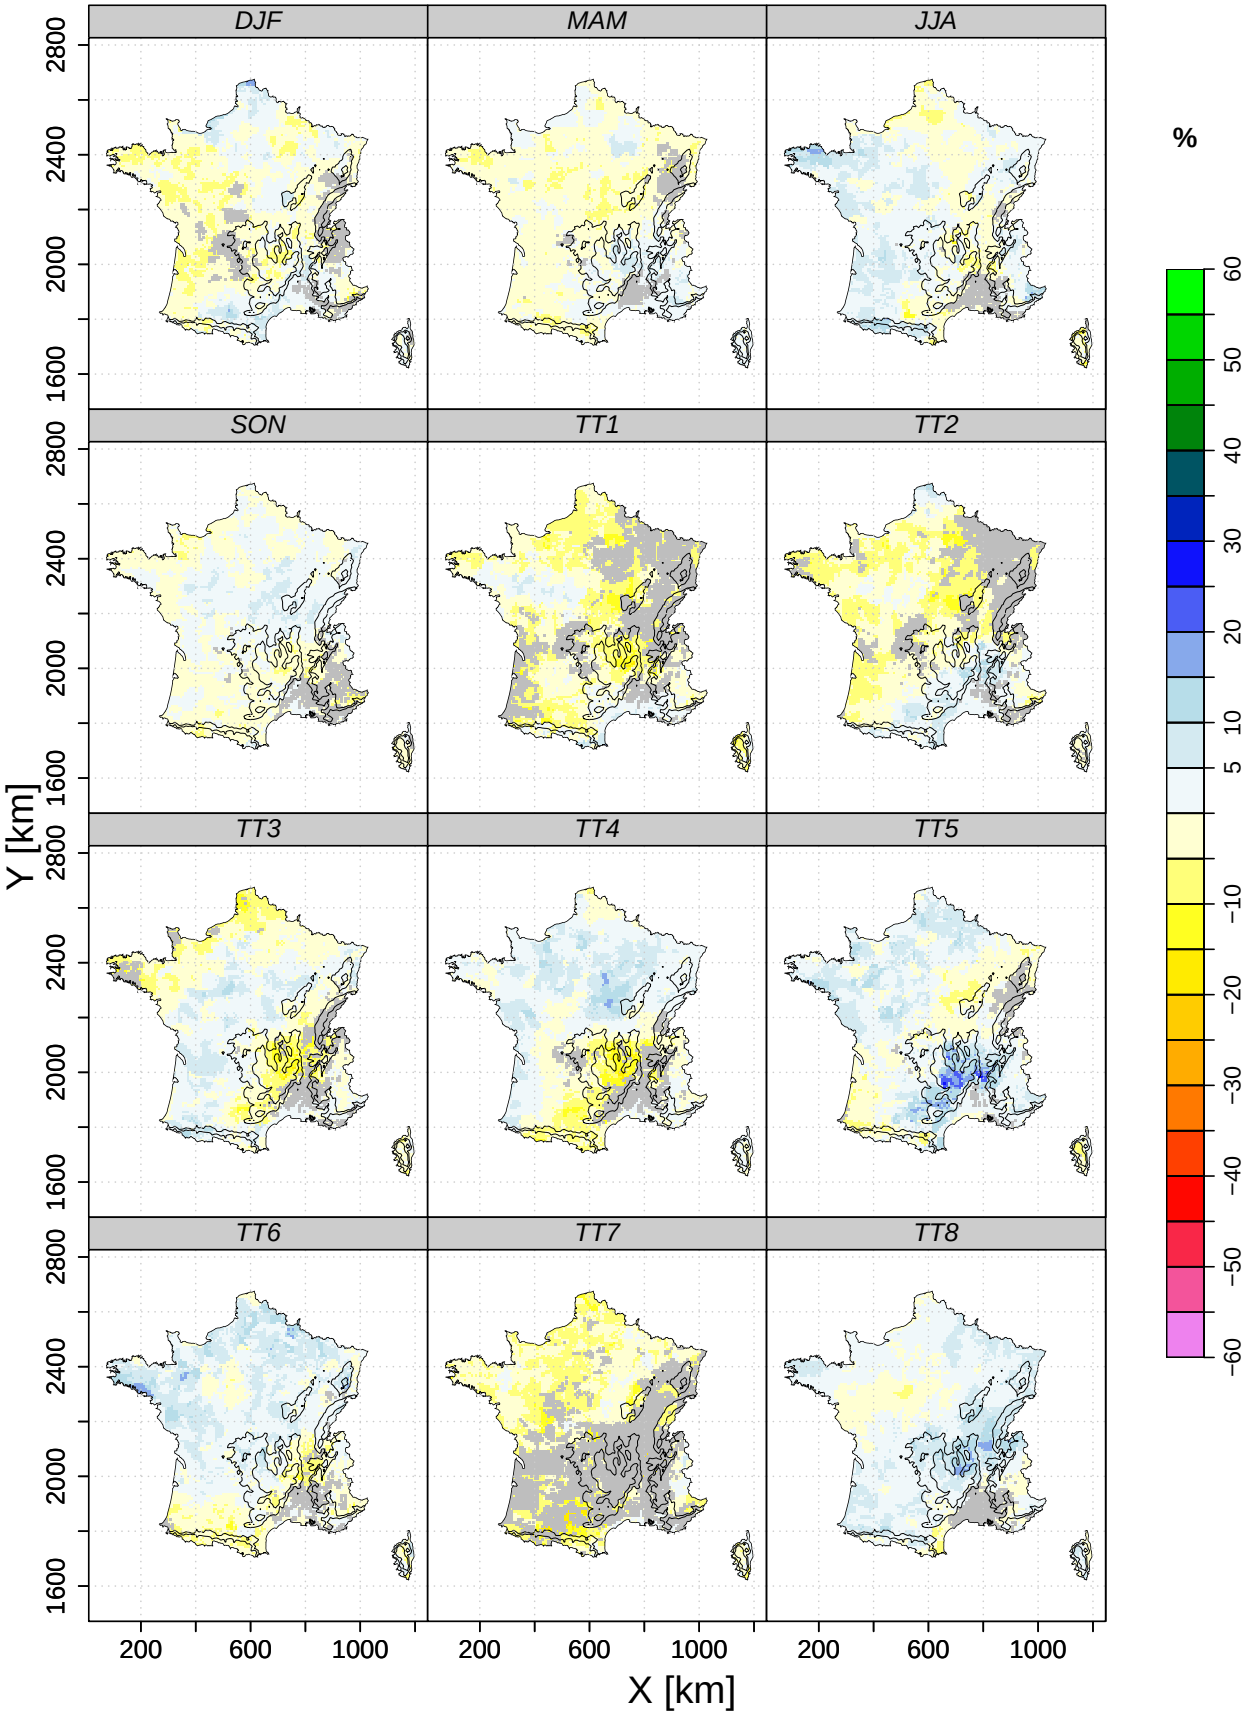

FIGURE D.13 – Différence de fréquence d'échantillonnage de la structure 1 (seulement basée sur R_2) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

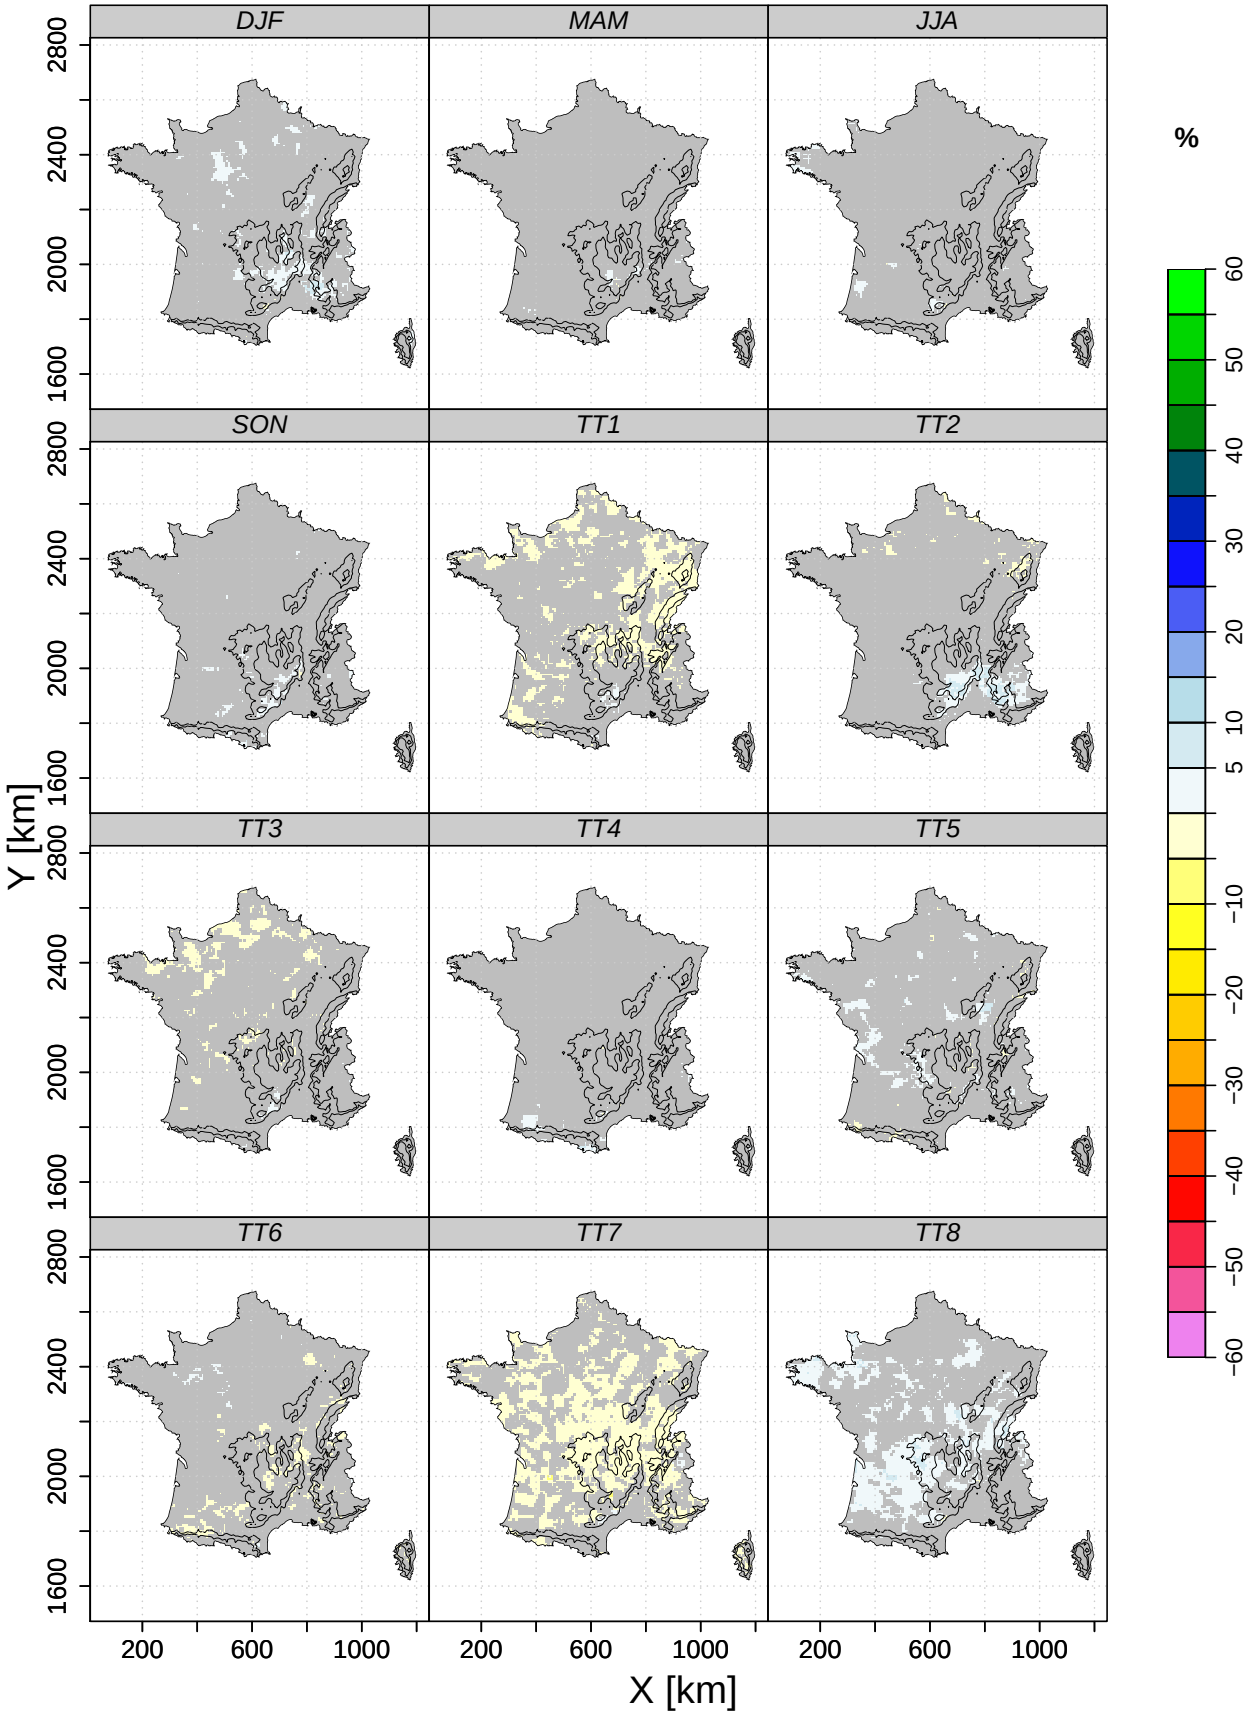

FIGURE D.14 – Différence de fréquence d'échantillonnage de la structure 3 (seulement basée sur H) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

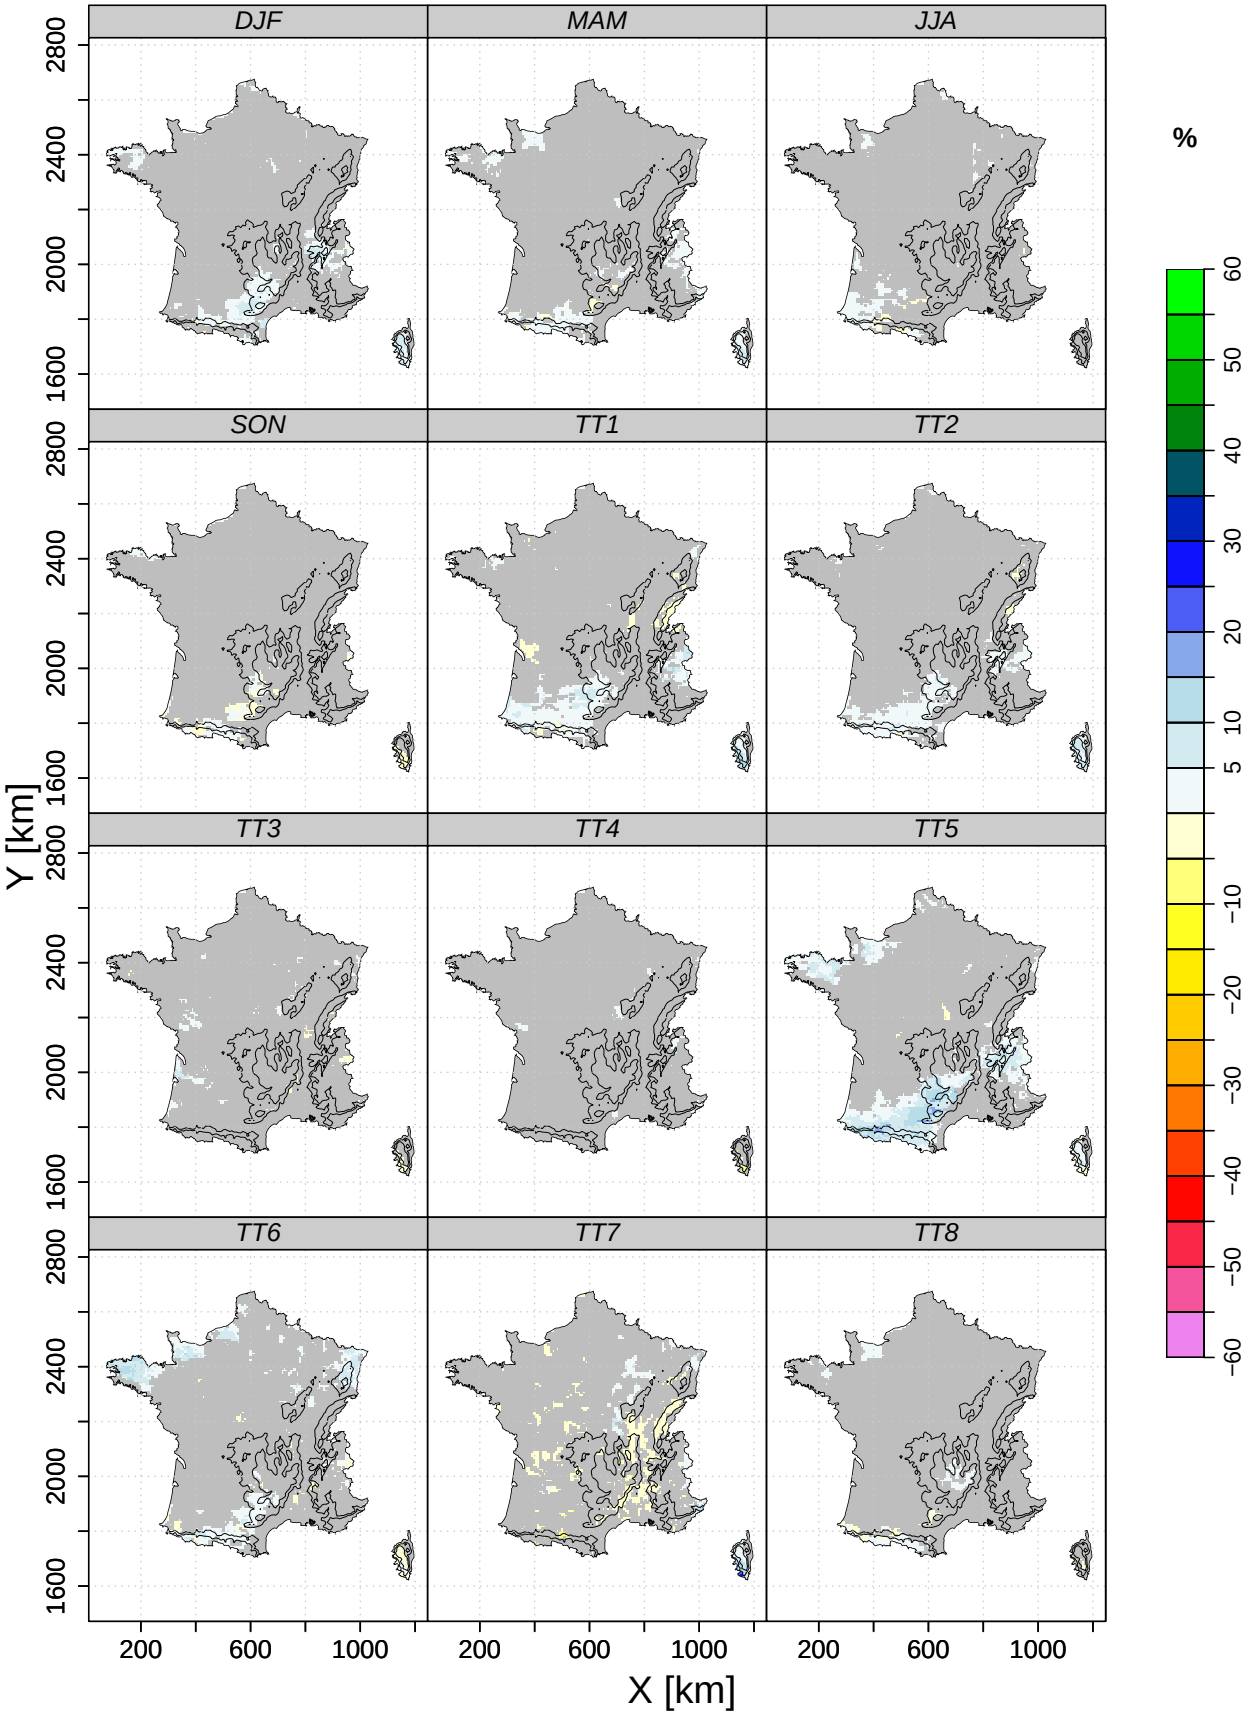

FIGURE D.15 – Différence de fréquence d'échantillonnage de la structure 5 (seulement basée sur $R_2 + T$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

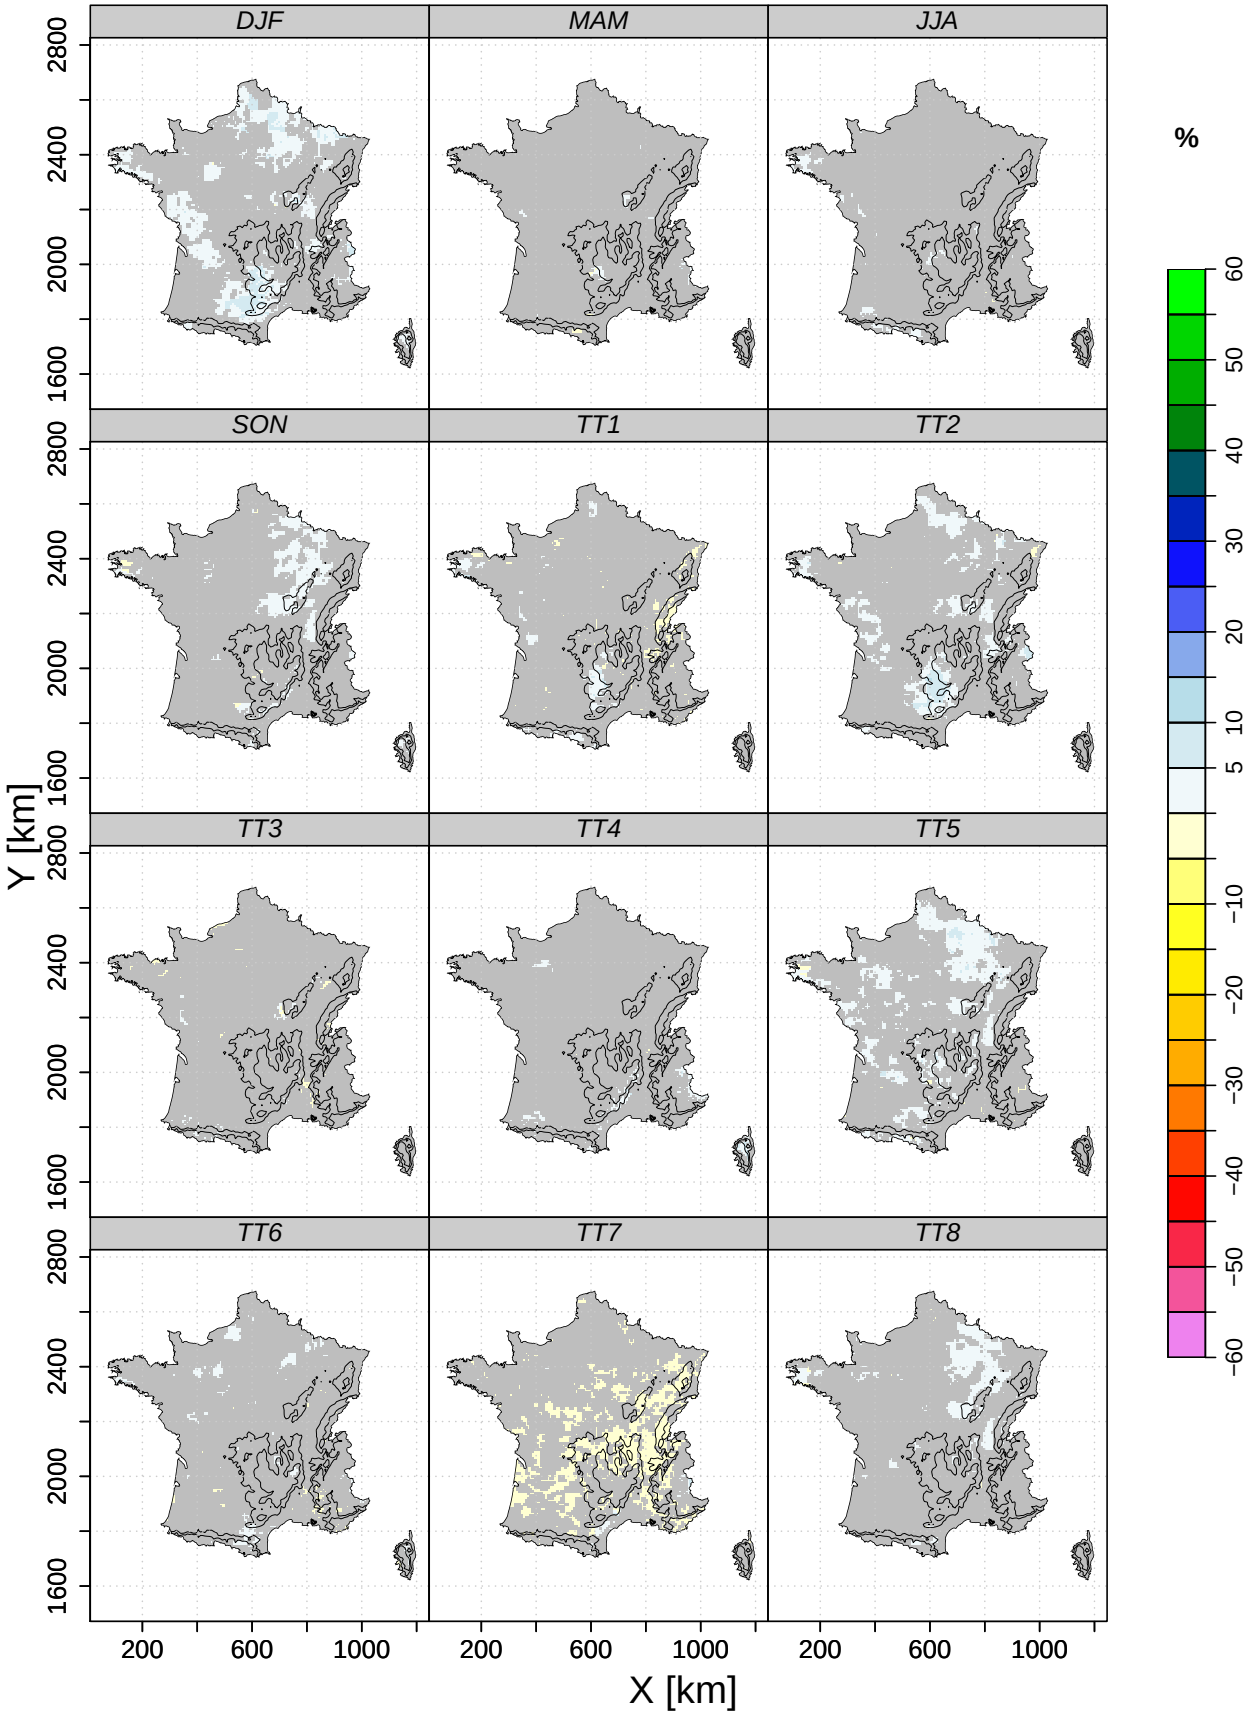

FIGURE D.16 – Différence de fréquence d'échantillonnage de la structure 6 (seulement basée sur $R_2 + H$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

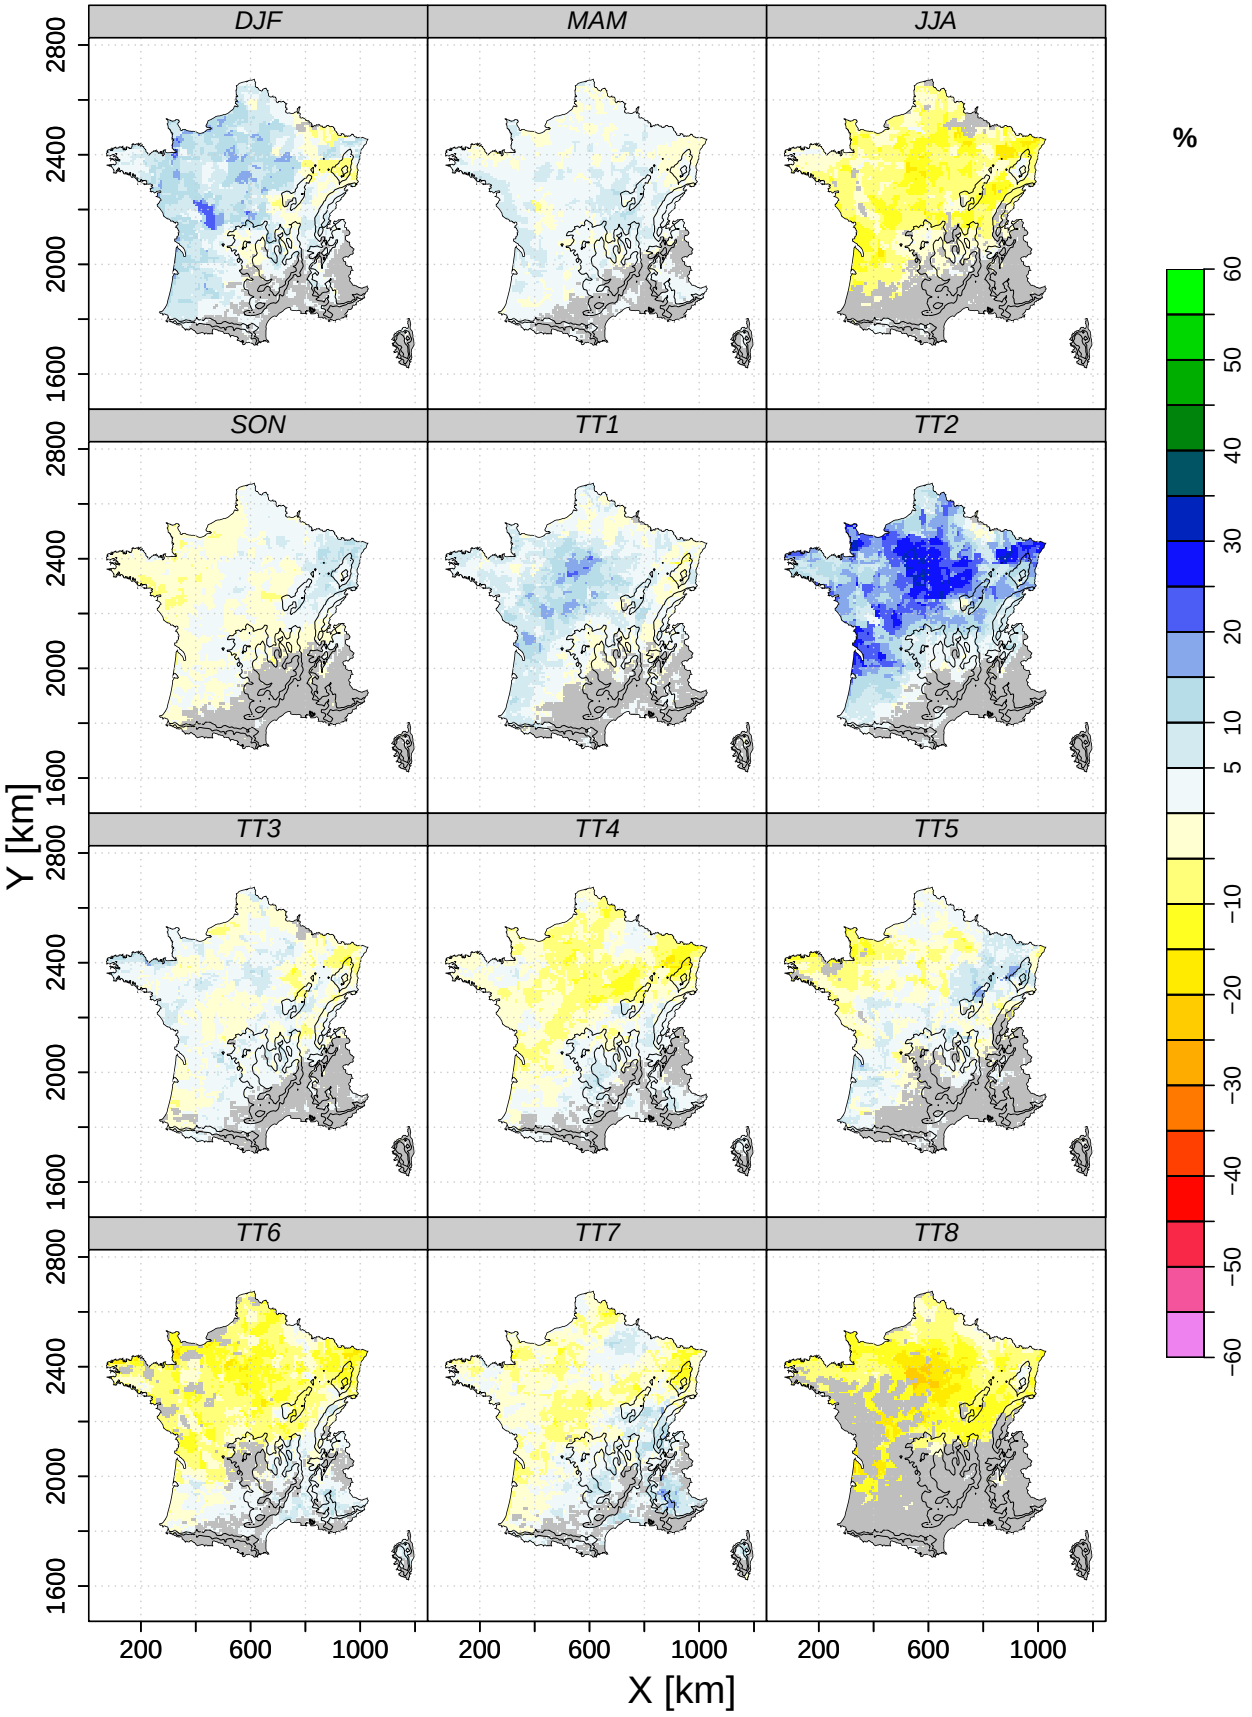

FIGURE D.17 – Différence de fréquence d'échantillonnage de la structure 7 (seulement basée sur $R_2 + W$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

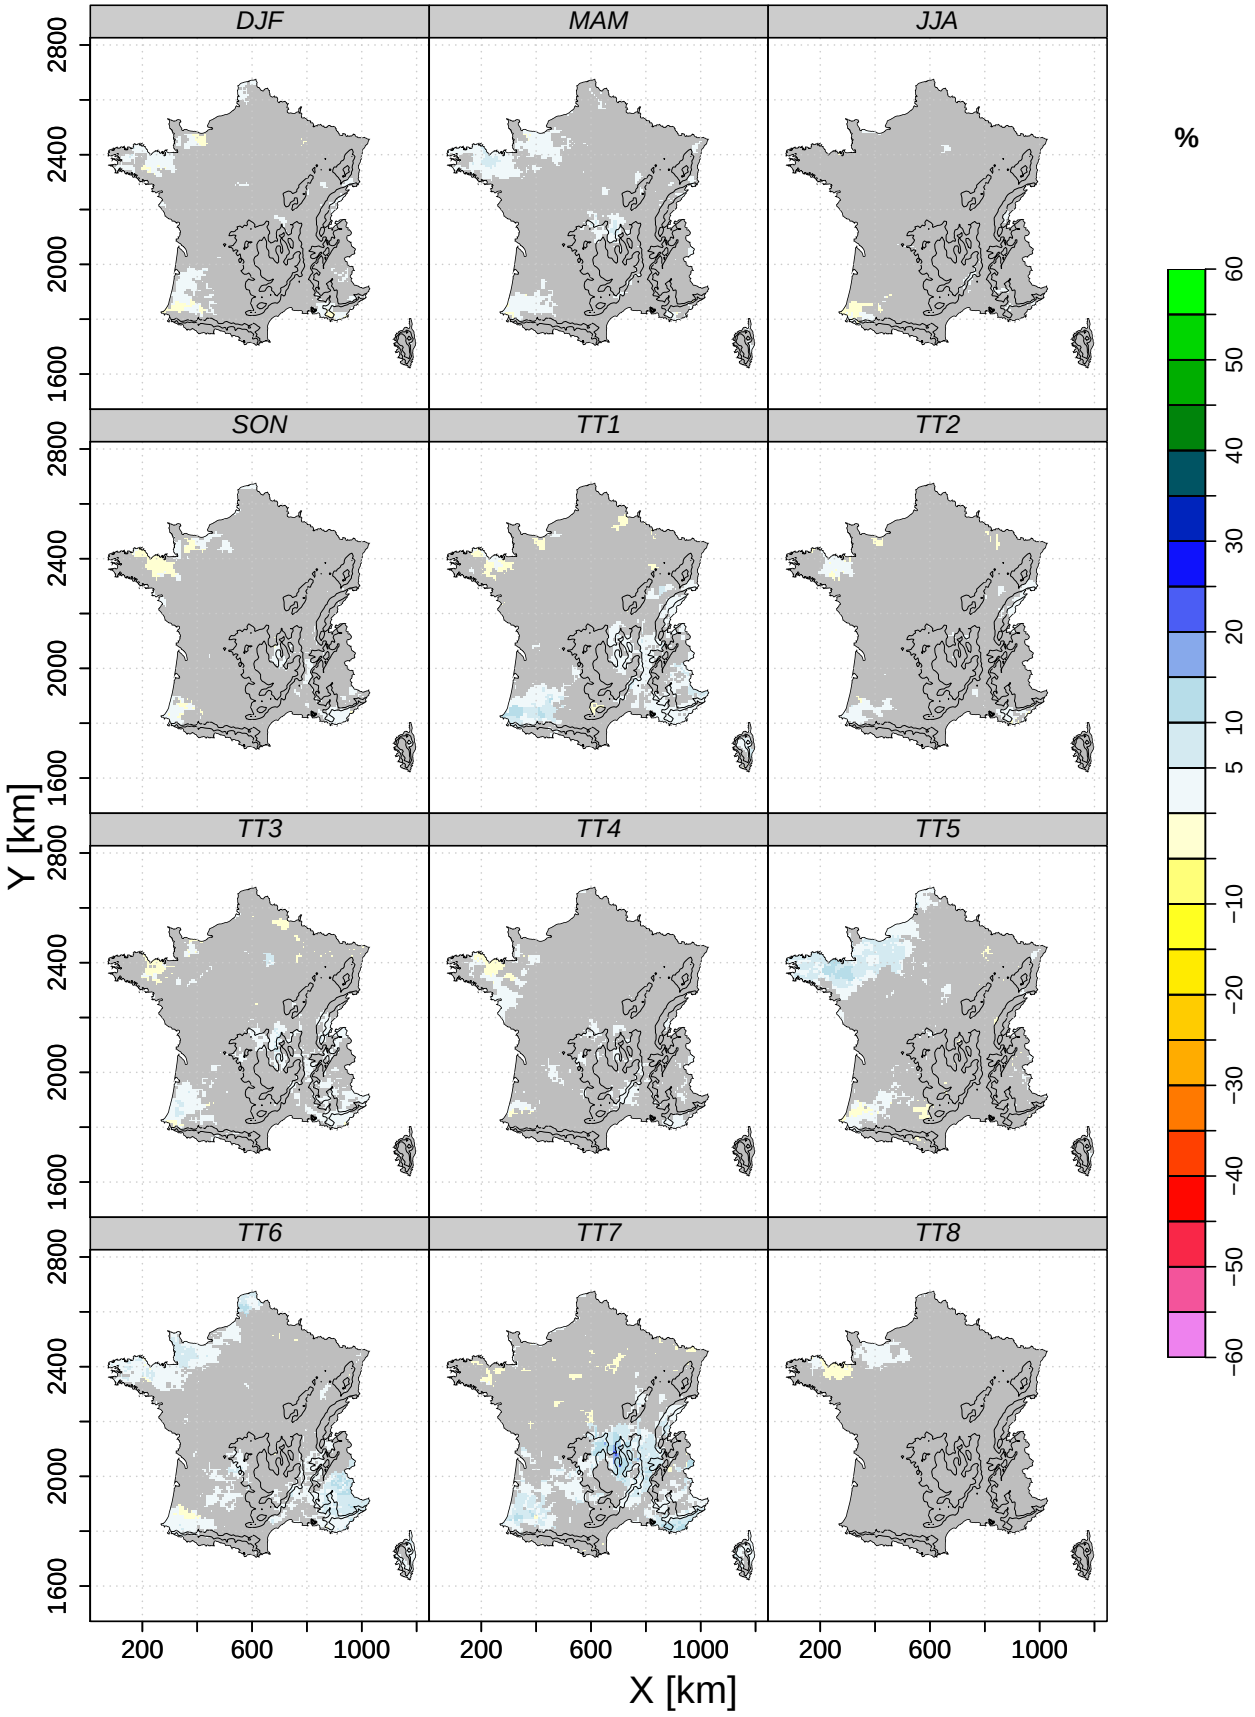

FIGURE D.18 – Différence de fréquence d'échantillonnage de la structure 9 (seulement basée sur $T + W$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

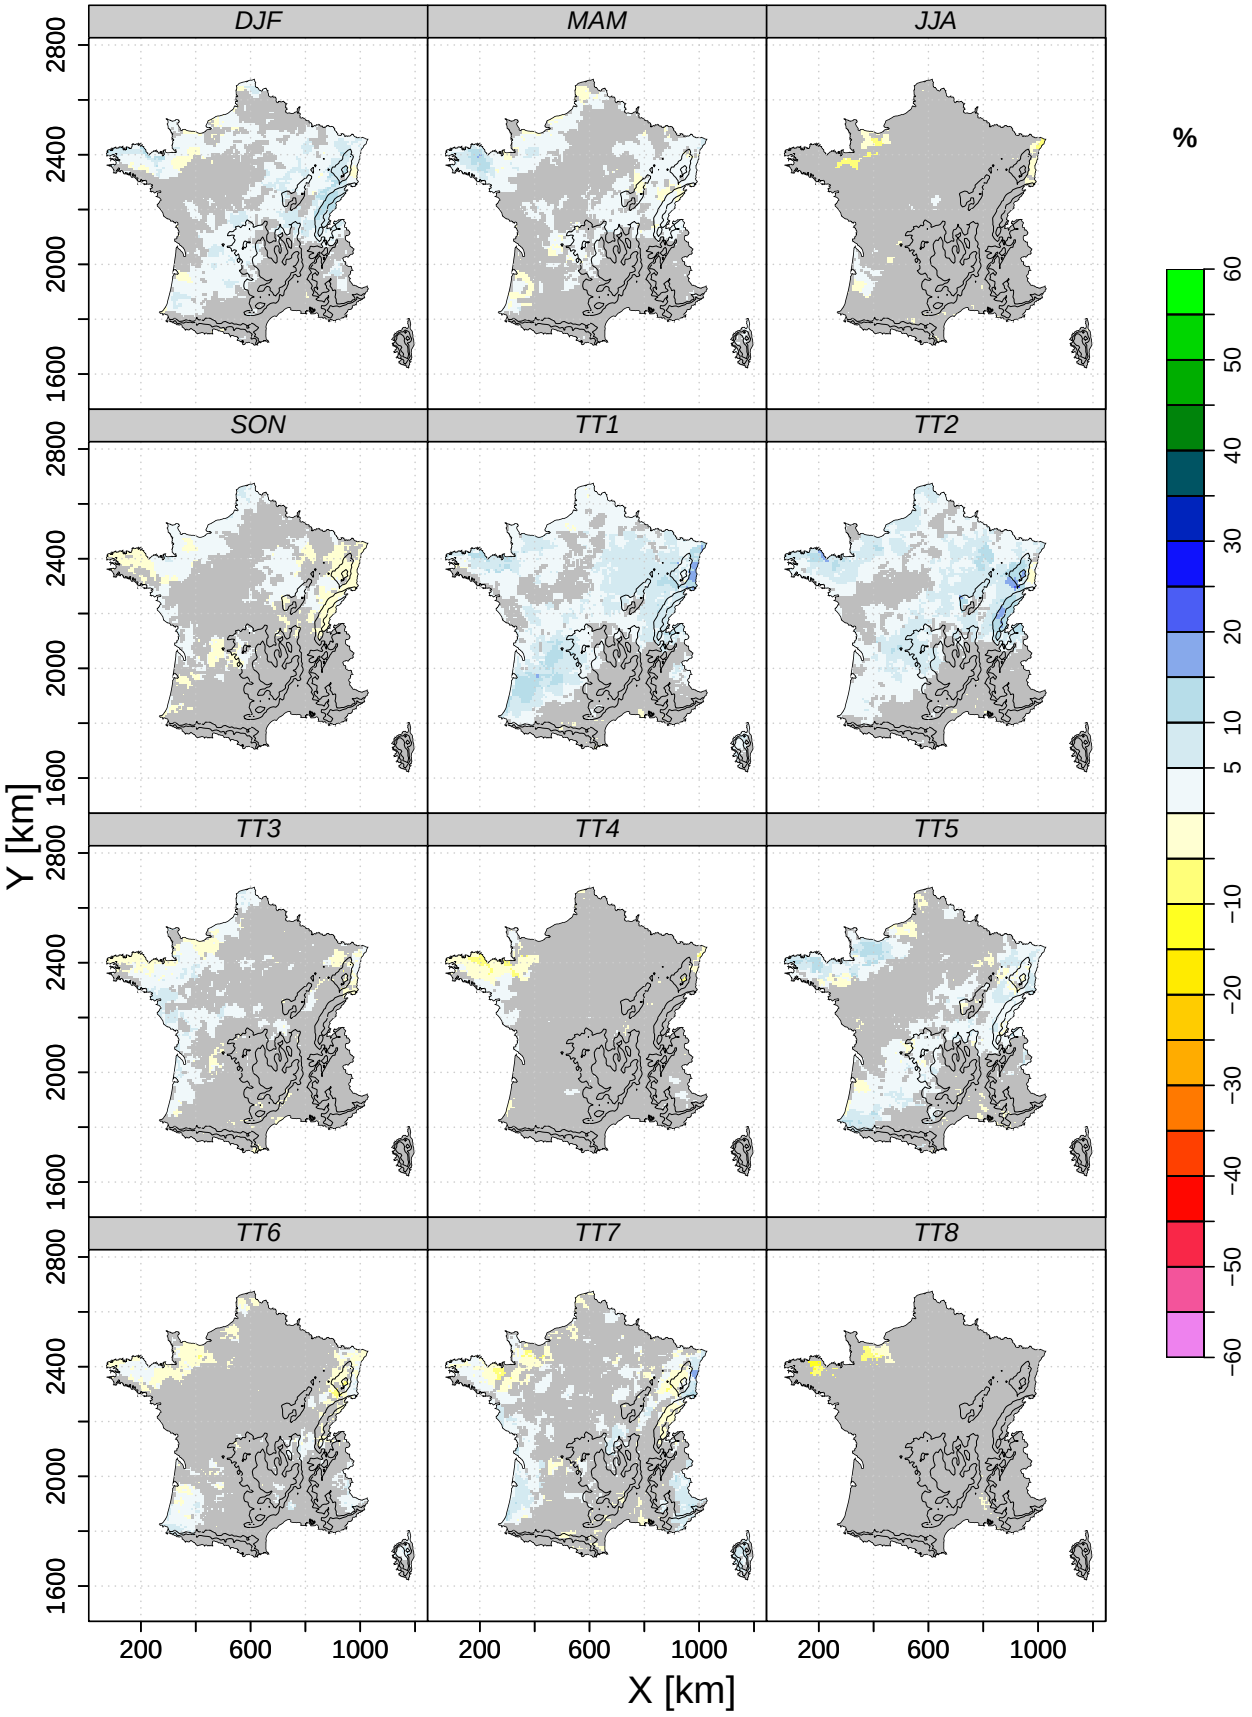

FIGURE D.19 – Différence de fréquence d'échantillonnage de la structure 12 (seulement basée sur R_2+T+W) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

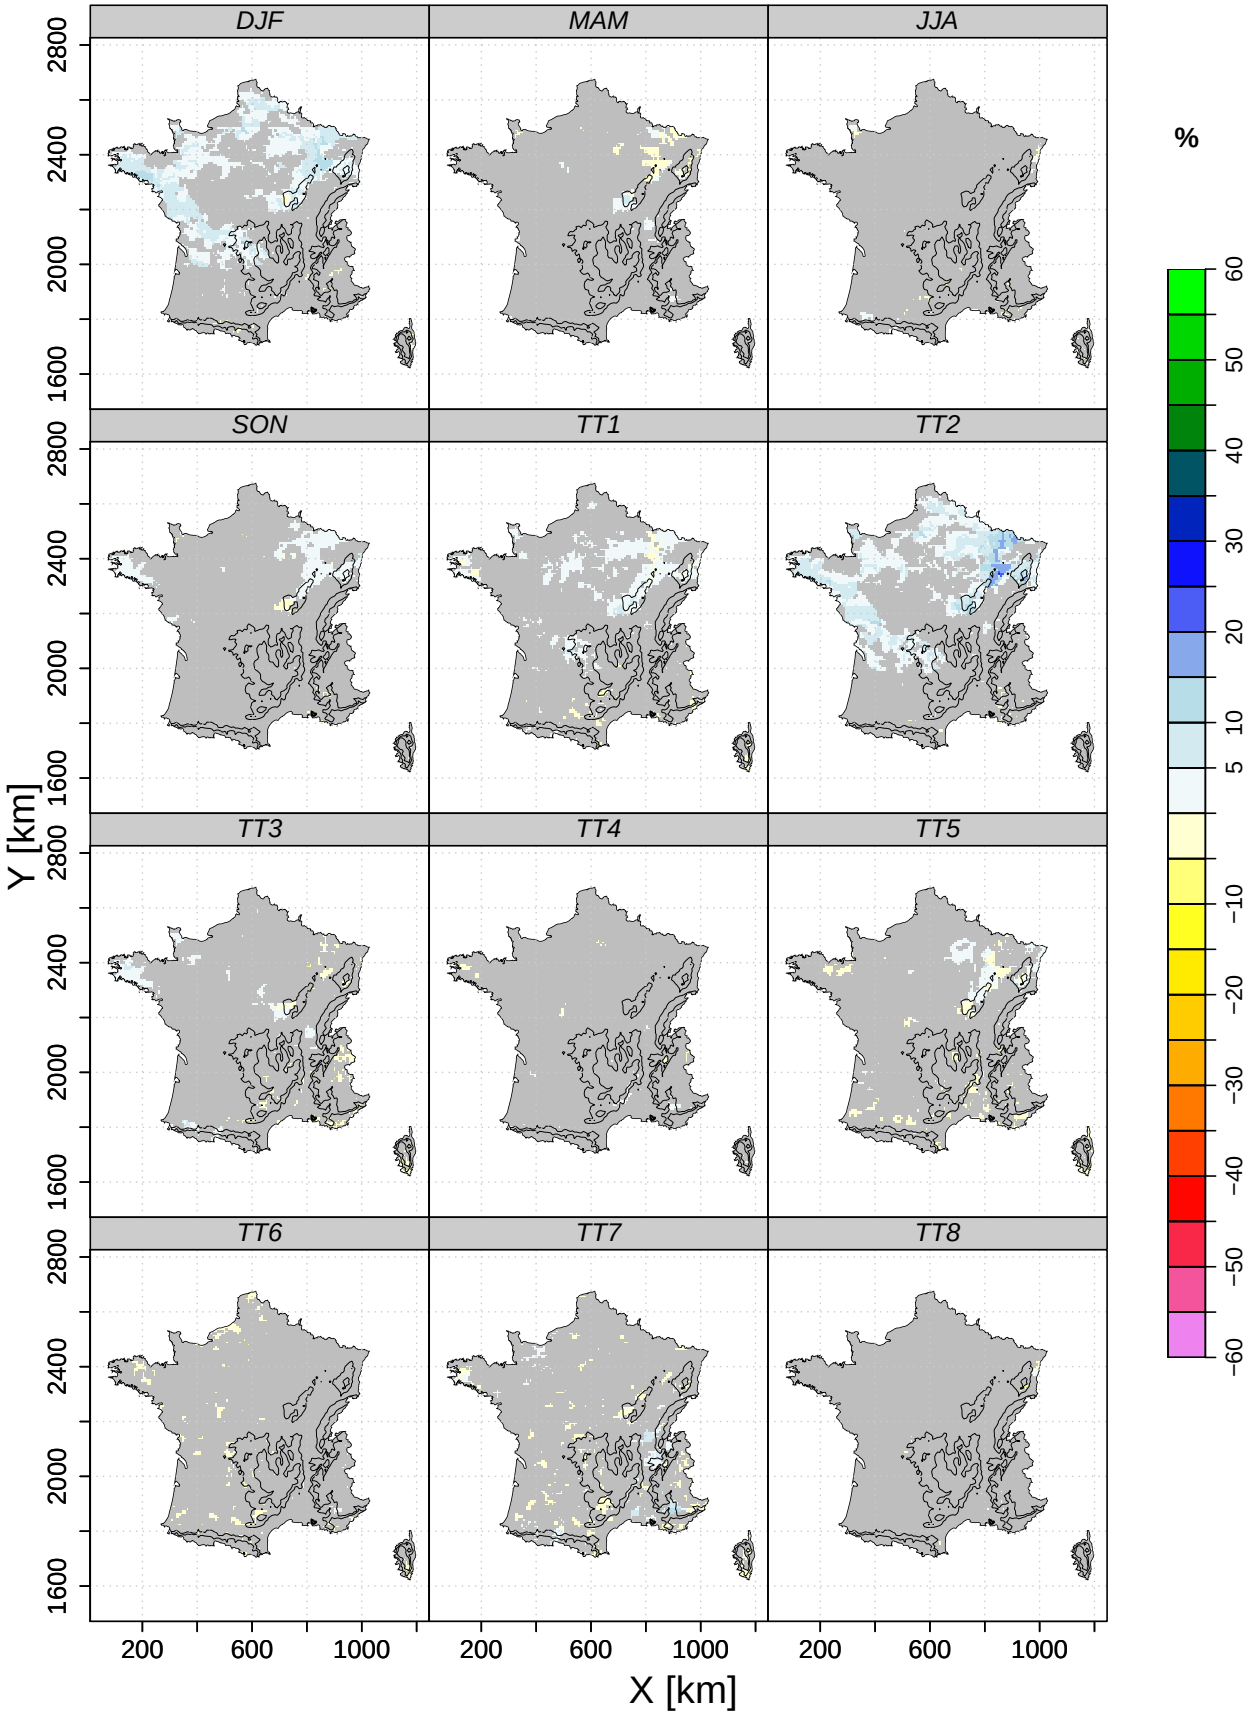

FIGURE D.20 – Différence de fréquence d'échantillonnage de la structure 13 (seulement basée sur $T + H + W$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

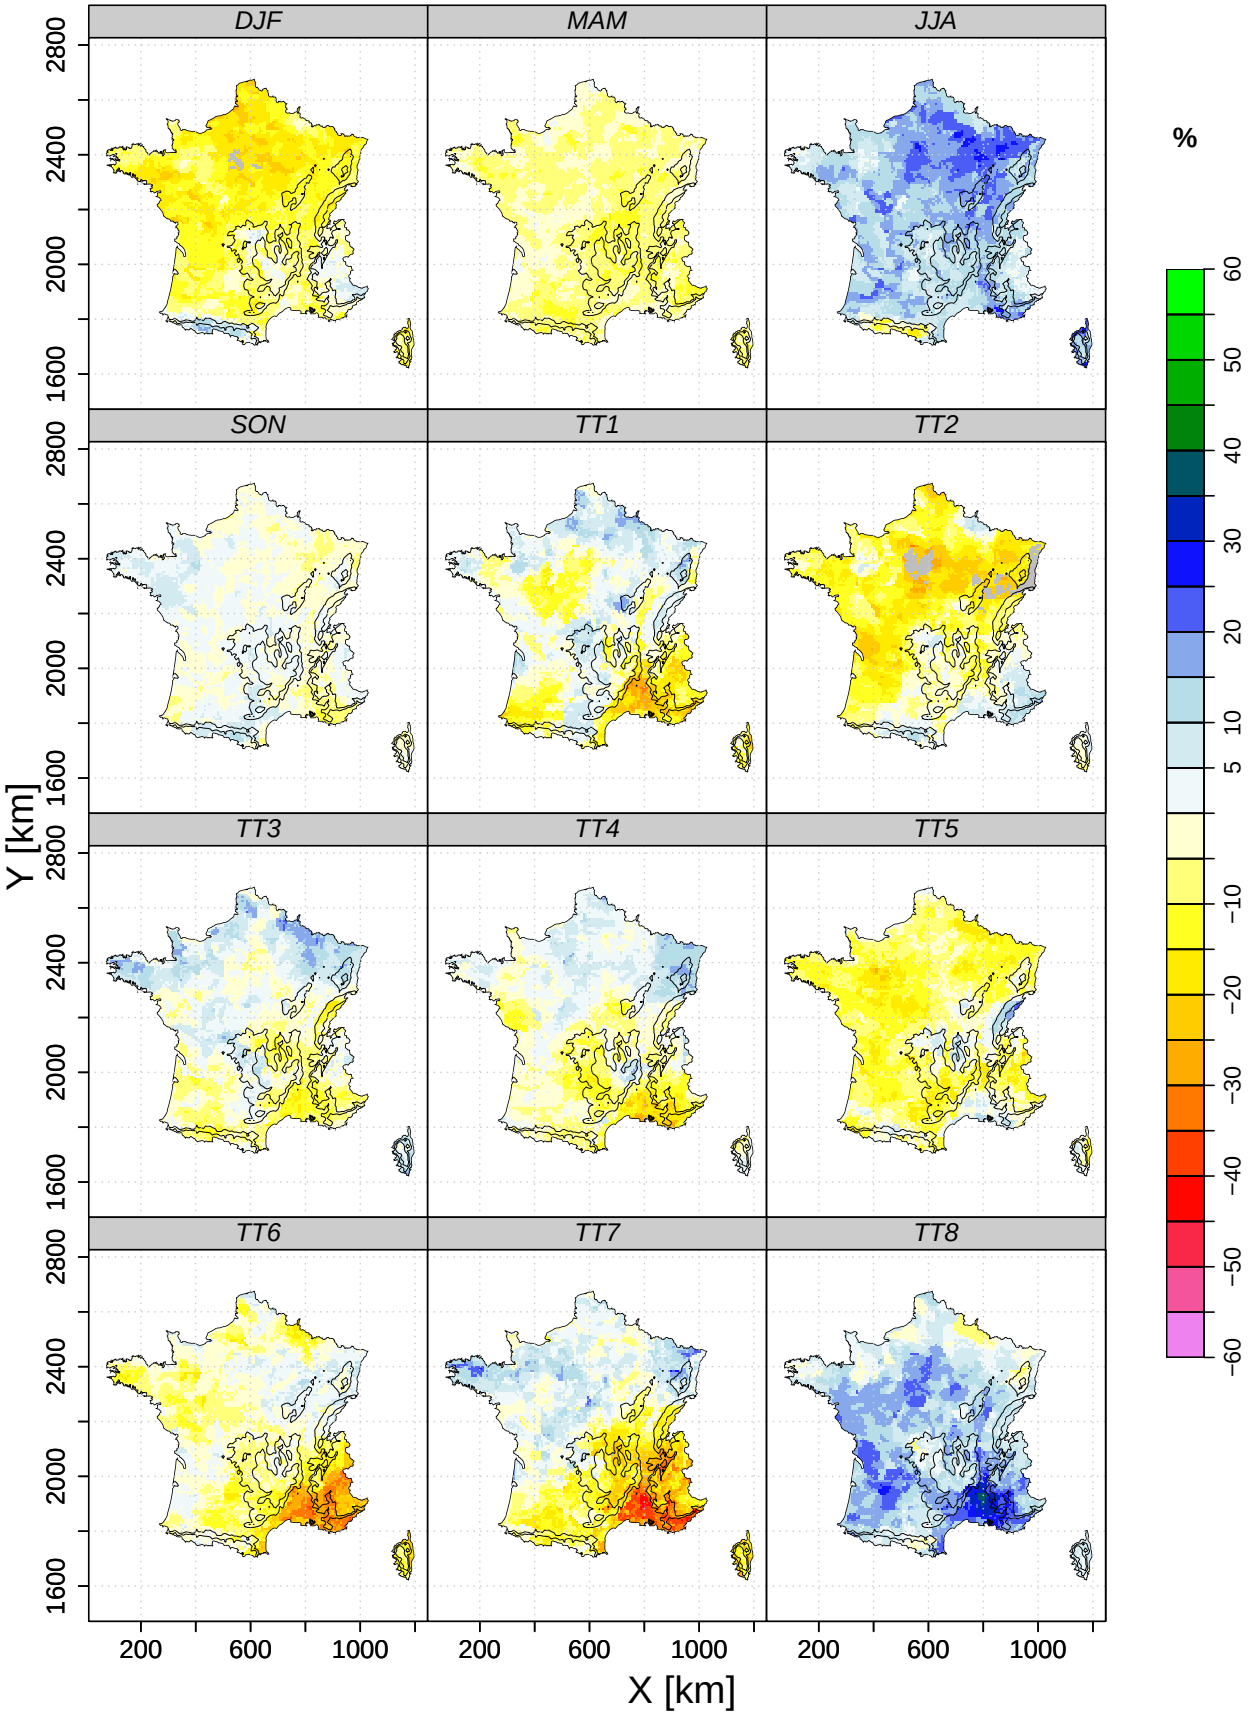

FIGURE D.21 – Différence de fréquence d'échantillonnage du modèle alternatif MA_{25}par rapport à sa fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps. Les mailles représentées en bleu indique que le modèle MA_{25}est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que ce dernier est sous-échantillonnée par rapport à la moyenne.

4. Mise en place d'un nouvel algorithme de sélection des structures régressives

A la section 1 du chapitre X, nous avons montré que, dans certains cas relativement peu fréquents, l'algorithme de sélection des structures régressives pouvait mener à l'utilisation du modèle MA_{25} alternatif lorsqu'une large majorité des dates analogues retenues pour une prédiction donnée conduit à des précipitations analogues positives. De façon à palier ce problème, l'algorithme de sélection des structures régressives a été modifié en conséquence. Pour la prédiction de la probabilité d'occurrence et de la quantité de précipitation, il est désormais le suivant :

i. Un modèle GLM est déterminé pour chacune des 15 structures régressives listées dans les tableaux IX.2 et VIII.3.

ii. Le modèle GLM qui obtient le critère BIC le plus faible et qui satisfait les conditions de significativité définies à la section 3.2 du chapitre VI est alors retenu. Si aucun modèle GLM ne statisfait les conditions de significativité, le modèle MA_{25} est alors sélectionné comme lien d'échelle alternatif.

iii. Le lien d'échelle retenu est enfin utilisé pour l'émission de la prédiction.

De nouveaux calculs utilisant ce nouvel algorithme de sélection des structures régressives ont été effectués entre le dépôt du manuscrit de thèse auprès du jury et la date de soutenance. Certains résultats présentés aux chapitre IX et X ont été mis à jour et sont disponibles dans cette annexe.

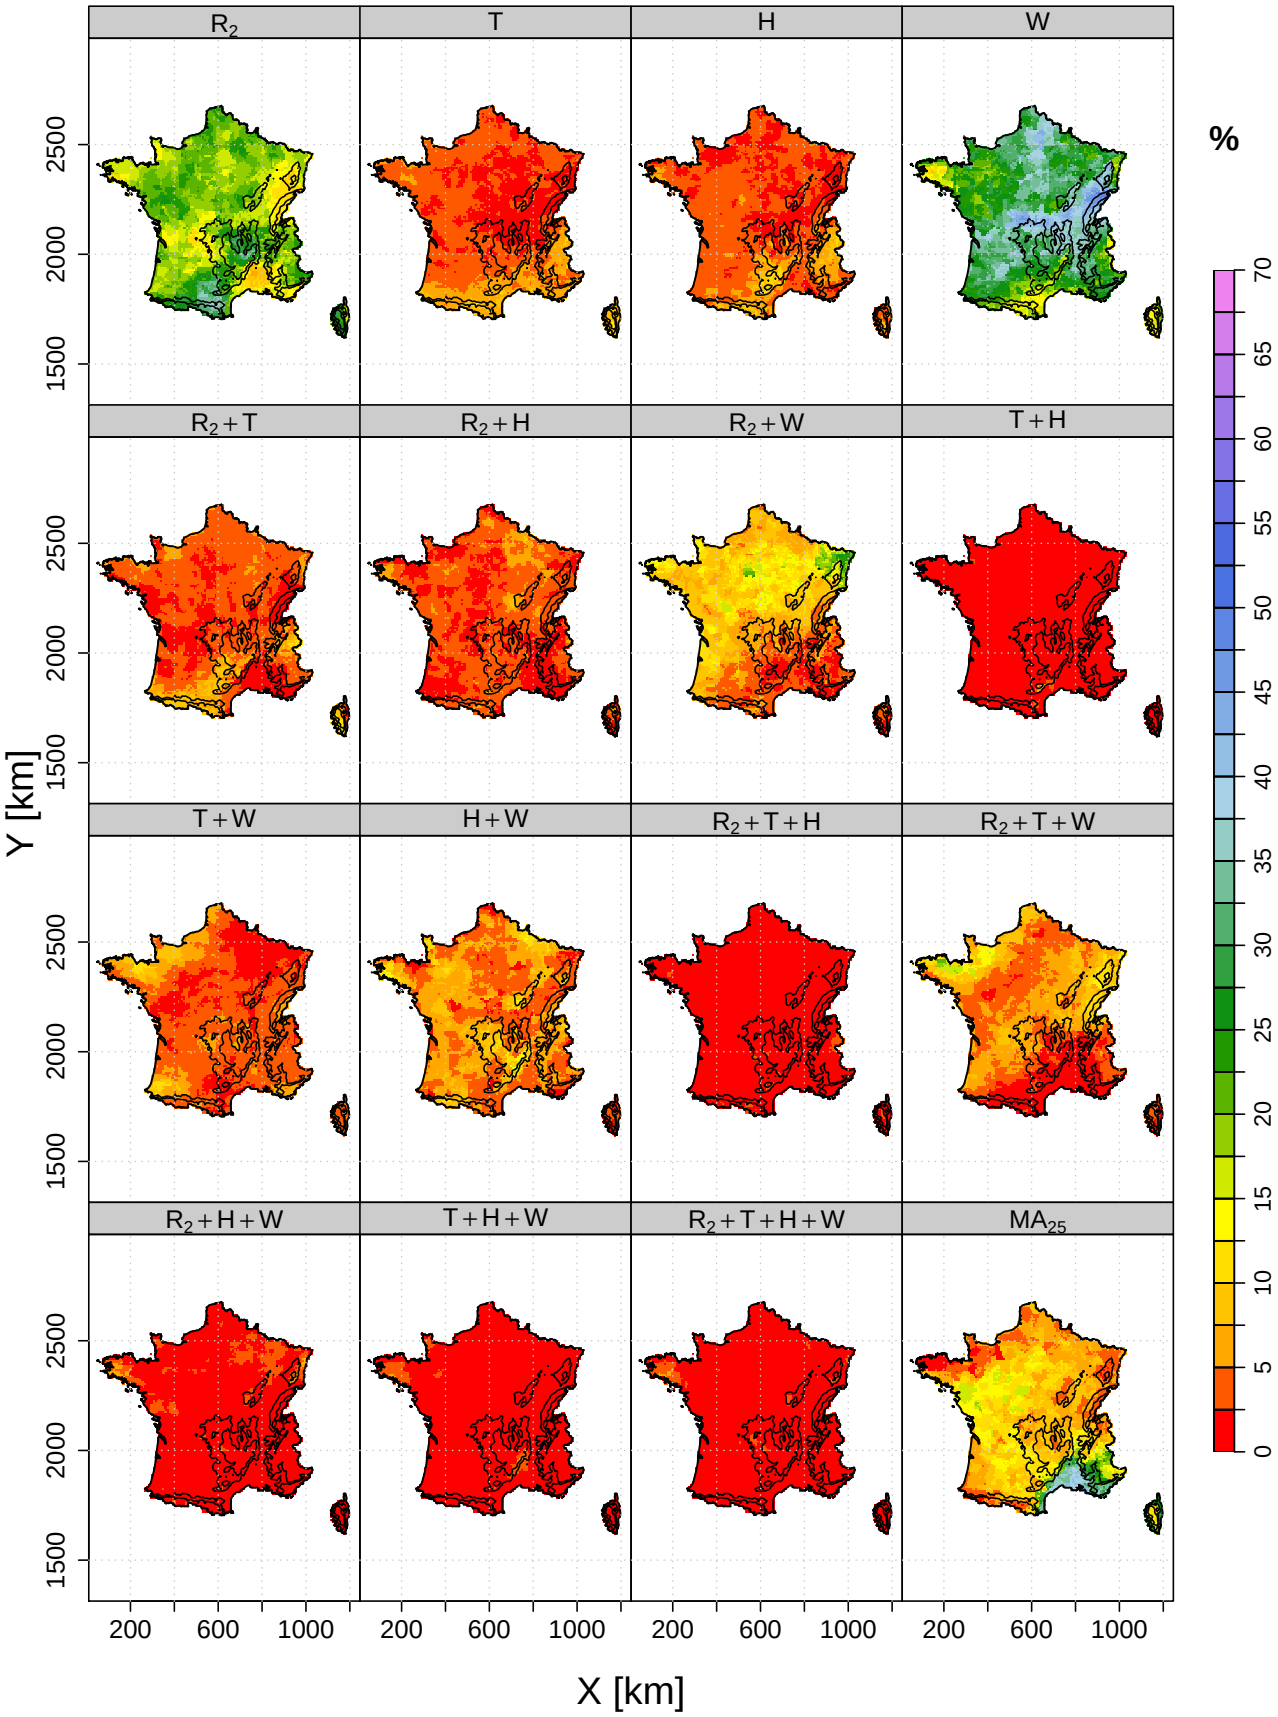

FIGURE D.22 – **Mise à jour de la figure IX.5** : Fréquences d'échantillonnage des structures régressives et du modèle MA_{25} du modèle de quantité unique pour la France (fréquences moyennes sur l'ensemble de la période 1982–2001) **en utilisant la nouvelle stratégie de sélection des structures régressives**. Les mailles blanches indiquent que la structure régressive concernée n'a jamais été utilisée.

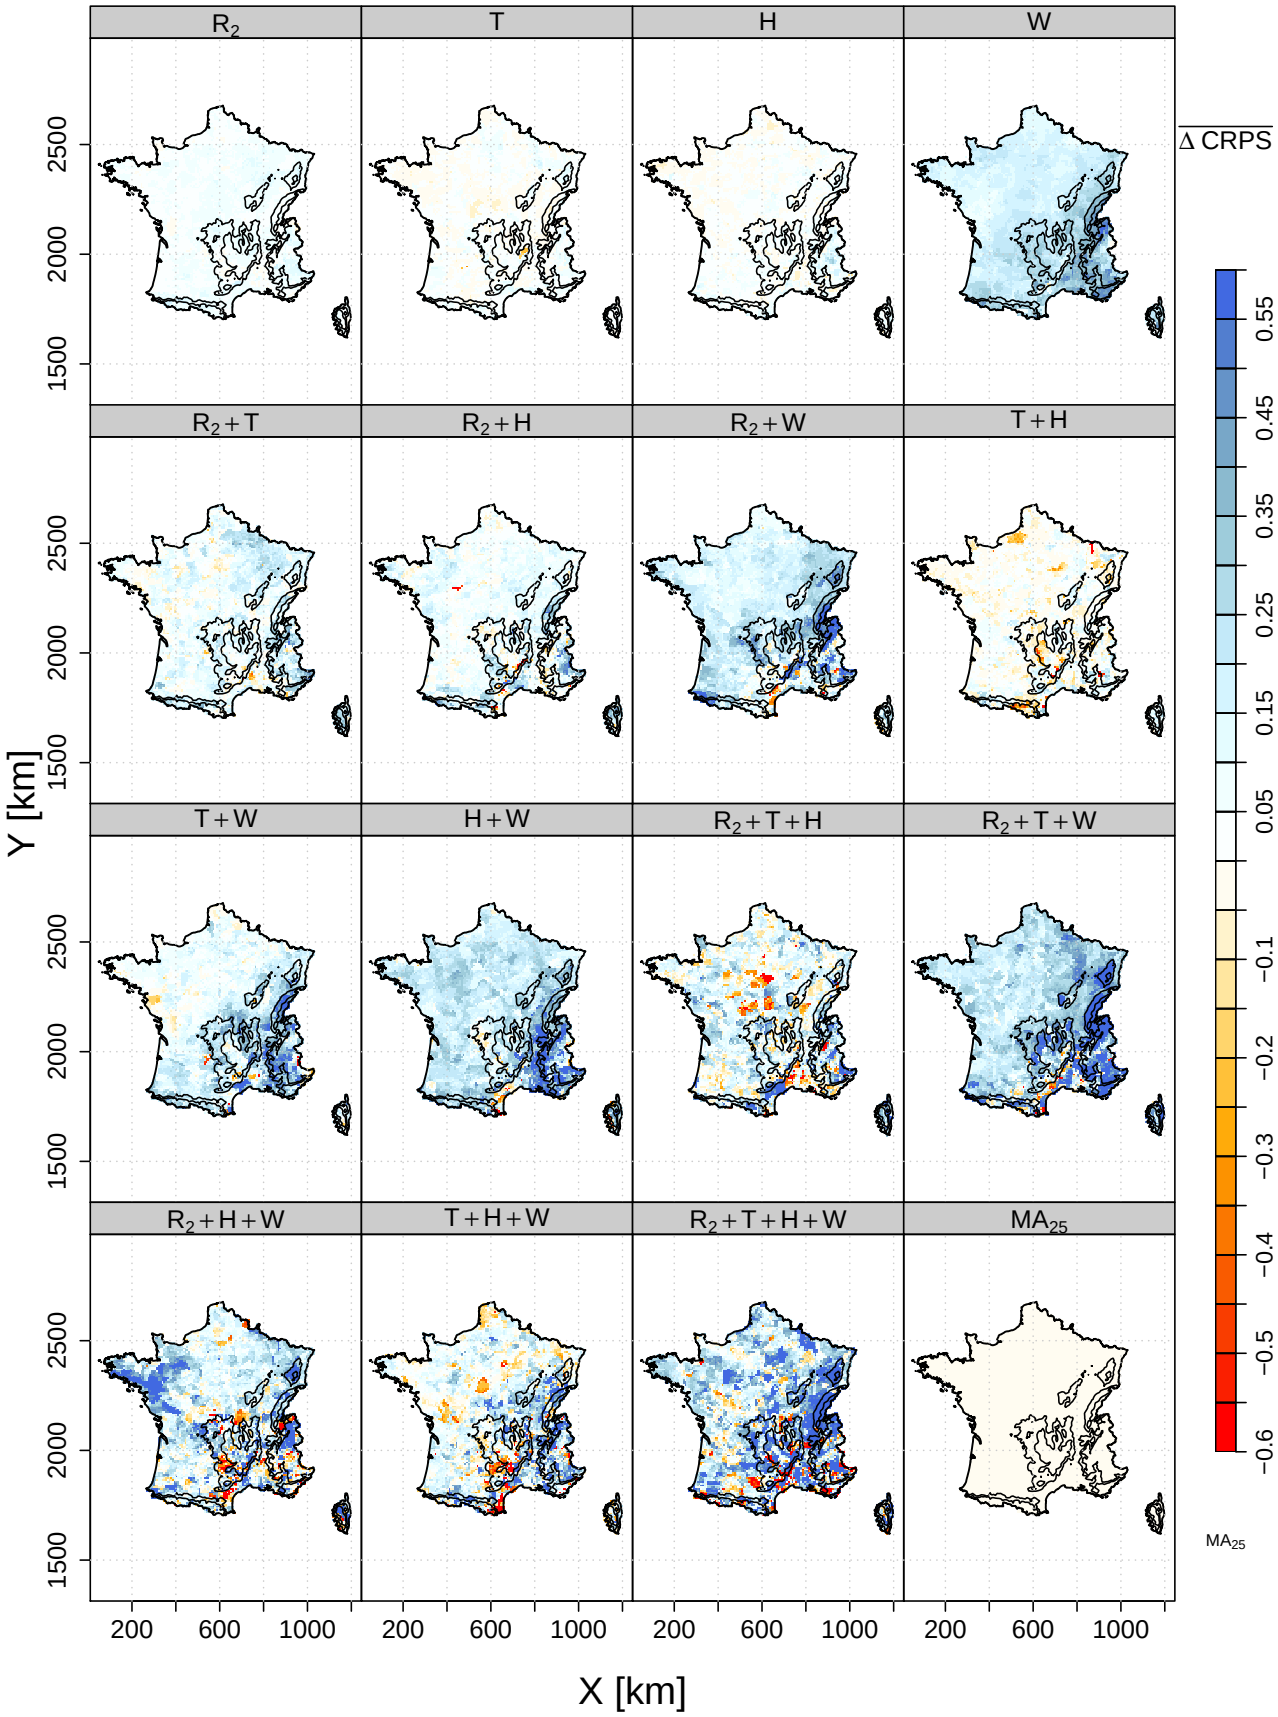

FIGURE D.23 – **Mise à jour de la figure IX.6** : Différence moyenne des erreurs en CRPS obtenues entre les modèles MA_{100}+GLM et MA_{25} par les structures régressives et du modèle MA_{25} du modèle de quantité unique pour la France **en utilisant la nouvelle stratégie de sélection des structures régressives**.

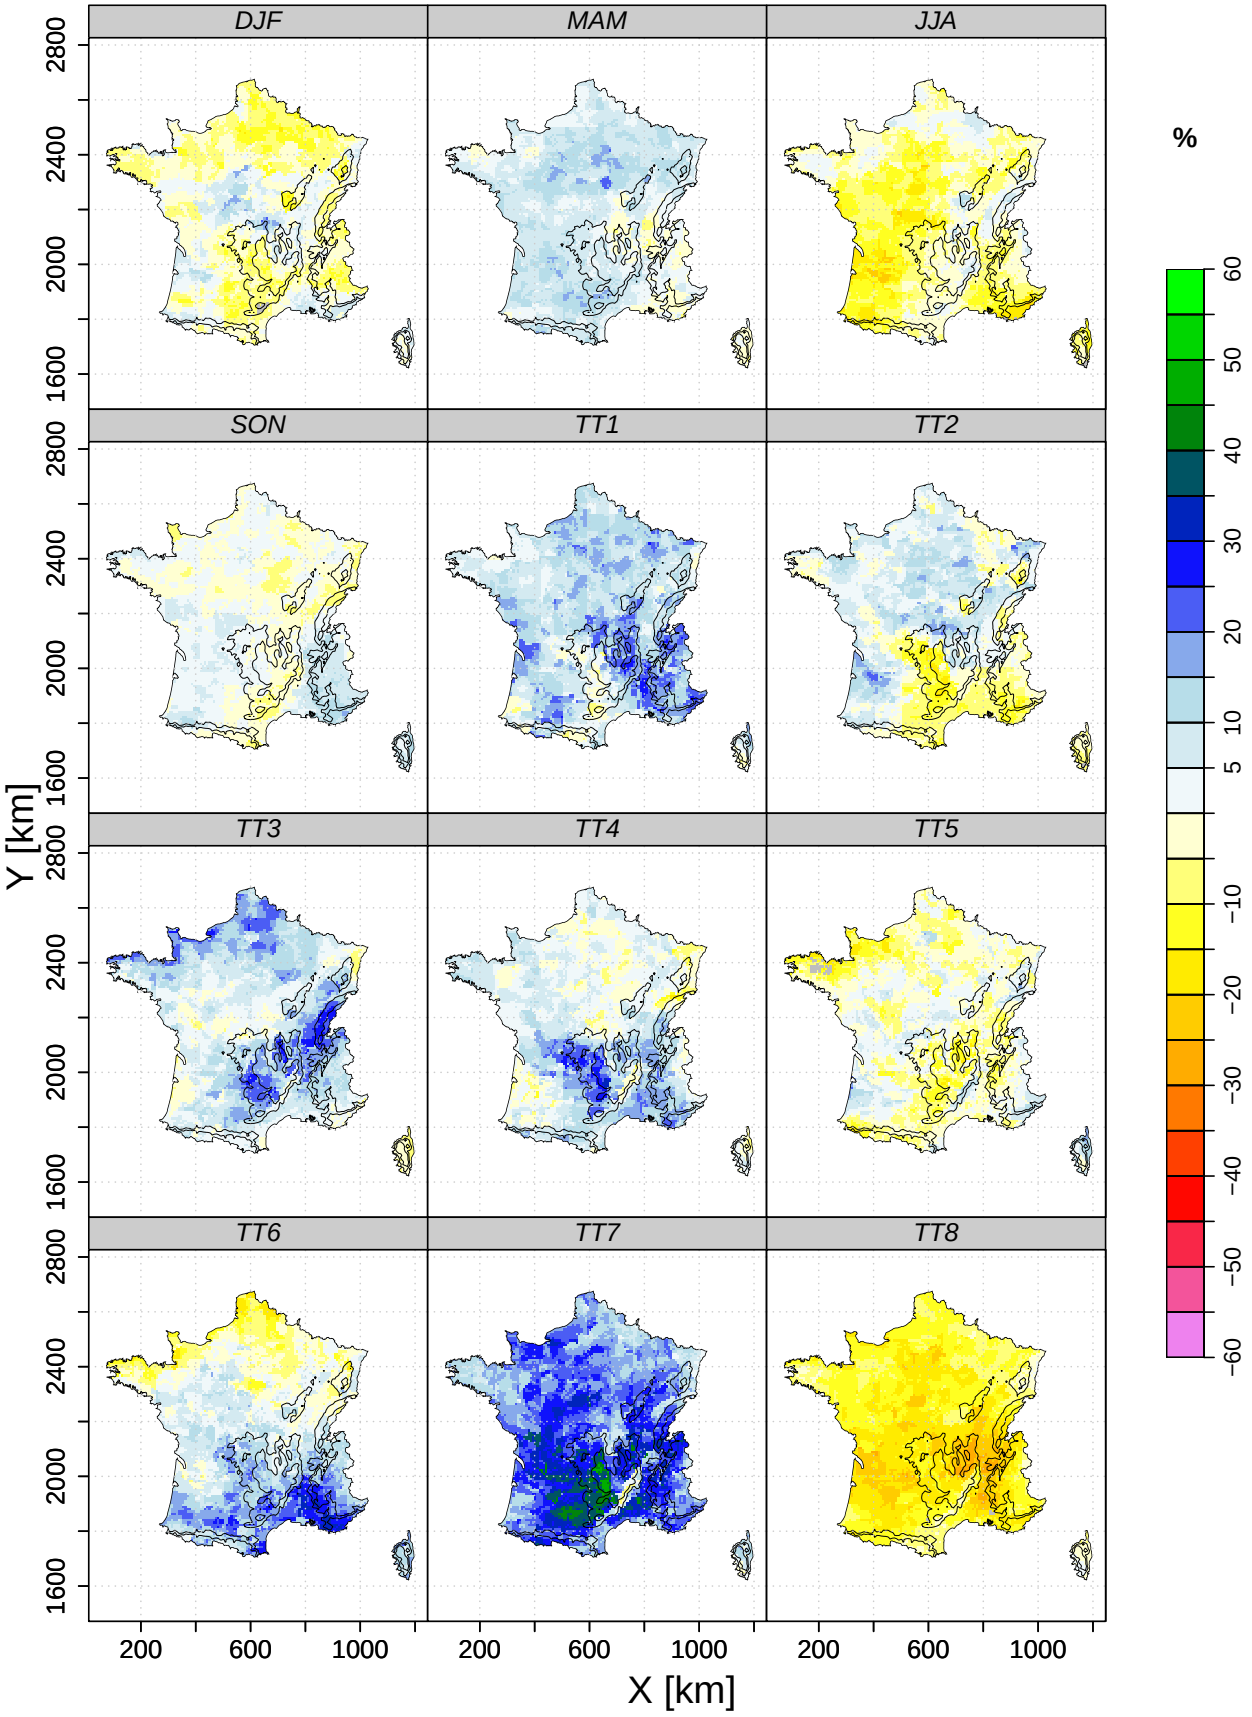

FIGURE D.24 – **Mise à jour de la figure IX.7** : Différence de fréquence d'échantillonnage de la structure 4 (seulement basée sur W) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps **en utilisant la nouvelle stratégie de sélection des structures régressives**. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

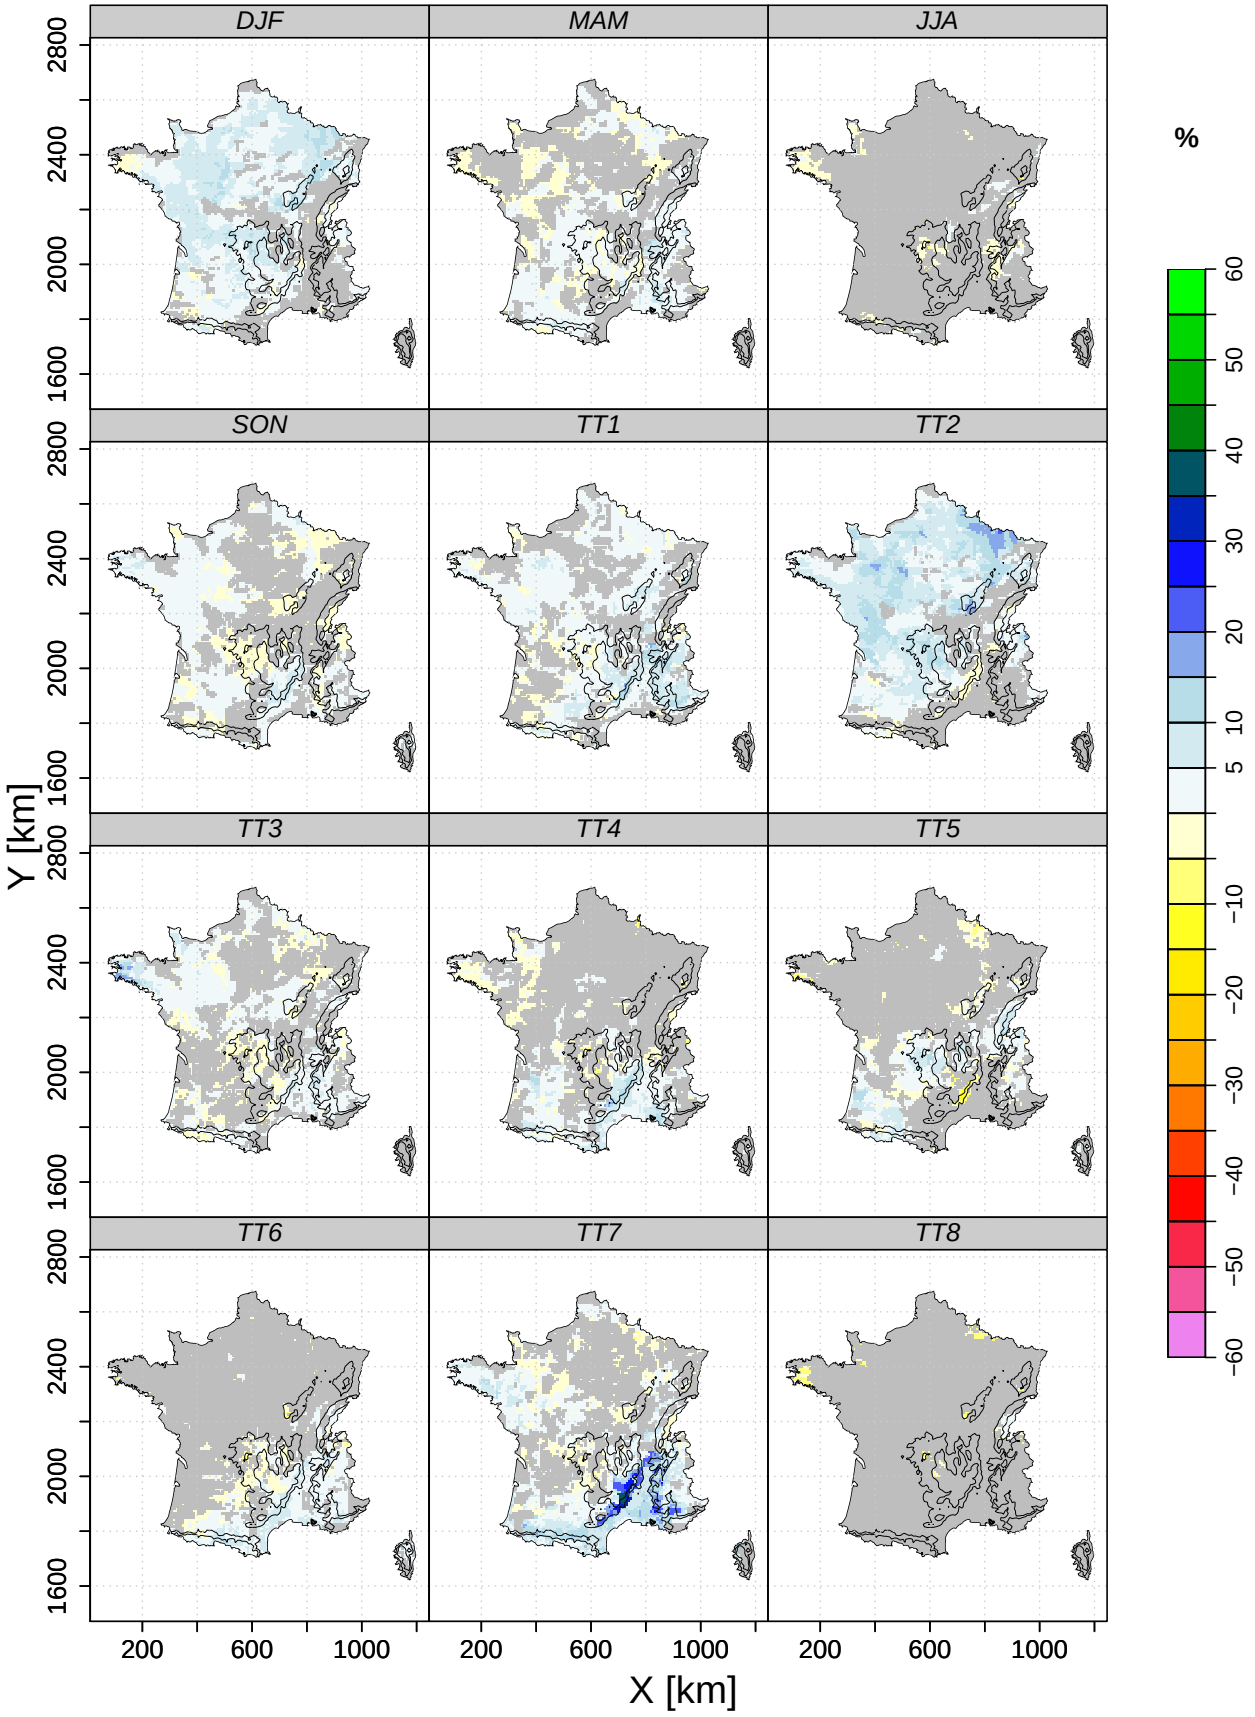

FIGURE D.25 – **Mise à jour de la figure IX.8** : Différence de fréquence d'échantillonnage de la structure 10 ($H+W$) par rapport à la fréquence d'échantillonnage globale (figure IX.5) pour chacune des saisons et des types de temps **en utilisant la nouvelle stratégie de sélection des structures régressives**. Les mailles représentées en bleu indique que la structure est sur-échantillonnée tandis qu'une maille coloriée en jaune indique que cette dernière est sous-échantillonnée par rapport à la moyenne.

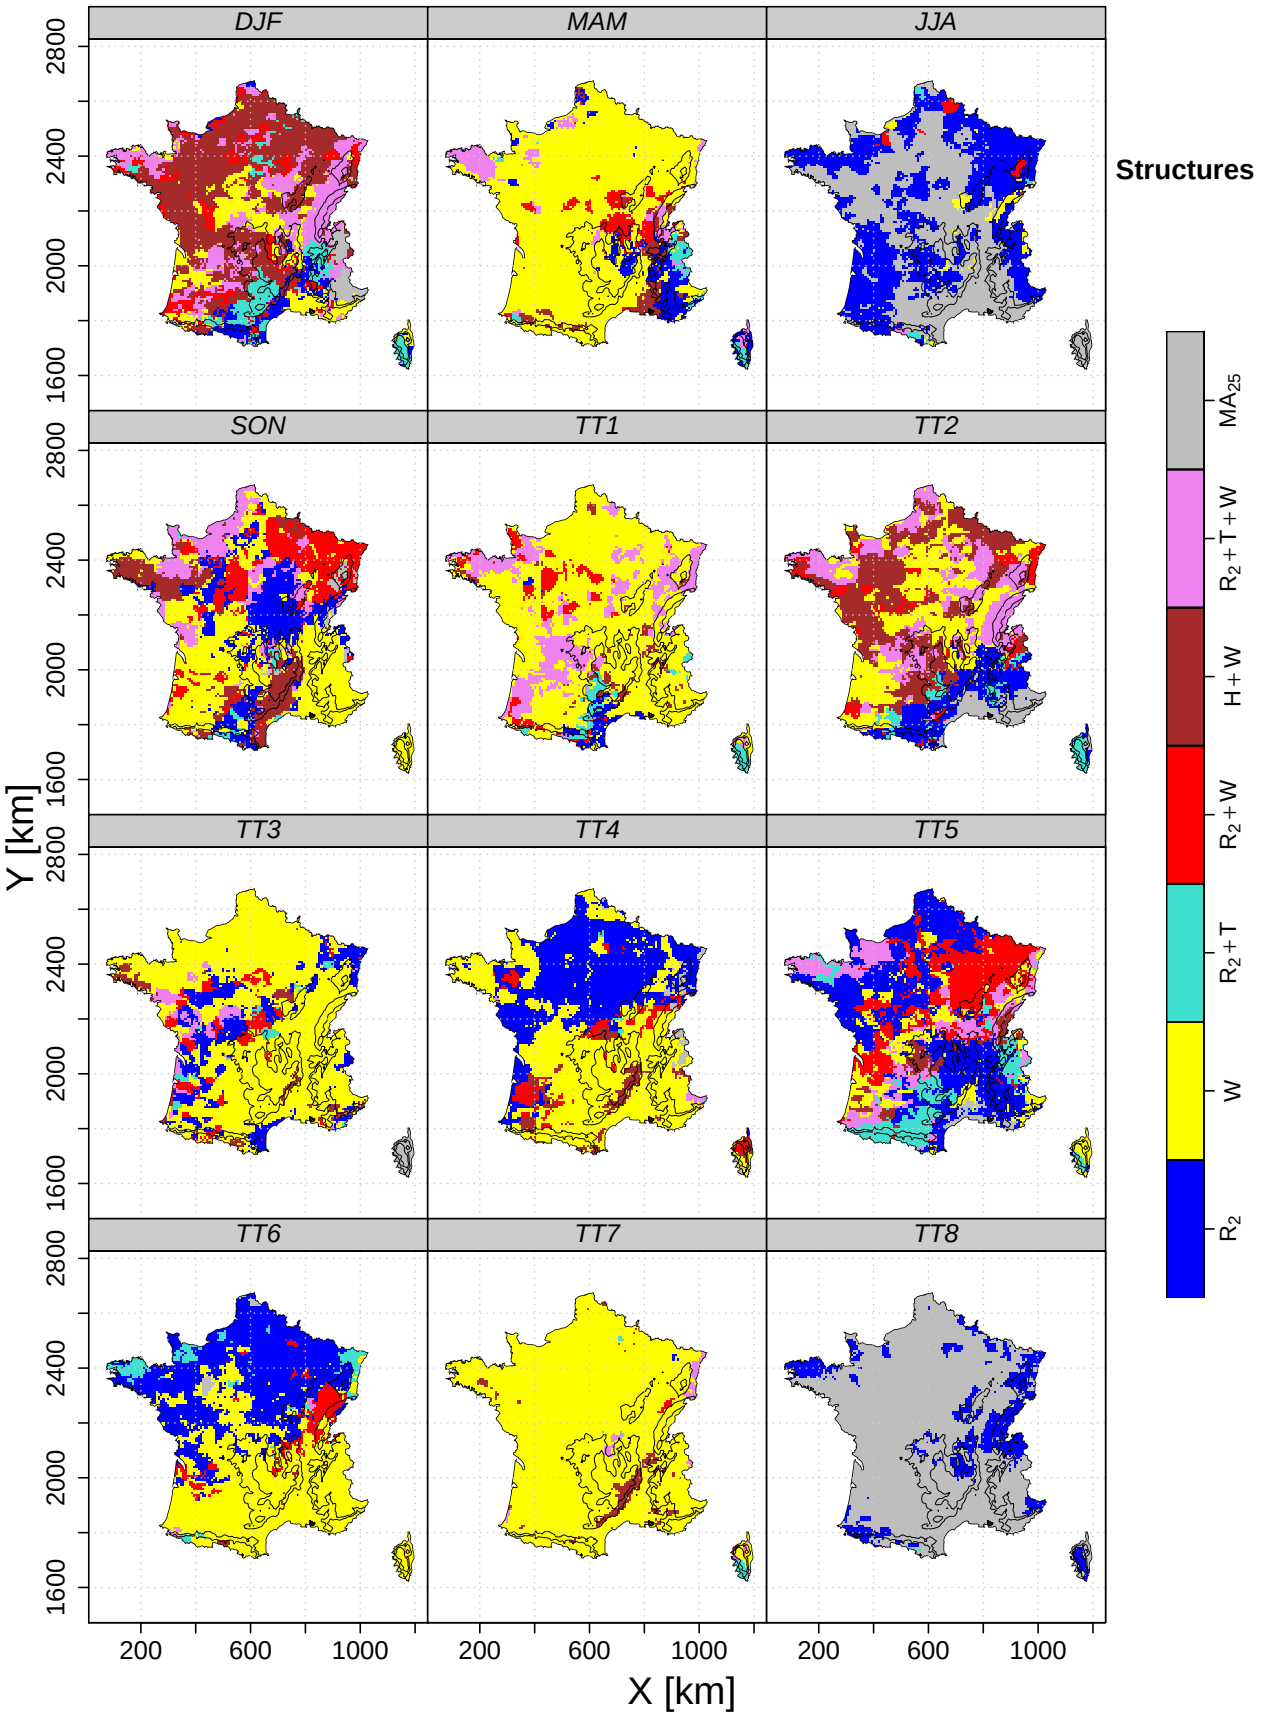

FIGURE D.26 – **Mise à jour de la figure IX.9** : Distribution spatiale des structures régressives pour lesquelles la différence d'échantillonnage est maximale en fonction des saisons et des types de temps **en utilisant la nouvelle stratégie de sélection des structures régressives**.

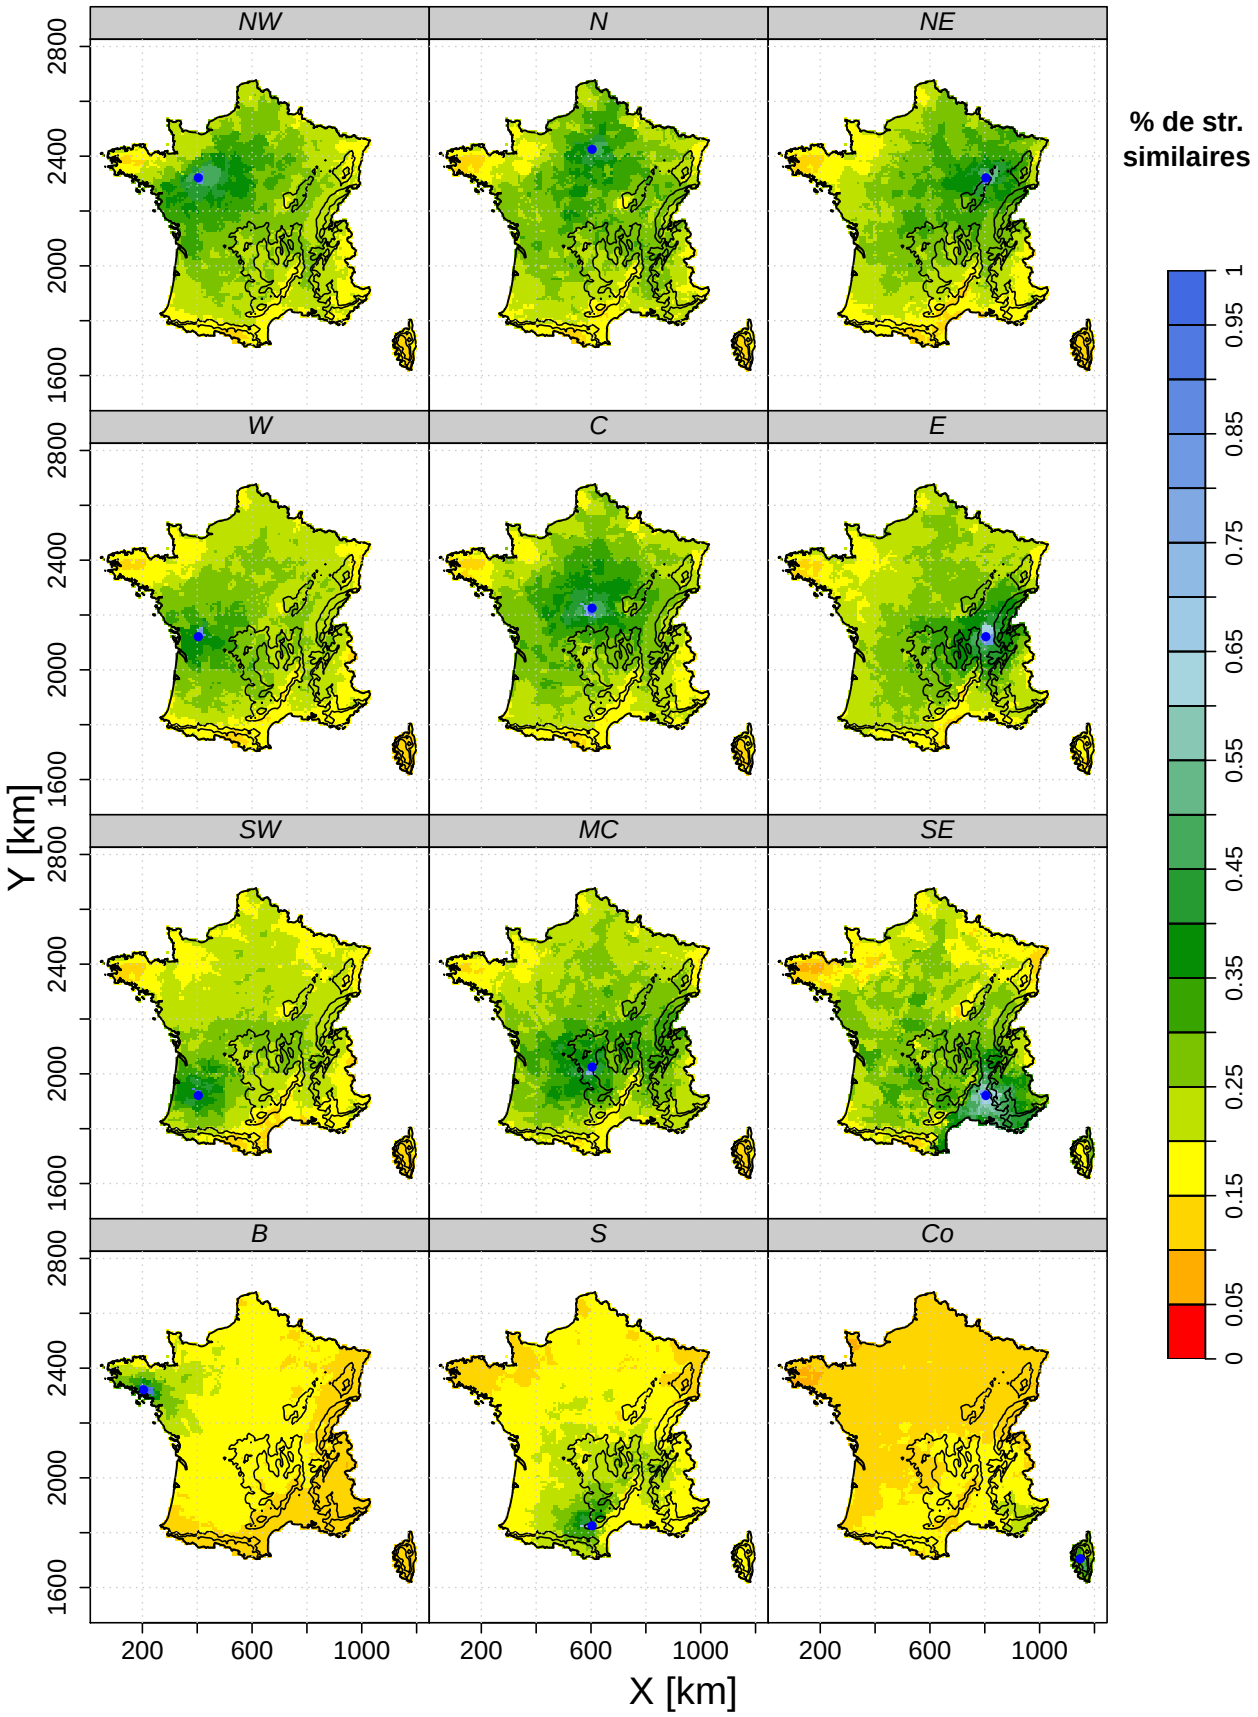

FIGURE D.27 – **Mise à jour de la figure IX.10** : Pourcentage de fois où la structure utilisée par l'une des mailles d'accroche (représentée en bleu sur les cartes) est similaire à celles utilisées par les autres mailles Safran **en utilisant la nouvelle stratégie de sélection des structures régressives**.

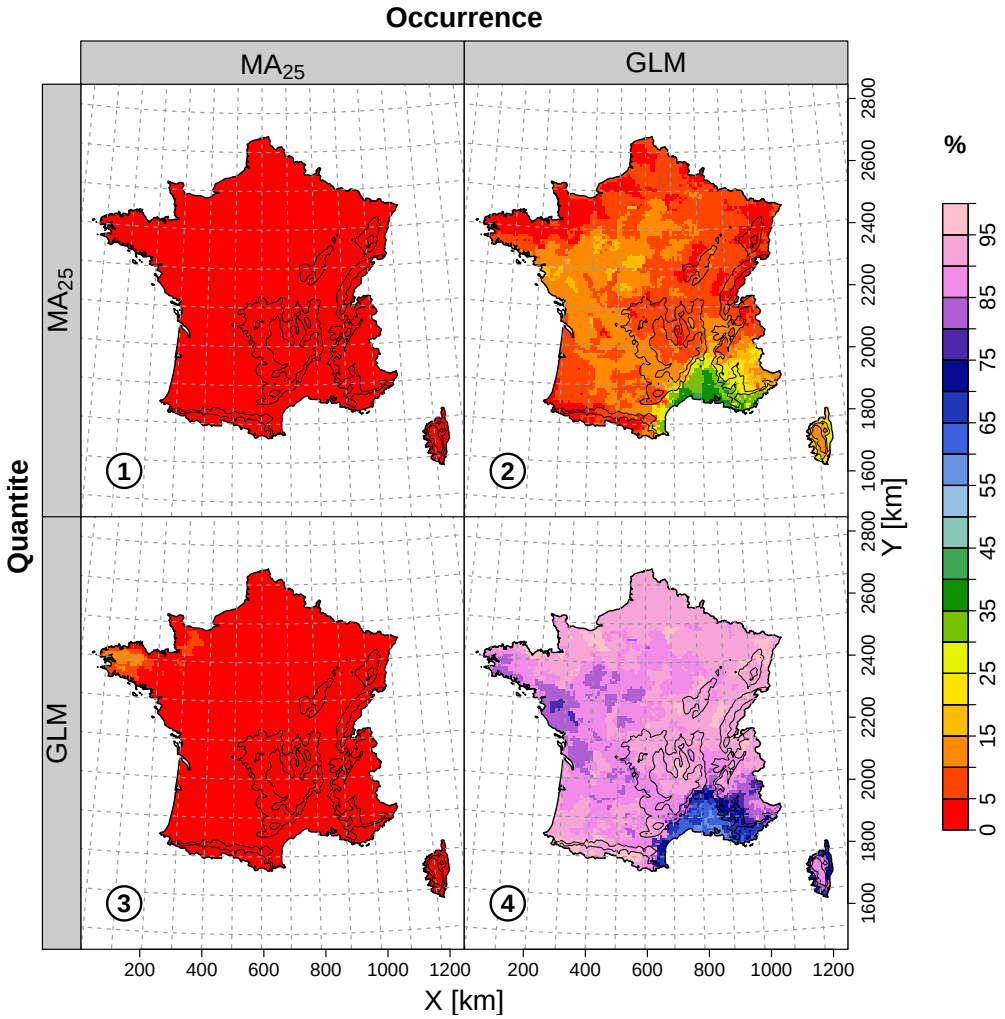

FIGURE D.28 – **Mise à jour de la figure X.1** : Distribution spatiale de l'échantillonnage des quatre assemblages possibles pour la combinaison des modèles d'occurrence et de quantité **en utilisant la nouvelle stratégie de sélection des structures régressives**.

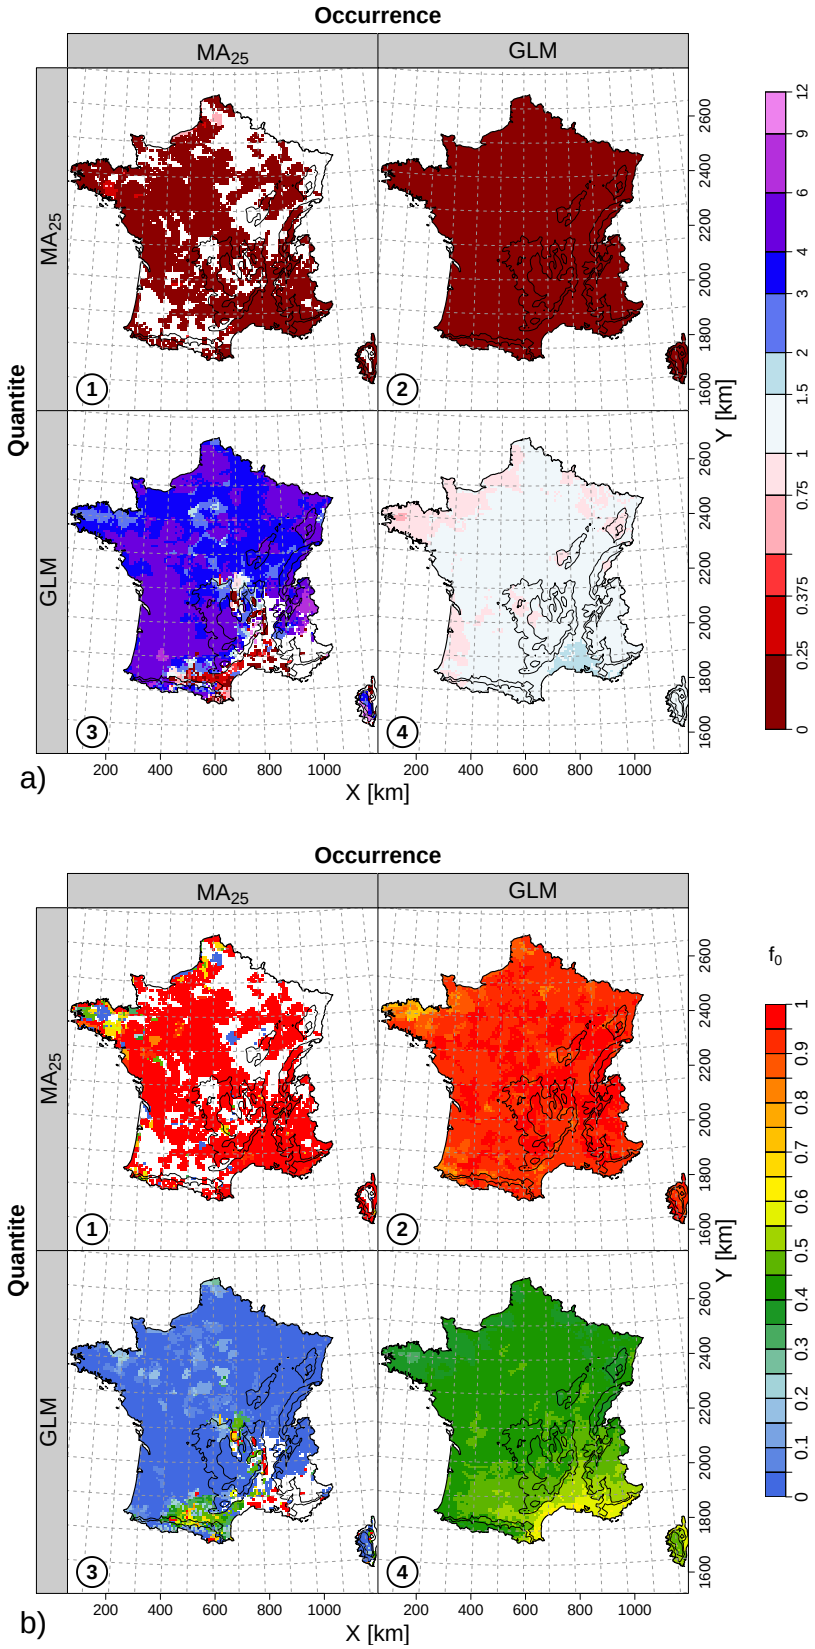

FIGURE D.29 – **Mise à jour de la figure X.2** : a) Distribution spatiale du quotient des pluies moyennes observées pour un assemblage considéré sur la pluie moyenne totale et b) distribution de la fréquence des jours secs pour chacun des quatre assemblages. 1) NoMAJ, 2) MAJOcc, 3) MAJQu et 4) MAJall. **Utilisation de la nouvelle stratégie de sélection des structures régressives**.

Intérêts de la méthode des analogues pour la génération de scénarios de précipitations à l'échelle de la France métropolitaine. Cohérence spatiale et adaptabilité du lien d'échelle.

Les scénarios hydrologiques requis pour les études d'impacts hydrologiques nécessitent de disposer de scénarios météorologiques non biaisés et qui soient de surcroît adaptés aux échelles spatiales et temporelles des hydro-systèmes considérés. Les scénarios météorologiques obtenus en sortie brute des modèles de climat et/ou des modèles de prévision numérique du temps sont de ce fait non appropriées. Les sorties de ces modèles sont par suite souvent adaptées à l'aide de Méthodes de Descente d'Echelle Statistique (MDES). Depuis les années 2000, les MDES ont beaucoup été utilisées pour la génération de scénarios météorologiques en un site. En revanche, la génération de scénarios spatiaux couvrant de larges territoires est une tâche plus difficile, en particulier lorsque l'on souhaite respecter la cohérence spatiale des précipitations à prédire. Parmi les MDES usuelles, les approches basées sur la recherche de situations analogues passées permettent de satisfaire cette contrainte.

Dans cette thèse, nous évaluons la capacité d'un Modèle Analog (MA) – où l'analogie porte sur les géopotentiels 1 000 et 500 hPa – pour la génération de scénarios de précipitation spatialement cohérents pour le territoire Français métropolitain. Dans un premier temps, la transposition spatiale du modèle MA est évaluée : le modèle s'avère utilisable pour la génération de scénarios spatiaux cohérents sur des territoires couvrant plusieurs dizaines de milliers de kilomètres carrés dès lors qu'aucune barrière climatique n'est rencontrée. Dans un second temps, nous évaluons la sensibilité des performances de prédiction à l'agrégation spatiale de la variable à prédire. L'augmentation de performance avec l'agrégation s'explique alors par la diminution de la variabilité du prédictand, pour autant que les variables de grande échelle considérées soient de bons prédicteurs pour la région considérée. Dans une dernière étude, nous explorons la possibilité d'améliorer la performance locale du modèle analogue par l'ajout de prédicteurs locaux. Le modèle combiné qui en résulte permet d'accroître sensiblement les performances de prédiction par l'adaptation du lien d'échelle sur la base d'un jeu de prédicteurs additionnels. Il apparaît de plus que la pertinence de ces prédicteurs dépend de la situation de grande échelle rencontrée ainsi que de la région considérée.

Mots clés : Analogue, Descente d'Echelle Statistique, Précipitation, Prédiction, Cohérence spatiale, GLM, France.

Interests of the analog method for the generation of precipitation scenarios for the French territory. Spatial consistency and adaptability of the scale relation.

Hydrological scenarios required for the impact studies need to have unbiased meteorological scenarios adapted to the space and time scales of the considered hydro-systems. Hence, meteorological scenarios obtained from global climate models and/or numerical weather prediction models are not really appropriated. Outputs of these models have to be post-processed, which is often carried out thanks to Statistical Downscaling Methods (SDMs). Since the 2000's, SDMs are widely used for the generation of scenarios at a single site. The generation of relevant precipitation fields over large regions or hydro-systems is conversely not straightforward, in particular when the spatial consistency has to be satisfied. One strategy to fulfill this constraint is to use a SDM based on the search of past analog situations.

In this PhD, we evaluate the ability of an Analog Model (AM) – where the analogy is applied to the geopotential heights 1000 and 500 hPa – for the generation of spatially coherent precipitation scenarios over the French metropolitan territory. In a first part, the spatial transferability of an AM is evaluated : the model appears to be usable for the generation of spatial coherent scenarios over territories covering several tens of thousands squared kilometers if no climatological barrier is met in between. In a second part, we evaluate the sensitivity of the prediction performance to the spatial aggregation of the predictand. The performance increases with the aggregation level as long as the large scale variables are good predictors of precipitation for the region under consideration. This performance increase has to be related to the decrease of the predictand variability. We finally explore the possibility of improving the local performance of the AM using additional local scale predictors. For each prediction day, the prediction is obtained from a parametric regression model, for which predictors and parameters are estimated from the analog dates. The resulting combined model noticeably allows increasing the prediction performance by adapting the downscaling link for each prediction day. The selected predictors for a given prediction depend on the large scale situation and on the considered region.

Keywords : Analog, Statistical Downscaling, Precipitation, Prediction, Spatial consistency, GLM, France.