



**HAL**  
open science

# Estimation de la dynamique à partir de l'assimilation d'images radars multi-échelles : application à la prévision des taux de précipitation à courte échéance, à partir des images radars

Aniss Zebiri

► **To cite this version:**

Aniss Zebiri. Estimation de la dynamique à partir de l'assimilation d'images radars multi-échelles : application à la prévision des taux de précipitation à courte échéance, à partir des images radars. Traitement du signal et de l'image [eess.SP]. Sorbonne Université, 2020. Français. NNT : 2020SORUS094 . tel-03457048v2

**HAL Id: tel-03457048**

**<https://theses.hal.science/tel-03457048v2>**

Submitted on 30 Nov 2021

**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.

---

# Estimation de la dynamique atmosphérique à partir de l'assimilation d'images radars multi-échelles

Application à la prévision des taux de précipitation à courte  
échéance, à partir des images radars

---

par Aniss ZEBIRI

soutenue le 11 Juin 2020 devant le jury constitué de :

Bernadette Dorizzi	Telecom SudParis	Rapporteuse
Laurent Barthes	UVSQ	Rapporteur
Isabelle Herlin	Inria	Directrice de thèse
Dominique Béréziat	Sorbonne Université	Co-directeur de thèse
Emmanuel Buisson	Weather Measures	Co-directeur de thèse
Sylvie Thiria	Sorbonne Université	Examinatrice
Lionel Lacassagne	Sorbonne Université	Examineur
Étienne Huot	UVSQ	Examineur

---

---

---

## Remerciement

J'adresse mes plus sincères remerciements à ma directrice de thèse, Madame Isabelle HERLIN, de m'avoir accueillie dans son équipe, pour son accompagnement scientifique et pour sa bienveillance tout au long de ce travail. Aucune expression de gratitude ne sera suffisante pour vous exprimer mon respect et ma reconnaissance.

Je remercie tout particulièrement mon co-encadrant de thèse, Monsieur Dominique BÉRÉZIAT, pour ses enseignements et encouragements, également pour sa grande compétence, sa disponibilité continue et de m'avoir orienté pendant toutes ces années. Ma sincère gratitude et un grand respect vous sont personnellement adressés.

J'adresse également mes remerciements à Monsieur Etienne HOUT, pour sa collaboration, sa disponibilité et ses nombreux conseils durant cette thèse.

Mes remerciements les plus sincères vont également à Monsieur Emmanuel BUISSON, directeur général de WM, pour son implication dans le projet, ses connaissances, ses qualités scientifiques et ses conseils pertinents et merci à toute l'équipe pour l'accueil, la bonne humeur, avec laquelle j'ai partagé des moments extraordinaires.

J'adresse mes plus sincères et chaleureux remerciements à : Madame Bernadette DORIZZI, Monsieur Laurent BERTHÈS de m'avoir fait l'honneur d'être rapporteurs de cette thèse, ainsi que Madame Sylvie THIRIA et Monsieur Lionel LACASSAGNE d'avoir bien voulu examiner ce travail. Je vous remercie pour avoir accepté de siéger dans mon jury.

J'aimerais également remercier tous les membres de Laboratoire d'Informatique de Paris 6 (LIP6), en particulier l'équipe PEQUAN pour leur accueil chaleureux et le partage scientifique.

Merci aussi à ma famille et mes proches qui ont toujours cru en moi, à ma chère mère, à mon cher père, pour tous les efforts et sacrifices, pour leur soutien permanent et encouragements malgré les kilomètres qui nous séparent et qui ont veillé à ce que je réussisse à mes études, Je leur en suis reconnaissant.

À mes frères, MOUNIR, FOUZI, CHAKER et sa petite famille, pour les moments de joie et de folie et leurs encouragements avec qui je partage le plus sacré lien affectif. J'espère les rendre fiers.

Je termine par remercier de tout mon cœur la personne qui partage ma vie, ma femme MERIEM, d'avoir été mon roc ces dernières années, de m'avoir soutenue dans les moments difficiles, de sa patience et de son empathie. Tu m'as donné le courage pour finir.

À toutes et tous, un grand merci !

---

---

# Table des matières

<b>1</b>	<b>Introduction</b>	<b>15</b>
<b>2</b>	<b>État de l'art sur l'estimation des précipitations</b>	<b>21</b>
2.1	Précipitations . . . . .	23
2.1.1	Définition et taxonomie . . . . .	23
2.1.2	Taux de précipitation . . . . .	28
2.2	Instruments de détection et de mesure des précipitations . . . . .	28
2.2.1	Radiomètres imageurs météorologiques . . . . .	29
2.2.2	Pluviomètres . . . . .	33
2.2.3	Disdromètres . . . . .	36
2.2.4	Radar . . . . .	37
2.3	Systèmes de prévision des précipitations à court terme, à partir d'images radar . . . . .	41
2.3.1	Un peu d'histoire . . . . .	41
2.3.2	Approches basées sur la mise en correspondance de blocs d'images . . . . .	43
2.3.3	Approches basées sur la mise en correspondance de cellules de précipitation . . . . .	46
2.3.4	Approches par flot optique . . . . .	51
2.3.5	Variational Echo Tracking (VET) . . . . .	54
2.3.6	Rain Nowcast . . . . .	56
2.4	Discussion et conclusion . . . . .	64
<b>3</b>	<b>Estimation multi-échelle du mouvement</b>	<b>65</b>
3.1	Approches multi-échelle . . . . .	67
3.2	Estimation multi-échelle du mouvement . . . . .	68
3.2.1	Sequential Motion Rain Nowcast (SMRN) . . . . .	68
3.2.2	Parallel Motion Rain Nowcast (PMRN) . . . . .	76
3.3	Conclusion . . . . .	79

## TABLE DES MATIÈRES

---

<b>4</b>	<b>Prévision des précipitations à partir de la dynamique</b>	<b>83</b>
4.1	Principes sous-tendant la prévision . . . . .	85
4.2	Correction de l'intensité du mouvement : hypothèse de vent géostrophique	89
4.3	Correction de la distribution des prévisions . . . . .	93
4.4	Conclusion . . . . .	96
<b>5</b>	<b>Analyse quantitative des résultats et validation</b>	<b>99</b>
5.1	Description des données . . . . .	101
5.1.1	Données radars en bande X . . . . .	101
5.1.2	Données Panthere . . . . .	105
5.1.3	Description des jeux de données . . . . .	105
5.2	Métriques . . . . .	108
5.3	Résultats . . . . .	110
5.3.1	Sequential Motion Rain Nowcast (SMRN) . . . . .	111
5.3.2	Parallel Motion Rain Nowcast (PMRN) . . . . .	116
5.3.3	Hypothèse de vent géostrophique . . . . .	122
5.3.4	Correction de la distribution de la prévision . . . . .	133
5.4	Conclusion . . . . .	138
<b>6</b>	<b>Conclusion</b>	<b>141</b>
<b>A</b>	<b>Calcul des gradients</b>	<b>147</b>
A.1	Calcul du gradient de $J$ . . . . .	147
A.2	Calcul du gradient des termes de régularisation . . . . .	152
<b>B</b>	<b>Implémentation opérationnelle</b>	<b>155</b>
B.1	Prévision . . . . .	155
B.2	Estimation du mouvement . . . . .	157

# Table des figures

2.3	Différents types de collision entre gouttes d'eau. . . . .	28
2.4	Ces images proviennent d'imagineurs satellite. À gauche : image prise le 22 mars 2002 par le satellite AQUA (circumpolaire). À droite : image prise le 21 avril 2018 par DSCOVR (géostationnaire). . . . .	30
2.5	Longueurs d'onde et bandes de fréquence. . . . .	31
2.6	Acquisitions du satellite MSG-3, le 19 septembre 2016 à 9h UTC, respectivement dans le canal visible, infrarouge et vapeur d'eau. Origine : Météo France. . . . .	33
2.7	Pluviomètre manuel. . . . .	34
2.8	Fonctionnement d'un pluviomètre à auget basculant. . . . .	35
2.9	Fonctionnement du disdromètre. Inspiré de [FL18]. . . . .	37
2.10	Une image radar prise le 2 novembre 2019 à 23 :45 UTC. Source : Infoclimat	38
2.11	Principe d'acquisition multi-élevations . . . . .	39
2.12	Principe d'acquisition radar. . . . .	40
2.13	Identification des RC. Figure extraite de [Han02]. . . . .	49
2.14	Illustration du problème d'ouverture : pour une position donnée (x,y), l'équation du flot n'admet pas de solution unique. . . . .	53
2.15	Estimation du mouvement par méthode variationnelle itérative. À gauche : initialisation de la procédure par un champ uniforme. Au milieu : une première estimation d'un champ de mouvement à résolution $5 \times 5$ . À droite : estimation finale du champ de mouvement à résolution $25 \times 25$ . Tiré de [GZ02].	55
2.16	Principe de la fenêtre glissante. Fenêtre 1 : les quatre premières acquisitions $I^o(t = t_1), I^o(t = t_2), I^o(t = t_3), I^o(t = t_4)$ sont utilisées pour produire le champ de vitesse $\mathbf{w}_1$ , l'ébauche $w_0^b$ sur la vitesse est alors nulle. Fenêtre 2 : une nouvelle acquisition est disponible, $I^o(t = t_2), I^o(t = t_3), I^o(t = t_4), I^o(t = t_5)$ sont utilisées pour produire le champ de vitesse $\mathbf{w}_2$ et l'ébauche $\mathbf{w}_1^b$ sur la vitesse est $\mathbf{w}_1(0)$ . . . . .	63



---

TABLE DES FIGURES

---

3.1	Représentation multi-échelle. À gauche : résolution grossière; à droite : résolution plus fine. . . . .	67
3.2	Exemple d’observations locales et régionales, acquises aux mêmes dates et utilisées par les algorithmes multi-échelle d’estimation du mouvement. Pour la visualisation, la même quantification couleur des quantités de pluie est utilisée pour les deux échelles. . . . .	69
3.3	Principe de l’algorithme SMRN : assimilation séquentielle à deux échelles différentes. . . . .	70
3.4	Mise en œuvre de la fenêtre glissante pour SMRN. . . . .	75
3.5	Exemple d’estimation du mouvement multi-échelle par assimilation 4DVar. (a) Observations locales et régionales aux mêmes dates. Le domaine d’acquisition des données locales est symbolisé par les 3 portions de cercle (voir section 5.1). (b) (c) (d) Estimation du mouvement par <i>Rain Nowcast</i> (à partir des observations locales), SMRN et PMRN. Chaque champ de vecteur vitesses est superposé à une représentation dense des vecteurs vitesse par la méthode Middlebury [BSL <sup>+</sup> 11] : la teinte représente l’orientation et la saturation l’intensité. . . . .	80
4.1	Un exemple de prévision : à partir de la dernière acquisition disponible (en haut à gauche) et du champs de vitesse $\mathbf{w}_{ME}$ calculé par l’une des méthodes du chapitre 3 (en haut à droite, affichage coloré de Middlebury), nous produisons (en bas, de gauche à droite) une prévision à $t_h = 30, 45, 60$ et $75$ minutes. . . . .	88
4.2	De gauche à droite : deux observations à deux temps successifs et intensité du mouvement estimé à partir de ces observations. . . . .	90
4.3	Exemple de mouvement estimé par <i>Rain Nowcast</i> , sous l’hypothèse de vent géostrophique et avec $\tau \in \{30, 70, 100\}$ . . . . .	92
4.4	À gauche le champ de vitesse initial estimé par <i>Rain Nowcast</i> , à droite le mouvement sous l’hypothèse de vent géostrophique. . . . .	93
4.5	Comparaison entre les prévisions obtenues avec ou sans hypothèse de vent géostrophique sur une région d’intérêt. (a) observation (vérité terrain), (b) prévision calculée par <i>Rain Nowcast</i> sans hypothèse de vent géostrophique, (c) prévision calculée sous l’hypothèse de vent géostrophique. . . . .	94
4.6	Effet de lissage introduit par le schéma semi-lagrangien. De gauche à droite : la condition initiale (observation) et les prévisions à $t_h = 5, 30$ et $60$ minutes. . . . .	94

---

## TABLE DES FIGURES

---

4.7	Comparaison entre les prévisions calculées sans et avec correction de la distribution. (a) L'observation qui a servi à produire la prévision et qui fournit la distribution de référence. (b) La prévision calculée à partir de l'observation (a). (c) La prévision calculée à partir de l'observation (a) après correction de sa distribution. . . . .	96
4.8	Graphe des fonctions de répartition de l'observation (en vert), de la prévision (en orange), de la prévision après correction (en bleu). . . . .	97
5.1	Radar WR25XP en bande X. À gauche, un radar installé sur un toit de bâtiment et, à droite, le radar sans le radôme. . . . .	101
5.2	Positionnement des radars. À droite : le réseau de la Limagne, à gauche : le réseau de la Beauce. La portée de chaque radar est indiquée par un cercle, rouge pour les radars d'une portée de 36 km, bleu pour les radars d'une portée de 72 km. Image de fond : Google Earth. . . . .	102
5.3	Grille cartésienne des points acquisition. . . . .	103
5.4	Exemple d'acquisition radar en bande X. À droite : image radar, chaque pixel mesure une quantité de pluie en mm. À gauche : quantification non linéaire des précipitations, sur la même acquisition, selon une échelle de 11 valeurs allant d'une quantité de pluie entre 0,01 et 0,5 mm (cyan) jusqu'à 100 mm ou plus (marron). L'absence de pluie est indiquée par la couleur blanche. Le domaine d'acquisition est visualisé sur la gauche. . . . .	104
5.5	À droite, le réseau PANTHERE ; à gauche, un exemple de données Panther (sources : <a href="http://meteofrance.com">http://meteofrance.com</a> , <a href="http://infoclimat.fr">http://infoclimat.fr</a> ). . . . .	106
5.6	En jaune, le réseau des radars PANTHERE. En rouge, le réseau des radars en bande X de Weather Measure. En vert, la portion d'images Panther correspondant au domaine d'acquisition en bande X. . . . .	106
5.7	Visualisation des précipitations à deux résolutions spatiales. Première ligne : carte de précipitations Panther. Seconde ligne : carte de précipitations obtenue par radars en bande X. . . . .	107
5.8	Illustration des variables VP, VN, FP et FN. Le cercle vert représente la structure nuageuse observée, le cercle bleu représente la structure nuageuse prédite. . . . .	109
5.9	Exemple de calcul des métriques. À droite : image sur laquelle sont représentées la prévision (en vert) et la vérité terrain (en cyan), ainsi que leur intersection. À gauche : les valeurs correspondant aux 3 métriques calculées à partir des quatre classes de pixels : vrai positif (VP), faux positif (FP), faux négatif (FN) et vrai négatif (VN). . . . .	110

---

TABLE DES FIGURES

---

5.10	Statistiques de SMRN et <i>Rain Nowcast</i> lors du calcul d'une prévision à $t_h = 15$ min à partir des données locales. Épisode du 30 juillet 2016. . . .	111
5.11	Statistiques de SMRN et <i>Rain Nowcast</i> lors du calcul d'une prévision à $t_h = 15$ min à partir des données régionales. Épisode du 30 juillet 2016. .	112
5.12	Prévisions à $t_h = 15$ min (en rouge) obtenues par <i>Rain Nowcast</i> (colonne de gauche) et SMRN (colonne de droite), comparées aux observations locales (en vert). L'intersection entre les zones pluvieuses sur la prévision et l'observation, en couleur grenat, devrait être idéalement la plus grande possible. Épisode du 30/07/2016. . . . .	114
5.13	Exemple de prévision à $t_h = 45$ minutes. Les deux premières lignes montrent respectivement les observations locales et régionales utilisées pour le calcul du mouvement. La troisième ligne illustre la prévision obtenue sur les observations locales par <i>Rain Nowcast</i> (à gauche), et SMRN (à droite). Épisode du 24 juin 2016. . . . .	115
5.14	Apparition et disparition de structures pluvieuses. . . . .	116
5.15	Statistiques de PMRN et <i>Rain Nowcast</i> , pour une prévision à $t_h = 15$ min sur les données locales. Épisode du 30 juillet 2016. . . . .	117
5.16	Statistiques de PMRN et <i>Rain Nowcast</i> , pour une prévision à $t_h = 15$ min sur les données régionales. Épisode du 30 juillet 2016. . . . .	117
5.17	Exemple de situation d'échec pour PMRN. Les première et seconde lignes montrent les observations locales et régionales utilisées pour l'estimation du mouvement. La troisième ligne compare les prévisions obtenues (de gauche à droite), respectivement, par <i>Rain Nowcast</i> , SMRN et PMRN. Épisode du 24 juin 2016. . . . .	119
5.18	Exemple de prévision à $t_h = 60$ min. Les première et seconde lignes montrent les observations locales et régionales pour l'estimation du mouvement. La troisième ligne montre la prévision obtenue par <i>Rain Nowcast</i> (à gauche) et PMRN (à droite). Épisode du 30 juillet 2016. . . . .	121
5.19	Illustration de l'absence de précipitation. . . . .	122
5.20	Statistiques d'une prévision à $t_h = 45$ min pour <i>Rain Nowcast</i> avec (en rouge) et sans (en vert) l'hypothèse de vent géostrophique sur la sous-séquence du 24/06/2016. Le seuil de détection est 0,2 mm. . . . .	123
5.21	Statistiques d'une prévision à $t_h = 45$ min pour <i>Rain Nowcast</i> avec (en rouge) et sans (en vert) l'hypothèse de vent géostrophique sur la sous-séquence du 30/07/2016. Le seuil de détection est 0,2 mm. . . . .	124

---

TABLE DES FIGURES

---

5.22	Exemples de prévisions à $t_h = 30$ et 60 minutes, réalisées par <i>Rain Nowcast</i> , avec et sans hypothèse de vent géostrophique. Première ligne : observations locales. Seconde ligne : prévision à 30 minutes sans (à gauche) et avec (à droite) hypothèse de vent géostrophique. Troisième ligne : prévision à 60 minutes sans et avec hypothèse de vent géostrophique. . . . .	125
5.23	Illustration de mauvaise prévision sous hypothèse de vent synaptique. À gauche : sans hypothèse de vent géostrophique. À droite : avec hypothèse de vent géostrophique. . . . .	126
5.24	Prévision à 60 minutes, réalisées par PMRN avec et sans hypothèse de vent géostrophique. . . . .	128
5.25	Prévision à 45 minutes par PMRN, sous l'hypothèse de vent géostrophique.	129
5.26	Exemple de mauvaise prévision par PMRN, sous l'hypothèse d'un vent géostrophique, à $t_h = 45$ min. Première ligne, de gauche à droite : données locales à la date de la condition initiale, à $t_h = 45$ min, à $t_h = 50$ min. Seconde ligne : données régionales aux mêmes dates. Troisième ligne, de gauche à droite : prévisions fournies par <i>Rain Nowcast</i> , PMRN avec hypothèse de vent géostrophique sur les données locales et PMRN avec hypothèse de vent géostrophique sur les données régionales. . . . .	131
5.27	Statistiques de SMRN, avec et sans hypothèse vent géostrophique, pour une prévision à $t_h = 60$ min et un seuillage à 0,5 mm pour la quantification des métriques. Sous-épisode du 24 juin 2016. . . . .	132
5.28	Exemple de prévision à $t_h = 15$ min de <i>Rain Nowcast</i> avec et sans correction d'histogramme sur les données régionales le 21/06/2016 à 16h55. . . . .	136

## TABLE DES FIGURES

---

# Liste des tableaux

2.1	Classification des nuages et illustration de leurs caractéristiques. Origine : OMM. . . . .	25
4.1	Statistiques sur un exemple de prévision de <i>Rain Nowcast</i> , sous l'hypothèse de vent géostrophique et à l'horizon $t_h = 30$ et 45 minutes en utilisant plusieurs valeurs pour $\tau$ . . . . .	91
5.1	Statistiques générales de SMRN et <i>Rain Nowcast</i> , pour une prévision à $t_h = 15$ min, sur les données régionales et locales. Épisode du 30 juillet 2016.	112
5.2	Statistiques générales de SMRN et <i>Rain Nowcast</i> , pour une prévision à $t_h = 15$ min, sur les données régionales et locales. Épisode du 24 juin 2016.	112
5.3	Statistiques de la prévision à $t_h = 15$ min pour <i>Rain Nowcast</i> et SMRN sur l'exemple présenté dans la figure 5.12 de l'épisode du 30/07/2016 à 17h35.	113
5.4	Statistiques générales des prévisions locales et régionales à $t_h = 45$ min de <i>Rain Nowcast</i> et SMRN pour l'épisode du 30/07/2016. . . . .	113
5.5	Statistiques générales des prévisions locales et régionales à $t_h = 45$ min de <i>Rain Nowcast</i> et SMRN pour l'épisode du 24/06/2016. . . . .	115
5.6	Statistiques générales obtenues par <i>Rain Nowcast</i> , SMRN et PMRN pour une prévision à $t_h = 15$ min, sur les données régionales et locales. Épisode du 30 juillet 2016. . . . .	118
5.7	Statistiques des prévisions à $t_h = 45$ min de <i>Rain Nowcast</i> , SMRN et PMRN sur l'exemple présenté dans la figure 5.17 de l'épisode du 24/06/2016 à 21h05. . . . .	118
5.8	Statistiques générales de <i>Rain Nowcast</i> , PMRN et SMRN pour une prévision à $t_h = 15$ min sur les données régionales et locales. Épisode du 24 juin 2016. . . . .	119
5.9	Statistiques des prévisions à $t_h = 60$ minutes de <i>Rain Nowcast</i> et PMRN, sur l'exemple présenté dans la figure 5.18 de l'épisode du 30/07/2016. . .	120

LISTE DES TABLEAUX

---

5.10	Statistiques des prévisions à 60 minutes de <i>Rain Nowcast</i> , avec et sans hypothèse de vent géostrophique (VG), pour l'exemple présenté dans la figure 5.22, épisode du 24/06/2016 à 17h20. . . . .	124
5.11	Statistiques moyennes de <i>Rain Nowcast</i> avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 24 juin 2016.	126
5.12	Statistiques moyennes de <i>Rain Nowcast</i> avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 30 juillet 2016. . . . .	127
5.13	Statistiques générales de PMRN, avec et sans hypothèse de vent géostrophique sur les données locales, pour le sous-épisode du 30 juillet 2016.	127
5.14	Statistiques générales de PMRN, avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 24 juin 2016. . .	128
5.15	Statistiques, calculées sur les données locales, pour SMRN, avec et sans hypothèse de vent géostrophique, sur le sous-épisode du 24 juin 2016. . .	132
5.16	Statistiques, calculées sur les données locales, pour SMRN, avec et sans hypothèse de vent géostrophique, sur le sous-épisode du 30/07/2016. . . .	133
5.17	Statistiques de <i>Rain Nowcast</i> , calculées sur les données locales, avec et sans correction de l'histogramme (CH) pour $t_h = 15$ min. Sous-épisode du 30 juillet 2016. . . . .	134
5.18	Statistiques de <i>Rain Nowcast</i> , calculées sur les données locales, avec et sans correction d'histogramme de la prévision pour $t_h = 15$ min. Sous-épisode du 24 juin 2016. . . . .	135
5.19	Statistiques de <i>Rain Nowcast</i> , calculées sur les données régionales, avec et sans correction de l'histogramme pour $t_h = 15$ min, sous-épisode de 24 juin 2016. . . . .	135
5.20	Statistiques de <i>Rain Nowcast</i> , calculées sur les données régionales, avec et sans correction de l'histogramme pour $t_h = 15$ min, sous-épisode de 30 juillet 2016. . . . .	135
5.21	Statistiques des prévisions sur un exemple de prévision fait par <i>Rain Nowcast</i> , avec et sans correction d'histogramme, sur les données régionales et pour différentes classes de précipitations. Le 26/06/2016 à 16h25. . . . .	137
B.1	Benchmarks de l'étape de prévision de <i>Rain Nowcast</i> (RN1.0 et RN2.1). .	157
B.2	Efficacité de l'estimation du mouvement après optimisation de L-BFGS. .	159

# Chapitre 1

## Introduction

L'importance des prévisions météorologiques dans toutes les activités quotidiennes, sociales et économiques, ne fait que croître depuis une décennie. On pourrait, à première vue, penser que ces prévisions n'ont d'intérêt que consultatif. Mais la météorologie est un facteur déterminant pour l'économie du pays, en lien étroit avec les habitudes de consommation et de mobilité des citoyens. En marketing, on désigne par le terme "météo-sensibilité" l'impact des conditions météorologiques sur notre environnement économique. Cet impact est particulièrement prégnant pour certaines activités dites saisonnières, comme celles autour du ski ou de la voile par exemple, mais devient également visible pour une gamme toujours plus large d'activités. Plus généralement, les secteurs considérés comme météo-sensibles sont ceux de l'agriculture, l'énergie, la logistique, le textile, l'agro-alimentaire, les transports, le tourisme et les activités des collectivités locales.

Afin de réduire l'impact potentiellement négatif de la météo-sensibilité sur le fonctionnement d'une entreprise, des sociétés (comme Météo France, Weather Measures,...) ont compris l'intérêt économique de cette problématique. Leurs experts proposent d'analyser les données météorologiques pour prévoir les facteurs influençant cette météo-sensibilité, avec un horizon temporel allant de quelques dizaines de minutes à quelques semaines. Ces prévisions permettent ainsi d'anticiper et d'adapter les modes opératoires des processus concernés. Cela peut aller de l'évacuation de sites en risque de crue rapide à l'approvisionnement des supermarchés en produits sensibles, tels que le sel pour la neige ou les denrées périssables. Les variables météorologiques utilisées par et pour ces prévisions sont par exemple la température, le vent, l'humidité, et les précipitations.

La prévision des quantités de précipitations et celle des taux de précipitations<sup>1</sup> oc-

---

1. La quantité de précipitation est le volume de pluie tombé sur une surface. Le taux de précipitation (en anglais : *Quantitative Precipitation Estimation*) est le volume de pluie tombe sur une surface durant un intervalle de temps.



cupent une place particulière, compte tenu de leur impact direct sur la plupart des domaines économiques évoqués précédemment. Ces prévisions permettent, d’une part, d’anticiper les contraintes environnementales et d’optimiser par exemple la gestion des ressources en eau, et, d’autre part, d’anticiper les risques d’inondations afin d’éviter les dommages humains et matériels et de réduire les coûts sociaux et économiques.

La prévision du taux de précipitations consiste à prévoir la quantité de pluie, neige ou grêle, qui tombera sur une surface donnée à un instant précis. Comme nous le verrons dans ce document, il est important d’avoir un dispositif de prévision pertinent et précis, afin de pouvoir considérer un horizon temporel éloigné pour la prévision, tout en conservant des résultats exploitables. La qualité de la prévision des précipitations dépend de plusieurs paramètres, mais le point central repose sur le type de données utilisé (et sur ses caractéristiques) ainsi que sur la disponibilité effective et continue de ces données.

L’étude de la littérature météorologique permet de constater que les méthodes opérationnelles de prévision de précipitations reposent sur plusieurs types de capteurs : pluviomètres, radars au sol, et imagerie satellite. Les données de télédétection (radar et satellite) sont parmi les plus utilisées actuellement. En effet, leur couverture horizontale a une taille importante et leur résolution spatiale est compatible avec la taille des structures précipitantes.

Dans la littérature scientifique, il existe de nombreuses approches pour réaliser la prévision des taux de précipitations. Cependant, on peut distinguer deux classes prédominantes. La première consiste à estimer directement ces taux à partir d’une historique de mesures quantitatives de précipitation ponctuelles. La seconde approche consiste à s’appuyer sur l’information structurée présente dans les images observées. Ceci permet de calculer la dynamique de ces structures précipitantes puis de prévoir leur déplacement, afin d’estimer les taux de précipitations futurs, à l’horizon choisi. C’est ce dernier type d’approche qui a été privilégié dans ce travail de thèse, en raison des performances annoncées dans la littérature scientifique dédiée à la prévision des précipitations. Dans ce contexte d’utilisation des images, la fréquence temporelle des acquisitions radar est la plus adaptée et c’est donc le type de données que nous avons utilisé.

Ce travail de thèse a été réalisé dans le contexte d’une bourse Cifre, avec le soutien d’un encadrement tripartite Inria, Weather Measures<sup>2</sup> et Sorbonne Université. Weather Measures est une entreprise située à Clermont-Ferrand, qui est spécialisée en météorologie de précision et dans la valorisation de données météorologiques multi-sources. La société développe, entre autres, des technologies pour améliorer la prévision des taux de précipitation pour un horizon temporel dit “à court terme”<sup>3</sup>, c’est-à-dire à une échéance

---

2. <https://www.weather-measures.fr/>

3. En anglais, on parle de *nowcasting*

comprise entre 30 minutes et deux heures.

Weather Measures dispose de sa propre chaîne de traitement opérationnelle, basée sur un réseau de radars météorologiques au sol. Elle exploite, en temps réel, le logiciel *Rain Nowcast* [Lep15], issu d’une collaboration scientifique antérieure, menée conjointement par la société Weather Measures et Inria<sup>4</sup>.

Le logiciel *Rain Nowcast* fournit une prévision des précipitations à partir d’une source unique de données radar, avec un horizon temporel très court, choisi au maximum à une valeur de 30 minutes. Cette limitation de l’horizon temporel a été jugée incompatible avec une exploitation commerciale de la méthode, même si celle-ci est apparue prometteuse et a fourni des résultats de qualité pour des événements majeurs de crue rapide.

Dans ce contexte historique, l’objectif général du travail de thèse, présenté dans ce manuscrit, est d’améliorer significativement les performances de l’algorithme *Rain Nowcast*, en considérant un horizon temporel plus lointain, tout en conservant un niveau pertinent pour la qualité des résultats de prévision des précipitations.

Le premier objectif scientifique est de développer un algorithme multi-échelle, afin de pouvoir fusionner deux types de données radar, de résolutions spatiales et temporelles différentes. Nous disposons à cet effet de deux systèmes d’acquisitions d’images radar, à deux échelles spatiales différentes. Le premier système permet l’acquisition d’images radar à haute résolution (200 mètres) en bande X, que nous noterons par la suite “bande X”. Le second système est celui de Météo-France, qui fournit des images radar à basse résolution (1 kilomètre), issues du réseau de radars ARAMIS. Celui-ci est constitué de plusieurs types d’instruments, principalement en bande C. Ces images seront appelées données Panthere dans ce document. Une image Panthere couvre un domaine spatial bien plus étendu que celui des radars en bande X, mais elle présente une résolution spatiale plus grossière. L’intérêt de fusionner Panthere et bande X est de pouvoir, d’une part, obtenir une vision globale du site grâce aux données Panthere et, d’autre part, d’avoir une vision locale détaillée grâce aux données bande X. Un autre avantage, est la possibilité d’anticiper l’arrivée des structures nuageuses dans le domaine spatial correspondant à l’acquisition bande X, en les détectant préalablement dans les données Panthere. En fusionnant les deux types de données, nous avons donc le potentiel pour améliorer la qualité de l’estimation de la dynamique des structures pluvieuses, comme nous le proposerons au chapitre 3. Avoir une bonne estimation de la dynamique, et donc du déplacement des structures pluvieuses, est la condition *sine qua none* pour anticiper les déplacements et estimer les positions futures.

Le deuxième objectif scientifique, présenté dans ce document, concerne l’évolution de l’algorithme de prévision afin d’en augmenter l’horizon temporel. Dans sa version initiale,

---

4. <https://www.inria.fr/fr>

l'algorithme *Rain Nowcast* fournit des prévisions pertinentes pour un horizon temporel de 30 minutes. Théoriquement, *Rain Nowcast* peut naturellement fournir des prévisions pour des horizons temporels au-delà de ce seuil de 30 minutes. Cependant, en terme de qualité de résultats, et donc du point de vue opérationnel, les prévisions fournies par *Rain Nowcast* se dégradent nettement à partir de ce seuil. Nous souhaitons donc augmenter significativement la valeur de cet horizon temporel pour aboutir à une échéance de 1h30 à 2h, tout en garantissant une bonne qualité de prévision, en termes de localisation et de quantités de précipitations.

Dans le contexte opérationnel en entreprise, la chaîne de traitement de Weather Measures fonctionne en mode fenêtre glissante, cadencée à la fréquence d'acquisition des images bande X, qui est de 5 minutes. Cette chaîne de traitement fournit ainsi des prévisions à horizon de 30 minutes, réévaluées toutes les 5 minutes, donc à chaque nouvelle acquisition d'image. L'augmentation de l'horizon temporel de prévision, pour la méthode implémentée dans *Rain Nowcast*, implique automatiquement un sur-coût en temps de calcul et en ressources informatiques. Le troisième objectif de notre travail de recherche est donc de repousser l'échéance temporelle de prévision dans ce contexte opérationnel, sans faire exploser les contraintes calculatoires.

La suite de ce manuscrit est organisée en 5 chapitres. Le chapitre 2 est un état de l'art sur la problématique de l'estimation des précipitations. Il décrit ce que sont les précipitations et nous y présentons les différents instruments dédiés à leur détection et à leur quantification. Nous focalisons toutefois le propos sur les systèmes radar. Ce chapitre détaille ainsi l'acquisition des données radar et leurs propriétés physiques en lien avec la pluie. Nous y présentons également un état de l'art méthodologique sur les systèmes de prévision opérationnels. Ce chapitre se termine par la description de la méthode d'estimation de la dynamique des structures pluvieuses, utilisée par l'algorithme *Rain Nowcast*.

Le chapitre 3 est consacré à l'estimation du mouvement multi-échelle. Il présente les différentes méthodes que nous avons proposées pour intégrer plusieurs échelles de résolution spatiale dans l'algorithme d'estimation : une approche séquentielle et une approche parallèle, utilisant des images acquises par deux capteurs radar et respectant toutes deux les contraintes opérationnelles.

Le chapitre 4 se focalise ensuite sur la prévision qui utilise l'estimation du mouvement précédemment effectuée. Nous proposons deux méthodes. La première se base sur l'hypothèse d'un vent géostrophique et permet d'améliorer significativement l'estimation du mouvement. La seconde, basée sur l'analyse des histogrammes, permet de corriger les défauts liés aux schémas numériques utilisés dans l'implémentation.

Le chapitre 5 fournit une analyse et une évaluation quantitative, à l'aide de métriques

pertinentes, des résultats obtenus par nos contributions méthodologiques.

Nous concluons ce manuscrit de thèse au chapitre 6, en résumant nos travaux de recherche et en dégagant des perspectives scientifiques pour la suite de ce travail.



## Chapitre 2

# État de l'art sur l'estimation des précipitations

## Sommaire

---

<b>2.1 Précipitations</b> . . . . .	<b>23</b>
2.1.1 Définition et taxonomie . . . . .	23
2.1.2 Taux de précipitation . . . . .	28
<b>2.2 Instruments de détection et de mesure des précipitations</b> . .	<b>28</b>
2.2.1 Radiomètres imageurs météorologiques . . . . .	29
2.2.2 Pluviomètres . . . . .	33
2.2.3 Disdromètres . . . . .	36
2.2.4 Radar . . . . .	37
<b>2.3 Systèmes de prévision des précipitations à court terme, à partir d'images radar</b> . . . . .	<b>41</b>
2.3.1 Un peu d'histoire . . . . .	41
2.3.2 Approches basées sur la mise en correspondance de blocs d'images	43
2.3.2.1 Tracking Radar Echoes by Correlation (TREC) . . . . .	44
2.3.2.2 Continuity Tracking Radar Echoes by Correlation (CO-TREC) . . . . .	45
2.3.3 Approches basées sur la mise en correspondance de cellules de précipitation . . . . .	46
2.3.3.1 Thunderstorm Identification Tracking Analysis and Nowcasting (TITAN) . . . . .	47
2.3.3.2 Storm Cell Identification and Tracking (SCIT) . . . . .	48
2.3.3.3 TRACE3D . . . . .	48
2.3.3.4 CELLTRACK . . . . .	50
2.3.4 Approches par flot optique . . . . .	51
2.3.5 Variational Echo Tracking (VET) . . . . .	54
2.3.6 Rain Nowcast . . . . .	56
<b>2.4 Discussion et conclusion</b> . . . . .	<b>64</b>

---

Ce chapitre s’articule en trois parties. La première est consacrée aux précipitations proprement dites. Nous y présentons le processus de formation des précipitations et leurs différentes formes, avant de décrire les instruments de détection et de mesure, qui sont associés. La seconde partie propose un état de l’art sur les méthodes de prévision des taux de précipitation et s’intéresse à des exemples de systèmes opérationnels. Enfin, nous décrivons le système opérationnel utilisé pour les travaux et développements menés dans cette thèse. Il s’agit de *Rain Nowcast*, opéré par Weather Measures.

## 2.1 Précipitations

### 2.1.1 Définition et taxonomie

On désigne par le terme “*précipitation*” l’ensemble des particules, composées de molécules d’eau, qui tombent de l’atmosphère vers le sol. Celles-ci peuvent être à l’état liquide (pluie, bruine) ou solide (neige, grêle, ...). Ces particules sont appelées, d’une manière générale, *hydrométéore*, qui provient de la fusion des deux mots “*hydro*” et “*météore*”. Leurs origines grecques “*hudôr*” et “*meteôra*” signifient respectivement “eau” et “qui est en haut”. Il existe de nombreux types d’hydrométéores. Leur taille et leur vitesse de chute varient fortement. Cela explique les difficultés de réaliser des mesures qui soient quantitativement pertinentes.

La formation des précipitations passe par plusieurs étapes et résulte de nombreux phénomènes physiques. Sous l’effet de la chaleur du soleil, l’eau présente à la surface de contact entre, d’une part, les océans, mers, fleuves, lacs, *etc*, et, d’autre part, l’atmosphère s’évapore. Cette évaporation représente le passage de la phase liquide de l’eau à une phase gazeuse. L’eau est, nous le savons, constituée de molécules  $H_2O$ , qui s’attirent mutuellement et vibrent plus ou moins fortement en fonction de leur énergie cinétique. La force d’attraction entre les molécules d’eau appartenant à la surface liquide des mers, lacs et rivières rend difficile leur échappement vers l’atmosphère. Toutefois, sous l’effet de la chaleur du soleil, l’énergie cinétique des molécules d’eau augmente, jusqu’à dépasser cette force d’attraction. C’est ce phénomène qui permet alors aux molécules d’eau de s’évaporer.

Au fur et à mesure que l’eau s’évapore, la quantité d’eau présente dans l’air augmente. La présence de la vapeur d’eau dans l’atmosphère est ce qu’on appelle l’humidité relative. Au-delà d’une certaine concentration d’humidité, la vapeur d’eau se transforme à nouveau en eau liquide : c’est le phénomène de condensation. On dit alors que l’air est saturé : la pression de la vapeur d’eau a atteint sa valeur maximale pour la température donnée et n’augmente plus. De façon plus imagée, on peut dire que s’il y a trop de molécules d’eau



en suspension dans l'air, un certain nombre d'entre elles retournent à l'état liquide.

Une échelle de valeurs est utilisée pour caractériser l'humidité relative dans l'atmosphère, dont les limites correspondent, d'une part, à l'absence de vapeur d'eau dans l'atmosphère (ce qui n'est rigoureusement jamais réalisé), affectée de la valeur 0%, et, d'autre part, à la saturation, représentée par la valeur 100%.

La vapeur d'eau provenant de l'évaporation est soulevée dans l'atmosphère, jusqu'à atteindre des altitudes où la température est très basse. Là, en présence de noyaux de condensation, qui sont des micro-particules de matière solide tels que cristaux de sel marin, pollens, poussière, ..., la vapeur d'eau se condense et prend la forme de gouttelettes d'eau. P.J. Coulier en 1875 et J. Aitken en 1880 [Spu00], conçoivent les premiers modèles d'expérimentation permettant d'étudier le processus de condensation de la vapeur d'eau. Ces deux scientifiques ont démontré expérimentalement le rôle décisif des noyaux de condensation dans la formation des gouttelettes d'eau.

En se basant sur la loi de Raoult et la loi de l'effet Gibbs-Thomson, August Köhler fut le premier à formuler les fondements de la théorie de la condensation en proposant l'équation (2.1), qui relie le diamètre  $D_p$  de la gouttelette aux grandeurs suivantes : la pression de vapeur d'eau  $p_{eau}$ , la pression de saturation au-dessus d'une surface plane  $p^0$ , la tension de surface entre l'eau liquide et la vapeur d'eau  $\sigma_{eau}$ , la masse volumique de l'eau pure  $\rho_{eau}$ , le nombre de moles de la solution  $n_s$  et la masse molaire de l'eau  $M_{eau}$  [RY89] :

$$\ln \left( \frac{p_{eau}(D_p)}{p^0} \right) = \frac{4M_{eau}\sigma_{eau}}{RT\rho_{eau}D_p} - \frac{6n_sM_{eau}}{\pi\rho_{eau}D_p^3} \quad (2.1)$$

Les hydrométéores ont une taille qui varie en ordre de grandeur de  $10 \mu\text{m}$  à  $2 \text{mm}$ . Pour les gouttelettes contenues dans les nuages, le diamètre  $D$  est généralement inférieur à  $100 \mu\text{m}$  et globalement limité à  $200 \mu\text{m}$ . De plus, les gouttelettes de diamètre inférieur à  $50 \mu\text{m}$  y sont largement majoritaires. Les diamètres les plus importants sont atteints par les cristaux, dont le processus de création et la géométrie sont complexes.

Tous les hydrométéores sont naturellement soumis au champ de pesanteur terrestre  $g$ . Compte tenu de leur masse, elles chutent à une vitesse  $v$ , inférieure à  $1 \text{m/s}$ . Une estimation raisonnable de vitesse limite  $v$  est donnée par l'équation (2.2), en considérant que les hydrométéores ne sont soumis, outre leur poids, qu'à la résistance de l'air exprimée par la loi de Stokes :

$$v = \frac{g(\rho_e - \rho_a)}{18\eta_a} D^2 \quad (2.2)$$

avec :

- $\rho_e \approx 1000 \text{ kg/m}^3$ ,
- $\rho_a \approx 1,29 \text{ kg/m}^3$ ,
- $\eta_a \approx 13,7 \mu\text{Pa} \times \text{s}$ ,
- $g = 9,81 \text{ m/s}^2$ .

Les gouttelettes formées par le processus de condensation, décrit ci-dessus, se regroupent et forment un nuage. Glickman (2000) [GS00] définit la notion de nuage comme un ensemble visible de petites gouttelettes d'eau et/ou cristaux de glace en suspension dans l'atmosphère.

En 1803, le météorologue amateur Luke Howard [HvG12] élabore une classification des nuages au moyen de termes latins. Cette classification sera par la suite considérée comme le fondement du système actuel, adopté par l'Organisation Météorologique Mondiale (OMM). L'OMM considère dix grandes classes de nuages, correspondant chacune à une forme caractéristique et se produisant à un intervalle spécifique d'altitude<sup>1</sup>. De plus, pour chacune de ces classes, il existe des sous-groupes caractérisant la forme et la structure interne des nuages, leur transparence, ainsi que l'agencement de leurs éléments constitutifs. Le tableau 2.1 et la figure 2.1 présentent les dix grandes classes de nuages.

précipitant	taille de précipitant	classe de nuage
bruine	0,1 à 0,5 mm	Stratus
neige	2 à 20 mm	Nimbostratus, Altostratus, Stratocumulus, Cumulus congestus, Cumulonimbus, Stratus(exceptionnellement)
pluie	0,5 à 6 mm	Nimbostratus, Altostratus, Stratocumulus, Cumulus congestus, Cumulonimbus, Altostratus(rarement)
granule de glace	$\leq 6\text{mm}$	Nimbostratus , Altostratus.
neige en grains	$\leq 1\text{mm}$	Stratus, Brouillard.
neige roulée	1 à 5 mm	Stratocumulus, Cumulus congestus, Cumulonimbus
grésil	2 à 5 mm	Cumulus congestus, Cumulonimbus.
grêle	5 à 50 mm	Cumulonimbus

TABLE 2.1 – Classification des nuages et illustration de leurs caractéristiques. Origine : OMM.

Les nuages qui sont constitués uniquement d'eau liquide contiennent typiquement quelques 100 à 1000 gouttelettes d'eau par  $\text{cm}^3$ . Toutefois, on trouve aussi des hydrométéores sous forme de glace dans les nuages. Ceux-ci se forment à des températures

---

1. <https://public.wmo.int/fr/journ%C3%A9e-m%C3%A9t%C3%A9orologique-mondiale-2017/classification-des-nuages>

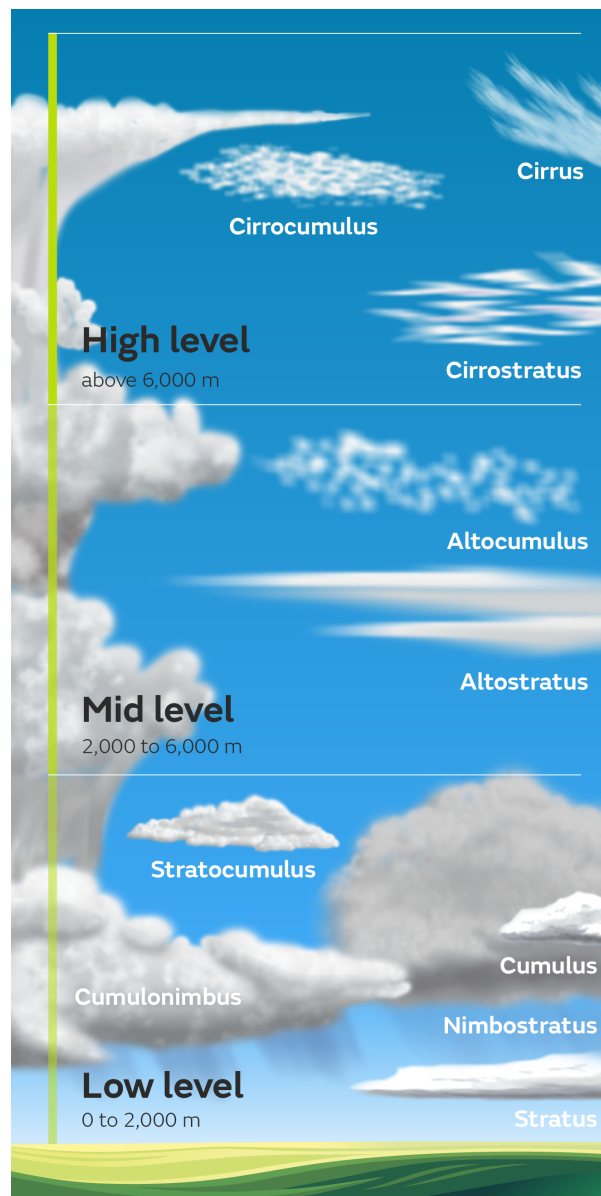


FIGURE 2.1 – Quelques exemples de structures nuageuses. Origine : OMM.

très basses, typiquement ( $\leq -20\text{ °C}$ ), en présence d'un type particulier d'aérosols : des noyaux de glaciation et/ou des noyaux de déposition. Les aérosols concernés modifient les conditions de surfusion et de sursaturation requises afin de permettre la formation de la glace dans le nuage. Les particularités de ces aérosols, par rapport aux noyaux de condensation, sont doubles : ils présentent une faible occurrence, ce qui explique la rareté de présence de glace dans les nuages ; leur taille est importante, ce qui rend possible de lier fortement des molécules d'eau dans ce type d'hydrométéores. Dans les nuages contenant ces cristaux de glace, il est assez rare de rencontrer plus d'un cristal par  $\text{cm}^3$ .

À l'intérieur d'un nuage, une fois les gouttelettes d'eau et/ou les cristaux de glace formés, ceux-ci poursuivent un processus de croissance par interaction avec leur environnement : les gouttelettes d'eau fusionnent entre elles, tandis que les cristaux grandissent par un phénomène d'absorption de la vapeur. Quand la masse des hydrométéores devient significative, ils tombent sous l'effet de la gravité, créant les précipitations que nous connaissons.

Les précipitations, lorsqu'elles se produisent, prennent une forme liquide ou solide selon les valeurs de température de l'air. La figure 2.2 décrit les différents types de précipitation selon la température dans l'atmosphère.




FIGURE 2.2 – Types de précipitation selon les températures dans l'atmosphère. Zone en bleu : température négative. Rouge : température positive. Marron : le sol (source : Wikipedia).

Par ailleurs, les hydrométéores subissent des collisions entre eux lors de leur chute. C'est un phénomène très complexe, qui dépend de plusieurs paramètres et qui génère des conséquences diverses :

- une coalescence, qui correspond à une fusion des gouttes d'eau en collision,
- une fragmentation en plusieurs gouttes d'eau, ou bien
- un rebond sans modification des gouttes d'eau.

La figure 2.3 illustre ces trois types possibles de collision.

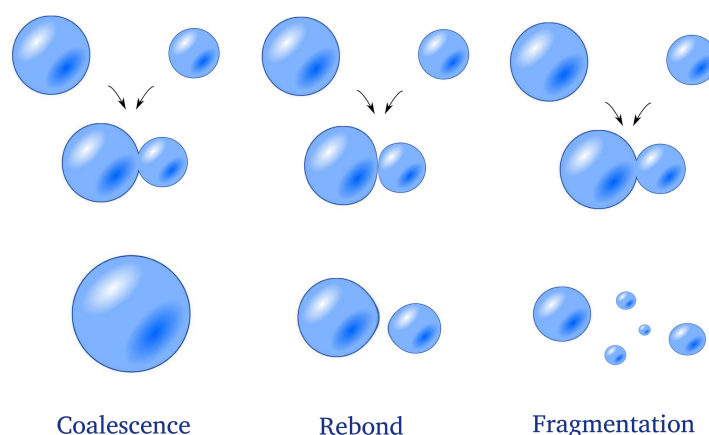


FIGURE 2.3 – Différents types de collision entre gouttes d'eau.

### 2.1.2 Taux de précipitation

Le taux de précipitation (SRI : Surface Rainfall Intensity) est calculé comme le ratio de la quantité de pluie tombée par la valeur de la surface  $S$  et la durée de l'intervalle de temps  $\Delta t$  correspondant. Ce taux de précipitation est exprimé en mm/h et est mathématiquement défini par :

$$\text{SRI} = \frac{1}{S} \frac{1}{\Delta t} V_p \quad (2.3)$$

où  $V_p$  est le volume de précipitations tombé sur  $S$  durant le temps  $\Delta t$ . À partir de l'équation (2.3) on peut calculer une grandeur, appelée cumul de précipitations (SRT : Surface Rainfall Total) et qui s'exprime en mm : elle mesure la quantité de pluie tombée sur la surface  $S$  pendant la durée  $\Delta t$  et est définie par :

$$\text{SRT} = \text{SRI} \times \Delta t \quad (2.4)$$

Les deux notions SRI et SRT sont fondamentales pour les méthodes de prévision que nous avons développées et qui sont présentées dans les chapitres 3 et 4.

## 2.2 Instruments de détection et de mesure des précipitations

Il existe 4 principaux types d'instruments pour la détection et la mesure des précipitations : les imageurs météorologiques, les pluviomètres, les disdromètres et les radars. Nous expliquons brièvement le mode d'acquisition et la nature des données fournies pour chacun d'eux.

### 2.2.1 Radiomètres imageurs météorologiques

Ces capteurs fournissent des images dans différentes longueurs d'onde. Ils sont embarqués à bord de satellites, généralement ceux à orbite géostationnaire. Un satellite est un véhicule placé dans l'espace avec une altitude variable, qui est principalement classée en trois niveaux :

- altitude basse, allant jusqu'à 2 000 kilomètres, qui représente la limite de l'orbite terrestre basse. On y trouve les satellites de télédétection, les satellites de télécommunications, ainsi que quelques stations spatiales, dont la Station Spatiale Internationale,
- altitude moyenne, située entre 2 000 et 35 786 kilomètres, qui représente l'orbite terrestre moyenne,
- altitude haute, au-dessus de 35 786 kilomètres.

Les satellites orbitent autour de la Terre selon une trajectoire définie en fonction de nature de leur mission. Le premier satellite, appelé *Sputnik*, a été lancé en 1957. Depuis cette date, les satellites jouent un rôle majeur, à la fois sur le plan économique (télécommunications, positionnement), militaire (renseignement, détection des cibles) et scientifique (observation astronomique, observation de la Terre, observation des océans, qualité de l'air,...). Grâce à la multiplicité des données qu'ils fournissent, les satellites sont devenus incontournables pour la compréhension du monde, la modélisation des changements climatiques et le support au fonctionnement de la société de l'information.

En particulier, la météorologie a été profondément marquée par l'arrivée de cette technologie. En 1959, le premier satellite météorologique appelé *Vanguard-2* est lancé. Il a eu pour mission de mesurer la couverture nuageuse à l'aide de deux télescopes optique et de déterminer la densité atmosphérique en fonction de l'altitude, la latitude, la saison et l'activité solaire. Depuis, les satellites météorologiques constituent, pour les centres météorologiques, une source d'information primordiale. Les phénomènes observés évoluent souvent très rapidement, sur des durées variant entre quelques heures pour les cyclones et les tempêtes à quelques jours pour les structures nuageuses de type vortex. Les satellites météorologiques peuvent suivre les évolutions spatiales des structures nuageuses avec une résolution temporelle et une résolution spatiale, qui dépendent essentiellement de leur altitude. Les systèmes d'acquisition météorologiques sont principalement installés sur deux types de satellites, les satellites géostationnaires et les satellites circumpolaires. La figure 2.4 présente deux images prise par des imageurs installés sur des satellites situés à deux altitudes différentes.

Les satellites géostationnaires gravitent autour de la Terre sur une orbite située à 36.000 km d'altitude au-dessus de l'équateur. Ils sont dits stationnaires, car leur vitesse




FIGURE 2.4 – Ces images proviennent d’imageurs satellite. À gauche : image prise le 22 mars 2002 par le satellite AQUA (circumpolaire). À droite : image prise le 21 avril 2018 par DSCOVR (géostationnaire).

angulaire autour de l’axe polaire est la même que celle de la terre, ce qui les rend immobiles par rapport au référentiel terrestre. Leur altitude élevée et leur position fixe par rapport à la Terre leur permettent d’observer, de façon continue, la même surface du globe terrestre et de délivrer des images couvrant une large part du globe terrestre. Les satellites géostationnaires récents permettent d’observer, en simultanée, jusqu’à 40% de la surface terrestre avec une résolution temporelle allant de 15 minutes pour GOES-8 et MSG à 5 minutes pour Météosat-8 en mode rapide scan. Leur résolution spatiale est d’environ 3 km. Ces imageurs-satellites sont bien adaptés pour caractériser l’évolution des nuages, pour réaliser des études sur le suivi des phénomènes cycloniques, le suivi des zones de gel, le déplacement des icebergs détachés des pôles, et pour observer les cendres volcaniques, les feux de forêt ou encore les tempêtes de sable dans le désert ou de poussière à grande échelle ...

Cependant, les satellites géostationnaires étant placés à une altitude importante par rapport à la terre, ils présentent un désavantage majeur en ce qui concerne la résolution spatiale des acquisitions. Étant situés à la verticale de l’équateur, c’est là que la résolution spatiale y est la plus fine. Ailleurs, la résolution dépend de la distance à l’équateur et diminue en allant vers les régions polaires. En conséquence, au-dessus de 60 degrés de latitude Nord et au-dessous de 60 degrés de latitude Sud, les acquisitions réalisées deviennent presque inutilisables.

Un autre inconvénient de l’élévation des satellites géostationnaires concerne l’impossibilité d’utiliser les techniques d’acquisition micro-ondes et radars. Ces satellites utilisent de fait




FIGURE 2.5 – Longueurs d'onde et bandes de fréquence.

des capteurs radiomètres-imageurs. Cela limite d'autant l'intérêt de ce type de satellites en ce qui concerne l'étude des précipitations à visée de prévision. Pour contourner les deux inconvénients précités, les capteurs utilisés pour la prévision des précipitations sont portés par des satellites circumpolaires. Ceux-ci orbitent à une altitude d'environ 850 km. Ils ne sont donc pas affectés par la problématique d'élévation. En revanche, et contrairement aux satellites géostationnaires, ces satellites ne sont pas immobiles par rapport au globe terrestre. Plus l'orbite du satellite est basse, plus sa vitesse orbitale est grande. À une altitude de 850 km, les satellites circumpolaires réalisent ainsi un tour du globe terrestre en deux heures. L'orbite de ces satellites passe au-dessus des deux pôles terrestres et leur trajectoire est héliosynchrone. En général, un satellite météorologique circumpolaire se déplace parallèlement au déplacement apparent du Soleil et couvre l'ensemble du globe en 12 heures. Cette caractéristique permet de revisiter chaque lieu du globe terrestre deux fois par jour, y compris les régions polaires, qui ne sont pas visibles par les satellites géostationnaires. Les satellites circumpolaires présentent une couverture spatiale très large, avec une résolution spatiale fine, d'environ 1 km pour GOES-8 et Météosat-8. En revanche, leur période de revisite est importante et la résolution temporelle des images est peu adaptée au suivi des structures nuageuses.

Les données délivrées par les capteurs météorologiques embarqués sur des satellites sont généralement issues de radiomètres-imageurs. Ces capteurs mesurent le rayonnement provenant des éléments de la surface terrestre et/ou de l'atmosphère. Ils disposent de plusieurs canaux d'observation, correspondant chacun à un intervalle spécifique de longueurs d'onde du spectre électromagnétique. Les trois principaux canaux utilisés sont : le canal visible, le canal infrarouge et le canal vapeur d'eau. La figure 2.5 présente les différents canaux appelés aussi bandes de fréquences, ainsi que leurs longueurs d'ondes respectives.

1. Le canal visible est celui qui a été utilisé sur les satellites les plus anciens. Ce canal mesure les rayonnements électromagnétiques émis dans l'intervalle de longueurs d'onde comprises entre 0,4 et 1,1  $\mu\text{m}$ . Cette gamme de longueurs d'onde est très proche de ce que l'œil humain perçoit. La réflectivité des nuages dépend de leur épaisseur : plus cette réflectivité est importante plus le nuage apparaît clair. Comme ce canal dépend exclusivement de l'éclairage par le soleil, il n'est utilisable que



lorsqu'il fait jour sur la terre. C'est une limitation qui constitue un inconvénient majeur pour l'utilisation de ces données.

2. Le canal infrarouge concerne le rayonnement électromagnétique pour des longueurs d'onde comprises dans l'intervalle entre 10,5 et 12,5  $\mu\text{m}$ . Il permet ainsi de mesurer l'émission thermique des molécules. Ce canal quantifie la température des objets observés. Dans les faits, il s'agit de la mesure de la partie supérieure des nuages ou de la surface terrestre, si celle-ci n'est pas masquée par les nuages. Plus les cibles sont froides, plus l'émission thermique est faible et plus la zone correspondante sur l'image apparaît sombre et, à l'inverse, plus les cibles sont chaudes plus elles apparaissent claires sur l'image. On sait que dans l'atmosphère, la température est directement reliée à l'altitude : plus cette dernière est élevée et plus la température est faible. Cette propriété est utilisée pour déduire l'altitude du sommet des nuages ainsi que leur classe 2.1, à partir de la mesure de température. L'avantage d'un capteur infrarouge est qu'il est uniquement dépendant de l'émission thermique des cibles observées. En conséquence, il est indépendant des émissions solaires réfléchies sur ces cibles, puisque l'émission thermique de ces photons est négligeable.
3. Enfin, le canal vapeur d'eau mesure le rayonnement électromagnétique dans l'intervalle de longueurs d'onde comprises entre 5,7 et 7,1  $\mu\text{m}$ . Ce canal correspond aux longueurs d'onde d'absorption par les molécules d'eau. Le capteur de vapeur d'eau permet donc d'estimer la partie du rayonnement infrarouge émise par la Terre et absorbée par la vapeur d'eau présente dans l'atmosphère. Les mesures obtenues permettent ensuite de calculer la quantité de vapeur d'eau présente dans l'atmosphère. Ce canal est particulièrement sensible et permet de mesurer de faibles quantités d'eau. Il permet ainsi une bonne caractérisation de l'ensemble de la surface et aussi bien des zones sèches que des zones humides. Cependant, ce type de capteur n'est pas en capacité de donner une information sur l'altitude et la nature des nuages.

La figure 2.6 illustre un exemple d'image satellite prise dans chacun des trois canaux par le satellite MSG-3.

Afin d'exploiter de façon optimale les informations obtenues par ces trois capteurs, des techniques de traitement d'images sont élaborées pour fusionner les différentes modalités d'acquisition et fournir des caractéristiques détaillées sur les cibles observées à savoir : les profils de l'humidité, de la température, de la saturation de l'atmosphère en  $\text{CO}_2$  et en aérosols...




FIGURE 2.6 – Acquisitions du satellite MSG-3, le 19 septembre 2016 à 9h UTC, respectivement dans le canal visible, infrarouge et vapeur d’eau. Origine : Météo France.

## 2.2.2 Pluviomètres

Le pluviomètre est un appareil destiné à mesurer les précipitations. Il est considéré comme l’un des plus anciens instruments de mesure des précipitations et comme étant le plus précis pour mesurer la quantité de pluie effectivement tombée au sol.

Les pluviomètres les plus anciens mesurent des quantités de précipitations. Le premier pluviomètre connu date ainsi de 1441 et a été retrouvé en Corée. Malgré tout, des manuscrits, écrits en langue Indo-Aryenne, indiquent que des mesures de pluies ont été effectuées dans plusieurs régions de l’Inde dès le quatrième siècle avant J.C., dans le cadre des pratiques agricoles. À l’origine, le pluviomètre était un instrument manuel, constitué d’un récipient permettant de récolter la pluie tombée sur sa surface. Un agent relevait régulièrement la quantité d’eau par une lecture directe sur l’appareil. Actuellement, ce type de pluviomètre est souvent utilisé par les amateurs, en raison de son faible coût et de sa facilité d’utilisation (voir figure 2.7).

Les pluviomètres plus modernes mesurent des taux de précipitation. Il s’agit de la quantité de précipitations tombée sur une surface prédéfinie, généralement située au niveau de sol, durant un intervalle de temps donné. Ils sont constitués de deux parties principales : un collecteur pour recueillir l’eau et un système de mesure pour comptabiliser la quantité d’eau. Ces pluviomètres sont dotés d’un capteur électronique, qui permet d’enregistrer en continu, sans intervention humaine, la courbe du taux de pluie. Leur mode de fonctionnement est relativement simple. L’eau arrive sur les collecteurs sous l’effet de la gravitation et elle est ensuite canalisée vers un système de mesure, constitué de deux petits réservoirs, fixés sur un auget basculant et associés à un système électronique de comptage. La figure 2.8 illustre le fonctionnement du pluviomètre à auget basculant.



FIGURE 2.7 – Pluviomètre manuel.




FIGURE 2.8 – Fonctionnement d'un pluviomètre à auget basculant.

Quand l'eau accumulée dans le premier réservoir dépasse un certain poids, celui-ci bascule. Cela provoque la fermeture brève du circuit électronique et le déversement de son contenu d'eau. Le deuxième réservoir se met alors en position de remplissage. Puis, une fois rempli, il bascule tout en réactivant le circuit électronique à son tour. Et ainsi de suite... On connaît la quantité de pluie tombée entre deux dates de basculement, puisqu'elle correspond au contenu des deux réservoirs. En divisant cette valeur par la durée entre ces deux dates, on aboutit à la mesure du taux de pluie. On obtient ainsi l'évolution temporelle du taux de précipitation moyen sur la période choisie.

La mesure s'exprime généralement en millimètres d'épaisseur ou en litres par mètre carré ( $1\text{ mm} = 1\text{ l/m}^2$ ). Aussi précise qu'elle puisse apparaître, la mesure effectuée par un pluviomètre est affectée par plusieurs sources d'erreurs : météorologique ou/et matérielle.

Les effets météorologiques sont les suivants :

- le vent, qui dévie la trajectoire de la chute de la pluie et qui produit un décalage spatial des mesures,
- l'évaporation de l'eau du réservoir, qui sous-estime les mesures en cas de pluies très faibles, et surtout en période de fortes chaleurs.

Les sources d'erreurs matérielles concernent :

- la perte d'eau au moment du basculement, qui peut être significative en cas de fortes pluies,
- l'emplacement du pluviomètre, en particulier s'il est installé à proximité d'obstacles : arbre, balcon, bas d'une colline ...
- enfin les problèmes de maintenance, responsables de la sous-estimation des mesures : bouchage partiel ou total de système de canalisation menant vers les résér-

voirs, blocage partiel du basculement de l'auget, dû aux résidus cumulés.

Les modèles de prévision, nous le verrons dans le document, font appel aux données des pluviomètres pour la calibration et la validation des prévisions, compte tenu de leur précision par rapport aux autres types de mesure, notamment celles obtenues par les radars au sol.

### 2.2.3 Disdromètres

Le disdromètre est un instrument utilisé en météorologie pour mesurer la distribution du diamètre des hydrométéores, ainsi que leur vitesse de chute.

La distribution du diamètre correspond au nombre de particules pour chaque valeur de diamètre. Cette distribution permet ensuite de calculer le taux de précipitations. Les mesures du disdromètre permettent l'étalonnage des appareils de détection de pluies, comme le radar météorologique (que nous présenterons en détails à la section 2.2.4).

Le disdromètre est un appareil particulièrement élaboré, qui est principalement utilisé soit dans un contexte de recherche, soit dans les stations météorologiques automatiques, soit comme capteur de précipitations le long des pistes d'aéroports.

Il existe deux types de disdromètre : mesure par impact ou mesure optique. Le premier est un capteur de force qui transforme le choc causé par l'énergie cinétique de l'hydrométéore s'y écrasant en une impulsion électrique, dont l'amplitude est proportionnelle à la masse et à la vitesse de chute de l'hydrométéore. Ce type de disdromètre est conçu pour les précipitations liquides. La forme légèrement conique de la plaque mobile sur le dessus de l'appareil permet aux précipitations de s'écouler pour laisser la place aux nouvelles gouttes arrivant sur la surface. Dans le cas de neige, il devient peu utile à cause de la faible masse des flocons.

Le deuxième type de disdromètre utilise un faisceau lumineux, qui est interrompu lors du passage d'un hydrométéore. On installe donc, sur le même plan horizontal, un émetteur et un capteur, avec un espace entre les deux pour observer le passage des précipitations. Le faisceau lumineux peut être laser, infrarouge ou même micro-ondes. Lors du passage d'une goutte au travers du faisceau lumineux, l'énergie lumineuse reçue par la photodiode du capteur du dispositif devient plus faible. Cette diminution de valeur est un signal, directement lié au passage de la goutte (voir figure 2.9). Son amplitude et sa durée sont respectivement proportionnelles à la section verticale et au temps de résidence (vitesse de chute) de la goutte dans le faisceau lumineux.

Cette vitesse de chute de la goutte au travers du faisceau est calculée comme le rapport entre la hauteur du faisceau sur la durée du signal, i.e. le temps de résidence, en faisant l'hypothèse que la goutte passe perpendiculairement au faisceau. Ce genre de capteur peut

être utilisé pour mesurer tous les types de précipitations, autant solides que liquides.

En disposant deux disdromètres par mesure optique sur la même horizontale et à angle droit l'un de l'autre, on obtient une vue à deux dimensions des hydrométéores passant dans les deux faisceaux. En utilisant une caméra au lieu d'un capteur de lumière dans chaque appareil, on peut obtenir des images de chaque cible. Cela permet de mener des études sur la forme des gouttes de pluie selon leur diamètre ou sur la forme des flocons de neige selon la température extérieure.




FIGURE 2.9 – Fonctionnement du disdromètre. Inspiré de [FL18].

## 2.2.4 Radar

L'idée d'utiliser les ondes pour la détection des objets date de la fin du XIX<sup>ième</sup> siècle, mais il a fallu attendre plusieurs décennies avant que le premier radar ne soit opérationnel. En 1935, le physicien britannique Robert Watson-Watt (1892-1973) réussit à expérimenter le premier système de radar permettant de détecter un avion. Durant la seconde guerre mondiale, les radars jouent un rôle crucial dans le conflit, ce qui a permis le développement important de cette technologie. Les opérateurs radars ont naturellement très vite remarqué que des échos parasites apparaissent sur le signal, qui semblent venir des précipitations. Des techniques furent alors mises au point pour filtrer ces échos gênants. Les météorologues, quant à eux, ont rapidement pris conscience du potentiel de ces échos pour la détection et la quantification des précipitations. Dès la fin du conflit militaire de la seconde guerre mondiale, certains radars sont mis à disposition pour ces applications météorologiques.

Le RADAR (RAdio Detecting And Ranging) est un outil de télédétection actif, puisqu'il fournit sa propre source d'énergie électromagnétique. Il est basé sur le principe de réflexion des ondes. Il émet, au moyen d'une antenne, des impulsions d'ondes électromagnétiques, qui se propagent dans l'atmosphère dans une direction bien définie et avec




FIGURE 2.10 – Une image radar prise le 2 novembre 2019 à 23 :45 UTC. Source : Info-climat

une vitesse fixe et égale à la vitesse de la lumière dans l’atmosphère. En présence d’un obstacle, une partie de ces ondes est réfléchiée, qui est ensuite détectée et mesurée par un récepteur installé sur le radar. Une cible réfléchit le signal en le dispersant dans toutes les directions. Ce phénomène est appelé diffusion. Donc, seule une partie du signal initial repart dans la direction opposée à celle des ondes incidentes. Ce phénomène est appelé rétrodiffusion.

La rétrodiffusion d’un objet dépend de sa réflectivité notée  $Z$ , qui est définie par [Mer16] :

$$Z = \int n(D)D^6 dD \quad (2.5)$$

où  $D$  représente le diamètre d’un hydrométéore et  $n$  est la distribution en taille de l’ensemble des hydrométéores,  $n(D)$  est le nombre d’hydrométéores de diamètre  $D$ .

La figure 2.10 montre un exemple d’acquisition radar.

Le radar émet un rayonnement de faisceau très étroit dans un plan vertical. L’angle formé entre le faisceau et l’horizon est appelé **angle de site** ou **élévation**. Certains capteurs radar peuvent effectuer un balayage vertical sur plusieurs angles de site : ce sont des radars multi-élévations, voir figure 2.11. Ils permettent ainsi une analyse de l’atmosphère sur plusieurs niveaux d’altitude et établissent des profils verticaux de l’atmosphère. Malheureusement, cela se fait au détriment de la durée totale d’acquisition, qui est naturellement plus longue dans le cas d’une acquisition multi-élévations.

Enfin, à l’aide d’un moteur, l’antenne du radar effectue une rotation sur elle-même,




FIGURE 2.11 – Principe d'acquisition multi-élevations

avec une vitesse qui varie selon le type de radar. Cela permet de pouvoir observer tout l'espace. La vitesse de rotation détermine la résolution temporelle du radar, qui correspond à la durée nécessaire pour une revisite de la même position, puisque pour acquérir sur le domaine complet à une altitude donnée, le radar doit faire un tour complet.

Le radar fonctionne en émettant des impulsions électromagnétiques de fréquence et de puissance constantes pendant une durée courte, appelée durée de l'impulsion. La durée nécessaire pour que la trajectoire aller d'une onde atteigne une cible est presque la même que la durée de rétrodiffusion de cette onde et la vitesse de propagation de l'onde est connue. Ces deux propriétés réunies permettent de calculer la distance  $r$  à laquelle se trouve la cible :

$$r = \frac{C_0 \Delta t}{2} \quad (2.6)$$

avec  $C_0$  la vitesse de lumière dans l'air et  $\Delta t$  la durée aller-retour du signal.

La résolution angulaire d'un capteur radar se définit comme l'écart angulaire minimal qui permette de distinguer deux cibles identiques, situées à une même distance par rapport à l'émetteur.

La figure 2.12 illustre le principe d'acquisition du radar météorologique.

Physiquement, le radar mesure la puissance  $P_r$  du signal rétrodiffusé par les cibles.  $P_r$






FIGURE 2.12 – Principe d’acquisition radar.

est reliée à la réflectivité  $Z$  par la formule [Mer16] :

$$P_r = \frac{CK^2Z}{r^2} \quad (2.7)$$

- $C$  est la constante du radar, qui s’exprime en  $\text{Wm}^3$ . Cette constante dépend des caractéristiques propres au radar : la puissance émise  $P_e$ , le gain de l’antenne<sup>2</sup>, la longueur d’onde, l’ouverture du faisceau et la période temporelle entre deux impulsions. En général, la valeur de cette constante  $C$  est déterminée expérimentalement.
- $K$  est la constante diélectrique de la cible, caractérisant l’atténuation du signal par les cibles présentes dans l’atmosphère. La constante  $K$  varie selon la nature des cibles. Par exemple, son carré  $K^2$  vaut 0,93 pour l’eau liquide et 0,2 pour la glace.

L’observation radar est considérée comme la source d’information la plus pertinente pour la détection en temps réel et le suivi de l’évolution des précipitations dans l’atmosphère avec une résolution temporelle fine [Bor02]. Les radars météorologiques sont des radars fixes situés au sol.

Les cibles concernées par les radars météorologiques sont des hydrométéores, qu’il importe de caractériser de manière fine. Comme l’objectif est de réaliser des prévisions de précipitations, il faut pouvoir caractériser les taux de précipitations en surface, notés  $R$ ,

---

2. Le gain d’une antenne est le rapport entre, d’une part, la densité de puissance moyenne rayonnée par l’antenne dans la direction considérée et, d’autre part, la densité de puissance pour un rayonnement isotrope.

au moyen des capteur radar. Il n'existe malheureusement pas de formule mathématique directe, qui relie la réflectivité  $Z$  et le taux de précipitation  $R$ . En effet, la relation qui les lie est complexe et dépend de la distribution en taille des gouttes de pluie, distribution inconnue et extrêmement variable selon les événements. Nous trouvons dans la littérature des relations du type :

$$Z = aR^b \tag{2.8}$$

où  $a$  et  $b$  sont des coefficients dont la valeur dépend de la nature des hydrométéores. Cette relation a été obtenue en faisant l'hypothèse que la distribution en taille des gouttes est décrite par la relation de Marshall et Palmer [MP48]. Dans la plupart des centres météorologiques opérationnels en Europe, les paramètres  $a$  et  $b$  sont fixés à une valeur constante, quelles que soient les conditions météorologiques [dC03] :  $a = 200$  et  $b = 1,6$ . Un autre avantage majeur pour l'utilisation des capteurs radars est leur capacité de prendre des mesures dans l'atmosphère à différentes altitudes.

## 2.3 Systèmes de prévision des précipitations à court terme, à partir d'images radar

La prévision à courte échéance des taux de pluie, à partir des observations météorologiques, a fait l'objet de nombreuses études. Ces études convergent toutes vers le même objectif d'estimation des quantités de pluie à un horizon temporel donné, mais divergent sur leur formulation théorique.

### 2.3.1 Un peu d'histoire

L'importance d'être en mesure de prévoir le temps qu'il fera dans les jours à venir est depuis très longtemps considéré comme particulièrement crucial et ceci pour de nombreuses applications. Les civilisations les plus anciennes faisaient appel aux dieux pour demander de leur amener soit de la pluie pour irriguer les champs et remplir les réserves d'eau soit le beau temps pour pouvoir se déplacer, nourrir les animaux ... Les Égyptiens sollicitaient Râ, dieu du soleil, les Mayas se tournaient vers Chac, quant aux Grecs, ils s'adressaient à Zeus pour pouvoir obtenir de bonnes récoltes, éviter les inondations, les tempêtes ... Ceux qui étaient capables de prédire le temps et semblaient donc être en capacité d'influencer sur ses caractéristiques étaient tenus en haute estime. Dès l'antiquité, aux alentours des années 650 av. J.-C., un ouvrage sur la météorologie a vu le jour en Chine, qui s'intéressait également aux prévisions. Les Babyloniens déduisaient le temps

futur grâce à l’observation des types de nuages. Aristote est aujourd’hui reconnu comme une référence historique de la science de la météorologie, grâce à son ouvrage “Météorologiques” autour de 340 av. J.-C. En 300 avant Jésus-Christ, le philosophe Théophraste publie “Les signes du temps”, premier ouvrage de prévisions météorologiques en Europe. Bien après, en 904, Ibn Wahshiyya, dans son livre “Agriculture Nabateann”, discute les signes précurseurs de certaines prévisions météorologiques, et en particulier celles correspondant aux pluies, en se basant sur l’observation des phases lunaires et le mouvement des vents.

Toutes ces méthodes anciennes de prévision du temps sont basées sur l’observation expérimentale de motifs répétitifs d’événements sur le lieu d’étude. Ainsi les explorateurs historiques, principalement des marins, prenaient des notes quotidiennes sur le temps qu’ils observaient. Ils furent donc les premiers collecteurs de données. Celles-ci servaient principalement comme descripteurs des événements et des lieux. C’est seulement en 1837, avec l’arrivée du télégraphe, que ces relevés individuels ont pu être diffusés rapidement et ont permis d’obtenir une idée précise, à un instant donné, de l’état de l’atmosphère. En projetant ces relevés sur des cartes géographiques, les météorologistes ont pu caractériser les changements temporels de l’état de l’atmosphère et réaliser des extrapolations, augurant déjà des prévisions basiques.

Francis Beaufort et Robert Fitzroy sont parmi les premiers à faire de telles prévisions [Ait19]. Malgré le scepticisme de leurs contemporains, ces deux membres de la Royal Navy réussirent à imposer leur travail scientifique grâce aux résultats obtenus. Le XX<sup>ième</sup> siècle a vu le développement de modèles physiques, exprimant les lois mathématiques qui régissent l’atmosphère. De nombreux scientifiques, dont ceux de l’école norvégienne, avec Vilhelm Bjerknes à sa tête, se sont consacrés à ces travaux. Ensuite, ces modèles physiques ont pu être exploités informatiquement, quand les ordinateurs sont devenus assez puissants, et ce dès les années 1970. Depuis, de nombreuses techniques et méthodes performantes ont vu le jour et sont utilisées de façon opérationnelle par les centres de météorologie.

Nous utilisons, dans la suite de ce document, le terme “approche” pour désigner un formalisme théorique, qui est ensuite décliné en une ou plusieurs techniques appelées algorithmes. En revanche, le terme de système de prévision désigne l’application opérationnelle de la prévision. Un système de prévision regroupe un ou plusieurs algorithmes issus d’une ou de plusieurs approches.

L’observation radar étant la plus pertinente pour la détection de la pluie, nous orientons donc nos travaux vers les approches de prévision des taux de précipitation à partir des données radar. En particulier, nous nous intéressons aux approches en deux étapes, fondées sur l’estimation de la dynamique suivie par l’extrapolation des cellules pluvieuses.

Nous appelons ces approches “*dynamique-extrapolation*” dans la suite du document.

Nous présentons ci-dessous un état de l’art sur ces approches, ainsi que sur les systèmes de prévision opérationnels basés sur celles-ci. Nous invitons donc le lecteur intéressé par les autres types de modèles de prévision à se reporter aux travaux de [Coi97] et [ID12].

Les approches de prévision dites dynamique-extrapolation se distinguent principalement dans la manière de détecter les cellules pluvieuses dans l’image et d’en estimer leur déplacement. En ce qui concerne la phase d’extrapolation, les différents systèmes procèdent globalement de façon assez similaire.

Deux approches différentes pour la partie estimation de la dynamique dominant dans les systèmes de prévision opérationnelle. La première approche est basée sur le principe du suivi des cellules pluvieuses détectées dans les images. La deuxième approche ne repose pas sur les structures car elle est basée sur le principe de la mise en correspondance de blocs d’images. Chaque stratégie a fait l’objet de nombreux travaux, qui ont donné naissance à plusieurs variantes algorithmiques. Plus récemment, une troisième approche, dite du flot optique, s’est imposée grâce aux performances obtenues.

### 2.3.2 Approches basées sur la mise en correspondance de blocs d’images

Cette approche est la plus basique et la plus ancienne. Elle a été introduite dans les années 60 par Hilst and Russo [HRC60]. L’idée de base consiste à identifier le déplacement entre deux images d’un ensemble de blocs, extraits dans la première image, afin d’estimer un vecteur de déplacement pour chacun de ces blocs. Chaque bloc est ensuite translaté au moyen de son vecteur de déplacement à partir de sa position sur la deuxième image afin de calculer une prévision, qui correspondent à sa position future.

Pour ce faire, il faut chercher pour chaque bloc, appelé aussi zone d’intérêt ou encore fenêtre d’interrogation, de la première image, le bloc qui lui ressemble le plus sur la deuxième image. Le critère de ressemblance repose sur l’intensité lumineuse des pixels du bloc examiné : nous supposons que ces valeurs sont conservées pendant le déplacement effectué au cours de la séquence temporelle. Une fois les correspondances spatiales établies, on déduit alors les déplacements sous forme de vecteurs. On peut traduire ce procédé en un problème d’optimisation résumé ci-dessous :

- sélectionner un bloc  $B$  dans l’image  $I_1$ ,
- chercher son correspond dans l’image  $I_2$  selon une mesure de similarité  $\text{Sim}$  :

$$\arg \max_{\delta x, \delta y} \int_B \text{Sim}[I_1(x + \delta x, y + \delta y), I_2(x, y)] dx dy \quad (2.9)$$

où  $(\delta x, \delta y)$  est le vecteur décrivant le déplacement du bloc  $B$  dans le domaine image et  $(x, y)$  représente les coordonnées du pixel courant.

Cette approche fournit des résultats pertinents si le bloc  $B$  a une taille adéquate en regard des structures que l'on souhaite prédire, dans notre cas les cellules pluvieuses. En revanche, l'approche n'est pas réellement efficace, en raison du coût de calcul important lié à l'optimisation, si l'objectif est de calculer un champ dense de vecteurs vitesse. La méthode peut naturellement être améliorée en restreignant la recherche du bloc similaire non plus dans toute la deuxième image, mais seulement dans un voisinage restreint de la position initiale. Ce voisinage peut être défini de façon statique ou évoluer au fur et à mesure de la séquence d'images.

Plusieurs algorithmes opérationnels ont été proposés à partir de cette approche. Les trois algorithmes les plus réputés, qui s'appellent TREC, COTREC et VET, sont détaillés dans les sous-sections suivantes.

### 2.3.2.1 Tracking Radar Echoes by Correlation (TREC)

Rinehart et Garvey [RG78] proposent un algorithme de mise en correspondance de blocs pour l'estimation du mouvement sur des images radars. La procédure de mise en correspondance est appliquée à des images quantifiant la réflectivité des ondes radars dans l'atmosphère.

Les images acquises successivement à  $t_1$  et  $t_2 = t_1 + \delta t$  sont chacune découpées en  $N$  blocs. Ensuite, pour chaque bloc  $B$  dans l'image à  $t_1$ , l'algorithme recherche le bloc le plus similaire dans l'image à  $t_2$ , en maximisant le coefficient de corrélation  $R$  défini comme suit :

$$R = \frac{\sum_{k \in B} Z_1(k) \times Z_2(k) - \frac{1}{2} \sum_{k \in B} Z_1(k) \times \sum_{k \in B} Z_2(k)}{\sqrt{\sum_{k \in B} Z_1^2(k) - N \bar{Z}_1^2} \times \sqrt{\sum_{k \in B} Z_2^2(k) - N \bar{Z}_2^2}} \quad (2.10)$$

avec :

- $Z_1$  et  $Z_2$  les images caractérisant les réflectivités,
- $k$  l'index d'un pixel,
- $N$  le nombre de pixels dans le bloc  $B$ ,
- $\bar{Z}_1$  et  $\bar{Z}_2$  la moyenne des réflectivités, respectivement de  $Z_1$  et  $Z_2$ , dans le bloc  $B$ .

Une fois les correspondances calculées, le vecteur reliant les centres des blocs code le déplacement du bloc initial. Le champ vectoriel ainsi obtenu est très lisse. Il est ensuite utilisé pour calculer un champ de trajectoires des pixels. Les imprécisions de vitesse et de direction le long des trajectoires fournit une "ellipse d'erreur" autour de chaque point de départ d'une trajectoire. Les précipitations futures, en un lieu spécifique, sont estimées

comme la moyenne pondérée des précipitations à l'intérieur de l'ellipse, sur la dernière image observée.

Le système Auto Nowcast (ANC) [MSR<sup>+</sup>03a], développé par *National Center for Atmospheric Research* (NCAR, U.S.A.), utilise notamment l'algorithme TREC dans la phase d'analyse de la dynamique. Différentes sources de données sont intégrées dans ANC : images radars météorologiques, images satellitaires, pluviomètres, ... Ces données sont fusionnées en utilisant des méthodes de logique floue pour calculer des champs de mouvement. Dans l'étape suivante, ces champs de mouvements sont combinés aux champs issus de modèles numériques de prévision météorologique afin de calculer une prévision. Pour plus détails, nous invitons le lecteur à se référer à Mueller *et al* [MSR<sup>+</sup>03b].

On peut également citer SWIRLS [LL04, WW17] (*Short-range Warnings of Intense Rainstorms in Localized Systems*), qui utilise une version de TREC combinée à une estimation globale du mouvement par suivi de structure orageuse.

### 2.3.2.2 Continuity Tracking Radar Echoes by Correlation (COTREC)

En 1994, Li *et al* [LSJ95], proposent l'algorithme du *Continuity Tracking Radar Echoes by Correlation*, version plus élaborée de l'algorithme TREC. Le but est de réduire le bruit présent dans le champ de vitesses estimé. Li *et al* considèrent que ce bruit est dû aux vecteurs de déplacement nul ( $\vec{0}$ ) ou divergents. Afin de le réduire, deux étapes supplémentaires ont été ajoutées à l'algorithme :

- La première étape consiste à éliminer les vecteurs de déplacement jugés erronés. Les vecteurs de déplacement dont la vitesse vaut zéro (causés généralement par des obstacles terrain) ou paraît aberrante par rapport à celles observées dans le voisinage sont remplacés par la moyenne des vecteurs dans le voisinage. Ainsi, les vecteurs dont l'orientation diverge de plus de 25 degrés par rapport à l'orientation moyenne de voisinage sont remplacés par cette valeur moyenne.
- La deuxième étape consiste à introduire une approche variationnelle pour calculer une solution qui vérifie la contrainte de conservation de la masse. Cette approche variationnelle est modélisée par la minimisation d'une fonction de coût  $J$  définie comme suit :

$$J(u, v) = \int_{\Omega} [(u - u^0)^2 + (v - v^0)^2] dx dy \quad (2.11)$$

où :

- $\Omega$  définit le domaine spatial sur lequel est calculé le champ de mouvement.
- $u^0(x, y)$  et  $v^0(x, y)$  représentent les deux composantes du vecteur de déplacement calculé par TREC,

- $u(x, y)$  et  $v(x, y)$  représentent la solution qui minimise le problème représenté par (2.11) et (2.12).
- $J$  est minimisée sous la contrainte de divergence nulle du champ de vitesse :

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} = 0 \quad (2.12)$$

où  $\frac{\partial u}{\partial x}$  désigne la dérivée partielle de  $u$  par rapport à la variable  $x$  et  $\frac{\partial v}{\partial y}$  la dérivée partielle de  $v$  par rapport à  $y$ .

En 2000, COTREC a fait l'objet d'une étude approfondie par Mecklenburg *et al* [MJS00], afin de quantifier son efficacité en terme de qualité de prévision et de proposer des optimisations algorithmiques. Une version commerciale de COTREC a été proposée par Schmid *et al* en 2000 [SMJ00], sous le nom de *RainCast*. Ce système a fait objet d'une étude de validation approfondie par Schmid et Wüest [SW05] en 2005. En 2002, Schmid *et al* [SMK02] ont proposé une version améliorée, appelée *RainCast+*. Cette dernière accroît le périmètre d'utilisation du logiciel, puisqu'elle permet de prévoir les précipitations de type neige et pluie glacée. Toutefois, la validation de *RainCast+* a été limitée à une étude qualitative sur quelques cas spécifiques. Le CHMI (Czech Hydrometeorological Institute) utilise l'algorithme COTREC dans son système de prévision [Nov07].

### 2.3.3 Approches basées sur la mise en correspondance de cellules de précipitation

Ces approches sont basées sur le principe de l'identification de cellules orageuses, puis de l'estimation de leur déplacement par mise en correspondance temporelle. Les vecteurs de déplacement correspondent à la translation des cellules de précipitation entre deux images. L'identification du déplacement des cellules comporte deux étapes principales : une étape de détection suivi d'un algorithme d'appariement.

Dans la première étape, des objets sont identifiés dans les images et leurs caractéristiques sont calculées. Chaque objet représente une région contiguë de pixels de réflectivité proche. Les caractéristiques d'intérêt associés à chaque objet sont typiquement les coordonnées du centroïde de la cellule, la surface, ...

Dans la seconde étape, ces caractéristiques sont utilisées pour mettre en correspondance l'occurrence de la cellule sur plusieurs images consécutives. De nombreux algorithmes ont été proposés à partir de cette approche, dont les quatre algorithmes les plus réputés sont : TITAN, SCIT, TRACE3D et CELLTRACK.

### 2.3.3.1 Thunderstorm Identification Tracking Analysis and Nowcasting (TITAN)

L'algorithme TITAN, proposé par Dixon et Wiener [DW93], a pour objectif la détection et le suivi des orages. TITAN utilise des données radars volumétriques en coordonnées cartésiennes. C'est donc un algorithme 3D. Un orage est défini comme la région dont le taux de réflectivité est supérieur ou égal à un seuil prédéfini,  $T_Z = 35\text{dBZ}$ , sur un volume d'espace prédéfini,  $T_V = 50\text{km}^3$ . Cette région est appelée cellule orageuse et est caractérisée par la réflectivité moyenne du centroïde  $\mathbf{x} = (\bar{x}, \bar{y}, \bar{z})$  et par son volume  $V$ .

Afin de suivre les cellules, après les avoir détectées, TITAN trace tous les chemins possibles entre les couples de cellules orageuses identifiées sur deux acquisitions successives, à  $t_1$  et  $t_2$ , puis choisit le chemin optimal pour chaque cellule de la première image, en prenant en compte une potentielle fusion ou fragmentation. Ce chemin optimal est le plus court parmi tous ceux pour lesquels les cellules sont similaires en termes de caractéristiques. On peut traduire ces deux critères d'optimalité, ressemblance et distance, par une fonction de coût décrivant l'association de la cellule  $i$  à l'instant  $t_1$  avec la cellule  $j$  à l'instant  $t_2$  :

$$C_{i,j} = w_1 d_p + w_2 d_V \quad (2.13)$$

$$d_p = \|\mathbf{x}_i^1 - \mathbf{x}_j^2\| \quad (2.14)$$

$$d_V = \left| \sqrt[3]{V_i^1} - \sqrt[3]{V_j^2} \right| \quad (2.15)$$

où :

- $\mathbf{x}_i^1$  et  $V_i^1$  sont respectivement les coordonnées du centroïde et le volume de la cellule  $i$  à l'instant  $t_1$ ,
- $\mathbf{x}_j^2$  et  $V_j^2$  sont respectivement les coordonnées du centroïde et le volume de la cellule  $j$  à l'instant  $t_2$ ,
- $d_p$  mesure le déplacement de la cellule  $i$  entre les instants  $t_1$  et  $t_2$ ,
- $d_V$  mesure la différence du volume entre les deux instants,
- $w_1$  et  $w_2$  sont deux coefficients de pondération choisis empiriquement.

Le déplacement global de l'ensemble des cellules est optimal s'il minimise la grandeur  $Q = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} C_{i,j}$ , où  $n_1$  et  $n_2$  représentent le nombre de cellules, respectivement à  $t_1$  et  $t_2$ . Cette optimalité globale correspond donc à un compromis entre proximité géographique et aspect de chacune des cellules.

La troisième phase de l'algorithme consiste à réaliser une extrapolation par régression linéaire des cellules, associées à leurs caractéristiques, afin d'obtenir une prévision à l'horizon temporel choisi.



Nombreux sont les systèmes de prévision utilisant cet algorithme : ANC développé par *National Center for Atmospheric Research (NCAR, U.S.A.)* [MSR<sup>+</sup>03b], CARDS (*Canadian Radar Decision Support*) [LASJ<sup>+</sup>99], et SWIRLS (*Short-range Warnings of Intense Rainstorms in Localized Systems*) [LSJ95].

### 2.3.3.2 Storm Cell Identification and Tracking (SCIT)

L'algorithme SCIT, proposé par Johnson *et al* [JMW<sup>+</sup>98], permet, tout comme l'algorithme TITAN, de détecter et suivre les cellules orageuses présentes dans les images radar volumétriques. À partir d'un ensemble prédéfini de seuils sur les taux réflectivité, SCIT identifie les cellules dont les réflectivités sont supérieures ou égales à ces seuils. Cela permet d'avoir une classification de ces cellules.

Le calcul du déplacement des cellules est ensuite basé sur le critère unique de plus courte distance : à la cellule  $i$  dans l'acquisition image à l'instant  $t_1$ , on associe la cellule  $j$  dans l'acquisition à l'instant  $t_2$ , qui est la plus proche en localisation de  $i$ , proximité exprimée par la distance euclidienne.

Une fois que le déplacement est identifié pour toutes les cellules, sur l'intervalle temporel entre les deux instants  $t_1$  et  $t_2$ , SCIT calcule le champ de mouvement global et utilise ce dernier pour faire la prévision de position des cellules dans le futur.

SCIT introduit le concept du *cell-based VIL (Vertically Integrated Liquid)* pour quantifier le profil vertical du taux d'eau liquide dans une cellule de précipitations. Les résultats [JMW<sup>+</sup>98] ont montré que SCIT donne de bons résultats pour le suivi des cellules convectives, qui sont des cellules orageuses essentiellement soumises à des courants ascendants et descendants. SCIT est utilisé dans le système WDSS-II<sup>3</sup> (Warning Decision Support System), développé par NSSL (National Severe Storms Laboratory).

### 2.3.3.3 TRACE3D

Handwerker [Han02] améliore la détection et le suivi des cellules nuageuses, en utilisant les données radars volumétriques. Pour identifier les cellules, TRACE3D procède en deux étapes :

1. la première étape consiste à déterminer les régions dont la réflectivité est supérieure ou égale à un seuil fixé à ( $_{\text{dBZ}}\text{LIMIT} = 35\text{dBZ}$ , soit environ  $5,61\text{ mm/h}$ ). Cette étape permet de diviser le volume sondé par le radar en plusieurs sous-régions appelées ROIP (*Region Of Intense Precipitation*).
2. la seconde étape consiste à identifier les noyaux dits RC, *Reflectivity Core*, présents dans les ROIPs. Pour cela, un second seuil est défini à  $_{\text{dBZ}}\text{DIFF} = 10\text{dBZ}$ . Pour

---

3. <http://www.wdssii.org>

chaque ROIP, nous identifions la valeur maximale de réflectivité dans la zone qu'il représente, notée  $MAX_{ROIP}$ . Les noyaux sont définis comme les régions ayant des réflectivités supérieures ou égales à :  $MAX_{ROIP} - \Delta BZ_{DIFF}$ . La figure 2.13 illustre le schéma permettant d'identifier les *Reflectivity Core* par TRACE3D.

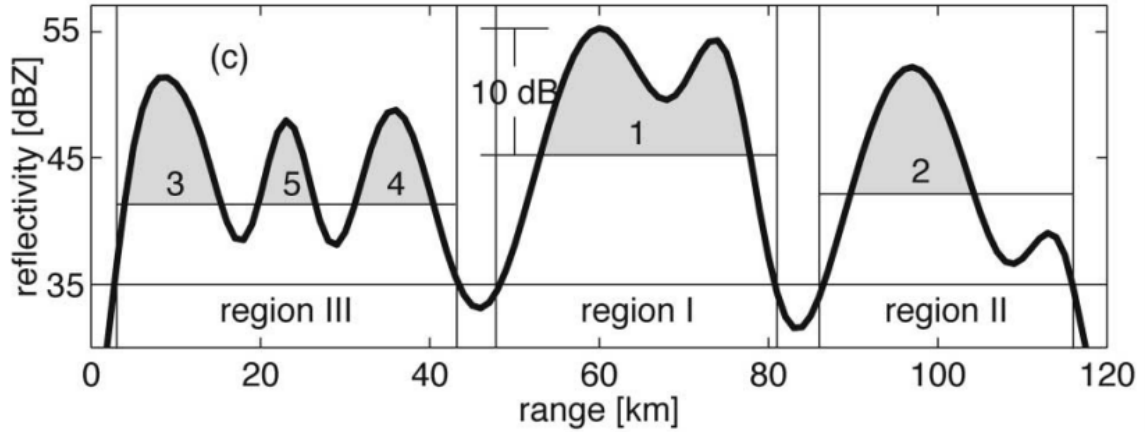


FIGURE 2.13 – Identification des RC. Figure extraite de [Han02].

Après avoir identifié les noyaux RC, TRACE3D estime la vitesse de déplacement  $\vec{v}_e(t)$  de ces RC, à l'instant présent, noté  $t_i$ , à partir de l'observation à l'instant précédent, noté  $t_{i-1}$ ; en se basant sur les positions des RC à l'instant  $t_{i-1}$  et sur celles à l'instant  $t_i$ . TRACE3D distingue plusieurs cas pour calculer la vitesse de déplacement  $\vec{v}_e$  :

- dans le cas où le noyau RC est suivi depuis un seul pas de temps, c'est-à-dire que nous disposons uniquement des positions des cellules à  $t - 2\delta t$  et à  $t - \delta t$ ,  $\delta t$  étant l'intervalle de temps entre deux observations radars, on calcule la vitesse comme :

$$\vec{v}_m(t - \delta t) = \frac{\vec{r}_m(t - \delta t) - \vec{r}_m(t - 2\delta t)}{\delta t}$$

où  $\vec{r}_m(t - 2\delta t)$  et  $\vec{r}_m(t - \delta t)$  sont les positions des RC à  $t - \delta t$  et  $t - 2\delta t$ .

Puis par définition TRACED estime  $\vec{v}_e$  par :

$$\vec{v}_e(t) = \vec{v}_m(t - \delta t)$$

- dans le cas où le noyau est suivi depuis plusieurs pas de temps, TRACE3D utilise une formule récursive pour estimer la vitesse comme suit :

$$\vec{v}_e(t) = k\vec{v}_e(t - \delta t) + (1 - k)\vec{v}_m(t - \delta t)$$

où  $k$  est un coefficient qui détermine la proportion d'utilisation de l'information

antérieure. Si  $k = 0$ , seule la dernière mesure de la vitesse est utilisée. En général,  $k$  est choisi empiriquement avec une valeur entre 0,5 et 0,9.

- dans le cas où une RC est identifiée à la date  $t$ , sans qu'on en ait trace dans les observations précédentes, sa vitesse estimée sera obtenue comme la moyenne de celles de toutes les autres RC.

Une fois le champ de mouvement estimé, TRACE3D estime une position pour l'instant  $t + \delta t$  pour chaque RC par extrapolation.

### 2.3.3.4 CELLTRACK

Les algorithmes décrits précédemment, notamment TITAN et TRACE3D, donnent des résultats tout à fait satisfaisants pour l'estimation du mouvement des cellules.

Toutefois, hormis SCIT, ils ne sont pas très efficaces pour le suivi de cellules convectives. Kyznarová et Novák [KN05, KN09] proposent donc une méthode spécifiquement dédiée au suivi de ces cellules convectives, appelé CELLTRACK. Pour identifier ces cellules, l'algorithme CELLTRACK utilise une technique de segmentation, avec un seuil prédéfini qui est égale à 44 dBZ (dans les faits il s'agit d'une méthode identique à celle utilisée dans l'algorithme TRACE3D, expliqué dans la section 2.3.3.3). La valeur du seuil a été choisie, d'une part, parce qu'elle témoigne d'une situation pluvieuse importante et, d'autre part, comme le meilleur compromis entre l'identification de cellules orageuses relativement faibles au sein de structures convectives et la distinction de cellules très proches spatialement les unes des autres. Une fois que les zones de valeur supérieures à 44 dBZ sont détectées, on identifie la valeur maximale de chacune d'elles, noté  $Z_{\max}$ . Ensuite, dans chaque zone, on élimine les pixels dont la réflectivité est inférieure à  $Z_{\max} - 10$ .

Une fois les cellules correctement identifiées dans les images sur deux temps consécutifs  $t_1$  et  $t_2$ , vient l'étape d'association des cellules de l'image  $t_2$  avec celles de l'image  $t_1$ . Le processus d'identification des couples est complexe et comporte plusieurs étapes. Tout d'abord, une première estimation est réalisée, de façon similaire à celle réalisée dans COTREC. Puis CELLTRACK propose d'utiliser une métrique qui quantifie la similarité  $\text{sim}$  entre une cellule à  $t_1$  et une cellule  $t_2$  :

$$\text{sim} = \frac{YY + NN}{YY + YN + NY + NN} \quad (2.16)$$

avec :

- $YY$  le nombre de pixels commun des deux cellules ;
- $YN$  le nombre de pixels appartenant à la cellule de l'image  $t_1$  et n'appartenant pas à la cellule de l'image  $t_2$  ;

- $NY$  le nombre de pixels appartenant à la cellule de l'image  $t_2$  et n'appartenant pas à la cellule de l'image  $t_1$  ;
- $NN$  le nombre de pixels n'appartenant à aucune des deux cellules dans les images  $t_1$  et  $t_2$ .

En se basant sur cette mesure, sur un critère de similarité de la forme géométrique et sur la distance, les associations entre cellules sur deux images consécutives sont réalisées.

Concernant le suivi de la division et de la fusion des cellules orageuses, CELLTRACK utilise la même méthode que celle de TITAN. Le vecteur de mouvement est élaboré en minimisant la métrique suivante :

$$\sum_{n \in X} |Z_{t_1}(n) - Z_{t_2}(n)| \quad (2.17)$$

où :

- $X$  représente l'union des zones des cellules qui ont été associées.
- $Z_{t_1}(n)$  et  $Z_{t_2}(n)$  représentent respectivement la réflectivité du pixel  $n$  dans la première et la deuxième image.

Le calcul de la prévision se fait par extrapolation des cellules en utilisant les vecteurs de déplacement calculés. La position des cellules extrapolées est effectuée en déplaçant le centroïde de chaque cellule, grâce au vecteur mouvement qui lui est associé. Bien que cette approche prenne en compte la fusion et la fragmentation des cellules, elle reste peu pertinente quand le scénario de fusion/fragmentation d'une image à l'autre est trop complexe, en particulier lorsque de nombreuses cellules apparaissent subitement. Cette limitation est valable pour toutes les méthodes présentées dans cette sous-section.

### 2.3.4 Approches par flot optique

Les méthodes de mise en correspondance de cellules répertoriées dans les sous-sections précédentes sont donc bien adaptées pour leur suivi lorsque celles-ci sont bien individualisées. Toutefois, lorsque les cellules fusionnent ou se fragmentent, le processus d'association des cellules peut échouer. Une solution à cette difficulté est de calculer un champ dense de vecteur vitesse, dense au sens où le calcul est effectué en chaque pixel du domaine image. Cette problématique est celle du calcul du flot optique.

Le terme de flot optique a été proposé par le psychologue James Jerome Gibson dans le cadre des travaux sur la vision humaine [Gib77]. Les premières formulations mathématiques ont été posées par Horn *et al*, en 1981 [HS81], et Lucas *et al*, la même année [LK81]. Tous deux ont fait l'hypothèse que l'intensité lumineuse est conservée le

long des trajectoires. Cela se traduit par l'équation suivante (2.18) :

$$\frac{d}{dt}(I(x(t), y(t))) = 0 \quad (2.18)$$

où  $(x(t), y(t))$  décrit le trajectoire d'un point dans le domaine image que l'on note  $\Omega$ .

La valeur du flot optique au temps  $t$ , et pour un pixel de coordonnées  $(x(t), y(t))$ , est définie comme la vitesse de déplacement du pixel sur le plan bi-dimensionnel correspondant à l'image :

$$\mathbf{w} = \begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} \frac{\partial x}{\partial t} \\ \frac{\partial y}{\partial t} \end{pmatrix} \quad (2.19)$$

En développant l'équation (2.18) et en dérivant la fonction de l'intensité lumineuse  $I(x(t), y(t), t)$  par rapport au temps, on obtient :

$$\frac{\partial I}{\partial x} \times \frac{\partial x}{\partial t} + \frac{\partial I}{\partial y} \times \frac{\partial y}{\partial t} + \frac{\partial I}{\partial t} = 0 \quad (2.20)$$

$$\begin{pmatrix} \frac{\partial I}{\partial x} & \frac{\partial I}{\partial y} \end{pmatrix} \begin{pmatrix} \frac{\partial x}{\partial t} \\ \frac{\partial y}{\partial t} \end{pmatrix} + \frac{\partial I}{\partial t} = 0 \quad (2.21)$$

En identifiant :

- $\begin{pmatrix} \frac{\partial I}{\partial x} \\ \frac{\partial I}{\partial y} \end{pmatrix}$  comme  $\nabla I$ , le gradient de  $I$ ,
- $\mathbf{w} = \begin{pmatrix} \frac{\partial x}{\partial t} \\ \frac{\partial y}{\partial t} \end{pmatrix}$  comme la vitesse au point  $(x, y)$ ,
- l'opérateur  $\cdot$  comme le produit scalaire.

l'équation du flot optique se réécrit :

$$\frac{\partial I}{\partial t} + \nabla I \cdot \mathbf{w} = 0 \quad (2.22)$$

Remarquons que ne nous pouvons pas calculer le flot optique  $\mathbf{w}$  directement, car nous disposons que d'une seule équation (2.22) avec deux inconnues  $u$  et  $v$ . C'est ce qu'on appelle le problème d'ouverture. Tant qu'aucune information supplémentaire n'est disponible sur le flot optique à estimer, la solution n'est pas unique (voir figure 2.14).

Un moyen de trouver une solution unique, pour résoudre l'équation (2.22), est d'introduire une hypothèse supplémentaire, généralement sous la forme d'une contrainte de régularisation. Par exemple, l'algorithme de Horn [HS81] minimise la fonction de coût




FIGURE 2.14 – Illustration du problème d’ouverture : pour une position donnée  $(x,y)$ , l’équation du flot n’admet pas de solution unique.

suivante :

$$\int_{\Omega} \left\| \nabla I \cdot \mathbf{w} + \frac{\partial I}{\partial t} \right\|^2 dx dy + \alpha \int_{\Omega} \|\nabla \mathbf{w}\|^2 dx dy \quad (2.23)$$

où  $\alpha$  est un hyper-paramètre qui règle la régularité de la solution. Il est facile de voir que la fonction de coût (2.23) est convexe et admet un minimum local. Le gradient de cette fonction est également facilement calculé. Le minimum de (2.23) est donc obtenu par une méthode de descente de gradient ou grâce à un solveur numérique.

Les méthodes de flot optique ont beaucoup évolué depuis 1981, car la méthode originale de Horn possède de nombreuses limitations. L’hypothèse de flot optique peut être relâchée et étendue aux grands déplacements, les termes de régularisation affinés, les normes peuvent être moins lissantes, ...

Un exemple d’amélioration : pour lever le problème des grands déplacements, Brox *et al* [BW02] proposent de remplacer l’équation (2.18) par :

$$I(x(t) + u(x(t), t)\delta t, y(t) + v(x(t), t)\delta t, t + d\delta t) - I(x(t), y(t), t) = 0 \quad (2.24)$$

On remarquera que l’équation (2.18) s’obtient à partir de (2.24) après un développement limité à l’ordre 1 du terme  $I(x(t) + u(x(t), t)\delta t, y(t) + v(x(t), t)\delta t, t + d\delta t)$ . Ce développement limité n’est valide que pour  $\delta t$  petit,  $\approx 1$  en pratique. Pour plus de détails sur l’évolution de ces méthodes, nous invitons le lecteur intéressé à lire des meta-analyses comme par exemple celles proposées dans [BB95, BSL<sup>+</sup>11, FBK15].

Depuis 2017, les approches de flot optique bénéficient également de la percée des méthodes de Machine Learning, voir par exemple [TXZ<sup>+</sup>19] pour un état de l’art récent sur ces approches. Les résultats obtenus par les algorithmes basés sur les réseaux de neurones et par les approches traditionnelles sont assez comparables. Néanmoins, une fois entraîné dans la phase d’apprentissage, un réseau de neurone a l’intérêt de pouvoir calculer très rapidement le flot optique dans la phase de test ou dans une phase opérationnelle. Toutefois, les réseaux de neurones doivent être entraînés sur une base d’apprentissage

exhaustive (i.e. : prenant en compte tous les types d'événements pluvieux possibles). De plus, les données radars sont éparées, à la fois en temps et en espace, ce qui est une difficulté majeure pour réaliser cet apprentissage.

Une fois le champ de vitesse dense calculé, une prévision peut être calculée en extrapolant, à l'aide du champ de mouvement correspondant, la dernière observation réalisée.

Nous présentons ci-dessous deux systèmes, basés sur le flot optique, que nous avons étudiés : **Variational Echo Tracking (VET)** et *Rain Nowcast*. Ce dernier système, nous le rappelons, sert de base pour les réalisations développées dans cette thèse, qui sont directement implémentées dans ce système afin de contourner ses limitations initiales.

### 2.3.5 Variational Echo Tracking (VET)

VET est un algorithme initialement proposé par Laroche et Zawadzki en 1994 [LZ94], dans le but d'estimer un champ de vents tridimensionnel, à partir d'images radar fournissant la réflectivité de l'atmosphère à différentes altitudes.

Cet algorithme utilise l'équation de conservation de la réflectivité, c'est-à-dire l'hypothèse de flot optique appliquée aux images de réflectivité, et l'équation de continuité, comme contrainte forte sur le champ de vitesse 3D. L'équation de continuité relie entre elles les 3 composantes du vecteur vitesse. Elle est définie par :

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial q}{\partial z} = k\mathbf{w} \quad (2.25)$$

où  $(u, v, q)$  est le champ de vitesse 3D et  $k$  une constante physique dépendant des conditions atmosphériques. La contrainte forte (2.25) permet de ramener le problème de l'estimation de la vitesse 3D à une série d'estimations de vitesses 2D.

Pour estimer le champ de vitesses à une altitude donnée, on minimise la fonction de coût  $J_{\text{VET}}$  définie par :

$$J_{\text{VET}} = W_Z J_Z + J_V \quad (2.26)$$

où :

- $J_Z$  correspond à la conservation de la réflectivité, équivalente à la contrainte de flot optique (2.18) en l'appliquant aux images de réflectivité :

$$J_Z = W_Z \int_{\Omega} \left\| \nabla I \cdot \mathbf{w} + \frac{\partial I}{\partial t} \right\|^2 dx dy \quad (2.27)$$

- $W_Z$  est un coefficient de pondération sur la contrainte de conservation de la réflectivité. Il dépend principalement de la qualité de la donnée. Cependant, dans la

plupart des applications, il est considéré comme une constante dans le domaine  $\Omega$ .

- $J_V$  est un terme de régularisation, qui permet d'assurer un champ de vitesse régulier. Il est défini comme suit :

$$J_V = w_V \int \int \left[ \left( \frac{\partial^2 u}{\partial x^2} \right)^2 + \left( \frac{\partial^2 u}{\partial y^2} \right)^2 + 2 \left( \frac{\partial^2 u}{\partial x \partial y} \right)^2 + \left( \frac{\partial^2 v}{\partial x^2} \right)^2 + \left( \frac{\partial^2 v}{\partial y^2} \right)^2 + 2 \left( \frac{\partial^2 v}{\partial x \partial y} \right)^2 \right] dx dy \quad (2.28)$$

- $w_V$  est un coefficient de pondération lié à la contrainte de lissage.

En 2002, Germann et Zawadzki [GZ02] proposent une amélioration de la méthode en implémentant un calcul multi-résolution, inspiré des travaux de Bergen *et al* [BAHH92]. De plus, la contrainte  $J_Z$  est remplacée par l'équation du flot optique prise dans sa forme non linéaire (voir (2.24)) :

$$J_Z = W_Z \int \int_{\Omega} (I(x, y, t_0) - I(x - u\delta t, y - v\delta t, t_0 - \delta t)) dx dy \quad (2.29)$$

Une première estimation du champ des vitesses est réalisée à résolution grossière puis un algorithme itératif permet de raffiner le calcul au fur et à mesure que l'on affine la résolution. La figure 2.15 montre ainsi un exemple de calcul à plusieurs résolutions.




FIGURE 2.15 – Estimation du mouvement par méthode variationnelle itérative. À gauche : initialisation de la procédure par un champ uniforme. Au milieu : une première estimation d'un champ de mouvement à résolution  $5 \times 5$ . À droite : estimation finale du champ de mouvement à résolution  $25 \times 25$ . Tiré de [GZ02].

VET, dans cette version itérative multi-résolution, fait partie du système *McGill Algorithm for Precipitation nowcasting by Lagrangian Extrapolation* (MAPLE), utilisée au Canada [BZK<sup>+</sup>10].



### 2.3.6 Rain Nowcast

*Rain Nowcast* [LH15] est un algorithme opérationnel de prévision qui se déroule en deux phases. Dans la première phase, nous estimons le mouvement  $\mathbf{w}$  pour chaque point du domaine image, noté  $\Omega$ , par assimilation variationnelle de données (on parle de 4DVar) à partir d'une séquence de quatre images. Dans la deuxième étape, nous utilisons le champ du mouvement  $w$  précédemment calculé pour estimer une prévision du taux de précipitations à un horizon temporel choisi par l'utilisateur. À chaque nouvelle acquisition, ces deux étapes sont recalculées sur les quatre images les plus récentes, afin d'assurer une mise à jour continue de la prévision. Cette technique est dite méthode par *fenêtre glissante*.

Dans le travail de recherche mené dans cette thèse, nous nous sommes contraints à suivre le mode de fonctionnement opérationnel de *Rain Nowcast*, afin de respecter ses contraintes de temps réel pour la production d'une prévision. Une observation radar est disponible toutes les 5 minutes et, pendant ce laps de temps, l'algorithme doit calculer le champ de vitesses et calculer une prévision pour un horizon temporel de 30 minutes. Le but est d'obtenir une prévision de qualité pour un horizon temporel le plus éloigné possible.

#### Estimation du mouvement par 4DVar

Comme nous l'avons évoqué précédemment, l'estimation du mouvement par *Rain Nowcast* repose sur une approche d'assimilation de données, selon une méthode dite 4DVar.

L'assimilation de données désigne un large ensemble de méthodes, dont la tâche est de déterminer l'état complet, noté  $X$ , d'un système physique à partir d'observations partielles, en temps et en espace, de l'état du système et à partir des connaissances physiques dont on dispose sur ce système [BC99, ABN16]. L'observation partielle de l'état du système se fait au moyen d'un opérateur d'observation, noté  $\mathbb{H}$  dans la littérature. La connaissance physique sur ce système s'exprime par un modèle mathématique, noté  $\mathbb{M}$  dans la littérature, qui correspond généralement à une ou plusieurs équations aux dérivées partielles. L'approche 4DVar [LDT86] est variationnelle et se résout grâce à une technique de contrôle optimal [Lio71].

Dans *Rain Nowcast*, le vecteur d'état du système,  $X$ , est défini par :

$$X(x, y, t) = \begin{pmatrix} \mathbf{w}(x, y, t) \\ I(x, y, t) \end{pmatrix} \quad (x, y) \in \Omega, t \in [0, T] \quad (2.30)$$

où  $\Omega$  est le domaine image et  $[0, T]$  un intervalle de temps.

Les composantes de  $X$  sont :

- $\mathbf{w}$  correspond au mouvement en chaque point du domaine image  $\Omega$ . Il est représenté par un vecteur à deux dimensions :

$$\mathbf{w}(x, y) = \begin{pmatrix} u(x, y) \\ v(x, y) \end{pmatrix} \quad (x, y) \in \Omega \quad (2.31)$$

- $I$  est une image, appelée traceur, qui est de la même nature que les observations. Autrement dit, elle décrit les quantités de pluie en chaque point du domaine.

Nous définissons le modèle  $\mathbb{M}$ , qui décrit l'évolution temporelle de la variable d'état  $X$ . Pour cela, nous définissons une équation d'évolution pour chacune des composantes de  $X$ .

Nous considérons que le mouvement des objets dans une séquence d'images est stationnaire. Cela se traduit mathématiquement par :

$$\frac{\partial \mathbf{w}}{\partial t}(x, y, t) = \vec{0} \quad (x, y) \in \Omega, t \in [0, T] \quad (2.32)$$

Cela exprime que  $\mathbf{w}(x, y, t) = \mathbf{w}(x, y, 0), \forall t \in ]0, T]$ . La stationnarité de  $\mathbf{w}$  signifie que le mouvement ne varie pas dans un petit intervalle de temps. Cette hypothèse repose sur le fait que les phénomènes physiques (vent, pression,...), qui influencent le déplacement des structures nuageuses associés aux précipitations ne varient pas ou très peu dans l'intervalle de temps considéré. Cette hypothèse est vérifiée dans le cas du vent dans la haute atmosphère, car celui-ci ne varie pas ou peu dans un intervalle de temps de petite durée. Cette hypothèse de stationnarité est donc applicable sur nos données qui ont une résolution temporelle de cinq minutes, engendrant un intervalle temporel de quinze minutes sur les fenêtres de calcul contenant quatre observations. Dans ce cas, l'intégration temporelle, portant sur le champ de mouvement n'est pas nécessaire.

Les structures de l'image  $I$  étant transportées par le mouvement  $\mathbf{w}(x, y, t)$ , il est possible d'utiliser la théorie du flot optique, c'est-à-dire que l'évolution de l'image  $I(x, y)$  dans le temps est décrite par l'équation d'advection suivante :

$$\frac{\partial I}{\partial t}(x, y) + \mathbf{w}(x, y) \cdot \nabla I(x, y) = 0 \quad (2.33)$$

À partir du système d'équations (2.32, 2.33), nous pouvons décrire l'évolution temporelle du vecteur d'état  $X$  à 3 dimensions (2 pour le vecteur vitesse et 1 pour la composante image) par le modèle  $\mathbb{M}$ , comme suit :

$$\frac{\partial X}{\partial t}(x, y, t) + \mathbb{M}(X)(x, y, t) = \vec{0} \quad (2.34)$$

avec :

$$\mathbb{M}(X)(x, y, t) = \begin{pmatrix} \vec{0} \\ \mathbf{w}(x, y, t) \cdot \nabla I(x, y, t) \end{pmatrix} \quad (2.35)$$

Le lien entre les observations, notées  $I^o$ , et le vecteur d'état se fait au travers de l'opérateur  $\mathbb{H}$  :

$$\mathbb{H}(X(x, y, t)) = I(x, y, t) \quad (2.36)$$

L'opérateur  $\mathbb{H}$  est ainsi une simple projection, qui retourne la composante  $I$  du vecteur d'état  $X$ . La composante  $I$  est comparée aux observations  $I^o$  : elles doivent idéalement être les plus similaires possible.

On peut résumer la problématique d'estimation du mouvement à partir d'images par la résolution du système d'équations suivant :

$$\frac{\partial X}{\partial t}(x, y, t) + \mathbb{M}(X)(x, y, t) = \vec{0} \quad (2.37)$$

$$X(x, y, 0) = X^b(x, y) + \epsilon_B(x, y) \quad (2.38)$$

$$\mathbb{H}(X(x, y, t)) = I^o(x, y, t) + \epsilon_R(x, y, t) \quad (2.39)$$

- L'équation (2.37) correspond à l'évolution temporelle de  $X(x, y, t)$  par le modèle  $\mathbb{M}$ .
- L'équation (2.38) décrit la connaissance sur l'état initial, appelée aussi ébauche et notée  $X^b(x, y)$ . L'exposant  $b$  est utilisé pour représenter le mot *background*.
- $\epsilon_B(x, y)$  est un terme d'erreur, qui représente l'incertitude sur l'ébauche. On suppose que cette erreur suit une loi gaussienne de moyenne nulle et de matrice covariance  $B$ . On considère qu'il n'y a pas de covariance entre les 3 composantes du vecteur d'état.
- L'équation (2.39) est l'équation d'observation qui quantifie la différence entre la composante  $I$  de la variable  $X$ , calculée par le modèle, et la composante  $I^o$  de la variable  $X^o$ , qui est effectivement observée.
- $\epsilon_R(x, y)$  est un terme d'erreur, qui décrit le bruit d'acquisition sur l'observation. On suppose que cette erreur suit une loi gaussienne, de moyenne égale à zéro, et de matrice de covariance  $R$ .

L'idée de la méthode est donc de calculer le mouvement  $w(0)$  de façon à ce qu'il transporte  $I(0)$  pour que la trajectoire soit proche des observations, c'est-à-dire avec une erreur  $\epsilon_R$  la plus petite possible.

Le système (2.37,2.38,2.39) s'inscrit dans le cadre de l'assimilation de données :

- la connaissance *a priori* sur l'état initial est décrite par l'équation (2.38),
- l'équation (2.39) fait le lien entre les observations et l'état,
- l'équation (2.37) décrit l'évolution temporelle de l'état.

L'approche 4DVar est une formulation variationnelle, dans laquelle on minimise la fonctionnelle de coût :

$$\begin{aligned}
 J(X(x, y, 0)) &= \frac{1}{2} \int_{\Omega} (X(x, y, 0) - X^b(x, y))B(x, y)^{-1}(X(x, y, 0) - X^b(x, y))dxdy \\
 &+ \int_{\Omega} \int_0^T (I^o(x, y, t) - \mathbb{H}(X)(x, y, t))R(x, y, t)^{-1}(I^o(x, y, t) - \mathbb{H}(X)(x, y, t))dxdydt
 \end{aligned} \tag{2.40}$$

sous contrainte de l'équation (2.37). Minimiser  $J$  en  $X(x, y, 0)$  revient à trouver la condition initiale telle que les termes d'erreurs  $\epsilon_B$  et  $\epsilon_R$  soient les plus petits possible. En particulier, avoir une erreur  $\epsilon_R$  petite signifie que l'écart entre le traceur  $I$  et les observations est faible. Le terme  $\epsilon_B$  est petit si la condition initiale reste proche de l'ébauche. Ces écarts sont modulés différemment par l'algorithme en fonction des valeurs des matrices de covariance  $R$  et  $B$ . Celles-ci jouent donc un rôle de pondération dans la fonctionnelle  $J$ .

En pratique, dans *Rain Nowcast*, l'estimation du mouvement par assimilation d'images se fait en considérant une séquence discrète composée de quatre images et non pas un continuum d'observations sur  $[0, T]$ . La première image de la séquence est utilisée comme ébauche, les trois autres sont utilisées comme observations.

Afin de simplifier l'écriture de la fonction  $J$ , nous introduisons le produit scalaire sur  $L^2(\Omega)$  ( $\|u\|_{L^2} = (\int_{\Omega} \|u(x, y)\|^2 dxdy)^{\frac{1}{2}}$ ) :

$$\langle A, B \rangle = \int_{\Omega} A^T(x, y)B(x, y)dxdy \tag{2.41}$$

La fonction de coût  $J$  se réécrit plus façon plus compacte sous la forme :

$$\begin{aligned}
 J(X(0)) &= \langle (X(0) - X^b)^T, B^{-1}(X(0) - X^b) \rangle \\
 &+ \int_0^T \langle (I^o(t) - \mathbb{H}X(t))^T, R^{-1}(I^o(t) - \mathbb{H}X(t)) \rangle dt
 \end{aligned} \tag{2.42}$$

Le calcul du gradient de  $J$  ne s'effectue pas de façon directe, mais il est calculé à l'aide d'une formulation adjointe [LDT86], qui nécessite la mise en place d'une variable

adjointe  $\lambda$ , laquelle vérifie le système suivant :

$$\lambda(T) = \vec{0} \quad (2.43)$$

$$-\frac{\partial \lambda}{\partial t} + \left(\frac{\partial \mathbb{M}}{\partial X}\right)^* \lambda = -\mathbb{H}^T R^{-1}(I^o(t) - \mathbb{H}(X(t))) \quad (2.44)$$

où  $\left(\frac{\partial \mathbb{M}}{\partial X}\right)^*$  représente l'opérateur adjoint du modèle  $\mathbb{M}$ . Il est défini formellement par :

$$\left\langle \frac{\partial \mathbb{M}}{\partial X} \alpha, \beta \right\rangle = \left\langle \alpha, \left(\frac{\partial \mathbb{M}}{\partial X}\right)^* \beta \right\rangle \quad \alpha, \beta \in L^2(\Omega) \quad (2.45)$$

Le gradient de la fonction de coût  $J$  s'écrit alors :

$$\frac{\partial J}{\partial X(0)}(X(0)) = B^{-1}(I(0) - I^b) + \lambda(0) \quad (2.46)$$

La démonstration du calcul de ce gradient est donnée dans l'annexe [A](#).

On remarque que le calcul de la fonction adjointe  $\lambda$  se fait en remontant le temps, en mode rétrograde de  $t = T$  jusqu'à  $t = 0$ . Ceci implique que le 4DVar n'est pas une méthode temps réel, au contraire d'autres méthodes d'assimilation de données. Toutefois, le calcul reste localisé sur une petite fenêtre temporelle, contenant les quatre observations successives, qui forment la fenêtre glissante utilisée par l'algorithme. On peut alors la qualifier de quasi-temps réel. Une fois le gradient calculé, l'état  $X$  du système est mis à jour par une méthode de descente de gradient. Le solveur quasi-newtonien L-BFGS [[ZBLN97](#)] est utilisé à cette fin, car il converge assez vite vers une solution satisfaisante.

La méthode d'estimation du mouvement de Rain Nowcast est résumée dans l'algorithme [1](#).

Pour une implémentation effective, il faut encore choisir des valeurs adéquates pour l'ébauche  $X^b$ , les matrices  $B$  et  $R$ , ainsi qu'un schéma numérique pour  $\mathbb{M}$  et pour les équations [\(2.35\)](#) et [\(2.44\)](#). Il faut également calculer l'adjoint du modèle  $\mathbb{M}$ .

- Les choix pour  $X^b$ ,  $B$  et  $R$  sont discutés dans le chapitre [3](#),
- le schéma numérique de  $\mathbb{M}$  est discuté dans le chapitre [4](#),
- les équations [\(2.35\)](#) et [\(2.44\)](#) sont approchées en temps par un schéma d'Euler,
- le calcul de l'adjoint est fait de façon automatique par un logiciel de différentiation automatique [[HP13a](#)] et discuté dans l'annexe [B](#).

## Régularisation

L'algorithme d'estimation du mouvement de *Rain Nowcast* reste mal posé au sens de Tikhonov [[Tik63](#)]. En particulier, il est sensible aux conditions initiales : de petites pertur-

---

**Algorithm 1** Motion Estimation (ME)

---

**Require:** :  $X_b, I^o(t_1), I^o(t_2), I^o(t_3), B, R, MaxIter$

- 1: Set the iteration index  $k = 0$
- 2: Initial condition of state vector  $X^k(0) = X_b$
- 3: **repeat**
- 4:     Forward integration : compute  $X^k(t)$  for all time with Eq. (2.37), and compute  $J^k$
- 5:     Backward integration : compute  $\lambda^k(t)$  for all time with Eqs. (2.43,2.44) and compute  $\nabla J^k$
- 6:     Update state vector  $X(0)$  with the L-BFGS solver :

$$X(0)^{k+1} = \text{LBFGS}(X(0)^k, J^k, \nabla J^k)$$

- 7:      $k=k+1$
  - 8: **until**  $|\nabla J^k| < \varepsilon$  or  $k > MaxIter$
  - 9: **return**  $X(0)^k$
- 

bations peuvent changer significativement le résultat. En pratique, il convient d'ajouter des contraintes de régularisation à la condition initiale. Ceci peut être encodé dans la matrice de covariance  $B$ , qui contraint la condition initiale [LH16].

Toutefois, nous choisissons de les exprimer en dehors de  $B$  pour des raisons opérationnelles, la matrice  $B$  ayant une taille trop grande pour être stockée en mémoire.

La régularisation porte uniquement sur la composante  $w$  de la condition initiale. Il n'est en effet pas utile de régulariser la composante  $I$ , car elle est contrainte à rester proche de son ébauche, fournie par la première observation.

On définit un premier terme de régularisation  $\mathcal{R}_1$ , qui opère sur la norme du gradient des champs de mouvement. Ce terme assure la régularité spatiale des vecteurs mouvement : ils doivent avoir localement des orientation et intensité très proches.

$$\mathcal{R}_1(X(0)) = \alpha \int_{\Omega} \|\nabla(\mathbf{w}(x, y, 0))\|^2 dx dy \quad (2.47)$$

On définit un second terme  $\mathcal{R}_2$ , qui assure une orientation cohérente des vecteurs mouvement et évite les champs totalement convergents et ou bien totalement divergents :

$$\mathcal{R}_2(X(0)) = \beta \int_{\Omega} (\text{div}(\mathbf{w}(x, y, 0)))^2 dx dy \quad (2.48)$$

avec  $\text{div}(\mathbf{w}) = \frac{\partial u}{\partial x} + \frac{\partial v}{\partial y}$ .

Ces termes de régularisation sont pondérés par les deux hyper-paramètres  $\alpha$  et  $\beta$ . Ceux-ci fixent l'importance de la régularisation dans la fonction de coût  $J$ , par rapport au terme portant sur les observations et à ceux portant sur l'ébauche et les observations.

---

Ces deux paramètres sont fixés empiriquement. En pratique nous procédons comme suit :

- la configuration  $\beta \gg \alpha$  aurait pour conséquence de favoriser un champ à faible divergence et à fort rotationnel. Mais, à l'échelle du domaine utilisé dans nos expériences, il n'y a pas de champ rotationnel. Nous choisissons donc  $\beta \ll \alpha$ .
- la valeur de  $\alpha$  est obtenue par *grid search*, de façon à obtenir le meilleur champ au sens de la prévision, c'est-à-dire qui minimise l'erreur moyenne, en valeur absolue, entre la prévision et l'acquisition correspondante.

La fonction de coût  $J$  devient, après inclusion des termes de régularisation :

$$\begin{aligned}
 J(X(0)) &= \langle (X(0) - X^b)^T, B^{-1}(X(0) - X^b) \rangle \\
 &+ \int_0^T \langle (I^o(t) - \mathbb{H}X(t))^T, R^{-1}(I^o(t) - \mathbb{H}X(t)) \rangle \\
 &+ \mathcal{R}_1(X(0)) + \mathcal{R}_2(X(0))
 \end{aligned} \tag{2.49}$$

Comme nous l'avons expliqué auparavant, la minimisation de la fonction de coût nécessite le calcul du gradient. L'ajout des deux termes de régularisation dans la fonction de coût  $J$  nécessite donc le calcul du gradient de ces deux termes. La démonstration est donnée dans l'annexe A.2. Le gradient de (2.49) s'écrit :

$$\frac{\partial J}{\partial X(0)}(X(0)) = B^{-1}(I(0) - I^b) + \lambda(0) + \begin{pmatrix} -\alpha \nabla^2 \mathbf{w}(0) \\ 0 \end{pmatrix} + \begin{pmatrix} -\beta \nabla \operatorname{div}(\mathbf{w}(0)) \\ 0 \end{pmatrix} \tag{2.50}$$

### Fenêtre glissante

Dans le cadre opérationnel, *Rain Nowcast* est employé en mode fenêtre glissante, comme nous l'avons déjà signalé. Cela consiste à itérer le processus d'estimation du mouvement à chaque fois qu'une nouvelle observation est disponible. On note  $O^i$  l'acquisition obtenue à l'instant  $t_i$ . En mode opérationnel, l'ensemble des données ne sont pas disponibles simultanément et les acquisitions arrivent au fil de l'eau, à intervalle de temps constant.

À chaque nouvelle acquisition, on considère que c'est le démarrage d'une nouvelle fenêtre de traitement, qui se termine par cette acquisition. Cette fenêtre de calcul pour 4DVar correspond à 4 acquisitions radar, notées  $I_1^o$  à  $I_4^o$ . La première sert d'ébauche pour le traceur  $I$  et les 3 autres servent d'observations et sont comparées à la sortie de l'opérateur  $\mathbb{H}$  dans la fonction de coût. L'ébauche  $X^b$  (équation (2.38)) est initialisée comme suit :

$$X^b = \begin{pmatrix} \mathbf{w}^b \\ I^o(0) \end{pmatrix}$$

où  $I^o(0)$  est la première observation de la fenêtre de traitement et  $\mathbf{w}^b$  est l'ébauche sur les vitesses. Elle a pour valeur :

- la vitesse calculée par le 4DVar dans la fenêtre précédente ou
- $\vec{0}$  si la fenêtre courante est la première.

La figure 2.16 illustre le processus de la fenêtre glissante.

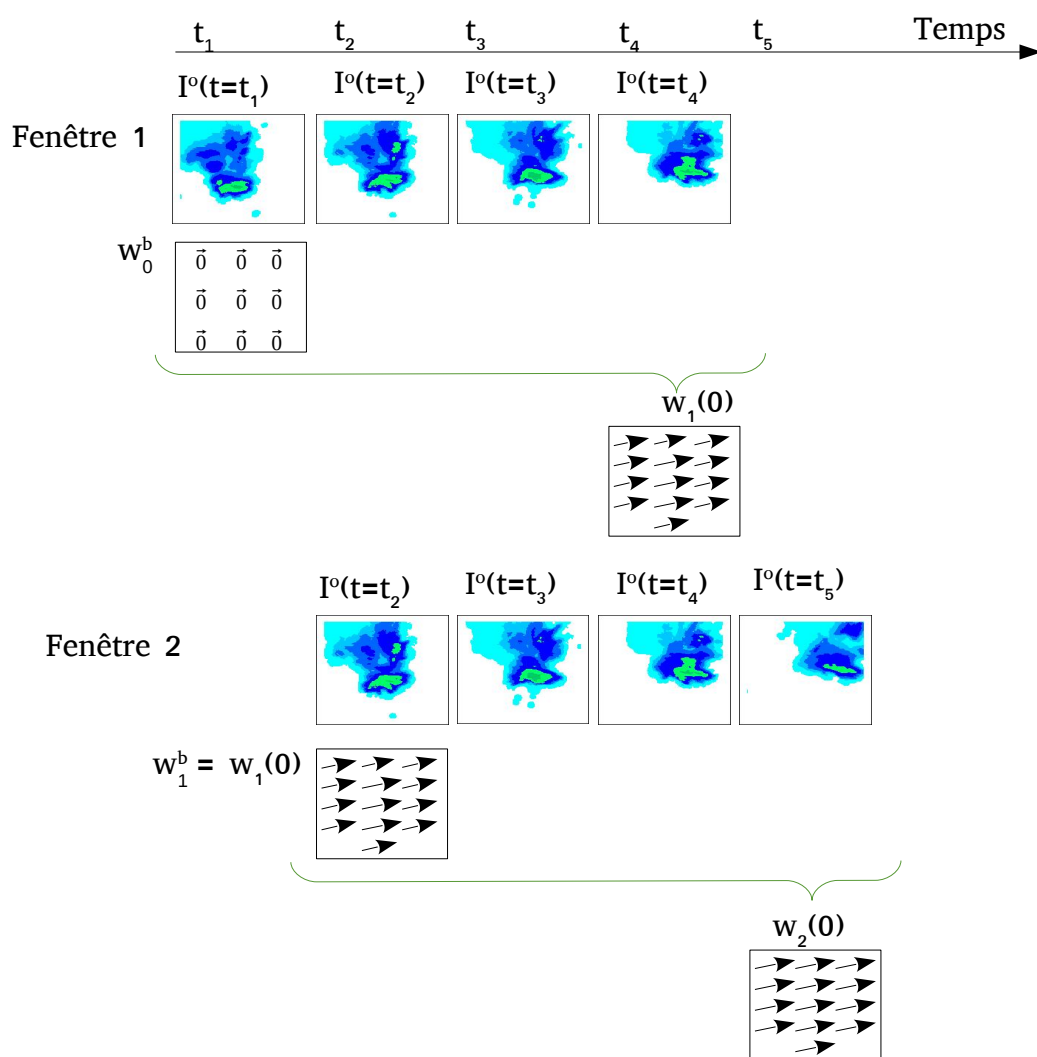


FIGURE 2.16 – Principe de la fenêtre glissante. Fenêtre 1 : les quatre premières acquisitions  $I^o(t = t_1)$ ,  $I^o(t = t_2)$ ,  $I^o(t = t_3)$ ,  $I^o(t = t_4)$  sont utilisées pour produire le champ de vitesse  $\mathbf{w}_1$ , l'ébauche  $w_0^b$  sur la vitesse est alors nulle. Fenêtre 2 : une nouvelle acquisition est disponible,  $I^o(t = t_2)$ ,  $I^o(t = t_3)$ ,  $I^o(t = t_4)$ ,  $I^o(t = t_5)$  sont utilisées pour produire le champ de vitesse  $\mathbf{w}_2$  et l'ébauche  $\mathbf{w}_1^b$  sur la vitesse est  $\mathbf{w}_1(0)$ .



## 2.4 Discussion et conclusion

Une très grande variété existe dans le paysage des méthodes de prévision des taux de précipitation ainsi que dans les systèmes opérationnels les implémentant.

Certaines approches sont basées sur un seul type d'observation tandis que d'autres intègrent des observations de différents types. Bien entendu, faire baser la prévision sur des observations multiples aboutit à de la complexité algorithmique.

Il est souvent difficile de prouver la supériorité de ces systèmes élaborés par rapport à des méthodes plus limitées. La raison principale de cette difficulté est que la validation des résultats d'un système de prévision n'est pas aisée : un taux de précipitation peut être prédit de manière très satisfaisante, mais être caractérisé par des scores d'erreur très élevés dans les schémas de validation, en raison d'une petite erreur de positionnement en espace ou/et en temps.

Un autre point important dans l'étude des algorithmes de prévision, et dans le développement des systèmes opérationnels, concerne la qualité des observations. Leur qualité médiocre peut conduire à de mauvais résultats, y compris en face d'un très bon algorithme.

Enfin, la variabilité d'échelles des différentes observations rend difficile la quantification des résultats. Les développements futurs devraient donc se concentrer tout autant sur l'évaluation des propriétés de la prévision que sur la prévision elle-même.

Après avoir présenté brièvement l'origine des précipitations ainsi que leurs différents types, nous avons, dans ce chapitre, présenté les quatre principaux instruments de mesure. Nous avons également présenté un état de l'art sur les différentes approches et algorithmes de prévision des taux de précipitations, basés sur l'extrapolation des cellules pluvieuses, à partir du calcul de leurs déplacements. En fin de chapitre, nous avons discuté l'algorithme opérationnel *Rain Nowcast*, qui sert de support aux développements issus de ce travail de thèse. Dans le chapitre 3, nous présentons de façon détaillée nos contributions méthodologiques sur l'estimation d'un mouvement à partir de données radar acquises à deux échelles différentes.

## Chapitre 3

# Estimation multi-échelle du mouvement

## Sommaire

---

<b>3.1</b>	<b>Approches multi-échelle</b> . . . . .	<b>67</b>
<b>3.2</b>	<b>Estimation multi-échelle du mouvement</b> . . . . .	<b>68</b>
3.2.1	Sequential Motion Rain Nowcast (SMRN) . . . . .	68
3.2.2	Parallel Motion Rain Nowcast (PMRN) . . . . .	76
<b>3.3</b>	<b>Conclusion</b> . . . . .	<b>79</b>

---




FIGURE 3.1 – Représentation multi-échelle. À gauche : résolution grossière; à droite : résolution plus fine.

Après avoir présenté un état de l’art des différentes approches de prévision des taux de précipitation, nous nous intéressons à la problématique de l’estimation du mouvement multi-échelle. Il est important de rappeler que notre objectif est d’améliorer la qualité de la prévision réalisée par *Rain Nowcast*. Nous le faisons en utilisant deux sources d’information différentes pour l’estimation de la dynamique atmosphérique. Ces deux sources proviennent de réseaux de radars météorologiques, travaillant avec des résolutions spatiales différentes. Les données fournies par ces radars sont de plus acquises par des capteurs opérant à deux longueurs d’onde différentes. Nous avons ainsi à notre disposition :

- les images acquises par les radars de Weather Measures, en bande X, c’est-à-dire avec une fréquence autour de 9400 MHz pour une longueur d’onde située dans l’intervalle allant de 2,5 à 3,75 cm,
- les images dites Panthere, fournies par Météo-France sur la base de son réseau de capteurs radar Aramis. Ce réseau est en fait constitué de plusieurs types de radar. La majorité d’entre eux sont en bande C, dont la fréquence va de 300 MHz à 1 GHz, avec une longueur d’onde de 7,5 à 15 cm.

Ces données sont présentées en détail au chapitre 5.

### 3.1 Approches multi-échelle

Dans la littérature scientifique, la signification du terme “multi-échelle” n’est pas unique. Ce terme est employé différemment selon le domaine d’étude. Nous l’utilisons ici dans son sens habituel dans la communauté de traitement d’images, où le terme multi-échelle renvoie à l’utilisation d’images acquises à différentes résolutions, permettant ainsi une observation à plusieurs échelles (voir figure 3.1).

Pour une même formation météorologique, la taille, et en conséquence la forme, d’une structure sera différente selon le type d’acquisition choisi, et donc dans les images correspondantes. Il y a deux causes pour expliquer ces différences d’apparence d’un type

d'image à l'autre :

- l'interaction avec les éléments atmosphériques se fait différemment selon la longueur d'onde, ainsi que selon d'autres paramètres, tels que la polarisation, l'élévation, ...
- La résolution spatiale des capteurs varie selon la longueur d'onde.

Estimer un mouvement multi-échelle revient donc à analyser les images des deux types d'acquisitions disponibles pour construire un champ de mouvement décrivant le déplacement des structures dans les deux types d'images. Cette estimation peut être élaborée selon au moins deux manières :

- de manière séquentielle : en traitant d'abord un type d'image, avec la résolution la plus grossière, puis en raffinant le résultat à l'aide du second type d'image, avec la résolution la plus fine ;
- de manière parallèle ou globale : en traitant simultanément les deux types d'images.

## 3.2 Estimation multi-échelle du mouvement

Nous présentons ici deux contributions permettant d'améliorer la prévision des taux de précipitation par la chaîne *Rain Nowcast*. Les méthodes qui y sont associées concernent la phase d'estimation du mouvement, car la phase de prévision sera discutée au chapitre 4.

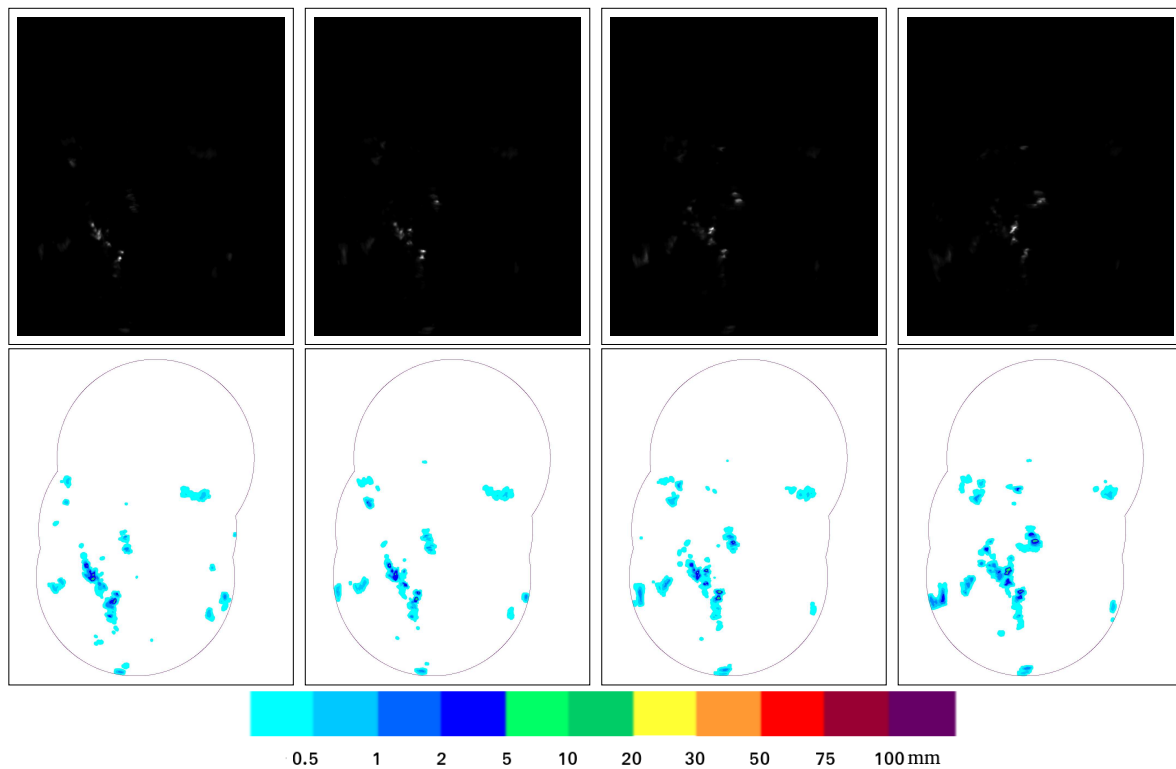
Comme expliqué précédemment, nous disposons de deux types de données, avec deux échelles spatiales différentes : les données en bande X ont une résolution spatiale de 200 mètres par pixel tandis que les données Panther ont une résolution de 1000 mètres par pixel. De plus, les données Panther couvrent un domaine spatial important, qui inclut le domaine correspondant aux acquisitions en bande X.

La conséquence immédiate de ces constats est que les images acquises par les deux capteurs n'ont pas la même taille. Nous adoptons dans la suite le terme de données "régionales" pour désigner les données Panther et le terme données "locales" pour désigner les données en bande X, afin de faciliter, pour le lecteur, l'appréhension du raisonnement.


La figure 3.2 montre un exemple des données locales et régionales utilisées par les algorithmes multi-échelle proposés dans cette thèse. Pour visualiser les événements pluvieux, nous utilisons une table de couleurs en 11 classes, allant d'une faible pluie (moins de 0,5 mm) à une très forte (plus de 100 mm). Cette quantification sera à présent utilisée tout au long de ce manuscrit.

### 3.2.1 Sequential Motion Rain Nowcast (SMRN)

Pour cette approche, l'estimation du mouvement se fait en deux étapes. La première étape concerne une estimation dite régionale : elle consiste à faire une estimation de



(a) Observations locales. Première ligne : images en bande X ; seconde ligne : quantification en couleurs des quantités de pluie pour les mêmes images.



(b) Observations régionales. Première ligne : images Panthere brutes ; seconde ligne : quantification en couleurs des quantités de pluie pour les mêmes images.

FIGURE 3.2 – Exemple d’observations locales et régionales, acquises aux mêmes dates et utilisées par les algorithmes multi-échelle d’estimation du mouvement. Pour la visualisation, la même quantification couleur des quantités de pluie est utilisée pour les deux échelles.

mouvement avec l'algorithme *Rain Nowcast* à partir des données régionales Panthere, afin d'obtenir une estimation du mouvement à cette échelle. La seconde étape concerne l'estimation locale : le mouvement régional calculé à l'étape précédente sert d'ébauche à une nouvelle estimation du mouvement, toujours avec l'algorithme *Rain Nowcast* mais à partir des données locales. Cette seconde estimation fournit un mouvement à l'échelle des données en bande X. La figure 3.3 schématise le déroulement de la procédure d'estimation du mouvement séquentiel.

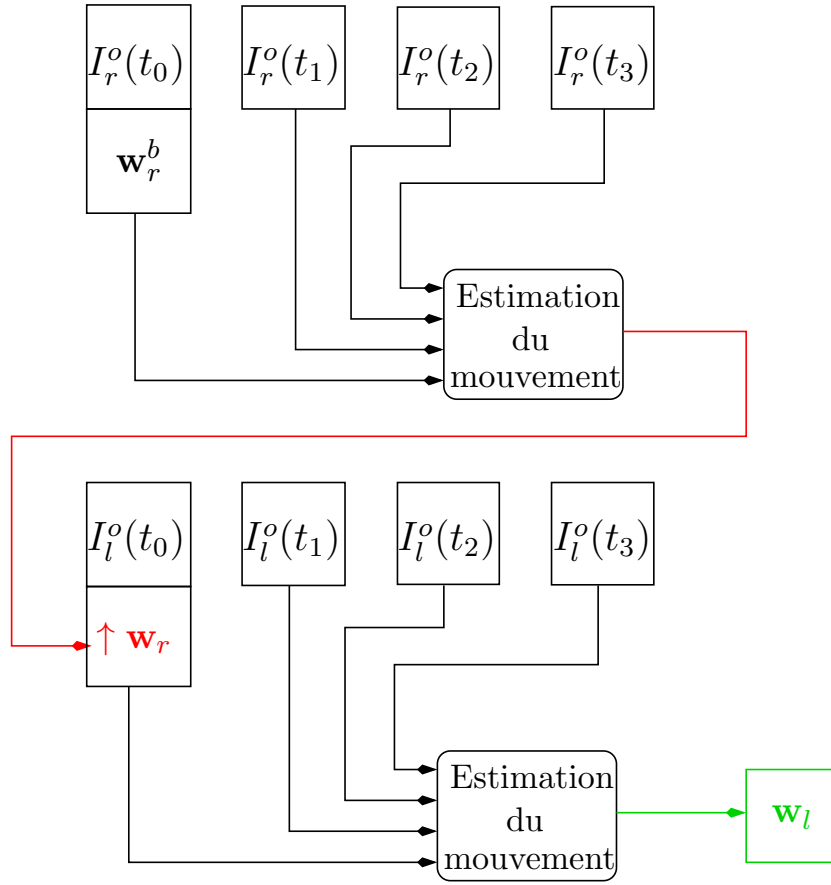


FIGURE 3.3 – Principe de l'algorithme SMRN : assimilation séquentielle à deux échelles différentes.

Lors de l'estimation régionale du mouvement, la variable d'état  $X_r$  ( $r$  signifiant régional) est définie par :

$$X_r = \begin{pmatrix} \mathbf{w}_r \\ I_r \end{pmatrix} \quad (3.1)$$

où  $\mathbf{w}_r$  représente le mouvement en chaque point du domaine régional, appelé  $\Omega_r$ ;  $I_r$  représente le traceur des observations régionales à la résolution Panthere.

Le modèle M utilisé est celui défini par l'équation (2.35). La vitesse est donc supposée

stationnaire le long de la fenêtre temporelle d'acquisition, ce qui est une hypothèse raisonnable et suffisante pour les données Panthere. La vitesse advecte le traceur régional :

$$\mathbb{M}(X_r) = \begin{pmatrix} \vec{0} \\ \mathbf{w}_r \cdot \nabla I_r \end{pmatrix} \quad (3.2)$$

L'opérateur d'observation  $\mathbb{H}$  est inchangé et il nous permet de comparer la composante  $I_r$  de  $X_r$  aux observations régionales  $I_r^o$  :

$$\mathbb{H}(X_r) = I_r \quad (3.3)$$

La première étape d'estimation du mouvement multi-échelle se traduit donc par la résolution du système d'équations suivant :

$$\frac{\partial X_r}{\partial t}(x, y, t) + \mathbb{M}(X_r)(x, y, t) = \vec{0} \quad (3.4)$$

$$X_r(x, y, 0) = X_r^b(x, y) + \epsilon_{B_r}(x, y) \quad (3.5)$$

$$\mathbb{H}(X_r(x, y, t)) = I_r^o(x, y, t) + \epsilon_{R_r}(x, y, t) \quad (3.6)$$

Ce système correspond exactement au cas d'utilisation de *Rain Nowcast* présenté au chapitre 2. Ainsi :

- l'équation (3.4) décrit l'évolution temporelle de  $X_r$  (équation (3.1)) par le modèle  $\mathbb{M}$  défini dans l'équation (3.2) ;
- l'équation (3.5) décrit la connaissance sur l'état initial des observations régionales  $I_r^o$ .  $\epsilon_{B_r}$  représente l'incertitude sur l'ébauche régionale sur la condition initiale. Celle-ci, notée  $X^b$ , est défini par :

$$X^b = \begin{pmatrix} \mathbf{w}_r^b \\ I_r^b \end{pmatrix} \quad (3.7)$$

où  $I_r^b$  représente la première observation régionale, disponible dans la fenêtre de traitement :  $I_r^b = I_r^o(t_i)$ ,  $t_i$  est l'indice de la fenêtre en cours d'analyse.  $\mathbf{w}_r^b$  est initialisé à  $\vec{0}$  en ce qui concerne la première fenêtre de traitement, puis, puisque l'algorithme fonctionne en fenêtre glissante, il est initialisé avec le résultat de l'estimation du mouvement sur la fenêtre de traitement précédente (voir la sous-section 2.3.6). La matrice de covariance  $B_r$  est définie comme suit :

$$B_r = \begin{pmatrix} +\infty & 0 & 0 \\ 0 & +\infty & 0 \\ 0 & 0 & B_{I_r} \end{pmatrix} \quad (3.8)$$



c'est-à-dire que, d'une part, les composante  $u$ ,  $v$  et  $I$  de la condition initiale du vecteur d'état sont décorrélées et que, d'autre part, on autorise une variance infinie sur les composantes  $u$  et  $v$  du vecteur d'état par rapport à celles de l'ébauche. Autrement dit, les composantes  $u$  et  $v$  de  $X(0)$  ne sont pas contraintes à être proche de celles de l'ébauche. La matrice  $B_{I,r}$  est supposée diagonale. D'un point de vue bayésien, cela revient à considérer que la composante  $I(0)$  est proche de l'ébauche et que cette ébauche est entachée d'un bruit gaussien, de moyenne nulle et dont la variance en un pixel prend la valeur correspondante dans la diagonale de  $B_{I,r}$ . En pratique, la variance est la même pour tous les pixels et est fixée à la variance des observations ;

- l'équation 3.6 quantifie la différence entre la composante  $I_r$  de la variable  $X_r$ , calculée par le modèle, et l'observation  $I_r^o$  au même instant.  $\epsilon_R(x, y)$  est le terme d'erreur qui décrit le bruit d'acquisition sur l'observation régionale. On suppose que cette erreur suit une loi gaussienne, de moyenne égale à zéro et de matrice de covariance  $R_r(t)$ . Celle-ci est également supposée diagonale. On définit tout d'abord un seuil, noté  $t_m$ , en dessous duquel on considère que le signal n'est pas dû à une précipitation mais correspond à un bruit. Deux cas de figure sont donc considérés : au temps  $t$  et à la position  $(x, y)$ , le coefficient de la matrice de covariance est fixée à une valeur très grande si le signal associé à ce pixel, dans l'observation correspondante, est inférieur au seuil et n'est donc pas significatif. Si la valeur du pixel est au dessus de ce seuil, la variance qui lui est affectée est identique à celle utilisée dans  $B_{I,r}$ . Seules les valeurs de signal supérieures à  $t_m$  sont donc effectivement prises en compte dans le processus d'estimation (ou "assimilées" dans le vocabulaire de l'assimilation de données). Si on s'intéresse aux cellules orageuses, la valeur  $t_m$  peut être choisie en cohérence avec les algorithmes TITAN et VET présentés dans le chapitre 2. Dans notre étude,  $t_m$  a été choisi à 0,5 mm sur des critères météorologiques et techniques discutés avec Weather Measures.

La fonction de coût (2.49) s'écrit donc :

$$\begin{aligned}
 J_r(X_r(0)) &= \langle I_r(0) - I_r^b, B_{q,r}^{-1}(I_r(0) - I_r^b) \rangle_{\Omega_r} \\
 &+ \int_{t_1}^T \langle I_r(t) - I_r^o(t), R_r^{-1}(t)(I_r(t) - I_r^o(t)) \rangle_{\Omega_r} dt \\
 &+ \mathcal{R}_1(X_r(0)) + \mathcal{R}_2(X_r(0))
 \end{aligned} \tag{3.9}$$

La minimisation de cette fonction  $J_r$  est effectuée comme dans la sous-section 2.3.6.

La deuxième phase d'estimation consiste à améliorer et affiner le résultat  $\mathbf{w}_r(0)$ , en effectuant une nouvelle estimation du mouvement à partir des observations locales. On

note  $X_l$  le vecteur d'état local :

$$X_l = \begin{pmatrix} \mathbf{w}_l \\ I_l \end{pmatrix} \quad (3.10)$$

Pour cela, nous utilisons l'algorithme *Rain Nowcast*, en utilisant le champ de vitesse régional  $\mathbf{w}_r$  lors de l'initialisation. Or, les domaines local et régional n'ont pas la même résolution : 200 mètres pour le premier et 1000 mètres pour le second. La résolution locale est donc 5 fois plus fine que la régionale. Nous extrayons alors, dans le domaine régional, la portion du champ de vitesse correspondant à ce domaine local, puis nous le sur-échantillonons avec un facteur 5. De cette façon, nous obtenons une vitesse régionale représentée à la résolution locale.

Dans la suite de ce document, nous symbolisons par l'opérateur  $\uparrow$  cette opération d'extraction de région et de sur-échantillonnage. L'opération de sur-échantillonnage peut paraître brutale, puisqu'il s'agit d'une recopie de valeurs, qui se traduit naturellement par des discontinuités entre pixels adjacents. Nous avons donc étudié l'effet d'un lissage effectué après le sur-échantillonnage (lissage par filtre moyenneur ou gaussien), sans que les résultats obtenus ne soient significativement meilleurs. Étant contraints, pour l'utilisation de la plateforme opérationnelle, par l'obtention d'un résultat en temps-réel, il a donc été décidé de conserver un simple sur-échantillonnage.

L'ébauche sur la condition initiale du vecteur d'état local s'écrit :

$$X_l^b = \begin{pmatrix} \uparrow \mathbf{w}_r(0) \\ I_l^o \end{pmatrix} \quad (3.11)$$

où  $I_l^o$  est la première observation locale disponible dans la fenêtre d'assimilation courante.

Nous résolvons ensuite le même système d'équations (3.4,3.5,3.6), mais sur le domaine local  $\Omega_l$ . Cela s'écrit :

$$\frac{\partial X_l}{\partial t}(x, y, t) + \mathbb{M}(X_l)(x, y, t) = \vec{0} \quad (3.12)$$

$$X_l(x, y, 0) = X_l^b(x, y) + \epsilon_{B_l}(x, y) \quad (3.13)$$

$$I_l(x, y, t) = I_l^o(x, y, t) + \epsilon_{R_l}(x, y, t) \quad (3.14)$$

Nous effectuons donc la même fonctionnelle que celle de l'équation (3.9), réécrit :

$$\begin{aligned} J(X_l(0)) &= \langle I_l(0) - I_l^b, B_{q,l}^{-1}(I_l(0) - I_l^b) \rangle_{\Omega_l} \\ &+ \int_0^T \langle (I_l(t) - I_l^o(t), R_l^{-1}(t)(I_l(t) - I_l^o(t))) \rangle_{\Omega_l} dt \\ &+ \mathcal{R}_1(X_l(0)) + \mathcal{R}_2(X_l(0)) \end{aligned} \quad (3.15)$$

en conservant pour définir  $B_{I,l}$  et  $R_l$ , les choix effectués pour  $B_{I,r}$  et  $R_r$ , et en adaptant les seuils et variances aux données locales.

Ainsi, nous faisons choix de ne pas imposer d'attache à la condition initiale sur les composantes du mouvement. En effet comme nous travaillons sur des paramètres sous-maille, nous préférons le mouvement à être estimé loin de sa condition initiale provenant de l'estimation régionale.

L'algorithme 2 illustre le processus d'estimation du mouvement multi-échelle séquentiel.

---

**Algorithm 2** Sequential Motion Rain Cast

---

- 1: Read the regional acquisitions  $I_r^o(t_i)_{i=\{0,1,2,3\}}$
- 2: Set the values of regional covariance matrices  $B_r$  and  $R_r$
- 3: Set the initial background

$$X_r^b = (\mathbf{w}_r(0) \quad I_r^o(0))^T$$

- 4: Regional estimation (ME=Motion Estimation)

$$X_r(0) = \text{ME}(X_r^b, I_r^o(t_i)_{i=\{1,2,3\}}, B_r, R_r, \text{MaxIter})$$

- 5: Oversample the regional estimation to local resolution  $\mathbf{w}_l(0) = \uparrow \mathbf{w}_r(0)$
- 6: Read the local acquisitions  $I_l^o(t_i)_{i=\{0,1,2,3\}}$
- 7: Set the values of local covariance matrices  $B_l$ ,  $R_l$
- 8: Set the initial background

$$X_l^b = (\mathbf{w}_l(t_0) \quad I_l^o(t_0))^T$$

- 9: Local refinement

$$X_l(0) = \text{ME}(X_l^b, I_l^o(t_i)_{i=\{1,2,3\}}, B_l, R_l, \text{MaxIter})$$


---

Tout comme *Rain Nowcast*, SMRN fonctionne en fenêtre glissante comme illustrée par la figure 3.4. Pour la première fenêtre, nous partons d'une ébauche de vitesse  $\mathbf{w}_r^b$  nulle sur le domaine régional, puis nous calculons une vitesse régionale  $\mathbf{w}_r$  et ensuite une vitesse locale  $\mathbf{w}_l$ . La vitesse régionale  $\mathbf{w}_r$  sert alors d'ébauche pour le calcul régional de la fenêtre suivante (flèche bleu dans la figure 3.4).

Nous ne disposons naturellement pas de vérité terrain pour évaluer qualitativement la qualité du champ de vitesse produit par SMRN. Dans ce travail de thèse, nous utiliserons donc comme critère de performance de chacune des méthodes étudiées la capacité à produire une prévision pertinente d'image de précipitation en utilisant le champ de vitesses estimé. La technique utilisée pour réaliser cette prévision à partir d'un champ de vitesses est discutée dans le chapitre 4. La figure 3.5 montre ainsi un exemple d'estimation du mouvement par la méthode SMRN et le compare à celui obtenu par l'algorithme *Rain Nowcast*, décrit dans la section 2.3.6, sur un épisode peu pluvieux. Les performances de

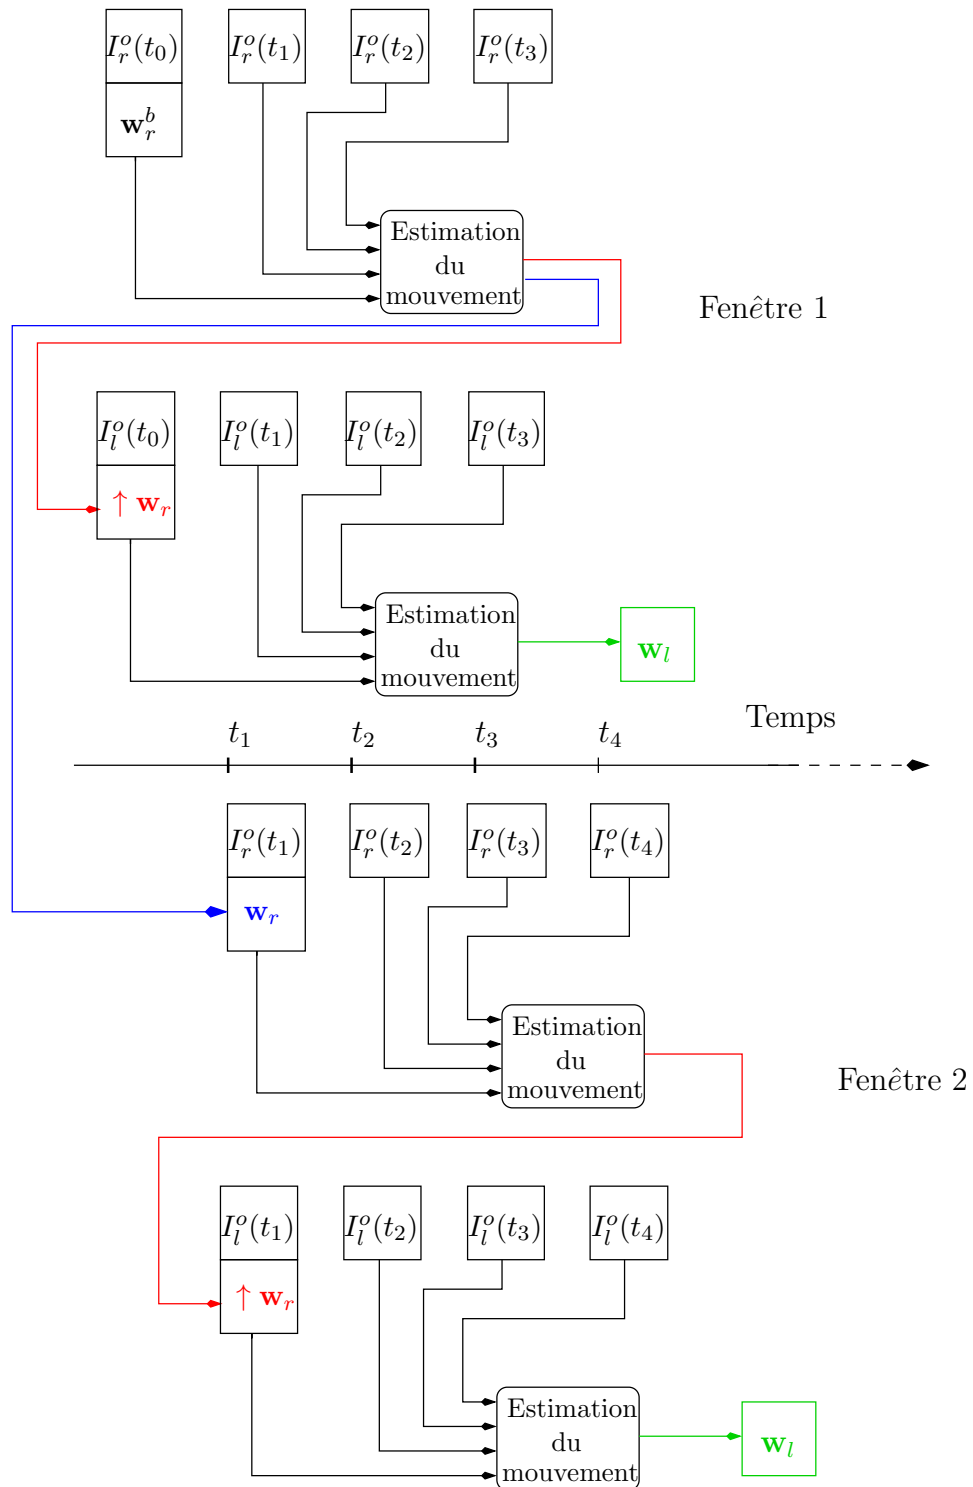


FIGURE 3.4 – Mise en œuvre de la fenêtre glissante pour SMRN.

SMRN sont analysées quantitativement au chapitre 5.

### 3.2.2 Parallel Motion Rain Nowcast (PMRN)

Dans cette section, nous proposons une seconde méthode d'estimation du mouvement multi-échelle, en utilisant simultanément les données locales et régionales.

Rappelons que la variable d'état  $X$  est constituée des deux composantes  $\mathbf{w}$ , représentant le mouvement, et  $I$ , image synthétique, appelée traceur. Le principe de l'estimation de mouvement par assimilation d'images consiste à minimiser l'écart entre l'image observée et ce traceur. Ce dernier est obtenu à la date de comparaison, par advection de la valeur initiale du traceur par le vecteur vitesse. Nous conservons ce principe d'estimation et nous étendons la comparaison à l'ensemble des observations, aussi bien locales et régionales. Nous introduisons donc deux traceurs dans le vecteur d'état. Le premier est nommé  $I_r$  et il correspond aux caractéristiques d'observation à l'échelle régionale. Le second est noté  $I_l$  et il correspond aux caractéristiques d'observations à l'échelle locale. Cela permettra donc que, via le processus d'assimilation, le mouvement soit estimé simultanément à partir des images régionales et locales.

Les images locales et régionales n'ayant pas la même résolution spatiale, nous adoptons une stratégie similaire à celle utilisée par SMRN pour calculer l'ébauche du champ des vitesses : les données régionales sont sur-échantillonnées à la résolution locale, puis un lissage gaussien (convolution avec un filtre gaussien), de moyenne nulle et avec un écart-type de valeur 5, est appliqué sur l'image sur-échantillonnée afin d'éviter le problème d'ouverture (cf section 2.3.4 et [BB95]). En effet, un simple sur-échantillonnage recopie les valeurs et crée une région uniforme de taille  $5 \times 5$ . Le flot optique, calculé à l'intérieur de cette région uniforme, est alors sous-estimé, même s'il n'est pas identiquement nul en raison de l'impact de la régularisation. Disposer d'une image texturée limite le problème d'ouverture. C'est pourquoi nous effectuons une convolution, en faisant choix d'un écart-type à  $\sigma = 5$ , et en tronquant le filtre gaussien au delà d'une distance  $[3\sigma]$  de son centre. Le filtre ainsi obtenu est de taille  $31 \times 31$ . Sachant que l'on a des zones de  $5 \times 5$  pixels avec la même valeur à l'issue du sur-échantillonnage, ce moyennage quasi gaussien, effectué sur une fenêtre de taille  $31 \times 31$ , permet d'éliminer cette uniformité.

À ce stade, les observations locales et régionales ont la même résolution et peuvent donc être assimilées simultanément.

Pour garder le même formalisme que celui précédemment expliqué, les observations sont regroupées dans le vecteur d'observation  $I^o$ , qui s'écrit :

$$I^o = \begin{pmatrix} I_r^o \\ I_l^o \end{pmatrix} \quad (3.16)$$

De la même façon, le vecteur d'état de l'algorithme PMRN contient deux traceurs, l'un régional et l'autre local, et est défini comme suit :

$$X = \begin{pmatrix} \mathbf{w} \\ I_r \\ I_l \end{pmatrix} \quad (3.17)$$

Cela implique l'extension du modèle d'évolution  $\mathbb{M}$  pour prendre en compte 4 dimensions, 2 dimensions pour le vecteur vitesse et 2 dimensions pour les traceurs :

$$\mathbb{M}(X) = \begin{pmatrix} \vec{0} \\ \mathbf{w} \cdot \nabla I_r \\ \mathbf{w} \cdot \nabla I_l \end{pmatrix} \quad (3.18)$$

L'opérateur  $\mathbb{H}$  devient alors :

$$\mathbb{H}(X) = \begin{pmatrix} \mathbf{w} \cdot \nabla I_r \\ \mathbf{w} \cdot \nabla I_l \end{pmatrix} \quad (3.19)$$

de sorte que  $\mathbb{H}(X)$  et  $I^o$  ont la même dimension et puissent être comparés.

Avec ces formulations, la fonction de coût reste inchangée. L'intégration spatiale réalisée dans le calcul de cette fonction, porte sur le domaine  $\Omega_r$ , afin d'obtenir une estimation fine du mouvement sur le domaine local  $\Omega_l \subset \Omega_r$  et une estimation grossière en dehors de  $\Omega_l$ , soit  $\Omega_r \setminus \Omega_l$  :

$$\begin{aligned} J(X(0)) &= \langle I(0) - I^b, B_I^{-1}(I(0) - I^b) \rangle_{\Omega_r} \\ &+ \int_0^T \langle (\mathbb{H}(X(t)) - I^o(t), R^{-1}(t)(\mathbb{H}(X(t)) - I^o(t))) \rangle_{\Omega_r} dt \\ &+ \mathcal{R}_1(X(0)) + \mathcal{R}_2(X(0)) \end{aligned} \quad (3.20)$$

La matrice de covariance  $B$  est définie par :

$$B = \begin{pmatrix} \infty & 0 & 0 & 0 \\ 0 & \infty & 0 & 0 \\ 0 & 0 & B_l & 0 \\ 0 & 0 & 0 & B_r \end{pmatrix} \quad (3.21)$$

en supposant une absence de corrélation entre les 4 composantes du vecteur d'état à  $t = 0$ .  $B_l$  et  $B_r$  sont respectivement les matrices associées à l'ébauche sur le traceur local et régional. On suppose également que le champ de vitesse initial n'est pas contraint par la valeur choisie pour l'ébauche. Nous faisons pour  $B_r$  et  $B_l$  des choix identiques à ceux

effectués pour  $B_{I,r}$  et  $B_{I,l}$  de l'algorithme SMRN.

La matrice de covariance  $R$  est définie par :

$$R = \begin{pmatrix} R_l & 0 \\ 0 & R_r \end{pmatrix} \quad (3.22)$$

Nous faisons pour  $R_l$  et  $R_r$ , ainsi que pour le seuil  $t_m$  associé à chaque échelle, des choix identiques à ceux présentés dans la section 3.2.1.

En utilisant les définitions précédentes pour  $X$ ,  $X^b$ ,  $\mathbb{H}$ ,  $B$  et  $R$ , la fonction de coût se ré-écrit en :

$$\begin{aligned} J(X(0)) &= \langle I_r(0) - I_r^b, B_r^{-1}(I_r(0) - I_r^b) \rangle_{\Omega_r} \\ &+ \langle I_l(0) - I_l^b, B_l^{-1}(I_l(0) - I_l^b) \rangle_{\Omega_l} \\ &+ \int_0^T \langle I_r(t) - I_r^o(t), R_r^{-1}(t)(I_r(t) - I_r^o(t)) \rangle_{\Omega_r} dt \\ &+ \int_0^T \langle I_l(t) - I_l^o(t), R_l^{-1}(t)(I_l(t) - I_l^o(t)) \rangle_{\Omega_l} dt \\ &+ \mathcal{R}_1(X(0)) + \mathcal{R}_2(X(0)) \end{aligned} \quad (3.23)$$

L'algorithme 3 illustre le processus d'estimation du mouvement multi-échelle parallèle.

---

**Algorithm 3** Parallel Motion Rain Nowcast

---

- 1: Read the regional and local acquisitions  $I_r^o(t_i)_{i=\{0,1,2,3\}}$ ,  $I_l^o(t_i)_{i=\{0,1,2,3\}}$
- 2: Set the values of regional and local covariance matrices  $B_r$ ,  $R_r$ ,  $B_l$  and  $R_l$
- 3: Set the index  $k = 0$
- 4: Set the initial background

$$X^b = (\mathbf{w}_r(0) \quad I_r^o(0) \quad I_l^o(0))^T$$

- 5: **repeat**
- 6:     Forward integration : compute  $X(t)^k$  for all time with Eq. (2.37), and compute  $J^k$
- 7:     Backword integration : compute  $\lambda(t)^k$  for all time with Eqs. (2.43,2.44) and compute  $\nabla J^k$
- 8:     Update state vector  $X(0)$  with the L-BFGS solver :

$$X(0)^{k+1} = \text{LBFGS}(X(0)^k, J^k, \nabla J^k)$$

- 9:      $k=k+1$
  - 10: **until**  $|\nabla J^k| < \varepsilon$  or  $k > \text{MaxIter}$
  - 11: **return**  $X(t_0)^k$
- 

La figure 3.5 montre un exemple d'estimation du mouvement par PMRN et le compare

à ceux obtenus par les algorithmes *Rain Nowcast* et SMRN. Les performances de PMRN sont analysées de façon extensive au chapitre 5.

### 3.3 Conclusion

Dans ce chapitre, nous nous sommes intéressés à l'amélioration de l'estimation du mouvement effectué par l'algorithme *Rain nowcast*. Deux contributions ont été proposées et discutées en se basant sur une approche multi-échelle.

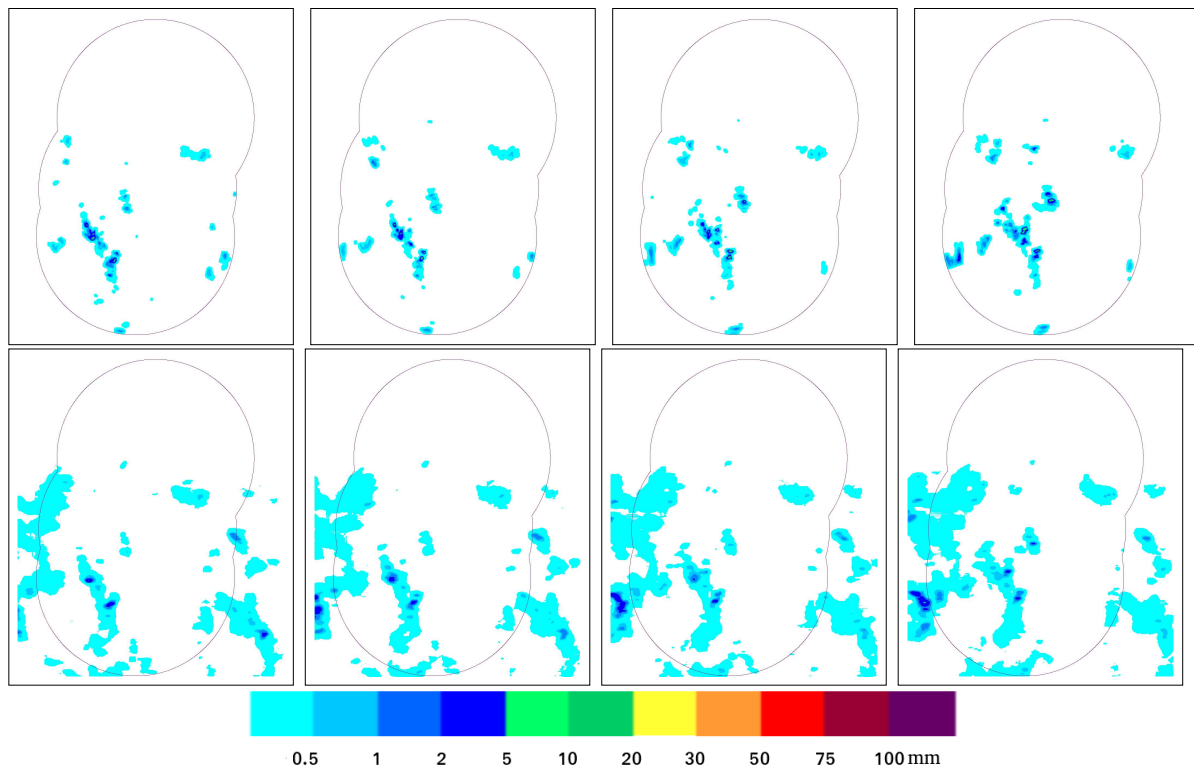
La première méthode propose une estimation de mouvement multi-échelle, en mode dit séquentiel. Un premier calcul est effectué à l'échelle régionale, qui est ensuite affiné par un second calcul réalisé à l'échelle locale. Le fait de prendre en compte deux échelles différentes est prégnant dans le résultat obtenu. En effet, l'échelle régionale permet d'anticiper les entrées des structures nuageuses dans le domaine local, alors qu'elles ne sont pas visibles par les capteurs correspondant. De plus, l'échelle locale raffine l'estimation du mouvement, grâce à sa résolution plus fine. Par ailleurs, il est important de noter que même si un des deux types d'acquisition se révèle indisponible, le modèle continue de fonctionner et de fournir des estimations. Le problème majeur de cette méthode est qu'elle est coûteuse en temps de calcul. En effet elle est séquentielle (calcul d'un champ de vitesse régionale puis raffinement à l'échelle locale) et ne peut donc pas être déployée sur une architecture parallèle.

La seconde méthode propose une estimation de mouvement multi-échelle dite en parallèle, en assimilant les deux échelles lors d'un processus unique. Puisque l'assimilation est faite en simultanée, les temps de calculs sont plus courts (il y a 2 fois moins d'itérations). De plus, on peut déployer cet algorithme sur une architecture parallèle de façon identique à ce qui a été fait pour *Rain Nowcast* (voir annexe B). La difficulté majeure provient du fait que les données régionales et locales proviennent de capteurs ne mesurant pas les mêmes grandeurs, puisque les longueurs d'ondes et élévations sont *a priori* différentes. Ceci peut engendrer des estimations de vitesses contradictoires. Le réglage des matrices  $B$  et  $R$  devient alors critique.

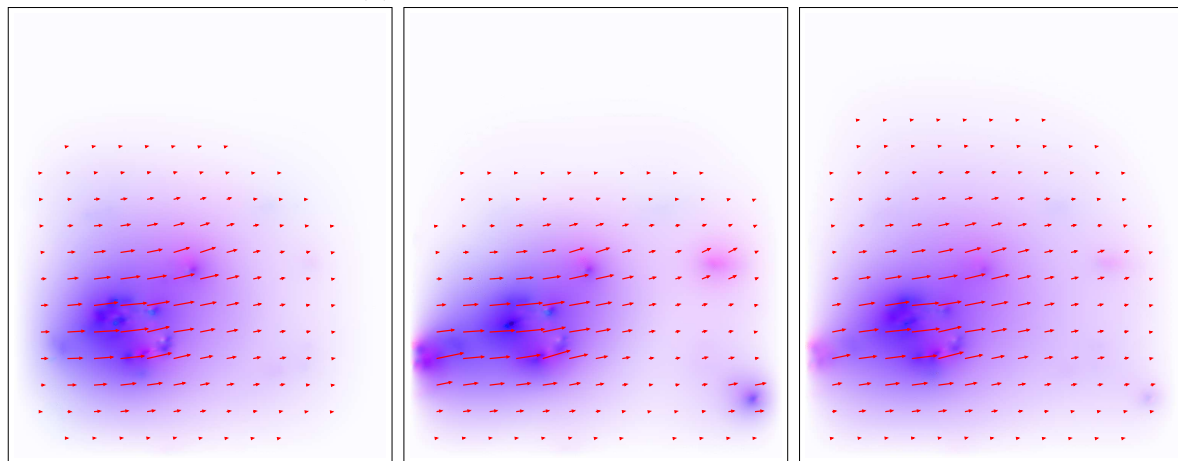
Les résultats obtenus, tels qu'illustrés dans ce chapitre, par les deux méthodes permettent de calculer un champ de vitesses plus réaliste. Ensuite, la dynamique des structures étant mieux estimée, la qualité de la prévision s'en trouve notablement améliorée. C'est ce critère de qualité qui guide dans le choix des hyperparamètres utilisés dans la fonction de coût et qui concerne la régularisation (paramètres  $\alpha$  et  $\beta$  des termes de régularisation  $\mathcal{R}_1$  et  $\mathcal{R}_2$  dans la fonction de coût (2.49)). Les valeurs des matrices de covariances sont fixés sur des considérations physiques.

Dans le chapitre 4, nous discutons les méthodes utilisées pour réaliser la prévision





(a) Observations locales et régionales.



(b) *Rain Nowcast*

(c) SMRN

(d) PMRN

FIGURE 3.5 – Exemple d’estimation du mouvement multi-échelle par assimilation 4DVar. (a) Observations locales et régionales aux mêmes dates. Le domaine d’acquisition des données locales est symbolisé par les 3 portions de cercle (voir section 5.1). (b) (c) (d) Estimation du mouvement par *Rain Nowcast* (à partir des observations locales), SMRN et PMRN. Chaque champ de vecteur vitesses est superposé à une représentation dense des vecteurs vitesse par la méthode Middlebury [BSL+11] : la teinte représente l’orientation et la saturation l’intensité.

d'une image de précipitations, à un horizon temporel donné, à partir de la dynamique estimée par les techniques présentées dans ce chapitre. Nous y détaillons en particulier les schémas numériques utilisés et proposons plusieurs contributions destinées à améliorer les performances en terme de qualité de prévision.



## Chapitre 4

# Prévision des précipitations à partir de la dynamique

## Sommaire

---

<b>4.1</b>	<b>Principes sous-tendant la pr�evision . . . . .</b>	<b>85</b>
<b>4.2</b>	<b>Correction de l'intensit�e du mouvement : hypoth�ese de vent g�eostrophique . . . . .</b>	<b>89</b>
<b>4.3</b>	<b>Correction de la distribution des pr�evisions . . . . .</b>	<b>93</b>
<b>4.4</b>	<b>Conclusion . . . . .</b>	<b>96</b>

---

Dans ce chapitre, nous expliquons comment, à partir de l'estimation de la dynamique qui a été réalisée dans le chapitre 3 (qui correspond concrètement à l'obtention d'un champ de vitesses sur le domaine spatial observé), on calcule une carte des précipitations, à un horizon temporel fixé par l'utilisateur.

Nous proposons deux contributions méthodologiques majeures, qui permettent d'améliorer la qualité de la prévision réalisée. Nous cherchons, d'une part, à assurer que les structures pluvieuses prédites soient correctement localisées sur le domaine spatial (précision spatiale de la prévision de pluie) et, d'autre part, à ce que les quantités de pluie soient estimées le plus précisément possible. Concernant la précision de la localisation, celle-ci dépend naturellement de la qualité de l'estimation des vitesses des cellules orageuses, mais elle dépend également de la performance du procédé d'extrapolation temporelle.

## 4.1 Principes sous-tendant la prévision

La phase de prévision consiste à intégrer en temps le vecteur d'état du système de prévision selon un modèle mathématique caractérisant l'évolution temporelle de l'état. Le vecteur d'état utilisé dans cette phase est le même que celui utilisé dans l'étape d'estimation du mouvement. Ce vecteur contient donc un ou deux traceurs image, selon la méthode d'estimation du mouvement utilisée, *Rain Nowcast* dans sa version originale, SMRN ou PMRN. C'est bien évidemment la ou les composantes de traceur ( $I$  ou  $I_r$  et  $I_l$ ) qui fournissent la prévision, c'est-à-dire la carte des précipitations estimées à l'horizon temporel choisi. Le vecteur vitesse du vecteur d'état n'est donc qu'un outil pour calculer cette prévision.

Soit  $t_{lastobs}$  le temps à laquelle la dernière acquisition  $I^o(t = t_{lastobs})$  est disponible. À cette date, un champ de vitesse calculé. Il faut donc attendre le délai nécessaire pour que le calcul soit terminé, avant que ce champ de vitesse ne soit disponible (dans l'annexe B nous discutons la problématique des temps de calcul) pour la prévision. Nous notons ce champ de vitesse  $\mathbf{w}_{ME}$ . Le vecteur d'état utilisé pour calculer la prévision est initialisé par :

$$X(t_{lastobs}) = \begin{pmatrix} \mathbf{w}_{ME} \\ I^o(t_{lastobs}) \end{pmatrix} \quad (4.1)$$

ou par :

$$X(t_{lastobs}) = \begin{pmatrix} \mathbf{w}_{ME} \\ \uparrow I_r^o(t_{lastobs}) \\ I_l^o(t_{lastobs}) \end{pmatrix} \quad (4.2)$$

dans le cas d'un champ de vitesses multi-échelle,  $I_r^o$  et  $I_l^o$  représentant respectivement les

acquisitions régionales et locales.

Le modèle d'évolution utilisé pour la prévision est noté  $\mathbb{M}_f$ . Comme précisé dans le chapitre 3, on suppose que l'évolution du vecteur d'état  $X$  est décrite par l'équation associée au modèle  $\mathbb{M}_f$  :

$$\frac{\partial X(x, y, t)}{\partial t} + \mathbb{M}_f(X)(x, y, t) = \vec{0} \quad (4.3)$$

$X$  peut alors être calculé pour tout temps  $t_h > t_{lastobs}$  en intégrant en temps l'équation (4.3) :

$$X(x, y, t_h) = X(x, y, t_{lastobs}) - \int_{t_{lastobs}}^{t_h} \mathbb{M}_f(X)(x, y, t) dt$$

Le modèle  $\mathbb{M}_f$  est choisi différemment de celui utilisé dans l'étape d'estimation du mouvement. En effet, puisque l'on souhaite intégrer sur une fenêtre temporelle de longue durée ( $t_h > 30$  minutes), l'hypothèse de stationnarité du mouvement, comme utilisée dans la phase d'estimation du mouvement, n'est plus valide. Nous faisons, cette fois, l'hypothèse d'une invariance lagrangienne du mouvement, c'est-à-dire que le mouvement est transporté par lui-même :

$$\frac{d\mathbf{w}(x(t), y(t), t)}{dt} = \vec{0} \quad (4.4)$$

Le terme de gauche de cette équation se développe en :

$$\begin{aligned} \frac{du(x(t), y(t), t)}{dt} &= \frac{\partial u(x(t), y(t), t)}{\partial t} + \frac{\partial x(t)}{\partial t} \frac{\partial u(x(t), y(t), t)}{\partial x} + \frac{\partial y(t)}{\partial t} \frac{\partial u(x(t), y(t), t)}{\partial y} \\ &= \frac{\partial u}{\partial t} + u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} = \frac{\partial u}{\partial t} + \nabla u \cdot \mathbf{w} \\ \frac{dv(x(t), y(t), t)}{dt} &= \frac{\partial v(x(t), y(t), t)}{\partial t} + \frac{\partial x(t)}{\partial t} \frac{\partial v(x(t), y(t), t)}{\partial x} + \frac{\partial y(t)}{\partial t} \frac{\partial v(x(t), y(t), t)}{\partial y} \\ &= \frac{\partial v}{\partial t} + u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} = \frac{\partial v}{\partial t} + \nabla v \cdot \mathbf{w} \end{aligned}$$

L'équation (4.4) se réécrit vectoriellement par :

$$\frac{\partial \mathbf{w}}{\partial t} + \nabla \mathbf{w} \cdot \mathbf{w} = \vec{0} \quad (4.5)$$

Étant transporté par lui-même, le mouvement pourra accompagner le transport des structures jusqu'à un horizon temporel éloigné et, en théorie, jusqu'à ce que les structures sortent du domaine spatial d'étude. Dans cette étape, les traceurs restent transportés par

le champ de mouvement. *In fine*, le modèle  $\mathbb{M}_f$  s'écrit :

$$\mathbb{M}_f(X) = \begin{pmatrix} \nabla \mathbf{w} \cdot \mathbf{w} \\ \nabla I \cdot \mathbf{w} \end{pmatrix} \quad (4.6)$$

ou encore, pour les algorithmes multi-échelle :

$$\mathbb{M}_f(X) = \begin{pmatrix} \nabla \mathbf{w} \cdot \mathbf{w} \\ \nabla I_r \cdot \mathbf{w} \\ \nabla I_l \cdot \mathbf{w} \end{pmatrix} \quad (4.7)$$

Pour écrire l'équation d'évolution (4.3), on utilise une approximation de la dérivée temporelle par un schéma d'Euler :

$$\frac{\partial X(t)}{\partial t} \approx \frac{X(t + \Delta t) - X(t)}{\Delta t}$$

où  $\Delta t$  est le pas de discrétisation en temps. L'équation d'évolution discrète en temps s'écrit donc :

$$X(t + \Delta t) = X(t) - \Delta t \mathbb{M}_f(X(t))$$

Le modèle  $\mathbb{M}_f$  contient les termes d'advection suivants :  $\nabla I \cdot \mathbf{w}$ ,  $\nabla u \cdot \mathbf{w}$ , et  $\nabla v \cdot \mathbf{w}$ . Ces termes peuvent être discrétisés en espace efficacement avec un schéma semi-lagrangien [SC91, TS01, Hor02], qui est inconditionnellement stable vis-à-vis des conditions CFL [CFL67]. L'avantage d'un tel schéma est visible lors de la paramétrisation de l'algorithme : l'absence de condition CFL permet de choisir n'importe quelle valeur de pas de temps  $\Delta t$ , tout en gardant un schéma stable. En augmentant  $\Delta t$ , on diminue le nombre de pas d'intégration et donc le temps de calcul nécessaire pour l'estimation. Mais, dans la pratique, des valeurs plus petites de  $\Delta t$  permettent de diminuer les erreurs numériques, puisque le schéma repose sur une interpolation linéaire. Il y a donc un compromis à réaliser entre temps de calcul et qualité du résultat. La figure 4.1 présente un exemple de prévision à partir d'une observation et d'un champ de mouvement estimé.

C'est sur le résultat de prévision que nous évaluons les résultats des algorithmes SMRN et PMRN par rapport à l'algorithme initial *Rain Nowcast*. Au chapitre 5 il sera montré que les performances de SMRN et PMRN sont meilleures : elles améliorent l'estimation du mouvement et, en conséquence, les structures nuageuses sont mieux localisées dans les prévisions. Cette meilleure localisation permet, d'une part, une meilleure estimation des taux de pluie et, d'autre part, d'étendre l'horizon temporel de la prévision à 45 minutes. Concernant les prévisions à cette valeur d'horizon, il est possible de formuler deux remarques :



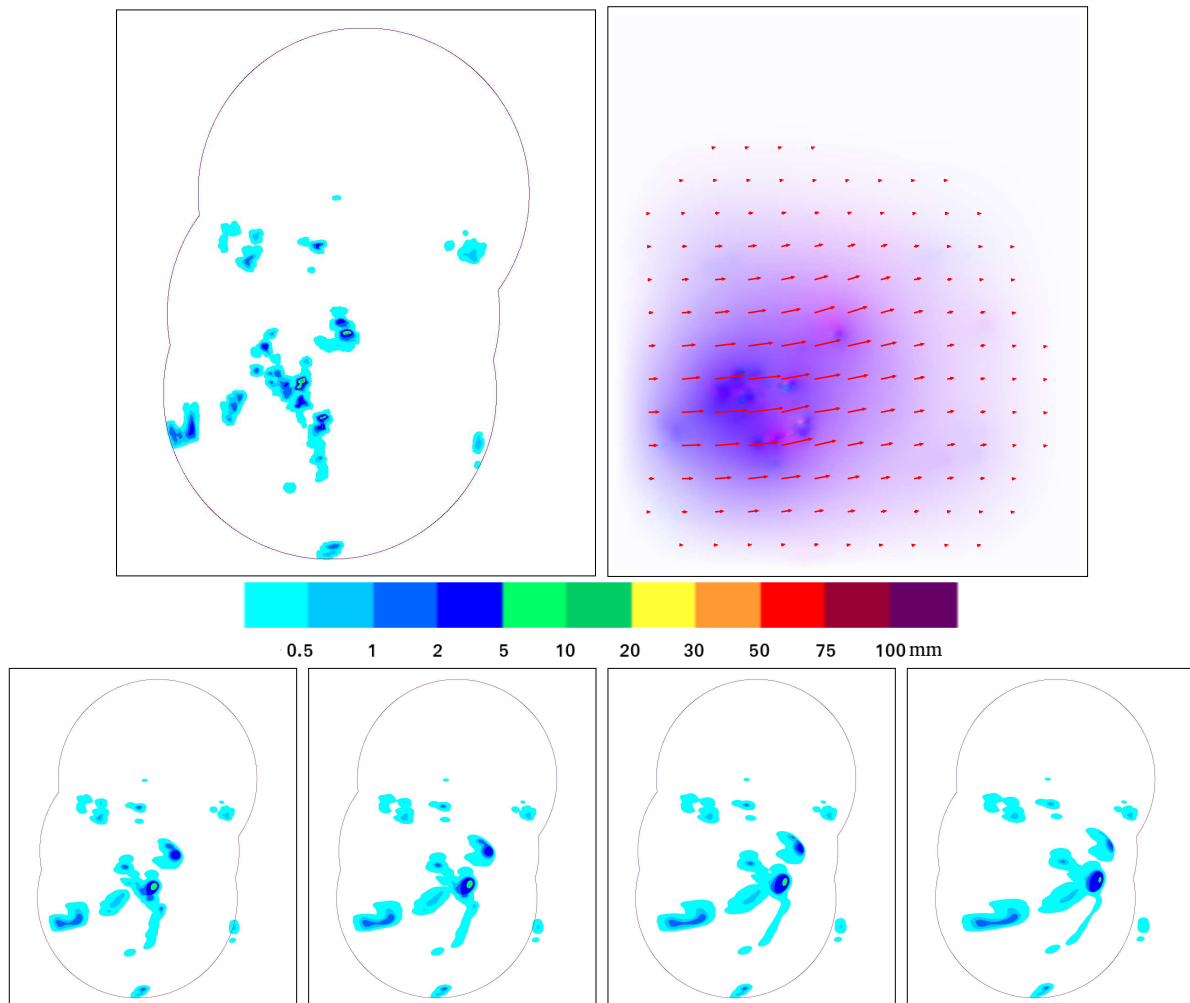


FIGURE 4.1 – Un exemple de prédiction : à partir de la dernière acquisition disponible (en haut à gauche) et du champs de vitesse  $w_{ME}$  calculé par l'une des méthodes du chapitre 3 (en haut à droite, affichage coloré de Middlebury), nous produisons (en bas, de gauche à droite) une prédiction à  $t_h = 30, 45, 60$  et  $75$  minutes.

1. sur les zones de faible contraste, le champ de vitesse est généralement sous-estimé, car les valeurs de gradient spatial  $y$  sont trop faibles, conduisant l'équation du flot optique à devenir non significative. Mais une sous-estimation de la vitesse, lors de la phase d'estimation de la dynamique atmosphérique, conduit automatiquement à une mauvaise localisation des structures lors de la phase de prévision ;
2. le schéma semi-lagrangien est connu pour lisser les résultats. En utilisant un tel schéma à un horizon temporel éloigné, on dégrade l'estimation des valeurs quantitatives des pixels de l'image, et en conséquence l'estimation des quantités de pluie.

Dans les sections suivantes, 4.2 et 4.3, nous présentons deux contributions de notre travail, destinées à compenser ces deux difficultés.

## 4.2 Correction de l'intensité du mouvement : hypothèse de vent géostrophique

Les méthodes d'estimation du mouvement présentées dans le chapitre 3 sont très sensibles aux gradients spatiaux calculés sur les images, puisque mouvement et gradients sont liés dans l'équation :

$$\frac{\partial I}{\partial t} + \nabla I \cdot \mathbf{w} = 0 \quad (4.8)$$

En conséquence, un gradient nul ne fournit aucune information sur  $\mathbf{w}$ .

Le vecteur vitesse  $\mathbf{w}$  est, comme tout vecteur, caractérisé par son orientation et sa norme. Si l'orientation est généralement correctement estimée, en partie grâce au terme de régularisation inclus dans la fonction de coût, il n'en est pas de même pour la norme. Celle-ci apparaît sous-estimée sur les zones de faible gradient spatial, également en raison de la régularisation. La figure 4.2 présente une comparaison entre la quantité de pluie dans une observation (à gauche et au milieu) et la norme du champ de vitesses estimé sur ces observations (à droite). On constate une corrélation entre la quantité de précipitations et l'intensité du mouvement alors que visuellement l'ensemble des structures se déplacent avec une vitesse similaire. Ce défaut engendre une mauvaise prévision en terme de positionnement spatial de certaines structures, dont le déplacement est généralement caractérisé par un retard.

Pour régler ce problème, nous faisons l'hypothèse d'un vent *géostrophique* [Mar09]. Un vent géostrophique est caractérisé par le fait que la norme du vecteur vitesse, sur le domaine spatial, est constante. Une telle hypothèse apparaît réaliste sur la région d'étude, le bassin de Clermont-Ferrand. En conséquence, nous seuillons la norme du champ de vitesses à un certain taux  $\tau$  de sa valeur maximale sur le domaine spatial  $\Omega$  : les vecteurs vitesse dont la norme est inférieure à ce seuil sont relevés à cette valeur et les autres




FIGURE 4.2 – De gauche à droite : deux observations à deux temps successifs et intensité du mouvement estimé à partir de ces observations.

vecteurs restent inchangés. Le traitement consiste donc à appliquer la transformation suivante aux vecteurs vitesse  $\mathbf{w}$  pour obtenir une vitesse  $\mathbf{w}_{\text{geo}}$ , sous hypothèse de vent géostrophique :

$$\mathbf{w}_{\text{geo}}(x, y) = \|\mathbf{w}_{\text{max}}\| \frac{\mathbf{w}(x, y)}{\|\mathbf{w}(x, y)\|} \quad (x, y) \in \Omega \quad (4.9)$$

où  $\mathbf{w}_{\text{max}}$  est défini par :

$$\mathbf{w}_{\text{max}} = \tau \times \max_{(x, y) \in \Omega} \mathbf{w}(x, y) \quad (4.10)$$

La correction, selon l'hypothèse de vent géostrophique et l'utilisation de  $\tau$ , n'affecte que la norme des vecteurs vitesse (voir équation (4.9)), l'orientation est inchangée.

Il nous reste à choisir  $\tau$ . Un seuil fixé trop haut provoque une mauvaise localisation pour certaines structures qui avancent trop vite car le champ de mouvement devient trop fort. La prévision aura donc davantage de faux positifs (prévision de pluies non observées dans la réalité). Un seuil fixé trop bas nous ramènera à la situation antérieure (un mouvement trop faible) et diminuera également les performances en terme de localisation des structures. La table 4.1 présente les statistiques des prévisions de *Rain Nowcast* aux horizons de 30 et 45 minutes, en utilisant plusieurs valeurs pour  $\tau$ . Les meilleures performances sont obtenues avec  $\tau = 70\%$  sur un exemple caractéristique. Le seuil  $\tau = 70\%$  a été consolidé sur l'ensemble des données à notre disposition. Il maximise bien la performance de la prévision (nous utilisons les métriques décrites au chapitre 5 pour étudier et évaluer les performances de prévision).

La figure 4.3 illustre un exemple du mouvement estimé par *Rain Nowcast*, corrigé en intensité en utilisant plusieurs valeurs de  $\tau$ . Cette méthode a l'inconvénient d'attribuer

TABLE 4.1 – Statistiques sur un exemple de prévision de *Rain Nowcast*, sous l’hypothèse de vent géostrophique et à l’horizon  $t_h = 30$  et 45 minutes en utilisant plusieurs valeurs pour  $\tau$ .

Horizon de prévision $t_h$	$\tau$ (en %)	POD	FMS	FAR	MAE
30 minutes	sans VG	0,416	0,280	0,526	1,102
	10	0,239	0,148	0,720	1,154
	20	0,289	0,181	0,674	1,108
	30	0,345	0,220	0,621	1,094
	40	0,402	0,263	0,567	1,062
	50	0,441	0,292	0,535	1,024
	60	0,456	0,299	0,534	1,002
	70	<b>0,470</b>	<b>0,314</b>	<b>0,513</b>	<b>0,986</b>
	80	0,419	0,267	0,575	1,046
	90	0,379	0,235	0,618	1,087
	100	0,345	0,208	0,656	1,134
45 minutes	sans VG	0,361	0,230	0,592	1,173
	10	0,160	0,093	0,816	1,139
	20	0,186	0,107	0,796	1,110
	30	0,243	0,143	0,742	1,145
	40	0,346	0,212	0,645	1,170
	50	0,400	0,250	0,598	1,109
	60	0,432	0,270	0,581	1,112
	70	<b>0,435</b>	<b>0,279</b>	<b>0,570</b>	<b>1,074</b>
	80	0,388	0,232	0,633	1,137
	90	0,333	0,190	0,692	1,149
	100	0,271	0,148	0,753	1,157

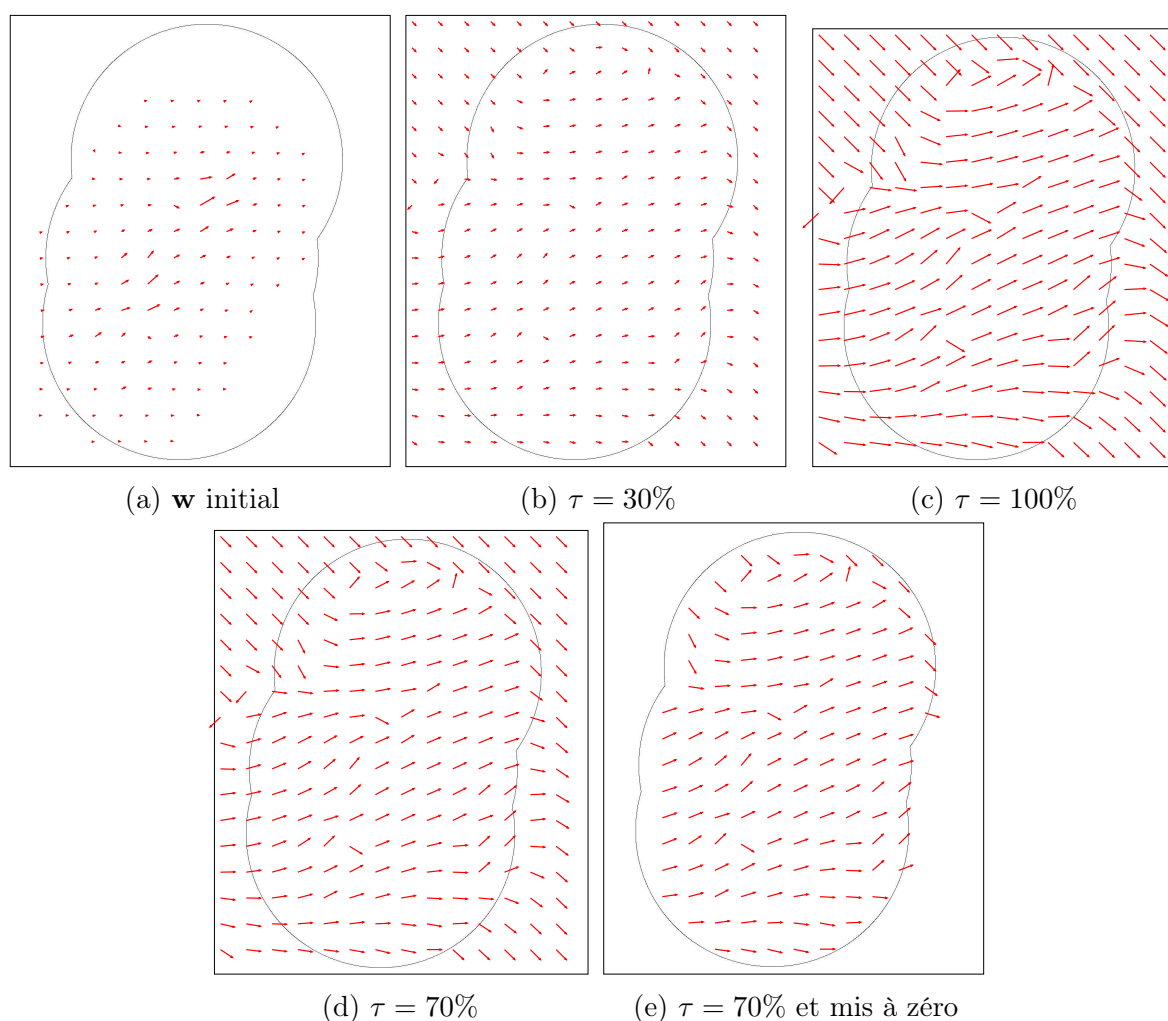


FIGURE 4.3 – Exemple de mouvement estimé par *Rain Nowcast*, sous l’hypothèse de vent géostrophique et avec  $\tau \in \{30, 70, 100\}$ .

une intensité égale à 70% de l’intensité maximale pour les vecteurs vitesse en dehors du domaine local, comme on peut le voir dans la figure 4.3d. Ces vecteurs sont la conséquence de la régularisation spatiale dans l’algorithme 4DVar. Pour ces vecteurs de très faible intensité, les orientations ne sont pas toujours significatives. Nous avons donc mis à zéro le champ de vitesse estimé en dehors du domaine local (voir figure 4.3e). De façon alternative nous pourrions décider d’un seuil bas, en dessous duquel nous ne corrigeons pas l’intensité, ou encore de conserver ces vecteurs tout en corrigeant leur direction à l’aide d’un processus de régularisation spatiale par exemple. Pour les mouvements estimés par les modèles PMRN et SMRN ces cas de figure ne se produisent pas car le domaine régional n’est pas discontinu.

La figure 4.4 explicite l’impact de l’utilisation d’une hypothèse de vent géostrophique sur le champ de mouvement. La figure 4.5 montre, quant à elle, un exemple de prévision obtenue si le mouvement est estimé par l’algorithme *Rain Nowcast* et si celui-ci est calculé




FIGURE 4.4 – À gauche le champ de vitesse initial estimé par *Rain Nowcast*, à droite le mouvement sous l’hypothèse de vent géostrophique.

sous hypothèse de vent géostrophique.

### 4.3 Correction de la distribution des prévisions

La deuxième piste d’amélioration concerne l’étape de prévision. Comme il a été dit dans la section 4.1, le modèle  $M_f$  est discrétisé par un schéma semi-lagrangien. L’avantage de ce schéma est qu’il est inconditionnellement stable et qu’il donne des résultats précis et à moindre coût de calcul. Néanmoins, il présente l’inconvénient majeur de lisser les structures. Plus l’horizon de prévision temporel est éloigné, plus cet effet de lissage devient important. Il a pour conséquence d’étaler les cellules orageuses, comme l’illustre la figure 4.6. Cet étalement engendre une sous-estimation des quantités de pluie là où elles sont les plus élevées, une sur-estimation des quantités de pluies là où elles les plus faibles, et une prévision erronée là où il n’y a pas de pluie.

En regard, il est important de comprendre que nous ne souhaitons pas changer de schéma, au profit d’un autre qui serait plus précis. En effet, les schémas explicites à l’ordre 2 pourraient être de bon candidats pour limiter l’impact des limitations du schéma semi-lagrangien. Mais l’utilisation opérationnelle de la méthode conduit à des contraintes fortes sur les temps d’exécution et ne permet pas de recourir à ces techniques.

Dans ce contexte, nous faisons choix d’utiliser une méthode de post-correction de la distribution des valeurs dans l’image prédite. Pour cela, nous faisons l’hypothèse que la loi




FIGURE 4.5 – Comparaison entre les prévisions obtenues avec ou sans hypothèse de vent géostrophique sur une région d'intérêt. (a) observation (vérité terrain), (b) prévision calculée par *Rain Nowcast* sans hypothèse de vent géostrophique, (c) prévision calculée sous l'hypothèse de vent géostrophique.

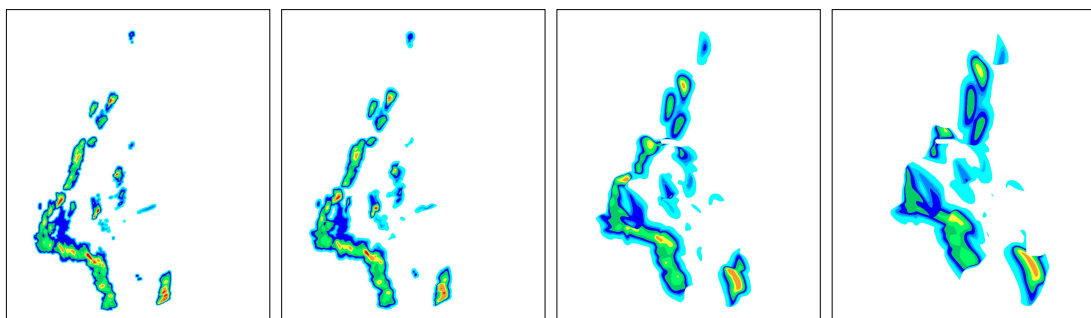


FIGURE 4.6 – Effet de lissage introduit par le schéma semi-lagrangien. De gauche à droite : la condition initiale (observation) et les prévisions à  $t_h = 5, 30$  et 60 minutes.

de distribution des valeurs de l'image prédite doit être la même que celle de l'observation qui est utilisée pour le calcul de la prévision. Cette hypothèse paraît en effet réaliste sur l'horizon temporel visé pour l'utilisation de la méthode.

Pour réaliser cette opération, nous utilisons une technique, largement décrite dans la littérature, pour corriger les mesures de pluviométrie estimées à partir d'images radar [RH15]. Soit  $I^\circ$  l'acquisition à partir de laquelle la prévision  $I$  a été calculée à un horizon temporel donné. Soient  $F_{I^\circ}$  et  $F_I$  les fonctions de répartition<sup>1</sup> respectives de  $I^\circ$  et  $I$ . À un pixel ayant la valeur  $v$  sur l'image  $I$ , on affecte une nouvelle valeur  $v'$  calculée par :

$$v' = F_{I^\circ}^{-1}(F_I(v)) \quad (4.11)$$

Cette transformation repose sur la propriété suivante : soit une variable aléatoire  $X$ , alors la fonction de répartition  $F(X)$  suit une loi uniforme sur l'intervalle  $[0, 1]$ , où  $F$  est la fonction de répartition de  $X$ . Ainsi les images  $F_I(I)$  et  $F_{I^\circ}(I^\circ)$  suivent une loi de répartition uniforme. En conséquence, l'image  $F_{I^\circ}^{-1}(F_I(I))$  a la même répartition que l'image  $I^\circ$ .

En pratique, il suffit donc de calculer les histogrammes des images  $I$  et  $I^\circ$ , et leurs fonctions de répartition  $F_I$  et  $F_{I^\circ}$ , puis d'établir une table de correspondance entre les valeurs  $v$  et leurs correspondants  $v'$  à l'aide de l'équation (4.11). Chaque occurrence  $t$  dans l'image  $I$  est ensuite remplacée par la valeur  $v'$  pour obtenir une nouvelle image de prévision  $I'$ . Après cette opération, les deux images  $I'$  et  $I^\circ$  ont le même histogramme.

Néanmoins, le calcul précédent reste approximatif, puisque l'histogramme calculé sur une image n'est qu'une représentation approximative de la loi statistique sous-jacente à cette acquisition. Une hypothèse très largement utilisée dans la communauté radar est de supposer que ce type d'acquisition suit une loi Gamma [IH06, RH15] de densité :

$$\gamma_{\alpha,\beta}(x) = \frac{\beta^\alpha x^{\alpha-1} e^{-\beta x}}{\Gamma(\alpha, \beta)} \quad (4.12)$$

où  $\alpha$  et  $\beta$  sont deux paramètres strictement positifs, qui caractérisent la loi et  $\Gamma$  représente la fonction Gamma d'Euler. Les deux paramètres  $\alpha$  et  $\beta$  sont estimés par maximum de vraisemblance.

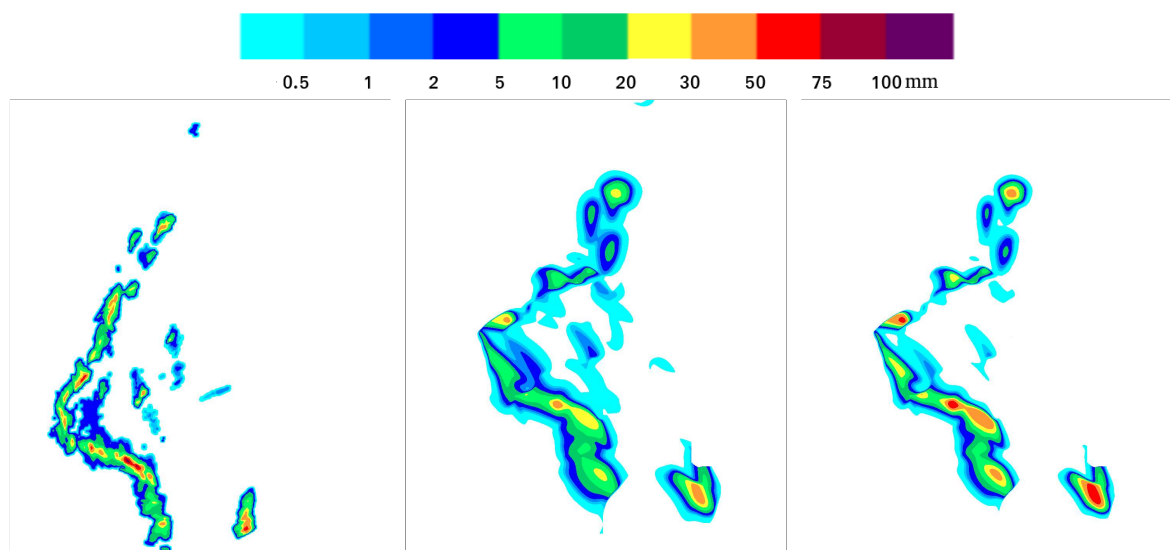
Nous estimons donc les paramètres  $\alpha$  et  $\beta$  pour les deux images  $I^\circ$  et  $I$ , afin d'estimer précisément les fonctions de répartition respectives  $F_{I^\circ}$  et  $F_I$ , sous l'hypothèse que les valeurs des images suivent une loi Gamma. Nous appliquons ensuite l'équation (4.11) pour obtenir l'image de prévision corrigée  $I'$ . La figure 4.7 montre un exemple d'une prévision des précipitations, obtenue selon ce principe. La figure 4.8 montre les fonctions

---

1. ou encore *Cumulative Distribution Function* dans la littérature scientifique anglophone



de répartition utilisées.



(a) Observation qui fournit la distribution de référence. (b) Prédiction sans correction. (c) Prédiction avec correction.

FIGURE 4.7 – Comparaison entre les prévisions calculées sans et avec correction de la distribution. (a) L’observation qui a servi à produire la prévision et qui fournit la distribution de référence. (b) La prévision calculée à partir de l’observation (a). (c) La prévision calculée à partir de l’observation (a) après correction de sa distribution.

## 4.4 Conclusion

Dans ce chapitre, nous avons proposé deux méthodes pour corriger les défauts de l’approche initiale, *Rain Nowcast*, qui restaient présents dans les approches SMRN et PMRN décrites au chapitre 4.

Le premier défaut correspond à une limitation intrinsèque des approches de type flot optique dans la phase d’estimation de la dynamique, qui sous-estime en intensité le mouvement des structures peu contrastées. Elle a été corrigée en utilisant une hypothèse de vent géostrophique sur les données.

Le second défaut concerne la phase d’advection en temps du vecteur d’état, afin de produire la prévision à l’horizon temporel choisi. Cette étape est affectée par les défauts du schéma numérique utilisé, choisi en raison des contraintes opérationnelles sur le temps de calcul. Pour corriger ce point, nous avons opté pour une approche statistique, en recalant les distributions des images prédites sur les observations réelles.

Nous avons discuté qualitativement l’apport de ces méthodes sur la pertinence des résultats. Les performances quantitatives sont analysées de façon extensive dans le chapitre 5.

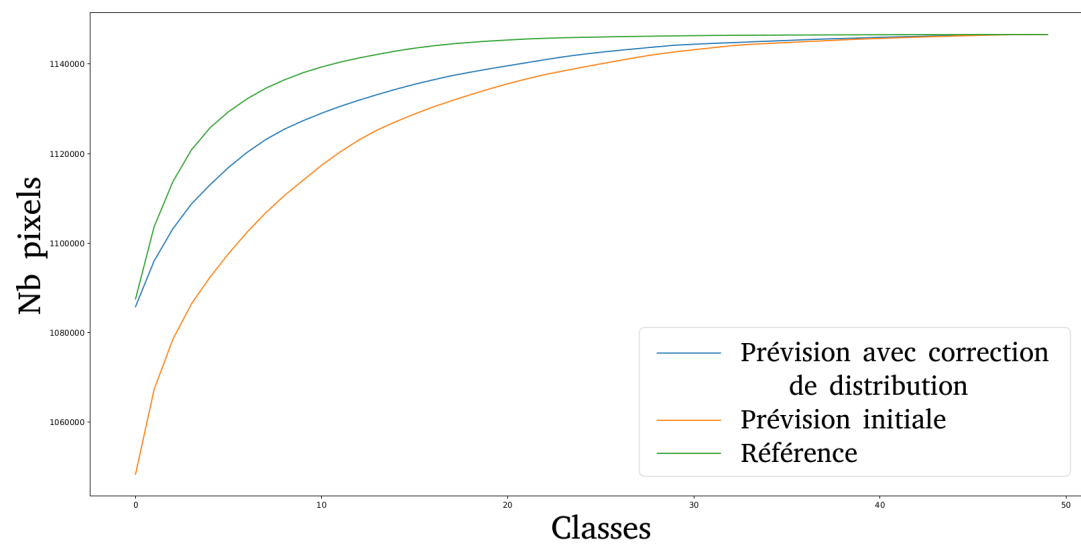


FIGURE 4.8 – Graphe des fonctions de répartition de l’observation (en vert), de la prévision (en orange), de la prévision après correction (en bleu).



# Chapitre 5

## Analyse quantitative des résultats et validation

## Sommaire

---

<b>5.1</b>	<b>Description des données</b>	<b>101</b>
5.1.1	Données radars en bande X	101
5.1.2	Données Panthere	105
5.1.3	Description des jeux de données	105
<b>5.2</b>	<b>Métriques</b>	<b>108</b>
<b>5.3</b>	<b>Résultats</b>	<b>110</b>
5.3.1	Sequential Motion Rain Nowcast (SMRN)	111
5.3.2	Parallel Motion Rain Nowcast (PMRN)	116
5.3.3	Hypothèse de vent géostrophique	122
5.3.4	Correction de la distribution de la prévision	133
<b>5.4</b>	<b>Conclusion</b>	<b>138</b>

---

Ce chapitre est principalement dédié à l'évaluation quantitative des différentes contributions présentées dans ce manuscrit de thèse. Dans un premier temps, nous présentons les caractéristiques des différentes données utilisées pour cette validation. Ensuite, nous décrivons et motivons les métriques utilisées pour quantifier les résultats obtenus. Chaque contribution est naturellement évaluée en regard de l'algorithme de référence, *Rain Nowcast*. Plusieurs cas tests sont identifiés pour discuter de la pertinence de chaque contribution.

## 5.1 Description des données

### 5.1.1 Données radars en bande X

La société Weather Measures s'intéresse à l'exploitation d'une nouvelle technologie de radar pluviométrique à haute résolution. Ce radar, de petite taille et dit en bande X, permet de cartographier la pluviométrie dans un rayon de l'ordre de 50 km. Il permet d'effectuer une revisite de l'acquisition toutes les 1 à 5 minutes, et présente des résolutions spatiales de quelques centaines de mètres. La figure 5.1 fournit des photos d'un radar en bande X.



FIGURE 5.1 – Radar WR25XP en bande X. À gauche, un radar installé sur un toit de bâtiment et, à droite, le radar sans le radôme.

Ces radars pluviométriques en bande X ont les caractéristiques suivantes :

- diamètre du radôme : 0,9 m ; hauteur : 1,3 m ; poids < 100 kg ;

- diamètre d'antenne : 0,75 m ;
- fréquence d'émission : 9400 MHz (3 cm - bande X) ;
- résolution spatiale : de 100 à 500 m ;
- résolution temporelle : de 1 à 5 minutes.

Dans les faits, Weather Measures exploite plusieurs versions de radars météorologiques, à savoir : le radar WR10XCE (développé en 2011), le radar WR10X (développé en 2006) et le radar WR25XP (développé depuis 2013). Weather Measures déploie ces radars sur deux réseaux en France métropolitaine. Le premier est localisé dans la Beauce et le deuxième dans la Limagne, une plaine de très grande taille située à côté de Clermont-Ferrand. Trois radars ont été déployés sur chacun de ces deux réseaux. Dans la Beauce, les trois radars sont localisés de telle manière qu'ils permettent de couvrir la plaine dans sa totalité, sur les sites d'Orléans, de Bailleau-le-Pin et de Saint-Amand-Longpré. En Limagne, les trois radars sont déployés du Nord au Sud, à Montoldre, Chappes et Pardines.

La figure 5.2 présente la couverture spatiale des deux réseaux de radars en bande X sur les plaines de Limagne et de la Beauce.

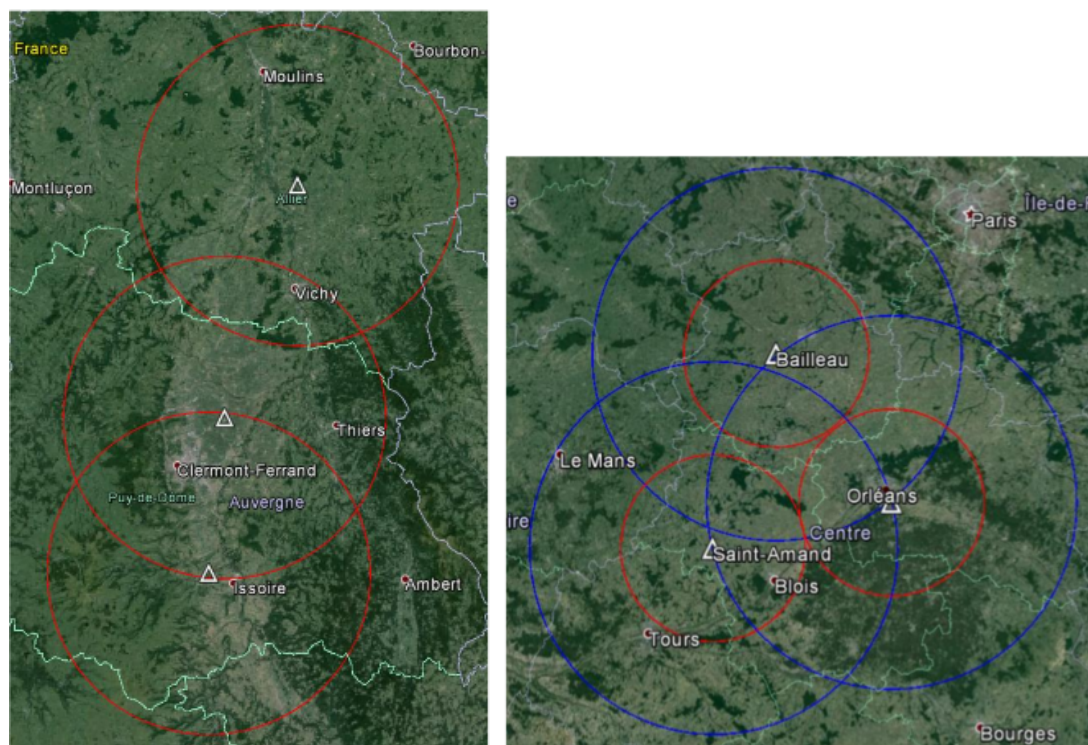


FIGURE 5.2 – Positionnement des radars. À droite : le réseau de la Limagne, à gauche : le réseau de la Beauce. La portée de chaque radar est indiquée par un cercle, rouge pour les radars d'une portée de 36 km, bleu pour les radars d'une portée de 72 km. Image de fond : Google Earth.

Pour chaque radar, les acquisitions sont obtenues sur plusieurs élévations. Les valeurs

acquises, plusieurs donc pour une même localisation au sol, sont fusionnées en ne retenant que la valeur maximale [PJ00]. La résolution angulaire des radars est de un degré. Pour chaque valeur d'angle, nous enregistrons des acquisitions sur un rayon composé de 240 points (appelés portes). Chaque point présente une résolution spatiale de 200 mètres. Les acquisitions, enregistrées en coordonnées polaires, sont ensuite converties en coordonnées cartésiennes, afin d'obtenir une image sur une grille cartésienne de  $481 \times 481$  pixels. Enfin, les valeurs des pixels sur ces grilles cartésiennes sont transformées en valeurs de taux de précipitation, en appliquant la formule de Marshall-Palmer (voir section 2.2.4).

Comme nous pouvons le constater sur la figure 5.3, en coordonnées cartésiennes, plus nous nous éloignons du radar, plus les portes du radar deviennent rares, ce qui implique une absence de données. Un grand nombre de techniques d'interpolation sont disponibles

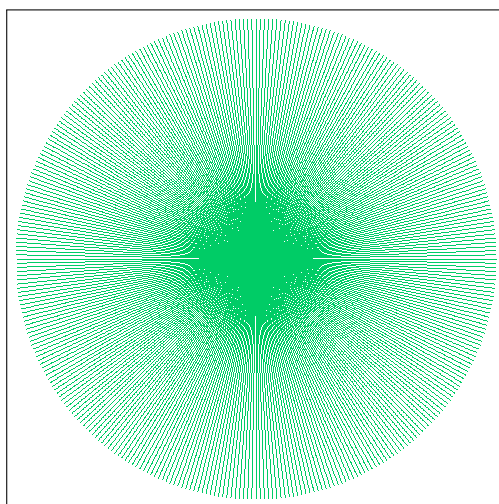


FIGURE 5.3 – Grille cartésienne des points acquisition.

dans la littérature [FN91] pour attribuer une valeur pertinente à chaque pixel de la grille cartésienne, en cohérence avec les acquisitions effectives. Dans le contexte de ce manuscrit de thèse, un processus de diffusion isotropique est utilisé. Il correspond dans les faits à effectuer une interpolation bilinéaire.

Comme nous l'avons dit, Weather Measures dispose de 3 radars sur la plaine adjacente à Clermont-Ferrand. Ceux-ci sont disposés de façon à couvrir le territoire le plus large possible. À partir de ces données, on peut réaliser une mosaïque. Pour ce faire, lorsque les zones d'acquisition se superposent, on fusionne les données en prenant à nouveau la valeur maximale. De ce processus, il résulte une image de taille  $980 \times 1170$ , avec une résolution spatiale de 200 mètres par pixel.

Pour chaque image, la valeur en chaque point représente le taux de précipitations, exprimé en  $\text{mm/h}$ . Ces valeurs sont ensuite transformées en quantités de précipitation, exprimées en mm.



Deux images  $980 \times 1170$  consécutives, issues de cette chaîne de traitement, sont disponibles à un intervalle de 5 minutes, qui correspondent à la période temporelle d’acquisitions des trois radars. Ces images, obtenues par la chaîne de traitement que nous venons de décrire, sont appelées acquisition radar en bande X dans la suite de ce manuscrit afin de ne pas rendre la formulation trop complexe, en rappelant sans cesse les prétraitements effectués. Le terme “données locales”, qui avait été introduit dans la section 3.2, fait également référence à ces images.

La figure 5.4 montre donc, sur la droite, une acquisition radar en bande X fournie par Weather Measures. Ce sont ces données que nous avons utilisées dans notre travail expérimental et qui sont lues en entrée de nos algorithmes.




FIGURE 5.4 – Exemple d’acquisition radar en bande X. À droite : image radar, chaque pixel mesure une quantité de pluie en mm. À gauche : quantification non linéaire des précipitations, sur la même acquisition, selon une échelle de 11 valeurs allant d’une quantité de pluie entre 0,01 et 0,5 mm (cyan) jusqu’à 100 mm ou plus (marron). L’absence de pluie est indiquée par la couleur blanche. Le domaine d’acquisition est visualisé sur la gauche.

L’image de gauche, dans la figure 5.4, est utilisée pour permettre une interprétation humaine de la problématique précipitation. On remarque que la couleur blanche est prédominante : elle correspond à une absence de signal. Dans ce cas, nous sommes soit en dehors du domaine d’acquisition effectif d’un des 3 radars en bande X, soit dans une zone

où il n'y a pas de pluie.

### 5.1.2 Données Panthere

Panthere, dont l'acronyme est **P**rojet **A**RAMIS **N**ouvelles **T**echnologies en **H**ydro-météorologie **E**xtension et **R**Enouvellement, est le nom d'un projet lancé en 2002 par Météo-France et le ministère de l'environnement dans l'objectif de : (1) moderniser le réseau de radars météorologiques de Météo-France, (2) étendre la couverture de réseau ARAMIS sur toute la France métropolitaine, afin de pouvoir créer une mosaïque d'images radar couvrant tout le territoire national (3) évaluer le potentiel des technologies modernes (observation volumétrique, Doppler, double polarisation) pour améliorer les estimations des précipitations [PTMG05].

Le réseau ARAMIS comprend, en Métropole et à la date du 11 juillet 2017, 30 radars : 19 radars en bande C, 5 en bandes S et 6 en bande X. Les radars en bande C (longueur d'onde 5 cm) et S (longueur d'onde 10 cm), dont les antennes mesurent de 3,5 à 6,5 mètres de diamètre, ont une portée allant jusqu'à 200 kilomètres. Les radars en bande X (longueur d'onde de 3 cm) ont une portée plus faible, de l'ordre de 50 kilomètres, mais sont aussi de taille plus réduite (le diamètre de leur antenne est de 2 mètres).

Météo-France commercialise un produit nommé Panthere<sup>1</sup>. Ces données quantifient, en coordonnées cartésiennes, les lames d'eau (quantités de pluie) à partir des données radar du réseau éponyme, acquises toutes les 5 minutes avec une résolution spatiale de 1 km.

La figure 5.5 montre la couverture du réseau d'acquisitions des données Panthere sur le territoire de la France métropolitaine en 2019, ainsi qu'un exemple de données Panthere.

### 5.1.3 Description des jeux de données

Nous utilisons donc deux types d'images : celles fournies par les radars en bande X de Weather Measures (images en bande X) et celles des radars du réseau PANTHERE (images Panthere). La figure 5.6 présente simultanément les deux réseaux d'acquisition et leurs intersections. On note que certaines zones ne sont pas couvertes, y compris sur la région que nous étudions, dans la plaine de Clermont-Ferrand.

Pour travailler simultanément sur les données Panthere et en bande X, une chaîne de traitement est proposée et décrite ci-dessous.

---

1. [https://donneespubliques.meteofrance.fr/?fond=produit&id\\_produit=103&id\\_rubrique=](https://donneespubliques.meteofrance.fr/?fond=produit&id_produit=103&id_rubrique=)  
34

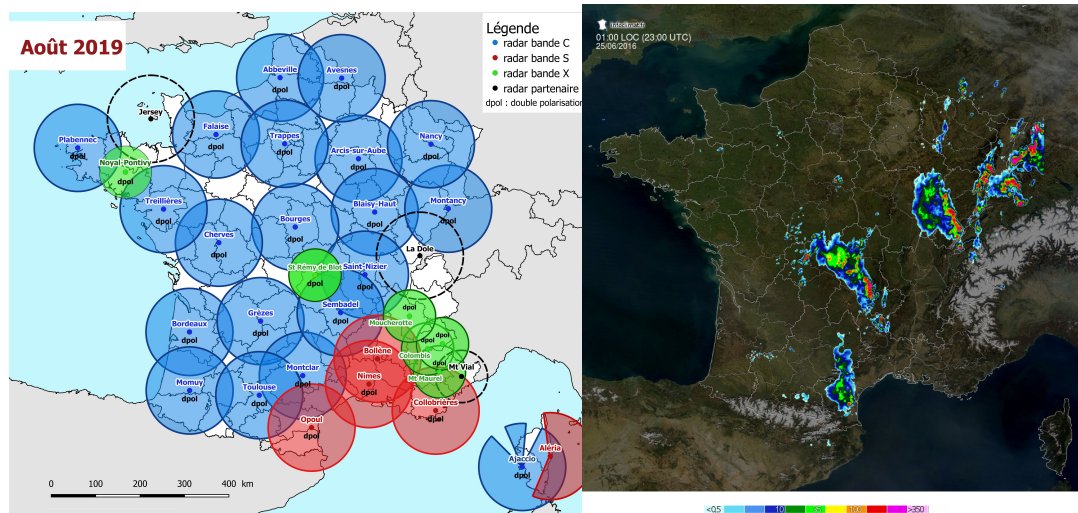


FIGURE 5.5 – À droite, le réseau PANTHERE ; à gauche, un exemple de données Panthere (sources : <http://météofrance.com>, <http://infoclimat.fr>).



FIGURE 5.6 – En jaune, le réseau des radars PANTHERE. En rouge, le réseau des radars en bande X de Weather Measure. En vert, la portion d’images Panthere correspondant au domaine d’acquisition en bande X.

Nous extrayons, sur les images Panthere, la zone correspondant au domaine d'acquisition des données en bande X. Nous sur-échantillons 5 fois les données Panthere, afin d'obtenir une résolution spatiale identique à celle des données en bande X. Nous obtenons ainsi une image de taille  $980 \times 1170$ , que nous appelons image Panthere dans la suite de ce manuscrit afin de ne pas rendre les formulations trop complexes. Le terme "donnée régionale" qui avait été introduit dans la section 3.2 fait référence, dans la suite de ce manuscrit, à ce nouveau type d'image, issu des acquisitions Panthere.

La figure 5.7 montre un exemple d'une image Panthere et d'une en bande X, qui sont positionnées sur le même domaine d'acquisition, après l'ensemble des prétraitements. On remarquera que dans ce domaine rectangulaire de  $980 \times 1170$  pixels, seuls 63% des pixels des données en bande X disposent d'une mesure radar. Le reste du domaine, pour les 37% pixels restant, est en dehors du domaine d'acquisition effectif des 3 radars en bande X. En revanche, sur les données Panthere, tous les pixels ont une valeur de mesure radar, puisque la zone concernée est à l'intérieur de la zone d'acquisition des capteurs du réseau Panthere.

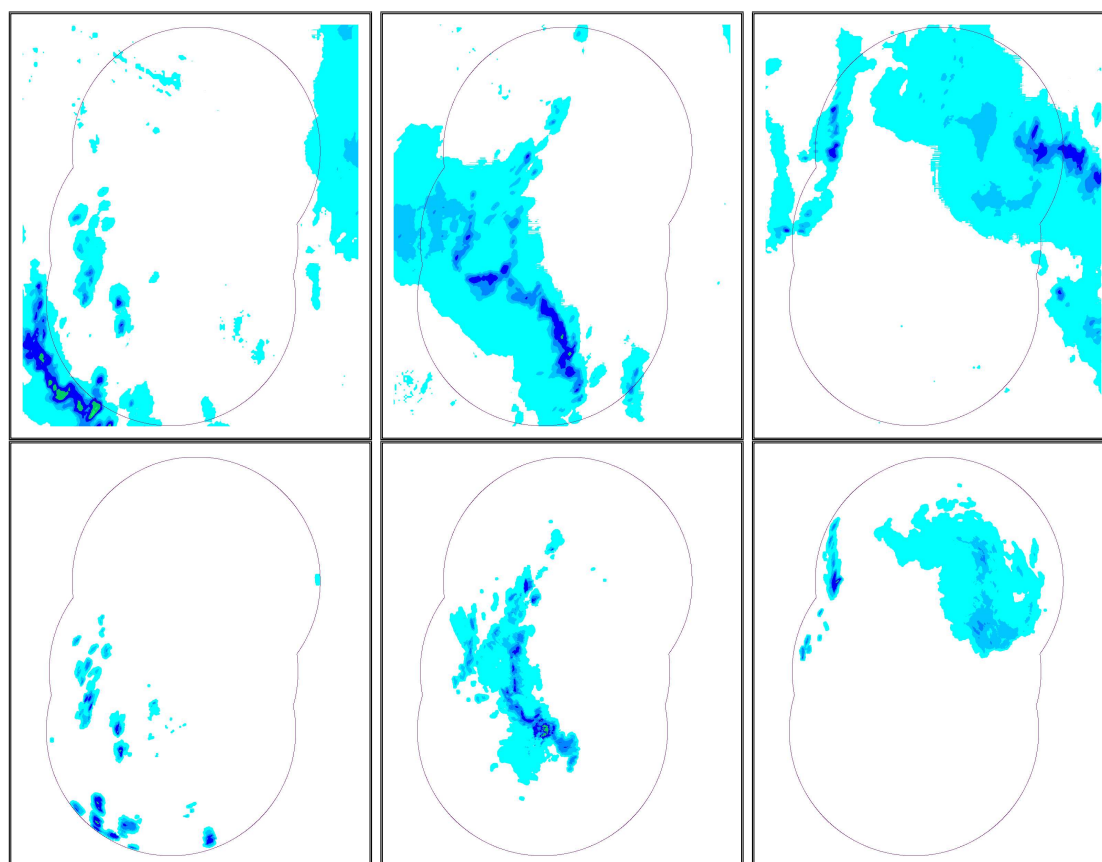


FIGURE 5.7 – Visualisation des précipitations à deux résolutions spatiales. Première ligne : carte de précipitations Panthere. Seconde ligne : carte de précipitations obtenue par radars en bande X.

L'ensemble des données à notre disposition, pour cette phase de tests et de validation, se compose de deux séquences d'acquisitions sur des événements pluvieux ayant eu lieu le 24 juin 2016 et le 30 juillet 2016. La première séquence comprend 98 images, correspondant à 8 heures d'acquisition entre 16h00 et minuit. La seconde séquence contient 110 images, correspondant à 9 heures d'acquisition entre 07h00 et 16h00.

## 5.2 Métriques

Afin de quantifier les résultats de prévision et de les comparer avec les observations, nous avons utilisé les quatre métriques suivantes : *Probability Of Detection* (POD), *Figure of Merit in Space*, *False Alarm Rate* (FAR) et *Mean Absolute Error* (MAE).

Les trois premières quantités s'intéressent à la position des structures, qui sont détectées à partir d'un seuillage des valeurs de précipitations sur les images. Le seuil est usuellement fixé à 0,2 mm (soit 2,4 mm/h). Il correspond à une quantité significative de pluie. Les pixels dans les images de prévision et ceux inclus dans les observations sont donc classés en deux catégories par ce seuillage : "1" pour présence de pluie, et "0" pour absence de pluie.

On quantifie alors :

- VP le nombre de pixels "vrai positif", c'est-à-dire prédits à une valeur "1" et observés à "1",
- VN le nombre de pixels "vrai négatif", c'est-à-dire prédits à une valeur "0" et observés à "0",
- FP le nombre de pixels "faux positif", c'est-à-dire prédits à une valeur "1" mais observés "0", et enfin,
- FN le nombre de pixels "faux négatif", c'est-à-dire prédit à une valeurs "0" mais observés à "1".

La figure 5.8 représente, de façon ensembliste, la définition des quatre variables VP, VN, FP et FN. Il est assez intuitif qu'une prévision sera bonne si les valeurs VP et VN sont élevées tandis que les valeurs FP et les FN sont petites (idéalement nulles).

La métrique POD quantifie le recouvrement entre les structures nuageuses observées et les structures correctement prédites. Elle est définie comme suit :

$$\text{POD} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (5.1)$$

Elle est comprise entre 0 et 1, 1 étant l'idéal car signifiant que le nombre de faux négatif FN est nul. Cette métrique ne s'intéresse donc qu'aux structures correctement prédites et ignore les autres.

	Observation	Prévision
VP	1	1
VN	0	0
FP	0	1
FN	1	0




FIGURE 5.8 – Illustration des variables VP, VN, FP et FN. Le cercle vert représente la structure nuageuse observée, le cercle bleu représente la structure nuageuse prédite.

La métrique FAR quantifie le recouvrement entre les structures nuageuses prédites faussement et la totalité des structures prédites, elle s'exprime par :

$$\text{FAR} = \frac{\text{FP}}{\text{FP} + \text{VN}} \quad (5.2)$$

Elle est comprise entre 0 et 1, 0 étant l'idéal, car correspondant à la situation où le nombre de vrai négatif VN est nul. Cette métrique ne s'intéresse donc qu'aux structures mal prédites et ignore les autres.

La métrique FMS quantifie le recouvrement entre les structures nuageuses observées et les structures prédites, elle correspond à :

$$\text{FMS} = \frac{\text{VP}}{\text{VP} + \text{FN} + \text{FP}} \quad (5.3)$$

Elle est également comprise entre 0 et 1, 1 étant l'idéal, car correspondant à la situation où les nombres de faux positif FP et de faux négatif FN sont nuls. Contrairement aux métriques POD et FAR, cette métrique s'intéresse à l'ensemble des structures prédites.

La figure 5.9 présente le résultat du calcul des métriques POD, FMS et FAR sur un exemple concret.

La quatrième métrique est notée MAE. Elle mesure le taux moyen d'erreur entre la quantité de pluie prédite et celle qui est observée. Alors que les trois premières métriques quantifiaient les performances en terme de positionnement des structures spatiales correspondant aux précipitations, la quatrième s'intéresse aux quantités de pluie et à la pertinence de la prédiction sur ce point. Cette métrique s'écrit :

$$\text{MAE} = \frac{1}{|\Omega|} \sum_{p \in \Omega} |O(p) - I(p)| \quad (5.4)$$

En considérant ces définitions, lorsque la prévision est pertinente et de qualité, les métriques POD et FMS doivent avoir des valeurs les plus élevées possibles et, au contraire,

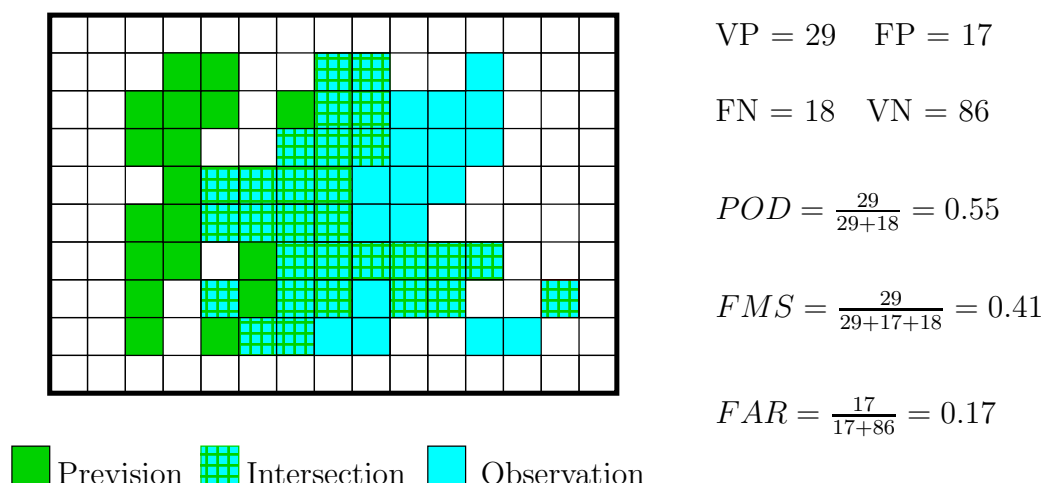


FIGURE 5.9 – Exemple de calcul des métriques. À droite : image sur laquelle sont représentées la prévision (en vert) et la vérité terrain (en cyan), ainsi que leur intersection. À droite : les valeurs correspondant aux 3 métriques calculées à partir des quatre classes de pixels : vrai positif (VP), faux positif (FP), faux négatif (FN) et vrai négatif (VN).

les métriques FAR et MAE doivent avoir des valeurs les plus faibles possibles. Dans ce cas là, nous parlerons de “bonnes performances”.

### 5.3 Résultats

Dans cette section, nous évaluons les performances des méthodes présentées dans les sections 3.2, 4.2 et 4.3 et nous les comparons à la méthode de référence, *Rain Nowcast*, qui a été décrite dans la section 2.3.6.

L'évaluation porte naturellement sur la qualité de prévision, qui est comparée aux observations locales et régionales en utilisant les quatre métriques décrites à la section 5.2.

Puisque lors de la phase d'estimation de la dynamique atmosphérique, nous utilisons des données à deux échelles différentes, il y a deux façons d'évaluer les performances :

- à l'échelle locale : les prévisions de *Rain Nowcast*, obtenues avec les seules observations locales, sont comparées avec les prévisions réalisées par les méthodes multi-échelle, qui utilisent à la fois les observations locales et régionales. Ceci permet de quantifier l'apport des données régionales lors de l'estimation d'un champ de mouvement local. Les différentes métriques sont quantifiées sur le domaine local, il s'agit des trois disques d'acquisition des trois radars en bande X, comme indiqué dans la figure 5.4,
- à l'échelle régionale : on compare les prévisions réalisées par *Rain Nowcast*, en utilisant les observations régionales, avec les prévisions obtenues par les méthodes multi-échelle, qui utilisent les deux types d'observation. Ceci permet de quantifier

l'apport des données locales pour l'estimation d'un champ régional. Les métriques sont quantifiées sur le domaine local, car c'est celui sur lequel l'utilisation des observations locales a un impact.

En ce qui concerne les contributions portant sur la phase de prévision, nous examinons les performances obtenues pour les deux échelles d'observation, afin de les comparer.

### 5.3.1 Sequential Motion Rain Nowcast (SMRN)

Dans cette sous-section nous évaluons les performances de SMRN. Les figures 5.10 et 5.11 montrent les performances de l'algorithme lors de la réalisation d'une prévision à 15 minutes par les deux algorithmes SMRN et *Rain Nowcast*, à partir, respectivement, des données locales et régionales extraites de l'épisode du 30 juillet 2016. On rappelle que cette séquence contient 148 images.

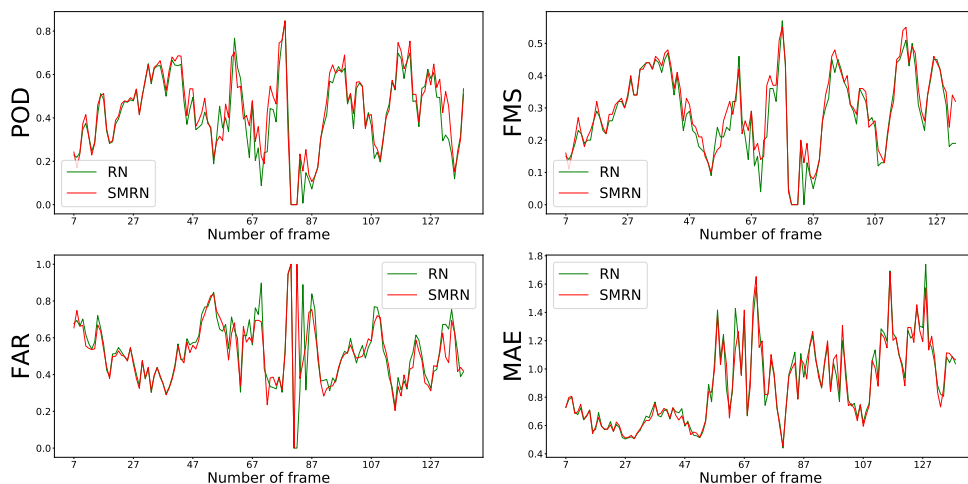


FIGURE 5.10 – Statistiques de SMRN et *Rain Nowcast* lors du calcul d'une prévision à  $t_h = 15$  min à partir des données locales. Épisode du 30 juillet 2016.

Pour obtenir ces résultats, nous avons procédé comme suit. L'estimation du mouvement est d'abord calculée à partir des acquisitions 1 à 4. Puis l'acquisition 4 est advectée à  $t_h = 15$  minutes, qui correspond, en temps, à la septième acquisition de la séquence. Nous avons ensuite itéré en utilisant les acquisitions 2 à 5 pour le mouvement...

Les tableaux 5.1 et 5.2 présentent les statistiques obtenues sur l'ensemble des images de la séquence du 30 juillet 2016 et du 24 juin 2016 respectivement, lors de la réalisation de prévisions à 15 minutes. Ces tableaux permettent de mettre en évidence que les performances de SMRN sont meilleures que celles de *Rain Nowcast*, que cela soit sur les données locales ou régionales.

La bonne performance de SMRN est principalement due au fait que le mouvement des structures situées à la limite du domaine local est mieux estimé en utilisant des données



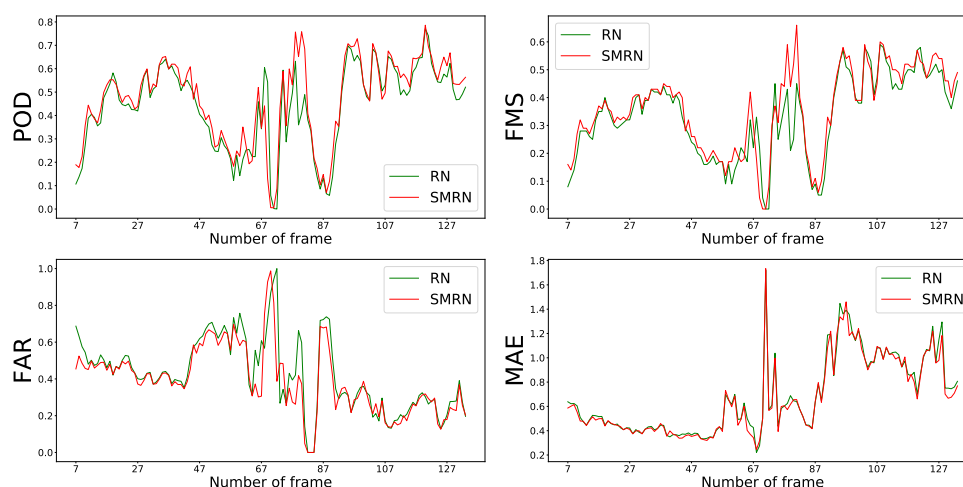


FIGURE 5.11 – Statistiques de SMRN et *Rain Nowcast* lors du calcul d’une prévision à  $t_h = 15$  min à partir des données régionales. Épisode du 30 juillet 2016.

TABLE 5.1 – Statistiques générales de SMRN et *Rain Nowcast*, pour une prévision à  $t_h = 15$  min, sur les données régionales et locales. Épisode du 30 juillet 2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,421	0,270	0,522	0,885
	SMRN	0,445	0,290	0,513	0,880
Données régionales	<i>Rain Nowcast</i>	0,439	0,332	0,423	0,682
	SMRN	0,475	0,365	0,386	0,665

TABLE 5.2 – Statistiques générales de SMRN et *Rain Nowcast*, pour une prévision à  $t_h = 15$  min, sur les données régionales et locales. Épisode du 24 juin 2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,459	0,327	0,464	0,653
	SMRN	0,490	0,344	0,446	0,649
Données régionales	<i>Rain Nowcast</i>	0,588	0,497	0,238	0,835
	SMRN	0,607	0,518	0,230	0,834

régionales. On peut le voir dans l'exemple montré dans la figure 5.12 en examinant sur la zone située en bas à droite.

Les statistiques correspondantes à cet exemple sont données dans la table 5.3, elles confirment la bonne performance de SMRN sur les données locales et régionales. La

TABLE 5.3 – Statistiques de la prévision à  $t_h = 15$  min pour *Rain Nowcast* et SMRN sur l'exemple présenté dans la figure 5.12 de l'épisode du 30/07/2016 à 17h35.

	Méthode	POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,346	0,190	0,702	0,695
	SMRN	0,373	0,210	0,667	0,684
Données régionales	<i>Rain Nowcast</i>	0,271	0,200	0,544	0,604
	SMRN	0,356	0,270	0,457	0,554

quantité de précipitations est également mieux prédite, à nouveau parce que SMRN peut tenir compte des précipitations observées en dehors du domaine local et qui sont présentes sur les données régionales.

Enfin, une autre amélioration liée à SMRN concerne l'estimation du mouvement à l'intérieur du domaine local, grâce à l'utilisation des données régionales dans le processus. Améliorer l'estimation du mouvement permet de mieux prévoir les structures de précipitations, comme on peut le voir sur le même exemple, en bas à gauche de la figure 5.12.

Nous avons également testé SMRN pour un horizon plus lointain. Les tables 5.5 et 5.4 présentent les statistiques générales des prévisions locales et régionales à  $t_h = 45$  min sur les deux épisodes.


Nous constatons toujours une meilleure performance de SMRN par rapport à *Rain Nowcast*. La figure 5.13 illustre un exemple très favorable pour SMRN par rapport à la référence *Rain Nowcast*, en considérant  $t_h = 45$  min.

Cependant, l'amélioration apportée par SMRM peut varier selon la nature des événements pluvieux. La figure 5.14 montre un cas moins favorable, où se produisent une apparition et une disparition de structures nuageuses.

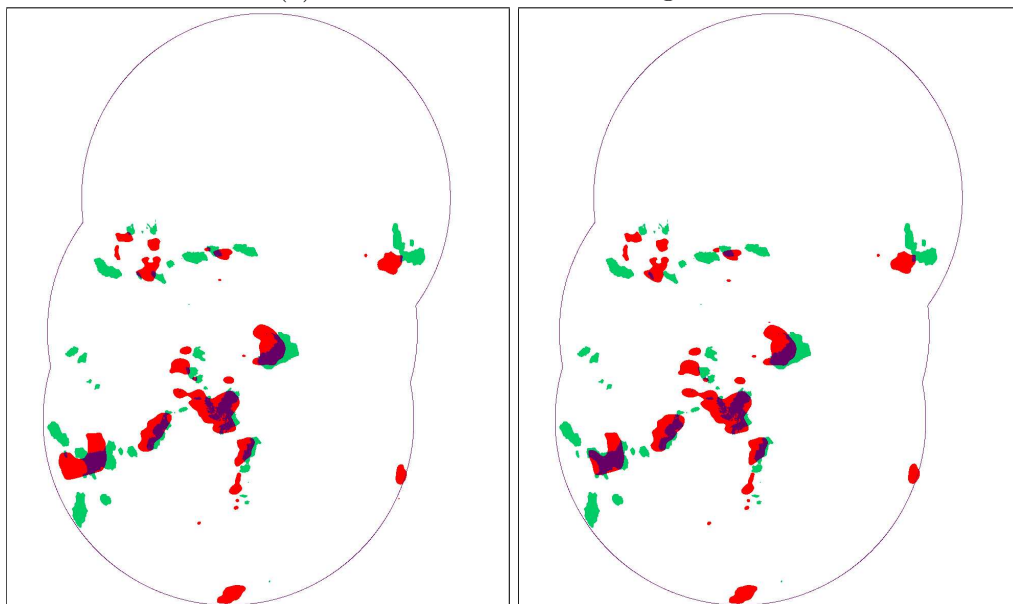
Ces phénomènes, apparition et disparition, sont d'une part des perturbateurs de l'estimation du mouvement et, d'autre part, ils conduisent à une sous-estimation ou une

TABLE 5.4 – Statistiques générales des prévisions locales et régionales à  $t_h = 45$  min de *Rain Nowcast* et SMRN pour l'épisode du 30/07/2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,179	0,106	0,768	1,013
	SMRN	0,192	0,120	0,730	1,012
Données régionales	<i>Rain Nowcast</i>	0,225	0,155	0,612	0,790
	SMRN	0,248	0,172	0,609	0,783



(a) Prévision et observation régionales



(b) Prévision et observation locale

FIGURE 5.12 – Prévisions à  $t_h = 15$  min (en rouge) obtenues par *Rain Nowcast* (colonne de gauche) et SMRN (colonne de droite), comparées aux observations locales (en vert). L'intersection entre les zones pluvieuses sur la prévision et l'observation, en couleur grenat, devrait être idéalement la plus grande possible. Épisode du 30/07/2016.

TABLE 5.5 – Statistiques générales des prévisions locales et régionales à  $t_h = 45$  min de *Rain Nowcast* et SMRN pour l'épisode du 24/06/2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,282	0,162	0,680	0,759
	SMRN	0,251	0,151	0,695	0,708
Données régionales	<i>Rain Nowcast</i>	0,264	0,205	0,487	0,896
	SMRN	0,282	0,221	0,485	0,931

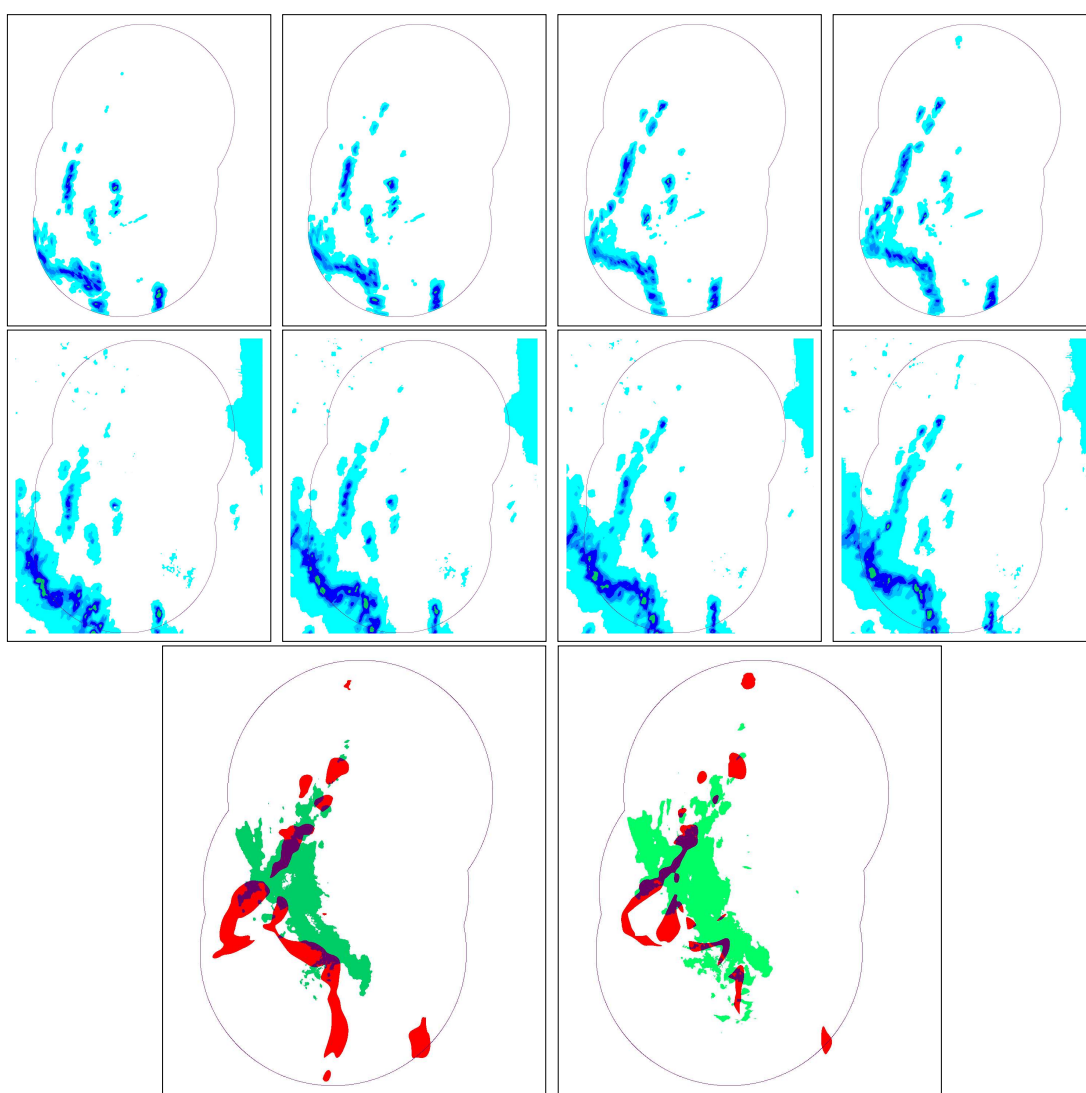


FIGURE 5.13 – Exemple de prévision à  $t_h = 45$  minutes. Les deux premières lignes montrent respectivement les observations locales et régionales utilisées pour le calcul du mouvement. La troisième ligne illustre la prévision obtenue sur les observations locales par *Rain Nowcast* (à gauche), et SMRN (à droite). Épisode du 24 juin 2016.




FIGURE 5.14 – Apparition et disparition de structures pluvieuses.

sur-estimation des quantités de pluies prédites. En effet, en advectant la condition initiale pour calculer la prévision, la quantité de pluie sera soit sur-estimée, si la structure disparaît ultérieurement dans la séquence, soit sous-estimée, si la structure apparaît ultérieurement dans la séquence.

En conclusion, l’algorithme SMRN améliore les performances des prévisions comme nous l’avons annoncé dans la conclusion (section 3.3) du chapitre 3. La fusion des données régionales et locales permet d’anticiper l’arrivée des structures pluvieuses dans le domaine d’observation local. Les prévisions locales et régionales sont toutes deux améliorées.

### 5.3.2 Parallel Motion Rain Nowcast (PMRN)

Dans cette section, nous présentons les résultats des prévisions obtenus par PMRN. Les figures 5.15 et 5.16 présentent les statistiques des prévisions à 15 minutes, obtenues par PMRN et *Rain Nowcast* sur la séquence du 30 juillet 2016.

La table 5.6 propose les statistiques moyennes pour les données locales et régionales sur la même séquence.

Nous constatons que l’algorithme PMRN présente, en moyenne, des performances plus élevées que celles de *Rain Nowcast*, mais moins élevées que celles de SMRN sur l’épisode du 30 juillet 2016.

La performance de PMRN peut être équivalente, voire moindre, à celle de *Rain Nowcast* dans certains exemples, comme celui illustré par la figure 5.17, où nous effectuons la prévision à un horizon  $t_h = 45$  min, afin de bien mettre en évidence les limitations

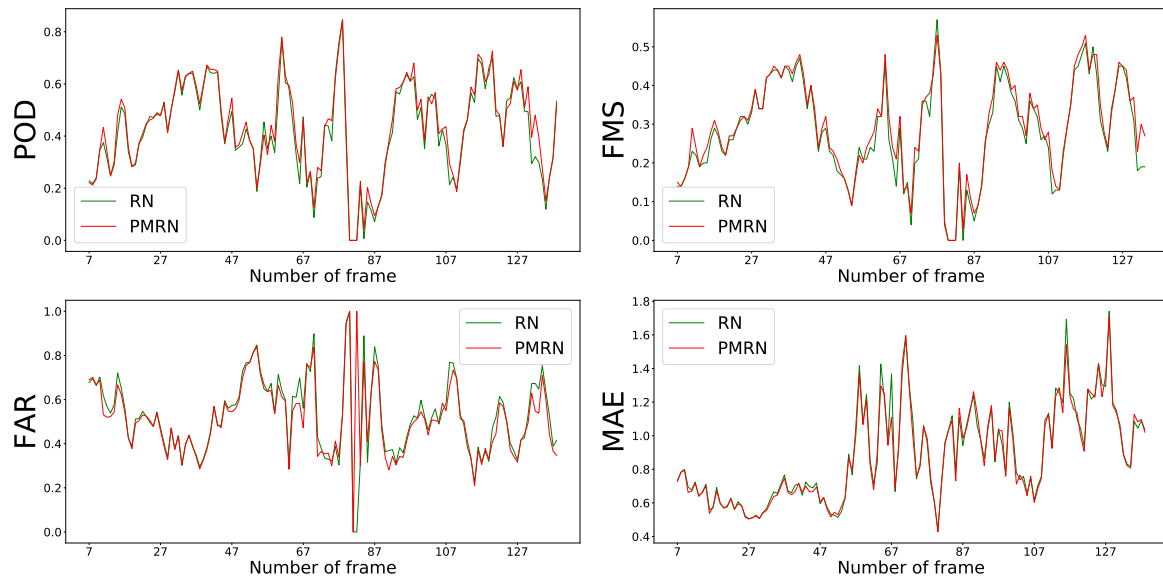


FIGURE 5.15 – Statistiques de PMRN et *Rain Nowcast*, pour une prévision à  $t_h = 15$  min sur les données locales. Épisode du 30 juillet 2016.

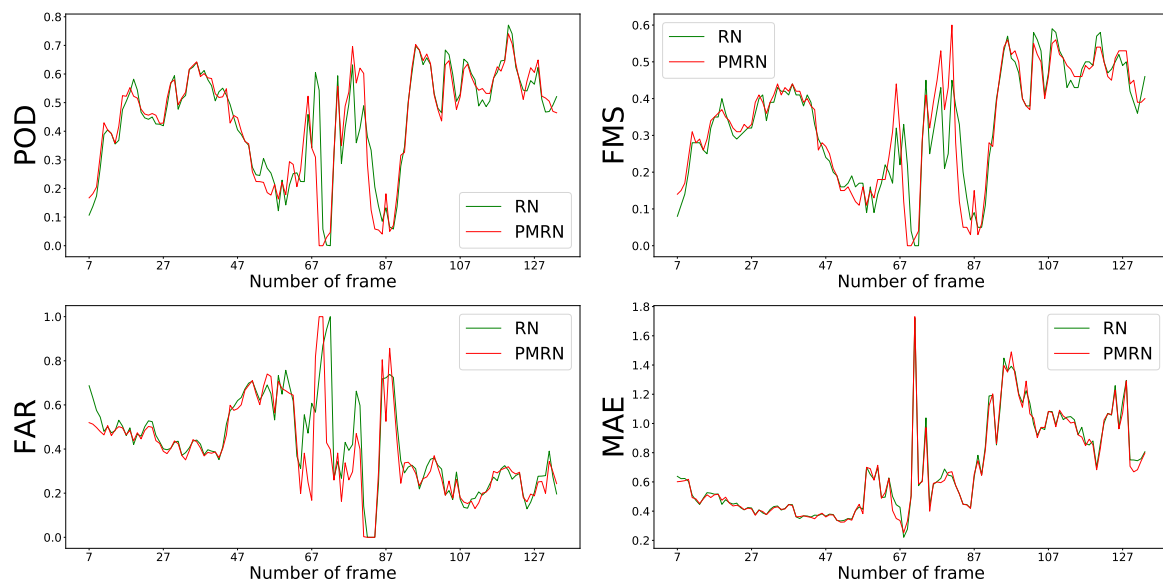


FIGURE 5.16 – Statistiques de PMRN et *Rain Nowcast*, pour une prévision à  $t_h = 15$  min sur les données régionales. Épisode du 30 juillet 2016.

TABLE 5.6 – Statistiques générales obtenues par *Rain Nowcast*, SMRN et PMRN pour une prévision à  $t_h = 15$  min, sur les données régionales et locales. Épisode du 30 juillet 2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,421	0,270	0,522	0,885
	PMRN	0,438	0,290	0,511	0,877
	SMRN	0,445	0,290	0,513	0,880
Données régionales	<i>Rain Nowcast</i>	0,439	0,332	0,423	0,682
	PMRN	0,442	0,342	0,390	0,674
	SMRN	0,475	0,365	0,386	0,665

de la méthode. Il s’agit du même cas que celui de la figure 5.13 illustrée dans la section précédente 5.3.1.

La table 5.7 confirme ces performances médiocres.

 TABLE 5.7 – Statistiques des prévisions à  $t_h = 45$  min de *Rain Nowcast*, SMRN et PMRN sur l’exemple présenté dans la figure 5.17 de l’épisode du 24/06/2016 à 21h05.

	POD	FMS	FAR	MAE
<i>Rain Nowcast</i>	0,205	0,137	0,645	0,789
SMRN	0,090	0,069	0,543	0,621
PMRN	0,163	0,136	0,775	0,656

Ce constat est principalement dû à un positionnement des structures nuageuses, qui n’est pas cohérent entre les deux types d’observations radar Panthere et bande X.

Sur les images locales (première ligne de la figure 5.17), les structures nuageuses en bas à gauche sont en avance par rapport aux mêmes structures sur les images régionales (deuxième ligne 5.17). Cela provoque une contradiction entre les deux types d’observations dans la fonction de coût de PMRN : il n’est pas possible d’avoir un champ de vitesses unique, en capacité de transporter aux mieux les structures régionales et les structures locales, puisque celles-ci ne sont pas situées aux mêmes lieux. Dans ce cas, le PMRN converge vers une solution de compromis entre les deux types d’observation. Cela se traduit par un champ de mouvement faible en intensité. En phase de prévision, ce champ de mouvement “faible en intensité” conduit à des déplacements de trop faible amplitude pour les structures nuageuses qui sont trop faibles. En conséquence, on assiste à un retard dans le déplacement des structures sur les prévisions par rapport aux observations. Cela conduit naturellement à une baisse des performances de l’algorithme.

Si on examine les performances de PMRN sur l’épisode du 26 juin 2016, fournies dans la table 5.8, on constate également qu’elles sont mauvaises. Les raisons sont identiques : nous n’observons pas la même dynamique entre les deux échelles et les observations régionales deviennent prédominantes.

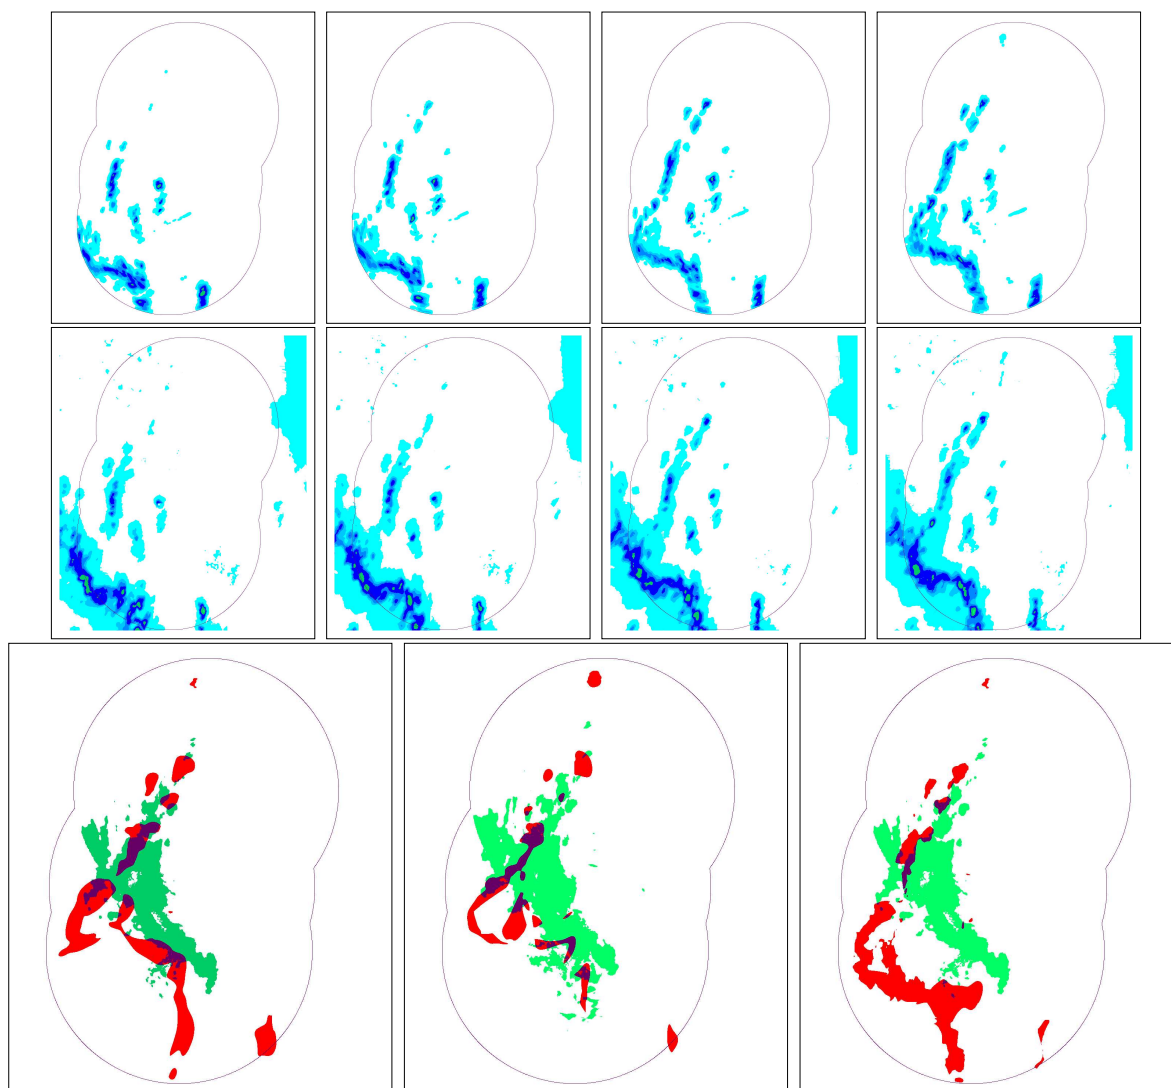


FIGURE 5.17 – Exemple de situation d’échec pour PMRN. Les première et seconde lignes montrent les observations locales et régionales utilisées pour l’estimation du mouvement. La troisième ligne compare les prévisions obtenues (de gauche à droite), respectivement, par *Rain Nowcast*, SMRN et PMRN. Épisode du 24 juin 2016.

TABLE 5.8 – Statistiques générales de *Rain Nowcast*, PMRN et SMRN pour une prévision à  $t_h = 15$  min sur les données régionales et locales. Épisode du 24 juin 2016.

		POD	FMS	FAR	MAE
Données locales	<i>Rain Nowcast</i>	0,459	0,327	0,464	0,653
	PMRN	0,388	0,264	0,543	0,709
	SMRN	0,490	0,344	0,446	0,649
Données régionales	<i>Rain Nowcast</i>	0,588	0,497	0,238	0,835
	PMRN	0,524	0,436	0,289	0,905
	SMRN	0,607	0,518	0,230	0,834



Les incohérences de positionnement des structures entre les deux échelles d’observations peuvent avoir plusieurs causes :

- un décalage d’horloge des deux capteurs radars,
- une imprécision liée à la projection des points d’acquisitions radar (les portes) en coordonnées polaires sur le plan cartésien, ces erreurs étant plus grandes à mesure que l’on s’éloigne du radar,
- un retard dans le transfert de l’acquisition, qui conduit à une mauvaise “datation” de certaines observations. C’est le cas le plus courant, dû principalement aux perturbations des réseaux,
- une panne matérielle.

Pour améliorer les performances dans ces cas d’incohérences entre échelles, nous devons agir sur les incertitudes relatives des deux échelles d’observation et modifier les valeurs associées aux pixels correspondants dans les matrices de covariance  $R_r$  et  $R_l$ . Il faut, dans les faits, privilégier une acquisition par rapport à l’autre. On peut également remarquer, toujours sur la figure 5.17, que l’algorithme SMRN obtient de meilleurs résultats sur les métriques FAR et MAE. Puisque cette méthode calcule d’abord un mouvement régional, puis affine le calcul à l’échelle locale, la primauté repose sur l’échelle locale. Nous pourrions donc, dans le contexte de PMRN, privilégier les données locales aux régionales lorsque les observations locales et régionales sont en contradiction.

Pour autant, PMRN donne également de bons résultats. La figure 5.18 illustre un cas test où le PMRN améliore significativement la prévision des structures pluvieuses par rapport à *Rain Nowcast*. Ce point est confirmé par les statistiques proposées dans la table 5.9. Les structures pluvieuses, qui se trouvent en bas à gauche et à droite du domaine de la figure 5.18, ne sont pas visibles sur les données locales. En revanche, ces structures sont bien visibles sur les données régionales. Ceci permet à PMRN d’estimer un champ de mouvement correct sur ces régions, alors que *Rain Nowcast* n’en a pas la possibilité.

TABLE 5.9 – Statistiques des prévisions à  $t_h = 60$  minutes de *Rain Nowcast* et PMRN, sur l’exemple présenté dans la figure 5.18 de l’épisode du 30/07/2016.

	POD	FMS	FAR	MAE
<i>Rain Nowcast</i>	0,100	0,713	0,740	0,675
PMRN	0,116	0,907	0,793	0,703

En conclusion, les performances des PMRN sont moindres que celles de SMRN, mais restent meilleures que celles de *Rain Nowcast* en terme de prévision pour les deux échelles, à la condition que les observations locales et régionales soient cohérentes entre elles. Dans

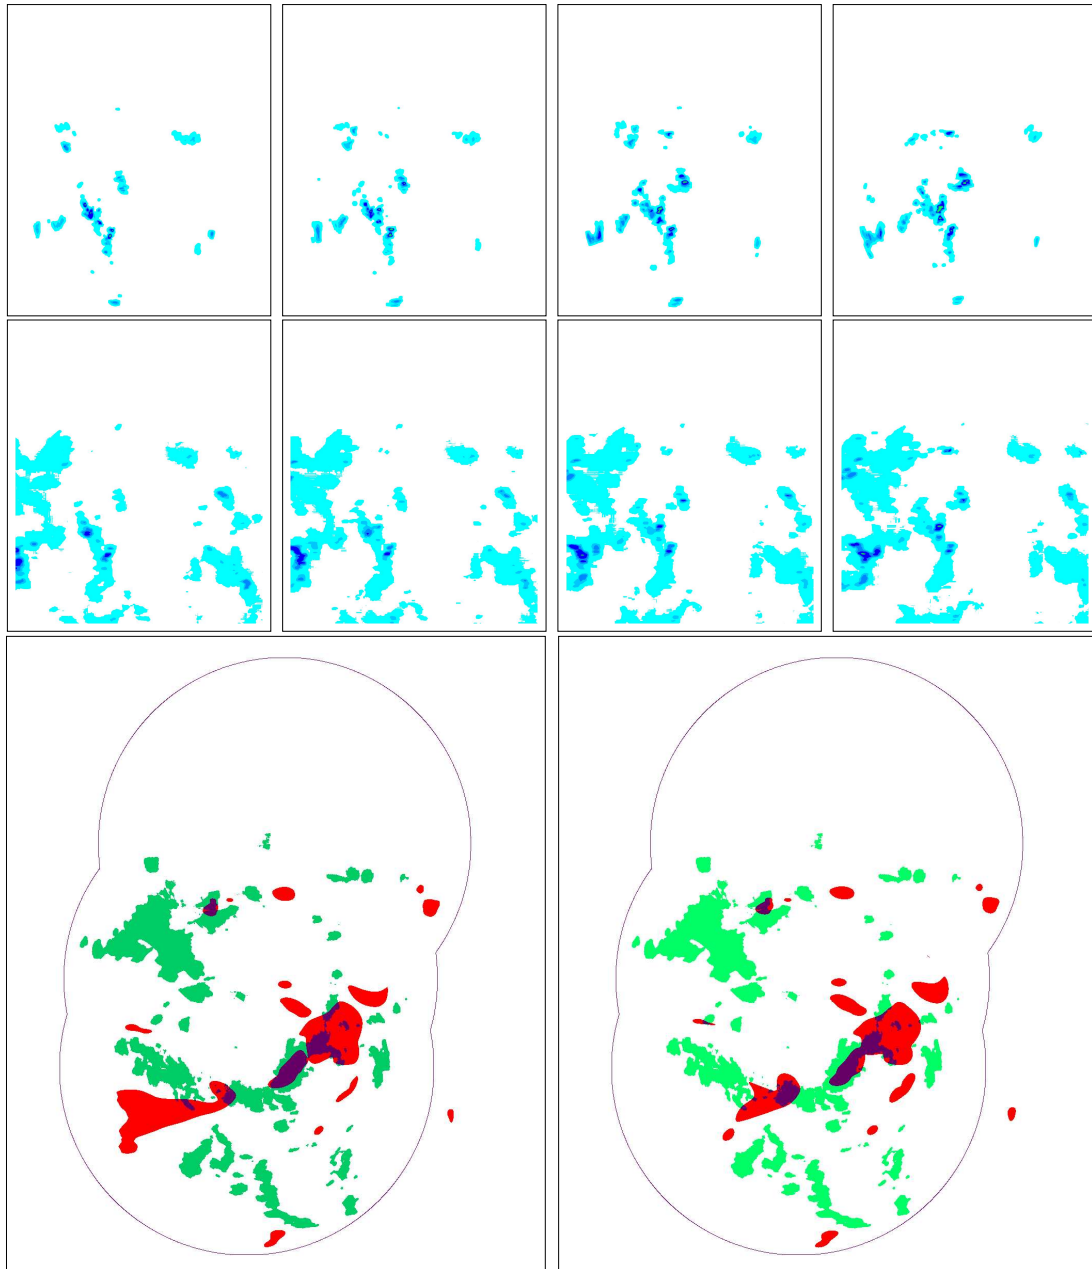


FIGURE 5.18 – Exemple de prévision à  $t_h = 60$  min. Les première et seconde lignes montrent les observations locales et régionales pour l'estimation du mouvement. La troisième ligne montre la prévision obtenue par *Rain Nowcast* (à gauche) et *PMRN* (à droite). Épisode du 30 juillet 2016.

le cas contraire, une solution est de privilégier une échelle sur l'autre. Puisque SMRN est l'algorithme le plus performant, il semble naturel de privilégier l'échelle locale sur la régionale. Pour détecter les incohérences entre échelles, nous pourrions calculer deux échelles de vitesses (locale et régionale) et vérifier la cohérence (en direction et en norme) des champs de vecteurs qu'elles produisent. Le choix des matrices  $R_r$  et  $R_l$  est donc beaucoup plus critique pour PMRN que pour SMRN. Un effort de recherche reste à faire sur la paramétrisation de ces deux matrices.

En l'absence d'un mécanisme de choix pertinent pour les matrices de covariance, SMRN est plus efficace que l'algorithme PMRN. En revanche, et comme nous le montrons dans l'annexe B, PMRN est moins coûteux en temps de calcul, ce qui est un avantage reconnu en utilisation opérationnelle. Il y a là, comme souvent, un compromis à réaliser entre le temps de calcul et les performances de résultats.

### 5.3.3 Hypothèse de vent géostrophique

Dans cette section, nous présentons les résultats obtenus sous l'hypothèse du vent géostrophique. Rappelons que cette hypothèse est appliquée directement sur le champ de mouvement  $\mathbf{w}$  estimé par l'une des méthodes du chapitre 3. L'évaluation se fait sur les trois méthodes de prévision disponibles : *Rain Nowcast*, SMRN et PMRN. Pour chacune des méthodes, nous réalisons l'expérimentation avec et sans l'hypothèse de vent géostrophique.

Dans les deux séquences de données que nous utilisons pour l'évaluation, il faut savoir que certaines images ne présentent aucune précipitation, voir par exemple la figure 5.19.




FIGURE 5.19 – Illustration de l'absence de précipitation.

Le but de la section étant d'évaluer la capacité de prévision des taux de précipitation, nous restreignons les épisodes d'étude à deux sous-séquences, sur lesquels toutes les images contiennent effectivement des cellules orageuses. Ces deux sous-séquences comprennent chacune 36 images, équivalant à 3 heures d'acquisition, et visualisent l'occurrence d'un événement pluvieux. Les tests et les mesures fournies ci-dessous sont obtenues à partir de ces deux sous-séquences.

Par ailleurs, nous avons également réalisé des expérimentations en modifiant le seuil utilisé pour le calcul des métriques POD, FMS et FAR, et nous avons choisi la valeur à 0,5 mm (soit 6 mm/h), afin de n'étudier que les zones où la pluie tombe en quantité significative.

### *Rain Nowcast*

Les figures 5.20 et 5.21 montrent les statistiques obtenues lors d'une prévision à  $t_h = 45$  minutes, en utilisant les deux seuils de détection (0,2 et 0,5 mm), sur les deux sous-séquences, avec et sans hypothèse de vent géostrophique. On constate une amélioration




FIGURE 5.20 – Statistiques d'une prévision à  $t_h = 45$  min pour *Rain Nowcast* avec (en rouge) et sans (en vert) l'hypothèse de vent géostrophique sur la sous-séquence du 24/06/2016. Le seuil de détection est 0,2 mm.

significative, sur une grande partie des deux événements, lorsque l'hypothèse de vent géostrophique est appliquée. Les statistiques générales indiquées dans les tables 5.11 et 5.12 le confirment, quel que soit le seuil utilisé, 0,2 mm ou 0,5 mm.

La figure 5.22 illustre toutefois un cas particulier pour lequel *Rain Nowcast* n'obtient pas de bonnes performances.

En revanche, sous l'hypothèse de vent géostrophique, l'algorithme améliore significativement ses performances de prévision. Les statistiques de la table 5.10 confirment cette amélioration. La difficulté de ce cas test est qu'une grande partie des structures pluvieuses semblent quasi-stationnaires.

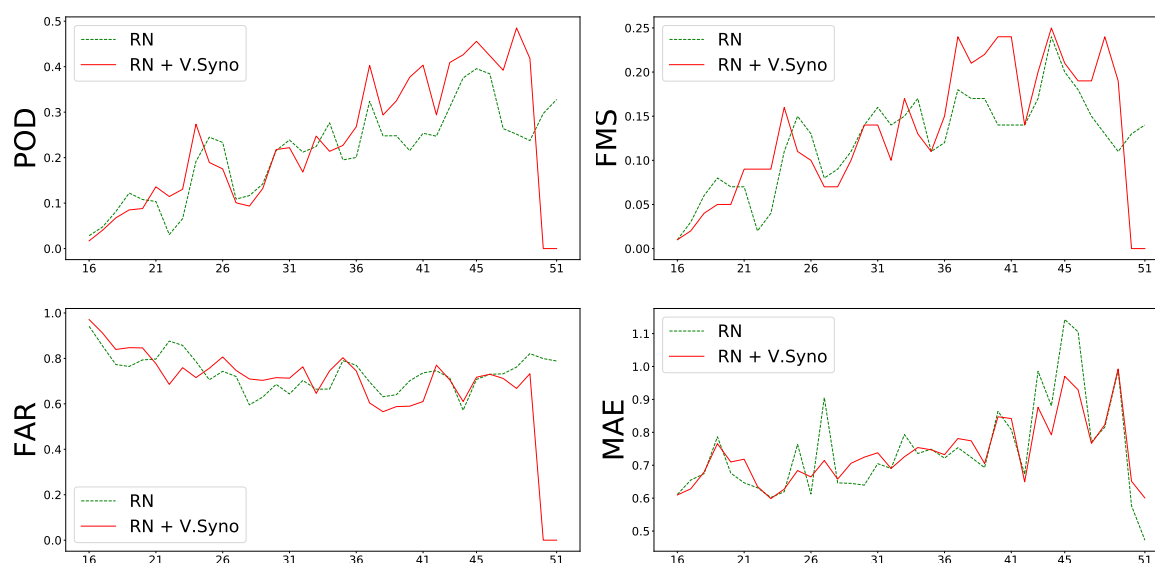


FIGURE 5.21 – Statistiques d’une prévision à  $t_h = 45$  min pour *Rain Nowcast* avec (en rouge) et sans (en vert) l’hypothèse de vent géostrophique sur la sous-séquence du 30/07/2016. Le seuil de détection est 0,2 mm.

TABLE 5.10 – Statistiques des prévisions à 60 minutes de *Rain Nowcast*, avec et sans hypothèse de vent géostrophique (VG), pour l’exemple présenté dans la figure 5.22, épisode du 24/06/2016 à 17h20.

Méthode	POD	FMS	FAR	MAE
sans VG	0,172	0,124	0,557	0,899
avec VG	0,372	0,206	0,693	1,042

En conséquence, le mouvement estimé a une intensité trop faible, en regard de la dynamique effective, et conduit à une mauvaise localisation des structures (retard de déplacement) dans la prévision. L’hypothèse de vent géostrophique a permis de corriger cette défaillance de l’algorithme. Au contraire, cette hypothèse peut parfois conduire à une sur-estimation de la vitesse et en conséquence à une mauvaise localisation des structures (avance de déplacement) dans la prévision, comme l’illustre la figure 5.23. Dans les deux cas, ce défaut augmente le taux de faux négatif.

L’hypothèse de vent géostrophique améliore les performances de prévision de *Rain Nowcast* à  $t_h = 30$ , 45 et 60 minutes (voir tables 5.11 et 5.12).

## PMRN

La figure 5.24 illustre un exemple de résultat de prévision à 60 minutes de modèle PMRN, avec et sans l’hypothèse de vent géostrophique. On peut observer que les structures sont mieux localisées sous l’hypothèse, améliorant globalement les performances de

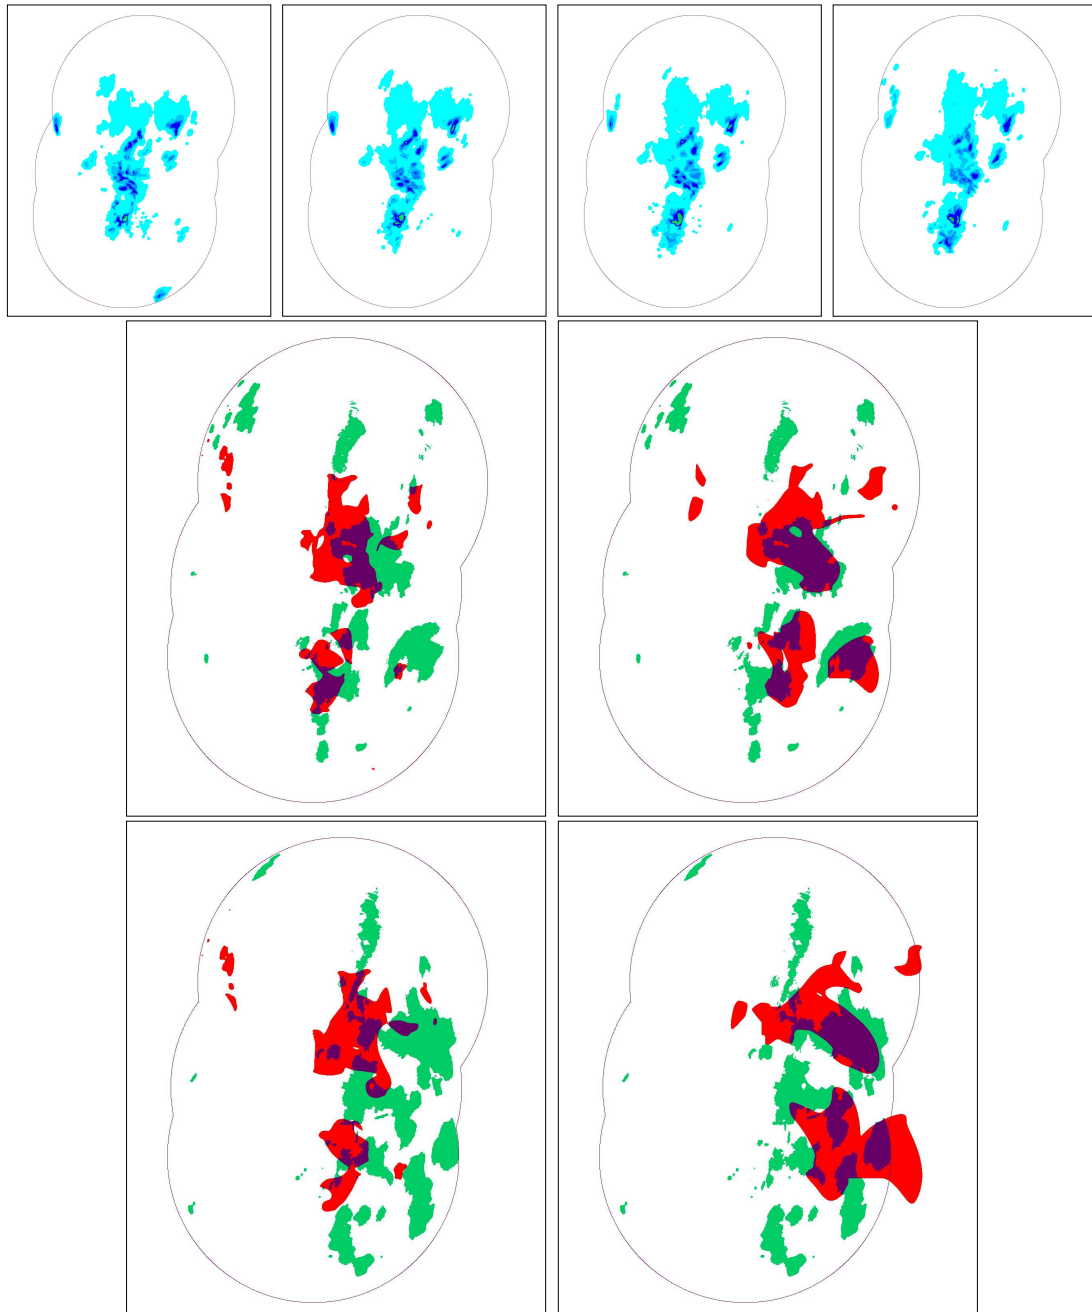


FIGURE 5.22 – Exemples de prévisions à  $t_h = 30$  et 60 minutes, réalisées par *Rain Now-cast*, avec et sans hypothèse de vent géostrophique. Première ligne : observations locales. Seconde ligne : prévision à 30 minutes sans (à gauche) et avec (à droite) hypothèse de vent géostrophique. Troisième ligne : prévision à 60 minutes sans et avec hypothèse de vent géostrophique.

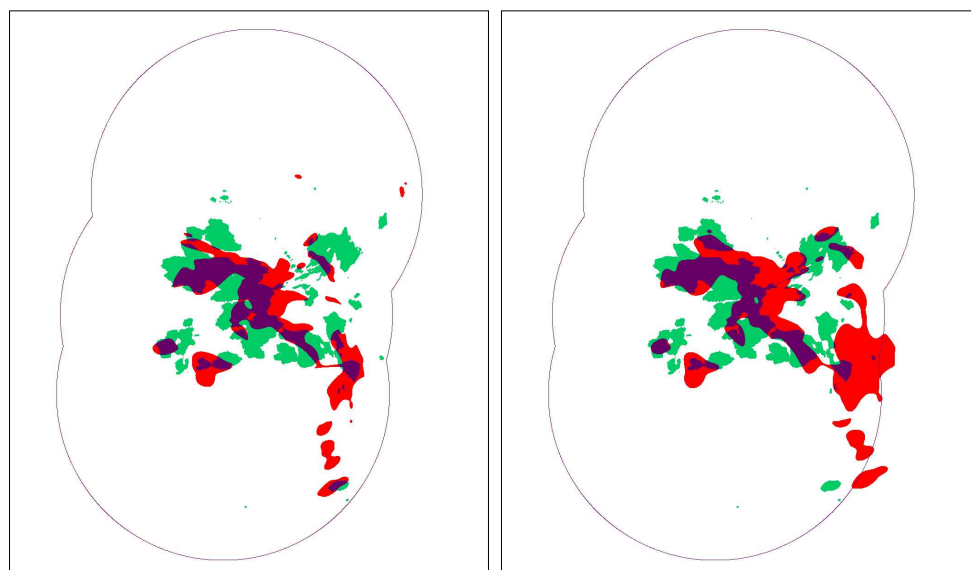


FIGURE 5.23 – Illustration de mauvaise prévision sous hypothèse de vent synaptique. À gauche : sans hypothèse de vent géostrophique. À droite : avec hypothèse de vent géostrophique.

TABLE 5.11 – Statistiques moyennes de *Rain Nowcast* avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 24 juin 2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,371	0,234	0,590	0,906
		avec VG	0,441	0,274	0,563	0,897
	45 minutes	sans VG	0,293	0,165	0,692	0,965
		avec VG	0,369	0,221	0,627	0,914
	60 minutes	sans VG	0,235	0,126	0,742	1,001
		avec VG	0,324	0,188	0,668	0,916
0,5 mm	30 minutes	sans VG	0,299	0,169	0,700	1,514
		avec VG	0,372	0,199	0,683	1,461
	45 minutes	sans VG	0,293	0,165	0,692	1,741
		avec VG	0,369	0,221	0,627	1,477
	60 minutes	sans VG	0,164	0,061	0,874	0,965
		avec VG	0,241	0,110	0,806	0,914

TABLE 5.12 – Statistiques moyennes de *Rain Nowcast* avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 30 juillet 2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,326	0,211	0,614	0,699
		avec VG	0,363	0,223	0,612	0,710
	45 minutes	sans VG	0,257	0,159	0,684	0,747
		avec VG	0,283	0,168	0,682	0,760
	60 minutes	sans VG	0,210	0,123	0,737	0,743
		avec VG	0,230	0,131	0,689	0,736
0,5 mm	30 minutes	sans VG	0,237	0,141	0,719	1,228
		avec VG	0,237	0,126	0,763	1,219
	45 minutes	sans VG	0,151	0,083	0,819	1,297
		avec VG	0,141	0,066	0,865	1,267
	60 minutes	sans VG	0,103	0,053	0,874	1,282
		avec VG	0,099	0,043	0,851	1,238

prévision.

Les performances générales de prévision de PMRN à  $t_h = 30, 45$  et 60 minutes sont aussi améliorées par l'hypothèse de vent géostrophique. Elles sont présentées dans les tables 5.13 et 5.14.

TABLE 5.13 – Statistiques générales de PMRN, avec et sans hypothèse de vent géostrophique sur les données locales, pour le sous-épisode du 30 juillet 2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,322	0,215	0,692	0,612
		avec VG	0,360	0,228	0,682	0,614
	45 minutes	sans VG	0,241	0,153	0,694	0,736
		avec VG	0,276	0,165	0,701	0,719
	60 minutes	sans VG	0,187	0,116	0,741	0,741
		avec VG	0,237	0,136	0,724	0,724
0,5 mm	30 minutes	sans VG	0,226	0,140	0,726	1,219
		avec VG	0,241	0,141	0,738	1,195
	45 minutes	sans VG	0,132	0,077	0,830	1,252
		avec VG	0,150	0,080	0,844	1,238
	60 minutes	sans VG	0,082	0,045	0,895	1,282
		avec VG	0,105	0,049	0,899	1,232

Concernant le cas test discuté dans la section 5.3.2, et présenté sur la figure 5.17, on constate que la prévision est améliorée si on applique l'hypothèse de vent géostrophique. Les structures sont en effet bien mieux positionnées par rapport à la vérité terrain, voir figure 5.25.

En revanche, dans l'exemple illustré par la figure 5.26, l'hypothèse de vent géos-






FIGURE 5.24 – Prédiction à 60 minutes, réalisées par PMRN avec et sans hypothèse de vent géostrophique.

TABLE 5.14 – Statistiques générales de PMRN, avec et sans hypothèse de vent géostrophique, sur les données locales, pour le sous-épisode du 24 juin 2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,306	0,152	0,688	0,865
		avec VG	0,235	0,205	0,620	0,916
	45 minutes	sans VG	0,172	0,100	0,775	0,849
		avec VG	0,216	0,143	0,681	0,911
	60 minutes	sans VG	0,127	0,067	0,836	0,840
		avec VG	0,163	0,114	0,704	0,891
0,5 mm	30 minutes	sans VG	0,135	0,082	0,811	1,473
		avec VG	0,242	0,145	0,734	1,480
	45 minutes	sans VG	0,094	0,049	0,879	1,474
		avec VG	0,164	0,097	0,797	1,493
	60 minutes	sans VG	0,077	0,027	0,930	1,471
		avec VG	0,114	0,067	0,836	1,464




FIGURE 5.25 – Prévion à 45 minutes par PMRN, sous l’hypothèse de vent géostrophique.

trophique ne permet pas d'améliorer les performances de la prévision par rapport à celle donnée par *Rain Nowcast*. Ce cas test est de fait l'un des plus difficiles à traiter parmi les données à notre disposition. Pendant l'intervalle de temps entre la date qui sert de condition initiale pour l'intégration du modèle de prévision et  $t_h = 45$  minutes, on constate que la structure nuageuse diminue fortement en taille sur les données locales. Mais ceci n'est pas vérifié sur les données régionales. En réalité, l'événement pluvieux ne décroît pas en intensité (voir la seconde ligne de la figure 5.26). Dans cette situation, les résultats des métriques calculées sur les données locales sont défavorables. Toujours dans la figure 5.26, on remarque qu'au delà de  $t_h = 45$  minutes, la structure nuageuse augmente à nouveau en taille. Une hypothèse est que ça puisse être dû à une mauvaise acquisition des radars de Weather Measures.

## SMRN

Pour cet algorithme, l'hypothèse de vent géostrophique peut s'appliquer de différentes manières. Une première est de l'utiliser lors de l'estimation du mouvement à l'échelle régionale, c'est-à-dire de corriger le champs de vitesses qui sert d'ébauche pour l'estimation du mouvement locale. Une seconde façon est de corriger l'estimation locale du champ de vitesses. Une troisième façon est de l'appliquer aux deux échelles.

La correction "vent géostrophique" est indépendante du choix de l'algorithme d'estimation du mouvement et du problème de fusion des échelles d'observation. Pour cette raison, nous avons choisi de l'appliquer et de l'évaluer uniquement sur l'échelle locale et sur le domaine local. Dans une utilisation opérationnelle, il pourra néanmoins être utile de l'étendre sur l'échelle régionale, afin d'augmenter les performances en dehors du domaine local.

La figure 5.27 présente les statistiques calculées sur les prévisions fournies par SMRN, avec et sans hypothèse de vent géostrophique, pour le sous-épisode du 24 juin 2016. On remarque que les statistiques spatiales sont nulles pour les fenêtres 45 et 46. Ceci est dû à l'absence de structures pluvieuses dans ces fenêtres.

Ces résultats montrent une amélioration globale des prévisions, quel que soit le seuil utilisé (0,2 mm ou 0,5 mm) pour les métriques spatiales. Elle sont présentées dans les tables 5.15 et 5.16. Les métriques POD et FMS calculées avec l'hypothèse de vent géostrophique sont supérieures à celles obtenues sans l'hypothèse de vent géostrophique sur la grande majorité des fenêtres. C'est le cas aussi pour la métrique FAR qui est inférieure (et donc meilleure) en hypothèse de vent géostrophique. L'hypothèse de vent géostrophique permet donc de mieux localiser les structures pluvieuses dans les prévisions. En revanche, les performances sont moins bonnes pour la métrique MAE. Dans la section suivante, nous en expliquons les raisons et y tentons d'y répondre.

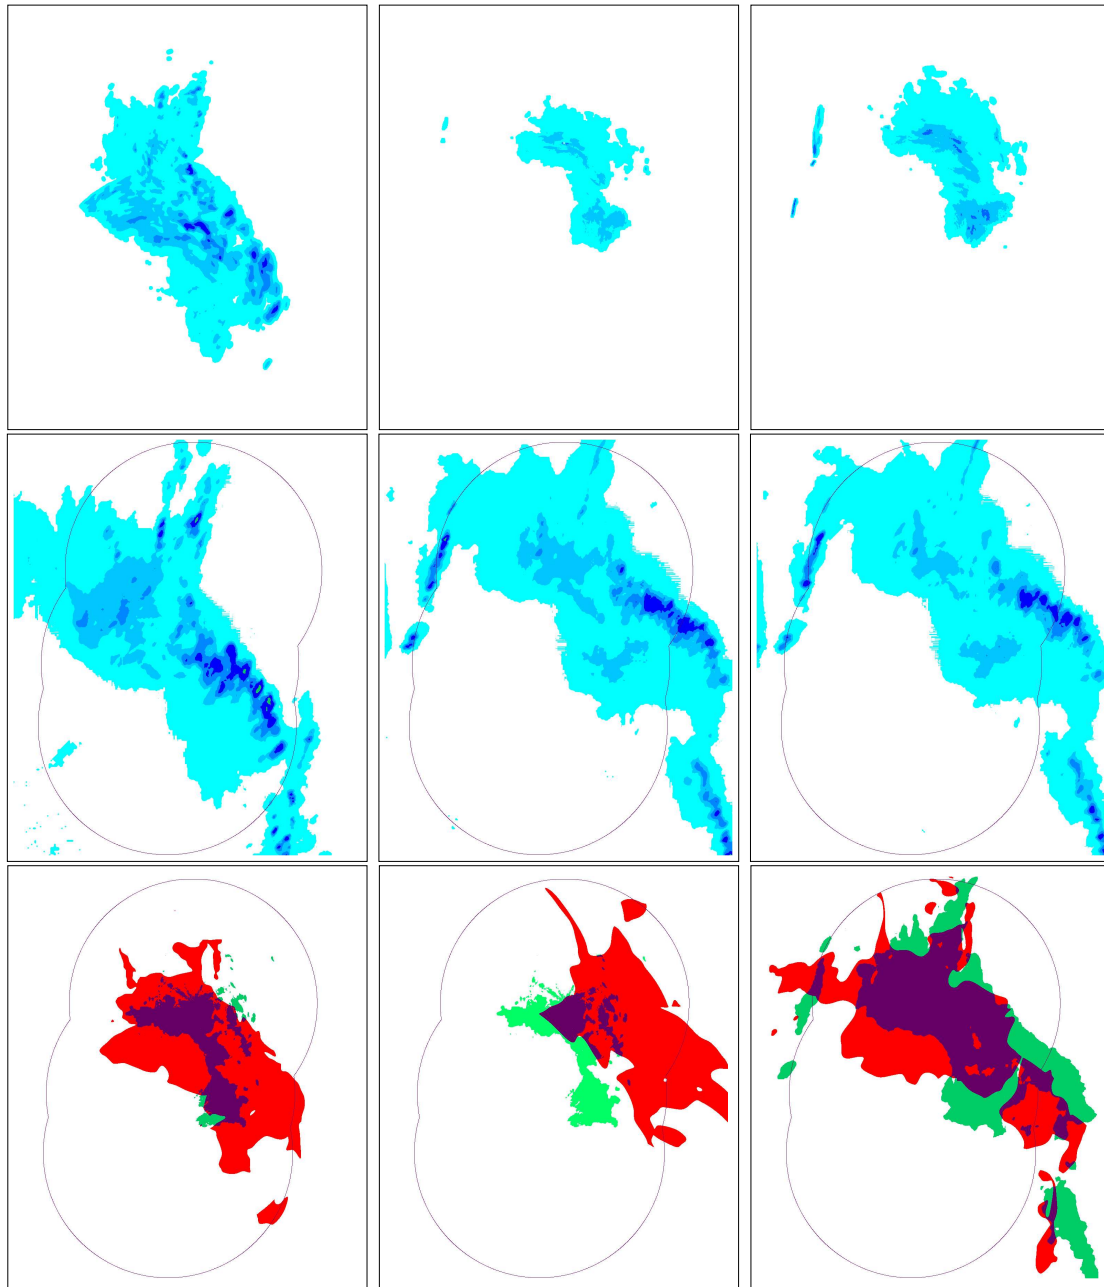


FIGURE 5.26 – Exemple de mauvaise prévision par PMRN, sous l’hypothèse d’un vent géostrophique, à  $t_h = 45$  min. Première ligne, de gauche à droite : données locales à la date de la condition initiale, à  $t_h = 45$  min, à  $t_h = 50$  min. Seconde ligne : données régionales aux mêmes dates. Troisième ligne, de gauche à droite : prévisions fournies par *Rain Nowcast*, PMRN avec hypothèse de vent géostrophique sur les données locales et PMRN avec hypothèse de vent géostrophique sur les données régionales.

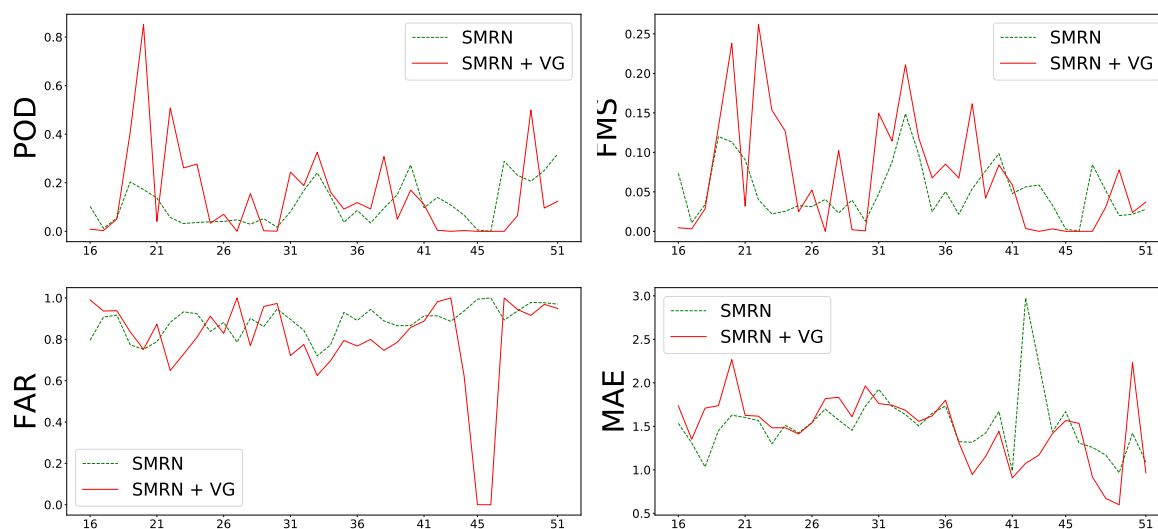


FIGURE 5.27 – Statistiques de SMRN, avec et sans hypothèse vent géostrophique, pour une prévision à  $t_h = 60$  min et un seuillage à 0,5 mm pour la quantification des métriques. Sous-épisode du 24 juin 2016.

TABLE 5.15 – Statistiques, calculées sur les données locales, pour SMRN, avec et sans hypothèse de vent géostrophique, sur le sous-épisode du 24 juin 2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,302	0,196	0,628	0,880
		avec VG	0,301	0,199	0,617	0,913
	45 minutes	sans VG	0,227	0,135	0,725	0,872
		avec VG	0,233	0,154	0,657	0,905
	60 minutes	sans VG	0,172	0,096	0,790	0,860
		avec VG	0,179	0,119	0,682	0,899
0,5 mm	30 minutes	sans VG	0,221	0,135	0,732	1,492
		avec VG	0,232	0,133	0,745	1,475
	45 minutes	sans VG	0,155	0,082	0,829	1,513
		avec VG	0,173	0,093	0,804	1,478
	60 minutes	sans VG	0,112	0,050	0,886	1,521
		avec VG	0,147	0,069	0,799	1,479

TABLE 5.16 – Statistiques, calculées sur les données locales, pour SMRN, avec et sans hypothèse de vent géostrophique, sur le sous-épisode du 30/07/2016.

Seuil	Temps prévision	Méthode	POD	FMS	FAR	MAE
0,2 mm	30 minutes	sans VG	0,331	0,219	0,610	0,708
		avec VG	0,375	0,234	0,611	0,692
	45 minutes	sans VG	0,246	0,156	0,689	0,753
		avec VG	0,292	0,173	0,695	0,732
	60 minutes	sans VG	0,196	0,119	0,742	0,753
		avec VG	0,251	0,139	0,742	0,736
0,5 mm	30 minutes	sans VG	0,299	0,169	0,700	1,514
		avec VG	0,372	0,199	0,683	1,461
	45 minutes	sans VG	0,293	0,165	0,692	1,741
		avec VG	0,369	0,221	0,627	1,477
	60 minutes	sans VG	0,164	0,061	0,874	0,965
		avec VG	0,241	0,110	0,806	0,914

En conclusion, l’hypothèse de vent géostrophique, faite sur les champs de vitesses, permet d’améliorer les résultats de la prévision réalisée par SMRN en terme de positionnement spatial des structures. Cette correction permet notamment d’atteindre l’horizon  $t_h = 60$  min avec de bonnes performances. Néanmoins, la correction d’intensité du champ de mouvement peut parfois engendrer une sur-estimation du mouvement, qui induit une advection trop rapide des structures pluvieuses et donc une mauvaise localisation sur l’image de prévision. Une des raisons possibles pour cette sur-estimation de l’intensité du mouvement concerne la valeur donnée au paramètre  $\tau$ , dans l’équation (4.10), qui est fixée empiriquement à 70%. Ce seuil pourrait être défini comme une fonction de l’intensité des gradients dans les images : là où les gradients spatiaux sont faibles, un seuillage fort à 70% est appliqué, tandis que sur les zones où les gradients sont plus forts, ce seuil pourrait être abaissé.

### 5.3.4 Correction de la distribution de la prévision

Dans cette section, nous présentons les résultats obtenus en appliquant une correction de l’histogramme de l’image prédite, telle qu’elle a été proposée à la section 4.3.

On rappelle qu’il s’agit de corriger l’effet de lissage des structures, qui produit lors de l’advection par l’équation (4.3), en raison du schéma semi-lagrangien utilisé pour discrétiser l’opérateur  $M_f$ , équation (4.6).

L’effet de lissage a notamment comme conséquence de sous-estimer les quantités de pluies là où elles sont les plus fortes et de les surestimer là où elles sont les plus faibles. L’évaluation de la correction de l’histogramme doit donc porter sur les quantités de pluies et non pas sur les localisation des structures orageuses. Une correction de l’histogramme,

et donc une correction des valeurs de pluies, n’aura pas d’impact sur le positionnement des structures.

Le positionnement des structures dans l’image prédite est très important pour permettre une évaluation convaincante : si les structures prédites sont mal localisées par rapport à celles observées, la comparaison des quantités de pluie entre l’image prédite et l’observation n’est pas pertinente. Donc si les structures sont mal localisées, une évaluation sur les quantités de pluies n’aura pas d’intérêt : l’erreur sera grande mais elle ne dira rien sur la pertinence des quantités de pluies estimées. Ces quantités peuvent très bien être correctement estimées mais mal localisées.

La méthodologie utilisée dans cette section diffère donc de celle utilisée dans les sections précédentes. Les métriques spatiales (POD, FMS et FAR) ne sont pas pertinentes pour évaluer la pertinence d’une correction d’histogramme, qui n’influe pas sur la position des structures. La métrique MAE, qui mesure directement les différences sur les quantités de pluie, est en revanche pertinente, mais à condition que les structures soient correctement localisées, autrement dit si les métriques spatiales sont bonnes.

Nous avons choisi de tester cette technique pour un horizon  $t_h = 15$  min, relativement court. À cet horizon, on peut observer des structures pluvieuses dans l’atmosphère qui ne subissent pas un grand changement (faible diminution ou augmentation des quantités de précipitations, forme relativement constante). De plus, un horizon plus long aurait pour conséquence de diminuer les performances en terme de positionnement spatial. Mais cet horizon est suffisamment long pour constater les effets délétères du schéma semi-lagrangien. Par contre, à un horizon plus petit, les effets lissant du schéma restent limités.

Comme la correction de l’histogramme de la prévision est indépendante de la manière dont on calcule le mouvement des structures orageuses, il n’est pas utile de tester systématiquement les trois méthodes *Rain Nowcast*, SMRN et PMRN. Nous nous restreignons à *Rain Nowcast*, sachant que les mêmes résultats ont été constatés pour les deux autres méthodes.

Les tables 5.17 et 5.18 fournissent, pour les deux sous-épisodes, les performances de *Rain Nowcast* lorsqu’on applique ou pas la technique de correction d’histogramme sur une prévision locale.

TABLE 5.17 – Statistiques de *Rain Nowcast*, calculées sur les données locales, avec et sans correction de l’histogramme (CH) pour  $t_h = 15$  min. Sous-épisode du 30 juillet 2016.

Méthode	POD	FMS	FAR	MAE
sans CH	0,439	0,303	0,496	0,630
avec CH	0,707	0,298	0,622	1,024

Nous constatons que la correction d’histogramme améliore la métrique POD, dégrade

TABLE 5.18 – Statistiques de *Rain Nowcast*, calculées sur les données locales, avec et sans correction d’histogramme de la prévision pour  $t_h = 15$  min. Sous-épisode du 24 juin 2016.

Méthode	POD	FMS	FAR	MAE
sans CH	0,539	0,388	0,404	0,814
avec CH	0,707	0,385	0,536	1,440

le métrique FAR et laisse relativement inchangée la métrique FMS. Ce résultat est essentiellement dû à des effets de seuil : la correction d’histogramme modifie les valeurs de précipitations, changeant ainsi le nombre des pixels dans les classes VP, VN, FP et FN et in fine les métriques POD, FAR et FMS. Toutefois, la correction d’histogramme n’a pas d’impact sur le positionnement des structures. Les métriques POD, FAR et FMS ne sont donc pas pertinentes pour juger de l’intérêt de corriger l’histogramme. Seule la métrique MAE est adaptée et on voit que celle-ci est dégradée après application de la correction de l’histogramme.

Nous obtenons des résultats similaires sur les données régionales, comme le montre les tables 5.19 et 5.20.

Méthode	POD	FMS	FAR	MAE
sans CH	0,464	0,325	0,466	1,875
avec CH	0,639	0,238	0,676	2,103

 TABLE 5.19 – Statistiques de *Rain Nowcast*, calculées sur les données régionales, avec et sans correction de l’histogramme pour  $t_h = 15$  min, sous-épisode de 24 juin 2016.

Méthode	POD	FMS	FAR	MAE
sans CH	0,459	0,304	0,533	0,462
avec CH	0,766	0,176	0,808	0,611

 TABLE 5.20 – Statistiques de *Rain Nowcast*, calculées sur les données régionales, avec et sans correction de l’histogramme pour  $t_h = 15$  min, sous-épisode de 30 juillet 2016.

Comme on le voit, la correction d’histogramme ne permet pas d’améliorer *a priori* les performances en terme de métrique MAE sur l’ensemble des deux sous-épisodes. Toutefois, en examinant plus attentivement ces données, nous pouvons isoler des fenêtres temporelles dans lesquelles les structures orageuses restent localement constantes en forme et en intensité. Elles sont donc les bonnes candidates pour évaluer l’intérêt de la correction d’histogramme. La figure 5.28 montre un exemple d’une telle situation sur les données régionales et les statistiques correspondantes sont données dans la table 5.21.

Plusieurs seuils de détection sont utilisés afin d’évaluer plus finement la correction d’histogramme sur plusieurs classes de quantité de précipitations. Les seuils de détec-






FIGURE 5.28 – Exemple de prévision à  $t_h = 15$  min de *Rain Nowcast* avec et sans correction d'histogramme sur les données régionales le 21/06/2016 à 16h55.

TABLE 5.21 – Statistiques des prévisions sur un exemple de prévision fait par *Rain Nowcast*, avec et sans correction d’histogramme, sur les données régionales et pour différentes classes de précipitations. Le 26/06/2016 à 16h25.

Seuil de détection (mm)	Méthode	POD	FMS	FAR	MAE
$\geq 2$	sans CH	0,328	0,213	0,634	3,932
	avec CH	0,376	0,236	0,561	3,784
$\geq 1$	sans CH	0,459	0,300	0,540	2,666
	avec CH	0,485	0,300	0,519	2,420
$\geq 0,5$	sans CH	0,517	0,360	0,441	1,915
	avec CH	0,513	0,362	0,438	1,697
$\geq 0,2$	sans CH	0,517	0,350	0,433	0,927
	avec CH	0,513	0,350	0,481	1,109
$\geq 0,1$	sans CH	0,532	0,380	0,419	0,766
	avec CH	0,610	0,390	0,464	0,631
$\geq 0,01$	sans CH	0,688	0,520	0,317	0,423
	avec CH	0,744	0,530	0,350	0,362

tion sont choisis en adéquation avec les quantités de précipitations présentes dans cet exemple d’une part, et, d’autre part, en adéquation avec les caractéristiques physiques prédéfinies avec les experts. On constate que les performances des métriques spatiales sont presque stables ou légèrement améliorées, ce qui est attendu. En revanche, la métrique MAE connaît une amélioration significative pour les prévisions faite par *Rain Nowcast*, si on applique la correction de l’histogramme, à l’exception d’une classe (précipitation supérieure ou égale à 0,2 mm).

Comme on peut le voir dans la figure 5.28, les classes de précipitations de la prévision corrigée sont plus proches de celles de l’observation que pour la prévision non corrigée. Sans correction d’histogramme, on perd les classes de précipitation les plus élevées ( $> 50\text{mm}$ ), alors qu’avec la correction d’histogramme elles sont préservées. C’est également le cas pour la classe 2-5 mm. Et d’une manière générale, l’ensemble des valeurs de pluies sont bien mieux estimées.

Si on examine plus précisément les résultats, fenêtre par fenêtre, on constate que dans 60% des cas, la statistique MAE est améliorée. Dans les cas restants, elle est dégradée suffisamment pour faire baisser la valeur de MAE moyenne, comme l’ont montré les tables 5.19 et 5.20. Nous jugeons donc utile de conserver la correction d’histogramme dans une implémentation opérationnelle de nos algorithmes.

Concernant les données locales, la correction d’histogramme ne permet pas d’améliorer les performances de *Rain Nowcast*, même en examinant fenêtre par fenêtre. Nous proposons deux explications possibles. D’une part les données locales ayant une résolution spatiale bien plus fines, elles observent des variations en forme des structures orageuses,

non perçues dans les données régionales. La métrique MAE étant très sensible à la localisation des structures, ces variations de forme dégradent la statistique. D'autre part, nous observons des discontinuités aux frontières de la portée de chaque radar, probablement dus à l'opérateur maximum sur la réflectivité utilisé en post-traitement des acquisitions radars lors de la fusion des trois domaines. Nous n'avons pas remarqué ce phénomène sur les données régionales.

## 5.4 Conclusion

Dans ce chapitre, nous avons évalué quantitativement les différentes contributions des chapitres 3 et 4, après avoir présenté les données et leurs caractéristiques, et les métriques utilisées pour l'évaluation quantitative.

Chaque contribution est évaluée par rapport à un algorithme de référence qui est *Rain Nowcast*. Les contributions sont évaluées sur les données locales et régionales, séparément l'une des autres, puis de façon combinée. Les résultats obtenus montrent une amélioration quasi-générale pour l'ensemble des contributions mais avec une certaine variabilité.

L'algorithme SMRN améliore les performances des prévisions par rapport *Rain Nowcast*. L'intérêt majeur de cet algorithme est la possibilité d'anticiper l'arrivée des structures pluvieuses dans le domaine d'observation local. Un autre intérêt est la robustesse de l'algorithme lorsque des informations non cohérentes entre les échelles existent dans les observations, l'échelle locale prenant alors le pas sur l'échelle régionale.

Cependant, et tout comme *Rain Nowcast*, les performances de SMRM varient selon la nature des événements pluvieux. C'est le cas lorsque des structures nuageuses, comme illustré par la figure 5.14, apparaissent ou disparaissent. Ce type d'événement, d'une part, perturbe l'estimation du mouvement et, d'autre part, conduit à une sous-estimation ou une sur-estimation des quantités des pluies prédites.

De même, l'algorithme PMRN améliore les prévisions par rapport *Rain Nowcast* mais il reste moins performant que SMRN. En particulier, PMRN est très sensible aux incohérences qui peuvent parfois exister entre les observations locales et régionales. La solution est d'avoir une stratégie d'adaptation de la matrice de covariance associée à l'opérateur d'observation.

L'hypothèse de vent géostrophique appliquée sur le champs de mouvement permet d'améliorer significativement les prévisions des trois algorithmes précédemment étudiés (SMRN, PMRN et *Rain Nowcast*) par rapport aux prévisions obtenues par ces mêmes algorithmes sans cette hypothèse. Les prévisions étant meilleures, nous pouvons augmenter l'horizon des prévisions jusqu'à  $t_h = 60$  min, tout en gardant des bonnes performances (en particulier avec SMRN). Toutefois, dans certains cas, cette hypothèse peut engendrer

une sur-estimation du mouvement qui à son tour, induit une mauvaise localisation des structures précipitantes sur l'image de prévision. Au lieu d'un retard, les cellules orageuses sont en avance par rapport à la vérité terrain. Le paramétrage de la valeur de  $\tau$  est donc primordiale afin d'assurer une bonne correction. L'étude que nous avons menée dans ces travaux nous a conduit à fixer la valeur de  $\tau$  à 70% de la valeur maximum. Cette valeur doit sans doute être différente pour d'autres types de données, d'autres situations géographiques ou encore pour d'autres événements pluvieux que ceux étudiés dans cette thèse.

Pour la correction d'histogramme de la prévision et contrairement aux précédentes contributions, les métriques spatiales (POD, FMS et FAR) ne sont pas pertinentes. Seule la métrique MAE est appropriée, car cette correction agit sur la quantité de précipitations et non sur le positionnement spatial. Toutefois, il faut que les structures prédites soient correctement localisées pour permettre une lecture pertinente de la métrique MAE. Les performances des prévisions obtenues avec la correction d'histogramme sont très variables. Elles dépendent principalement de la nature et la qualité des observations.

Pour les données locales, nous avons constaté une dégradation de la métrique MAE pour des prévisions avec correction d'histogramme par rapport aux prévisions sans correction. Cela est peut-être dû au procédé de post-traitement des données radar en Bande X de Weather Measures et de la fusion des trois domaines d'acquisition par l'opérateur maximum de réflectivité.

Pour les données régionales, l'amélioration des prévisions est constatée avec la correction d'histogramme. On notera que cette correction est pertinente seulement dans le cas où les structures précipitantes sont bien positionnées. Dans le cas contraire, la correction d'histogramme induit une sur-estimation des quantités des précipitations.



# Chapitre 6

## Conclusion

Cette thèse s'est intéressée à la problématique de la prévision à court terme des précipitations, en se basant sur l'analyse du mouvement dans une séquence d'acquisitions radar.

La première étape de ce travail concerne une étude de l'état de l'art sur les modalités de détection et de mesure des précipitations, en faisant un focus sur l'imagerie radar. Puis, dans une deuxième étape, nous avons décrit les différents systèmes de prévision opérationnels, fondés sur le principe d'estimation de la dynamique. En particulier, nous avons décrit en détails l'algorithme *Rain Nowcast*, qui sert de point de départ de cette thèse, dont l'objectif est d'améliorer significativement les performances de *Rain Nowcast* pour autoriser un déploiement opérationnel chez la société Weather Measures.

Au chapitre 3, nous avons proposé deux algorithmes permettant d'estimer le mouvement à partir d'images radars acquises selon deux échelles différentes. Le premier algorithme, *Sequential Motion Rain Nowcast* (SMRN), consiste à estimer un mouvement sur une première série d'images radar dont la résolution est grossière mais couvre un domaine spatial de grande taille, puis à raffiner ce résultat par une estimation sur une seconde série images radar dont la résolution est plus fine, mais le domaine spatial plus restreint. Le second algorithme, *Parallel Motion Rain Nowcast* (PMRN), consiste à estimer le mouvement simultanément sur les deux séries d'images radars, en incluant les deux échelles différentes.

L'algorithme SMRN a montré une bonne performance en particulier dans l'anticipation de l'arrivée des structures nuageuses dans le domaine local. En revanche, l'algorithme présente un coût en calculs plus élevé que *Rain Nowcast*, en raison de la nature séquentielle dans l'utilisation des images.

L'algorithme PMRN a également montré une bonne performance, dans le cas où les structures orageuses observées sur les deux échelles sont corrélées à la fois en espace et en temps. Dans le cas contraire, les performances se dégradent car les informations en

provenance de chaque échelle deviennent contradictoires. Dans ce cas, il est nécessaire de privilégier une échelle sur l'autre.

Pour les deux algorithmes, le paramétrage des matrices  $R$  et  $B$  est particulièrement primordial. Nous avons choisi de mettre le même poids concernant l'utilisation des observations régionales et locales. Cette paramétrisation est naïve et pourrait naturellement être améliorée. Par exemple, on observe une discontinuité sur les bords du domaine local qui n'existe pas dans les données régionales. Ces discontinuités gênent l'estimation du mouvement. Une solution serait donc de privilégier l'échelle régionale par rapport à l'échelle locale sur les bords du domaine local, en adaptant pour cela les matrices  $R_r$  et  $R_l$ .

Une amélioration possible concerne la condition initiale de la vitesse pour les deux méthodes SMRN et PMRN. Actuellement, celle-ci n'est pas contrainte à son ébauche (laquelle étant soit nulle pour la première fenêtre, soit obtenue par la vitesse calculée à la fenêtre précédente). Il serait possible de contraindre  $\mathbf{w}(0)$  à être proche de son ébauche en mettant des valeurs finies dans les éléments correspondant de la diagonale de  $B$  (voir équation 3.8). Ce faisant, la régularisation de  $\mathbf{w}(0)$ , qui est paramétrée par  $\alpha$  et  $\beta$  deviendrait, en théorie, inutile. Cette approche permettrait alors d'assurer une régularisation temporelle entre les valeurs de  $\mathbf{w}$  calculées d'une fenêtre à l'autre.

Dans cette étude, nous avons choisi d'estimer le mouvement régional sur une partie du domaine d'acquisition du capteur régionale (la zone équivalente au domaine d'acquisition du capteur local). L'élargissement du domaine de calcul à l'échelle régionale ne conduit pas à une amélioration des performances. En effet, nous avons constaté expérimentalement que les structures nuageuses présentes dans les images régionales loin du domaine local disparaissent ou changent de trajectoire, avant d'arriver dans le domaine local. En revanche, les structures nuageuses qui se forment près du domaine local traversent généralement ce domaine local.

L'algorithme SMRN estime deux champs de vitesses, l'un régional, l'autre local qui permet ainsi de raffiner le premier. On peut envisager une autre voie : *Rain Nowcast* calcule un champ régional  $\mathbf{w}_r$  à partir des données régionales et une autre instance de *Rain Nowcast* calcule un champ local  $\mathbf{w}_l$  à partir des données régionales. Ces deux instances peuvent s'exécuter en parallèle. On fusionne ces deux champs de vecteurs à l'aide d'une approche variationnelle 3D-Var, en minimisant la fonction de coût

$$J(\mathbf{w}) = \langle \mathbf{w} - \mathbf{w}_r, R_r^{-1}(\mathbf{w} - \mathbf{w}_r) \rangle + \langle \mathbf{w} - \mathbf{w}_l, R_l^{-1}(\mathbf{w} - \mathbf{w}_l) \rangle$$

Les matrices  $R_r$  et  $R_l$  quantifient l'incertitude sur chaque champ  $\mathbf{w}_r$  et  $\mathbf{w}_l$ . Les valeurs de ces deux matrices sont liées à la quantité de pluie correspondante observée. Lorsqu'une

structure orageuse est observée dans les deux échelles, une échelle doit primer sur l'autre, probablement l'échelle la plus fine.

Lors des spécifications de l'algorithme PMRN, nous avons choisi de sur-échantillonner les données régionales, afin qu'elles aient la résolution des données locales, afin de simplifier l'exécution des calculs ultérieurs. D'un point de vue algorithmique, cela implique un sur-coût d'environ 48% en terme d'occupation mémoire et temps de calcul. Une alternative serait d'assimiler directement les données à leur résolution d'acquisition. En particulier, on peut déléguer à l'opérateur d'observation des données régionales le soin de calculer la valeur pertinente, dans les acquisitions régionales, pour chaque position  $(x, y)$  de la grille locale.

Le chapitre 4 est dédié à l'amélioration de la phase de prévision. Nous avons débuté ce chapitre par la présentation de la méthode de prévision, basée sur l'estimation d'un champ de mouvement et sur l'intégration numérique d'un modèle simplifié de circulation du vent dans l'atmosphère. Nous avons discuté les limitations de cette approche et avons identifié deux problématiques majeures.

La première limitation est la sous-estimation de l'intensité du mouvement pour les structures peu contrastées dans les images radars. Pour cela, nous avons proposé une correction. Elle consiste à faire l'hypothèse d'un vent géostrophique, constant en intensité mais pas en direction. Cette hypothèse est basée sur l'analyse des situations atmosphériques qui se produisent sur le domaine local d'acquisition. Elle peut néanmoins se généraliser sur un domaine plus étendu, à condition d'adapter le seuil  $\tau$ , utilisé par la méthode, selon les caractéristiques du domaine.

La seconde limitation concerne le processus d'intégration numérique du modèle de prévision. Le choix du schéma numérique utilisé est le résultat d'un compromis entre qualité et temps de calcul. Le schéma que nous avons choisi présente l'inconvénient de lisser les images de précipitation prédites, à partir d'un horizon temporel de quelques minutes.. Les structures orageuses prédites sont ainsi dégradées, conduisant ainsi à des erreurs de prévision des précipitations. Une correction de l'histogramme de l'image de prévision a donc été mise en place pour corriger cet effet de lissage. Cette même technique est déjà utilisée pour une correction des mesures radars à partir des données obtenus par les pluviomètres.

D'autre part, les difficultés, liées au schéma numérique semi-lagrangien que nous avons implémenté, ouvrent une perspective à l'utilisation de schémas alternatifs, qui réduisent la diffusion implicite, cause de l'effet de lissage. Des schémas tels que [Smo83] ou des schémas de type CIP [YA91] permettent de conserver les discontinuités du champ à transporter. Toutefois, ces schémas ont coût algorithmique important, car l'estimation effectuée est plus précise. De plus, ces schémas sont explicites et, de ce fait, sont soumis aux conditions



CFL, ce qui implique de réduire la taille du pas de temps et d'en augmenter le nombre.

Enfin, nous utilisons le même schéma numérique pour l'advection des traceurs et l'advection de la vitesse par elle-même, mais des schémas différents, en prenant en compte la nature du traceur, pourraient être envisagés.

Au chapitre 5, nous avons présenté une analyse quantitative des algorithmes proposés dans cette thèse sur une large base de données radars. Dans la première partie, nous avons présenté les données ainsi que les métriques utilisées pour quantifier les résultats. Nous avons d'abord évalué les deux approches proposées au chapitre 3 (SMRN et PMRN) en les testant par rapport à *Rain Nowcast*, qui constitue la référence pour notre travail. Les résultats montrent une amélioration des prévisions effectuées l'algorithme SMRN, par rapport à la référence, ce qui permet d'étendre l'horizon des prévisions jusqu'à  $t_h = 45$  minutes. L'algorithme PMRN est lui systématiquement moins performant que SMRN et, parfois, moins performant que *Rain Nowcast*. Nous avons donc proposé des pistes pour améliorer ses performances.

Nous avons ensuite évalué les approches proposées au chapitre 4 pour *Rain Nowcast*, SMRN et PMRN, séparément ou en les combinant. L'hypothèse de vent géostrophique permet d'améliorer significativement le positionnement des structures nuageuses prédites par les trois algorithmes. Cette correction permet de prolonger l'horizon de prévision à  $t_h = 60$  minutes. En ce qui concerne la correction d'histogramme sur la prévision, les performances sont très variables. Sur les données locales, une dégradation est constatée par rapport aux prévisions sans correction. En revanche, sur les données régionales, l'amélioration est constatée grâce à la correction d'histogramme si les structures sont correctement positionnées.

Trois des quatre métriques utilisées, (POD, FMS et FAR), évaluent la performance des algorithmes de prévision en terme de positionnement géographique des structures orageuses. Elles dépendent donc d'un seuil de détection de la pluie et ne fournissent aucune information sur les quantités de pluie. Seule la métrique MAE est pertinente pour évaluer les performances en terme de quantité de pluie mais elle est de faible pertinence, si la structure orageuse prédite est mal localisée ou si la structure étudiée a changé significativement de forme dans les acquisitions radars.

Il reste donc difficile de quantifier les performances de nos algorithmes. Une amélioration serait de garder les métriques spatiales, mais, au lieu de considérer une quantification binaire (présence ou absence de pluie), d'admettre une quantification multi-classes, en sachant que les zones où les quantités de pluie sont importantes sont plus intéressantes pour l'expert.

Une prolongation possible de cette thèse concerne l'emploi d'autres capteurs pour fournir une information plus complète sur les structures orageuses (par exemple données

météorologiques satellitaires pour la température et l'humidité, ou des données de pollution comme les mesures de particules fines, qui sont aussi des traceurs pour le vent), en s'inspirant de nos approches multi-échelles pour les fusionner.

Il faut également signaler que les méthodes, que nous avons proposées, pourraient s'appliquer à d'autres problématiques environnementales, comme par exemple la prévision de la pollution atmosphérique par particules fines.

D'un point de vue théorique la phase de prévision est la partie qui ouvre le plus de perspectives. Pour prévoir avec plus de précision, le modèle de circulation simplifié que nous avons utilisé pourrait être enrichi par davantage de physique décrivant la mécanique d'évolution de l'atmosphère.



# Annexe A

## Calcul des gradients

Dans cette annexe nous détaillons le calcul du gradient de la fonction de coût  $J$  dans la phase d'estimation du mouvement de *Rain Nowcast*. La fonction de coût contient le terme d'ébauche et le terme sur les observations. Son gradient est donné dans la section [A.1](#). Le calcul sur les termes de régularisation est donné dans la section [A.2](#).

### A.1 Calcul du gradient de $J$

Soit le système d'équations [\(2.37,2.38,2.39\)](#) donné à page [58](#) de ce manuscrit :

$$\frac{\partial X}{\partial t}(x, y, t) + \mathbb{M}(X)(x, y, t) = \vec{0} \quad (\text{A.1})$$

$$X(x, y, 0) = X^b(x, y) + \epsilon_B(x, y) \quad (\text{A.2})$$

$$Y(X)(x, y, t) = \mathbb{H}(X)(x, y, t) + \epsilon_R(x, y, t) \quad (\text{A.3})$$

La fonction de coût associée s'écrit :

$$\begin{aligned} J(X(0)) = & \frac{1}{2} \int_{\Omega} (X(x, y, 0) - X^b(x, y)) B^{-1} (X(x, y, 0) - X^b(x, y)) dx dy \\ & + \frac{1}{2} \int_0^T \int_{\Omega} (Y(x, y, t) - \mathbb{H}(X)(x, y, t)) R^{-1}(x, y, t) \\ & (Y(x, y, t) - \mathbb{H}(X)(x, y, t)) dx dy dt \end{aligned} \quad (\text{A.4})$$

Afin de simplifier l'écriture de la fonction  $J$ , nous introduisons le produit scalaire associée à la norme  $L^2(\Omega)$  :

$$\langle A, B \rangle = \int_{\Omega} A^T(x, y) B(x, y) dx dy \quad (\text{A.5})$$

On réécrit alors la fonction de coût  $J$  en :

$$J(X(0)) = J_B(X(0)) + J_R(X(0)) \quad (\text{A.6})$$

$$J_B(X(0)) = \frac{1}{2} \langle X(0) - X^b, B^{-1}(X(0) - X^b) \rangle \quad (\text{A.7})$$

$$J_R(X(0)) = \frac{1}{2} \int_0^T \langle Y(t) - \mathbb{H}(X)(t), R^{-1}(t)(Y(t) - \mathbb{H}(X)(t)) \rangle dt \quad (\text{A.8})$$

avant de calculer le gradient de chacune de ses composantes  $J_B$  et  $J_R$ .

## Gradient de $J_B$

Le gradient de  $J_B$  s'obtient à partir de la dérivée directionnelle de  $J_B$ . La dérivée directionnelle de  $J_B$  en  $X(0)$  dans la direction du vecteur  $\eta$  est définie par :

$$\left\langle \frac{\partial J}{\partial X(0)}, \eta \right\rangle = \lim_{\nu \rightarrow 0} \frac{J_B(X(0) + \nu\eta) - J_B(X(0))}{\nu} \quad (\text{A.9})$$

où  $\langle \cdot, \cdot \rangle$  est le produit scalaire tel que défini par (A.5). Le terme de gauche dans le produit scalaire est le gradient. Pour déterminer le gradient, il faut donc calculer la dérivée directionnelle puis l'écrire sous la forme d'un produit scalaire.

Le calcul se poursuit comme suit :

$$\begin{aligned} \left\langle \frac{\partial J_B}{\partial X(0)}, \eta \right\rangle &= \frac{1}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} [\langle X(0) + \nu\eta - X^b, B^{-1}(X(0) + \nu\eta - X^b) \rangle \\ &\quad - \langle X(0) - X^b, B^{-1}(X(0) - X^b) \rangle] \\ &= \frac{1}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} [\langle X(0) - X^b + \nu\eta, B^{-1}(X(0) - X^b + \nu\eta) \rangle \\ &\quad - \langle X(0) - X^b, B^{-1}(X(0) - X^b) \rangle] \\ &= \frac{1}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} [\langle \nu\eta, B^{-1}(X(0) - X^b) \rangle + \langle \nu\eta, B^{-1}\eta\nu \rangle \\ &\quad + \langle X(0) - X^b, B^{-1}\eta\nu \rangle] \\ &= \frac{1}{2} \langle \eta, B^{-1}(X(0) - X^b) \rangle + \langle X(0) - X^b, B^{-1}\eta \rangle \\ &\quad + \lim_{\nu \rightarrow 0} \nu \langle \eta, B^{-1}\eta \rangle \end{aligned}$$

Le terme  $\lim_{\nu \rightarrow 0} \nu \langle \eta, B^{-1}\eta \rangle$  vaut zéro. Finalement, nous obtenons :

$$\left\langle \frac{\partial J_B}{\partial X(0)}, \eta \right\rangle = \langle B^{-1}(X(0) - X^b), \eta \rangle \quad (\text{A.10})$$

et le gradient de  $J_B$  est donc égale à :

$$\frac{\partial J_B}{\partial X(0)} = B^{-1}(X(0) - X^b) \quad (\text{A.11})$$

## Gradient de $J_R$

Nous calculons à présent le gradient de  $J_R$ . Il s'écrit :

$$J_R(X(0)) = \frac{1}{2} \int_0^T \langle Y(t) - \mathbb{H}(X(t)), R^{-1}(Y(t) - \mathbb{H}(X(t))) \rangle dt \quad (\text{A.12})$$

Par définition, voir (A.9), on a :

$$\left\langle \frac{\partial J_R}{\partial X(0)}, \eta(0) \right\rangle = - \int_0^T \langle \mathbb{H}^T R^{-1}(Y(t) - \mathbb{H}(X(t))), \eta(t) \rangle dt \quad (\text{A.13})$$

Le calcul de la différentielle de  $J_R$  est toutefois plus complexe que celui de  $J_B$ , car le terme sous l'intégrale est à présent fonction de  $X(t)$  alors qu'il n'était fonction que de  $X(0)$  dans le cas de  $J_B$ .

Nous savons que  $X(t)$  dépend uniquement de la valeur de  $X(0)$  (voir équations (A.1,A.2)).

En considérant l'équation (A.1) et en en ajoutant à  $X(t)$  un terme  $\delta X(t)$  petit, nous pouvons écrire :

$$\frac{\partial X(x, y, t) + \delta X(x, y, t)}{\partial t} + \mathbb{M}(X + \delta X)(x, y, t) = 0 \quad (\text{A.14})$$

Dans le cas où le modèle d'évolution  $\mathbb{M}$  est non linéaire, nous appliquons un développement limité d'ordre 1 afin d'obtenir une équation linéaire en  $\delta X(t)$  :

$$\mathbb{M}(X + \delta X)(x, y, t) \simeq \mathbb{M}(X)(x, y, t) + \frac{\partial \mathbb{M}}{\partial X}(\delta X)(x, y, t) \quad (\text{A.15})$$

Le terme de perturbation  $\delta X(t)$  étant petit, cette approximation est valide.

En utilisant ce développement, l'équation (A.14) se réécrit :

$$\frac{\partial X}{\partial t}(x, y, t) + \frac{\partial \delta X}{\partial t}(x, y, t) + \mathbb{M}(X)(x, y, t) + \frac{\partial \mathbb{M}}{\partial X}(\delta X)(x, y, t) = \vec{0} \quad (\text{A.16})$$

En utilisant (A.1), l'équation (A.16) devient :

$$\frac{\partial \delta X}{\partial t}(x, y, t) + \frac{\partial \mathbb{M}}{\partial X}(\delta X)(x, y, t) = \vec{0} \quad (\text{A.17})$$

On introduit à présent la variables adjointe  $\lambda$ , définie sur  $t \in [0, T]$ , telle que :

$$\lambda(x, y, T) = 0 \quad (\text{A.18})$$

$$-\frac{\partial \lambda(x, y, t)}{\partial t} + \left( \frac{\partial \mathbb{M}}{\partial X} \right)^* \lambda(x, y, t) = \mathbb{H}^T R^{-1} (Y(x, y, t) - \mathbb{H}(X)(x, y, t)) \quad (\text{A.19})$$

On multiplie alors l'équation (A.17) par  $\lambda(t)$  et on intègre en temps et en espace pour obtenir :

$$\int_0^T \left\langle \frac{\partial \delta X}{\partial t}(t) + \frac{\partial \mathbb{M}}{\partial X} \delta X(t), \lambda(t) \right\rangle dt = \vec{0} \quad (\text{A.20})$$

$$\int_0^T \left\langle \frac{\partial \delta X}{\partial t}(t), \lambda(t) \right\rangle dt = - \int_0^T \left\langle \frac{\partial \mathbb{M}}{\partial X} \delta X(t), \lambda(t) \right\rangle dt \quad (\text{A.21})$$

Nous appliquons alors une intégration par partie dans le terme de gauche de l'équation (A.21) :

$$\begin{aligned} \int_0^T \left\langle \frac{\partial \delta X}{\partial t}(t), \lambda(t) \right\rangle dt &= - \int_0^T \left\langle \delta X(t), \frac{\partial \lambda(t)}{\partial t} \right\rangle dt + [\langle \delta X(t), \lambda(t) \rangle]_0^T \\ &= - \int_0^T \left\langle \delta X(t), \frac{\partial \lambda}{\partial t} \right\rangle dt + \langle \delta X(T), \lambda(T) \rangle \\ &\quad - \langle \delta X(0), \lambda(0) \rangle \end{aligned}$$

Par définition  $\lambda(T) = 0$ , donc :

$$\int_0^T \left\langle \frac{\partial \delta X}{\partial t}(t), \lambda(t) \right\rangle dt = - \int_0^T \left\langle \delta X(t), \frac{\partial \lambda}{\partial t} \right\rangle dt - \langle \delta X(0), \lambda(0) \rangle \quad (\text{A.22})$$

En utilisant cette équation, (A.21) se réécrit selon :

$$\int_0^T \left\langle \delta X(t), \frac{\partial \lambda(t)}{\partial t} \right\rangle dt + \langle \delta X(0), \lambda(0) \rangle = \int_0^T \left\langle \frac{\partial \mathbb{M}}{\partial X(t)} \delta X(t), \lambda(t) \right\rangle dt \quad (\text{A.23})$$

$$\int_0^T \left\langle \delta X(t), \frac{\partial \lambda(t)}{\partial t} \right\rangle dt = - \langle \delta X(0), \lambda(0) \rangle + \int_0^T \left\langle \frac{\partial \mathbb{M}}{\partial X(t)} \delta X(t), \lambda(t) \right\rangle dt \quad (\text{A.24})$$

Nous définissons  $\left( \frac{\partial \mathbb{M}}{\partial X} \right)^*$  comme l'opérateur adjoint de  $\mathbb{M}$ , qui vérifie :

$$\left\langle \frac{\partial \mathbb{M}}{\partial X(t)} f, g \right\rangle = \left\langle f, \left( \frac{\partial \mathbb{M}}{\partial X(t)} \right)^* g \right\rangle \quad (f, g) \in L^2(\Omega) \quad (\text{A.25})$$

En multipliant l'équation (A.19) par  $\delta X(t)$  et en intégrant en temps et en espace, nous obtenons :

$$\begin{aligned} \int_0^T \left\langle \frac{\partial \lambda(t)}{\partial t}, \delta X(t) \right\rangle dt &= \int_0^T \left\langle \left( \frac{\partial \mathbb{M}}{\partial X(t)} \right)^* \lambda(t), \delta X(t) \right\rangle dt \\ &\quad - \int_0^T \langle \mathbb{H}^T R^{-1}(Y(t) - \mathbb{H}(X)(x, y, t)), \delta X(t) \rangle dt \end{aligned} \quad (\text{A.26})$$

En utilisant (A.24, A.26), on déduit :

$$\begin{aligned} & - \langle \lambda(0), \delta X(0) \rangle + \int_0^T \left\langle \frac{\partial \mathbb{M}}{\partial X(t)} \delta X(t), \lambda(t) \right\rangle dt = \\ \int_0^T \left\langle \left( \frac{\partial \mathbb{M}}{\partial X(t)} \right)^* \lambda(t), \delta X(t) \right\rangle dt &- \int_0^T \langle \mathbb{H}^T R^{-1}(Y(t) - \mathbb{H}(X)(t)), \delta X(t) \rangle dt \end{aligned} \quad (\text{A.27})$$

qui se simplifie en :

$$\int_0^T \langle \mathbb{H}^T R^{-1}(Y(t) - \mathbb{H}(X)(t)), \delta X(t) \rangle dt = \langle \lambda(0), \delta X(0) \rangle \quad (\text{A.28})$$

Et enfin, à partir de : (A.13, A.28), on obtient :

$$\left\langle \frac{\partial J_O}{\partial X(0)}, \eta(0) \right\rangle = \langle \lambda(0), \delta X(0) \rangle \quad (\text{A.29})$$

Le gradient de  $J_R$  est donc :

$$\frac{\partial J_R}{\partial X(0)} = \lambda(0) \quad (\text{A.30})$$

Le gradient de  $J$  s'écrit donc :

$$\frac{\partial J}{\partial X(0)} = B^{-1}(X(0) - X^b) + \lambda(0) \quad (\text{A.31})$$



## A.2 Calcul du gradient des termes de régularisation

Le terme  $\mathcal{R}_1$  est défini par :

$$\mathcal{R}_1(X(0)) = \frac{1}{2}\alpha \int_{\Omega} \|\nabla w(x, y, 0)\|^2 dx dy \quad (\text{A.32})$$

avec  $w(x, y, 0) = \begin{pmatrix} u(x, y, 0) & v(x, y, 0) \end{pmatrix}^T$ .

$\mathcal{R}_1$  se développe en :

$$\begin{aligned} \mathcal{R}_1(X(0)) &= \frac{1}{2}\alpha \int_{\Omega} (\|\nabla u(x, y, 0)\|^2 + \|\nabla v(x, y, 0)\|^2) dx dy \\ &= \frac{1}{2}\alpha \int_{\Omega} (u_x^2(x, y, 0) + u_y^2(x, y, 0) + v_x^2(x, y, 0) + v_y^2(x, y, 0)) dx dy \\ &= A(u) + B(u) + C(v) + D(v) \end{aligned}$$

où  $u_x = \frac{\partial u}{\partial x}$ .

$A(u)$  est le premier terme de  $\mathcal{R}_1$ , qui ne dépend que de  $u$ . Calculons sa différentielle :

$$\frac{\partial A}{\partial u}(\eta) = \lim_{\nu \rightarrow 0} \frac{A(u + \nu\eta) - A(u)}{\nu} \quad (\text{A.33})$$

Le calcul se poursuit comme suit :

$$\begin{aligned} \frac{\partial A}{\partial u}(\eta) &= \frac{\alpha}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} \int_{\Omega} \left( \frac{\partial u(x, y, 0) + \nu\eta(x, y)}{\partial x} \right)^2 - \left( \frac{\partial u(x, y, 0)}{\partial x} \right)^2 dx dy \\ &= \frac{\alpha}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} \int_{\Omega} (u_x(x, y, 0) + \nu\eta_x(x, y))^2 - u_x^2(x, y, 0) dx dy \\ &= \frac{\alpha}{2} \lim_{\nu \rightarrow 0} \frac{1}{\nu} \int_{\Omega} (\nu^2\eta_x^2(x, y) + 2u_x(x, y, 0)\nu\eta_x(x, y)) \\ &= \frac{\alpha}{2} \lim_{\nu \rightarrow 0} \int_{\Omega} \nu\eta_x^2(x, y) + 2u_x(x, y, 0)\eta_x(x, y) \\ &\quad + \nu\eta_y^2(x, y) + 2u_x(x, y, 0)\nu\eta_y(x, y) dx dy \\ &= \alpha \int_{\Omega} u_x(x, y, 0)\eta_x(x, y) dx dy \end{aligned}$$

En intégrant par partie, et en supposant que les termes de bord ont une valeur nulle, nous obtenons :

$$\frac{\partial A}{\partial u}(\eta) = -\alpha \int_{\Omega} \eta(x, y) \frac{\partial u_x}{\partial x}(x, y, 0) dx dy = -\alpha \int_{\Omega} \eta(x, y) \frac{\partial^2 u(x, y, 0)}{\partial x^2} dx dy \quad (\text{A.34})$$

On procède de la même façon pour les trois autres termes de  $\mathcal{R}_1$ , notés  $B(u)$ ,  $C(v)$  et

$D(v)$ , et nous obtenons :

$$\frac{\partial B}{\partial u}(\eta) = -\alpha \int_{\Omega} \eta(x, y) \frac{\partial^2 u(x, y, 0)}{\partial y^2} dx dy \quad (\text{A.35})$$

$$\frac{\partial C}{\partial v}(\eta) = -\alpha \int_{\Omega} \eta(x, y) \frac{\partial^2 v(x, y, 0)}{\partial x^2} dx dy \quad (\text{A.36})$$

$$\frac{\partial D}{\partial v}(\eta) = -\alpha \int_{\Omega} \eta(x, y) \frac{\partial^2 v(x, y, 0)}{\partial y^2} dx dy \quad (\text{A.37})$$

Nous pouvons réécrire ces équations en :

$$\frac{\partial \mathcal{R}_1}{\partial u}(\eta) = -\alpha \int \eta(x, y) \nabla^2 u(x, y, 0) dx dy \quad (\text{A.38})$$

$$\frac{\partial \mathcal{R}_1}{\partial v}(\eta) = -\alpha \int \eta(x, y) \nabla^2 v(x, y, 0) dx dy \quad (\text{A.39})$$

où  $\nabla^2 = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2}$  est l'opérateur laplacien.

Le gradient de  $\mathcal{R}_1$  s'écrit donc :

$$\frac{\partial \mathcal{R}_1}{\partial w} = -\alpha \nabla^2 w(0) \quad (\text{A.40})$$

Le terme  $\mathcal{R}_2$  est défini par :

$$\mathcal{R}_2(X(0)) = \frac{1}{2} \beta \int_{\Omega} (\text{div}(w(0)))^2 dx \quad (\text{A.41})$$

avec  $\text{div}(w(x, y, 0)) = \frac{\partial u(x, y, 0)}{\partial x} + \frac{\partial v(x, y, 0)}{\partial y}$ .

Pour calculer le gradient de  $\mathcal{R}_2$ , on procède de la même façon que pour le terme  $\mathcal{R}_1$  et on obtient :

$$\frac{\partial \mathcal{R}_2}{\partial w} = -\beta \nabla \text{div}(w(0)) \quad (\text{A.42})$$



# Annexe B

## Implémentation opérationnelle

Cette annexe discute les résultats des prévisions que nous avons présentées, en utilisant comme critère la durée d'exécution.

Les conditions opérationnelles d'utilisation nécessitent qu'un calcul de prévision soit fourni toutes les 5 minutes, afin de permettre une utilisation en temps réel (au rythme des acquisitions) dans le système informatique de Weather Measures. Il est donc nécessaire que l'estimation de la dynamique et la prévision à  $t_h = 60$  minutes soit réalisées en moins de 5 minutes.

Lors de l'estimation du mouvement et de la prévision par *Rain Nowcast*, une partie importante du coût de calcul (et c'est même la partie majeure de la prévision) provient de l'intégration numérique du modèle (voir équations (2.37) et (4.3)). Nous devons donc nous efforcer d'optimiser en priorité cette partie.

### B.1 Prévision

La partie la plus coûteuse en calcul, lors de la prévision, provient de l'intégration temporelle des équations (4.5,4.6). Le modèle  $M_f$  contient des termes d'advection, qui sont discrétisés à l'aide d'un schéma semi-lagrangien. Ce schéma repose essentiellement sur une interpolation bilinéaire et un raffinement itératif [SC91].

#### Exécution séquentielle

Sur une séquence test de 3601 pas de temps, le code initial *Rain Nowcast*, que nous renommeons ci-dessous RN1.0 et qui est écrit en C, C++ et Fortran, nécessite un calcul de 169 secondes sur un nœud (c'est-à-dire une unité de calcul indépendante dans un ordinateur) d'une machine PC récente sous Linux et composée de processeurs de type Intel Xeon.

L’optimisation du code correspondant est une tâche prioritaire à réaliser, si l’on souhaite obtenir un code performant et compatible avec les contraintes industrielles. Le code RN1.0 a donc été optimisé de façon à :

- exploiter les capacités de vectorisation des CPU modernes,
- réduire le nombre de déclarations conditionnelles ou redondantes,
- supprimer les déclarations de copie mémoire inutiles.

Dans les mêmes conditions expérimentales, le code optimisé, que nous nommons RN2.0, s’exécute en 76,9 secondes, ce qui correspond à une accélération<sup>1</sup> de 2,22.

### Exécution parallèle

Le code initial RN1.0 contient des instructions OpenMP<sup>2</sup>, afin de répartir les calculs selon une stratégie de partition du domaine image, chaque nœud calculant alors sur une portion du domaine. Pour mesurer la performance de la méthode proposée en terme de temps de calcul, nous proposons d’utiliser le critère de l’efficacité du passage à l’échelle<sup>3</sup>. Il s’agit d’une mesure statistique couramment utilisée dans la communauté HPC<sup>4</sup> pour mesurer l’efficacité d’un code parallèle lorsque le nombre de nœuds ou de processeurs augmente. Elle est définie comme suit :

$$\text{Efficacité} = \frac{T_1}{T_n \times n}$$

avec  $T_1$  le temps d’exécution du code séquentiel et  $T_n$  le temps d’exécution du code parallèle s’exécutant sur  $n$  nœuds. Le code initial RN1.0, qui s’exécute en 169 secondes sur un nœud, ne nécessite plus que 34 secondes sur 8 nœuds et 26 secondes sur 24 nœuds. Par conséquent, l’efficacité de la mise à l’échelle est de 62% sur 8 nœuds et de 27% sur 24 nœuds. Cela reste toutefois assez faible par rapport aux besoins opérationnels dans un contexte industriel.

Pour améliorer l’efficacité, les déclarations OpenMP sont affinées afin d’obtenir une meilleure granularité : utiliser des domaines indépendants de plus grande taille permet de réduire le nombre de nœuds (l’initialisation d’un nœud est coûteux) et permet de bénéficier de la vectorisation si les données sont contiguës en mémoire, ce qui est le cas pour les tableaux C utilisés pour le code RN1.0. En partant du code séquentiel optimisé RN2.0, fonctionnant en 76,9 secondes sur 1 nœud, cette nouvelle amélioration produit

---

1. L’accélération est définie comme le rapport entre le temps d’exécution du code original et le temps d’exécution du code optimisé.

2. <https://www.openmp.org/>

3. Le terme échelle n’a ici pas le même sens que dans les chapitres 4 et 5.

4. High Performance Computing.

un code que nous nommons RN2.1. Celui-ci présente les performances suivantes : 11,5 secondes sur 8 nœuds avec une mise à l'échelle efficace de 84% et 4,8 secondes sur 24 nœuds, avec une mise à l'échelle efficace de 67%.

Le tableau B.1 résume les performances des différents codes discutés ci-dessus. On peut y remarquer que la complexité de l'étape de prévision de RN2.1 est linéaire.

TABLE B.1 – Benchmarks de l'étape de prévision de *Rain Nowcast* (RN1.0 et RN2.1).

Nombre de nœuds	1	8	24
RN1.0 (temps en secondes)	169	34	26
RN1.0 (efficacité)		62%	27%
RN2.1 (temps en secondes)	76,9	11,5	4,8
RN2.1 (efficacité)		84%	67%

## B.2 Estimation du mouvement

Le code original pour la phase d'estimation du mouvement dans *Rain Nowcast* (que l'on nomme à nouveau RN1.0 dans la discussion suivante) fonctionne en 68 secondes sur un nœud, lorsque l'ébauche du mouvement est initialisée avec une valeur nulle.<sup>5</sup> L'objectif est d'atteindre une durée d'exécution inférieure à 30 secondes pour une utilisation opérationnelle.

Comme on peut le voir dans l'algorithme 1 du chapitre 2, page 61, l'estimation de mouvement est un processus itératif, chaque itération ayant trois composantes coûteuses : l'intégration *avant* du modèle par avancée en temps, l'intégration *retrograde* de l'adjoint par recul en temps, et l'appel au solveur. Nous détaillons, pour chaque composante, les problématiques à résoudre et la solution retenue.

### Intégration avant

L'équation (2.37) est intégrée en temps, de la même manière que pour l'étape de prévision. En conséquence, l'optimisation réalisée est identique à celle décrite dans la sous-section B.1.

À la fin de cette intégration avant, la fonction de coût  $J$  (2.49) doit être calculée. Ce calcul est optimisé en utilisant des instructions OpenMP (parallélisation grâce à une décomposition de domaine, puis réduction des calculs de chaque nœud sur un nœud unique).

---

5. Il s'agit d'une valeur typique, car l'estimation du mouvement nécessite la vérification d'un critère d'arrêt et correspond donc à un temps de calcul différent pour chaque expérience.

## Intégration rétrograde

L'équation (2.44) est d'abord intégrée de façon rétrograde en temps. Puis le gradient de  $J$ ,  $\frac{\partial J}{\partial X(0)}$ , est calculé selon l'équation (2.50). Le calcul de  $\frac{\partial J}{\partial X(0)}$  est également optimisé par utilisation d'instructions de parallélisation d'OpenMP.

Il est important de noter que le calcul de la variable adjointe  $\lambda$  nécessite la détermination du modèle adjoint  $(\frac{\partial M}{\partial X})^*$ . Comme le modèle  $M$  correspond à un morceau de code numérique, le modèle adjoint correspond également à un morceau de code, qui est obtenu avec un outil de différenciation automatique. Nous utilisons pour ce faire le logiciel Tapenade [HP13b]. Le code, qui est soumis à Tapenade pour réaliser la différenciation, est le code optimisé obtenu lors de la discussion sur l'intégration en avant. Le code adjoint, résultant de Tapenade, est cependant optimisé et parallélisé en post-process, comme expliqué ci-dessous.

Il convient de noter que Tapenade présente parfois des défauts concernant l'identification d'itérations indépendantes d'une boucle, comme c'est le cas dans la boucle principale de parcours du domaine de l'image. En effet, Tapenade doit stocker chaque variable d'image dans une pile pour le calcul de l'adjoint. Trois inconvénients majeurs en résultent : rupture de la vectorisation, augmentation de la taille mémoire requise et interdiction des directives parallèles OpenMP. Cependant, le code adjoint peut être considérablement amélioré si des directives sont données à Tapenade pour identifier les instructions indépendantes à l'intérieur des boucles. Cela supprime toutes les opérations de la pile de Tapenade. Le code adjoint qui en résulte bénéficie de la vectorisation et peut alors être facilement parallélisé avec les directives OpenMP. La nouvelle exécution avec ce code adjoint optimisé donne un résultat en 49,3 secondes sur un seul nœud à comparer avec les 68 secondes requises par le code initial.

Ayant introduit des instructions OpenMP dans le code adjoint, nous souhaitons estimer l'efficacité de cette réécriture pour le passage à l'échelle : sur 8 nœuds, le temps d'exécution est de 21,9 secondes, tandis que sur 24 nœuds, le temps d'exécution est de 19,4 secondes. On peut remarquer que l'efficacité de la mise à l'échelle diminue de manière significative pour plus de 8 nœuds, car le solveur ne fonctionne que sur un nœud unique, qui devient ainsi un réel goulot d'étranglement pour les calculs.

## Utilisation du solveur

Cette étape du calcul repose sur l'appel au solveur L-BFGS, qui est un code séquentiel écrit en Fortran 77. Dans le code de ce solveur, nous identifions quatre boucles coûteuses en temps de calcul et à instructions indépendantes. Nous introduisons donc des instructions OpenMP, afin de paralléliser ces boucles. Par ailleurs, L-BFGS utilisant des appels

BLAS, nous utilisons la bibliothèque OpenBLAS, qui distribue ses calculs sur les nœuds, pour remplacer le module BLAS fourni par la distribution du logiciel L-BFGS.

## Résultats finaux

Après toutes ces actions, nous obtenons les résultats suivants pour l'estimation du mouvement : 55,4 secondes sur un nœud, 20,1 secondes sur 8 nœuds et 12,5 secondes sur 24 nœuds. Le tableau B.2 donne une vue plus précise de l'efficacité de la mise à l'échelle du code d'estimation du mouvement. On peut voir que l'efficacité est bonne pour les phases d'intégration avant et arrière, et modérée pour le solveur.

TABLE B.2 – Efficacité de l'estimation du mouvement après optimisation de L-BFGS.

nb. nœuds	int. avant	int. arrière	solveur	temps total	efficacité
1	14,9	25,2	13,5	55,4	
2	12,9	25,0	11,9	51,7	54%
4	6,8	13,0	8,5	29,6	47%
8	4,3	7,3	7,2	20,1	34%
12	3,2	4,9	6,4	15,4	30%
16	2,8	3,8	6,2	13,8	25%
24	2,5	2,8	6,3	12,5	18%

Pour conclure, la version finale de *Rain Nowcast*, nommée RN2.1, est en mesure de fournir une prévision à un horizon temporel d'une heure en environ 30 secondes, sur une machine puissante. Sur une machine plus modeste, les temps de calcul restent toutefois en dessous de la minute.

On notera que Sequential Motion Rain Nowcast (SMRN) est une combinaison séquentielle de deux *Rain Nowcast* à des échelles spatiales différentes. Le calcul du mouvement régional se fait sur des images de taille 25 fois plus petites que lors du traitement des images locales. Le temps de calcul sur ces données régionales est donc beaucoup plus petit. Le temps d'exécution total est un peu rallongé par rapport à un calcul de *Rain Nowcast* uniquement fait sur les données régionales. Ainsi, les valeurs de durée nécessaire permettent de réaliser un déploiement opérationnel.

L'algorithme Parallel Motion Rain Nowcast (PNRM) a la même architecture algorithmique que *Rain Nowcast*. Il bénéficie donc de la même efficacité que RN2.1. Toutefois, le vecteur d'état utilisé par PNRM est plus grand de 33%, si on le compare à celui de *Rain Nowcast*. Les temps de calcul seront donc un peu plus long, avec une augmentation qui est du même ordre de grandeur. Le déploiement opérationnel est là encore tout à fait possible. On peut également remarquer que le traceur régional utilisé par PMRN a une taille inutilement grande, provenant du sur-échantillonnage. Le code pourrait donc être amélioré en supprimant ce sur-échantillonnage pour gagner en efficacité.





# Bibliographie

- [ABN16] M. Asch, M. Bocquet, and M. Nodet. *Data Assimilation. Methods, Algorithms, and Applications*. Fundamentals of algorithms. SIAM, 2016. 56
- [Ait19] A. Aitor. *Politics, Statistics and Weather Forecasting, 1840-1910 : Taming the Weather*. Routledge, 2019. 42
- [BAHH92] J. Bergen, P. Anandan, K. Hanna, and R. Hingorani. Hierarchical model-based motion estimation. *European Conference on Computer Vision*, pages 237–252, 1992. 55
- [BB95] S. Beauchemin and J. Barron. The computation of optical flow. *ACM Computing Surveys*, 27(3), September 1995. 53, 76
- [BC99] F. Bouttier and P. Courtier. Data assimilation concepts and methods. Technical report, Training Course of European Centre for Medium-Range Weather Forecasts, 1999. 56
- [Bor02] M. Borga. Accuracy of radar rainfall estimates for streamflow simulation. *Journal of Hydrology*, 267(1) :26 – 39, 2002. Advances in Flood Research. 40
- [BSL<sup>+</sup>11] S. Baker, D. Scharstein, J. Lewis, S. Roth, M. Black, and R. Szeliski. A database and evaluation methodology for optical flow. *International Journal in Computer Vision*, 92(1) :1–31, March 2011. 8, 53, 80
- [BW02] T. Brox and J. Weickert. Nonlinear matrix diffusion for optic flow estimation. *Pattern Recognition, Lecture Notes in Computer Science.*, 2449 :446–453, 2002. 53
- [BZK<sup>+</sup>10] A. Bellon, I. Zawadzki, A. Kilambi, H. Lee, Y. Lee, and G. Lee. McGill algorithm for precipitation nowcasting by lagrangian extrapolation (MAPLE) applied to the South Korean radar network. Part I : Sensitivity studies of the Variational Echo Tracking (VET) technique. *Asia-Pacific Journal of Atmospheric Sciences*, 46(3) :369–381, Aug 2010. 55
- [CFL67] R. Courant, K. Friedrichs, and H. Lewy. On the partial difference equations of mathematical physics. *IBM Journal of Research and Development*, 11(2) :215—234, March 1967. 87

- [Coi97] J. Coiffier. *Éléments de prévision numérique du temps "Cours et manuels"*. Météo-France, 1997. 43
- [dC03] J.-P. du Châtelet. Aramis, le réseau français de radars pour la surveillance des précipitations. Technical Report 40, Météo-France - Direction des systèmes d'observation, 7, rue Teisserenc-de-Bort - BP 202 - 78195 Trappes, Février 2003. 41
- [DW93] M. Dixon and G. Wiener. Thunderstorm Identification Tracking Analysis and Nowcasting - A radar based Methodology. *Journal of atmospheric and oceanic technology*, December 1993. 47
- [FBK15] D. Fortun, P. Bouthemy, and C. Kervrann. Optical flow modeling and computation : A survey. *Computer Vision and Image Understanding*, 134 :1–21, May 2015. 53
- [FL18] Valentin Freret-Lorgeril. *Le terme source des panaches de téphras : applications radars aux volcans Etna et Stromboli (Italie)*. PhD thesis, 11 2018. 7, 37
- [FN91] R. Franke and G. Nielson. *Geometric Modeling – Systems and Applications*, chapter Scattered Data Interpolation and Applications : A Tutorial and Survey. Springer, 1991. 103
- [Gib77] J. Gibson. *Perceiving, Acting, and Knowing. Towards an Ecological Psychology*, chapter The theory of affordances, pages 127–143. Hoboken, NJ : John Wiley & Sons Inc., 1977. 51
- [GS00] T.S. Glickman and American Meteorological Society. *Glossary of Meteorology*. American Meteorological Society, 2000. 25
- [GZ02] U. Germann and I. Zawadzki. Scale-dependence of the predictability of precipitation from continental radar images. part i : Description of the methodology. *Monthly Weather Review*, 130(12) :2859–2873, 2002. 7, 55
- [Han02] J. Handwerker. Cell tracking with trace3d — a new algorithm. *Elsevier Atmospheric Research*, 2002. 7, 48, 49
- [Hor02] M. Hortal. The development and testing of a new two-time-level semi-lagrangian scheme (settl) in the ecmwf forecast model. *Quarterly Journal of the Royal Meteorological Society*, 128(583) :1671–1687, 2002. 87
- [HP13a] L. Hascoët and V. Pascual. The Tapenade Automatic Differentiation tool : Principles, Model, and Specification. *ACM Transactions On Mathematical Software*, 39(3), 2013. 60

- [HP13b] L. Hascoët and V. Pascual. The Tapenade Automatic Differentiation tool : Principles, Model, and Specification. *ACM Transactions On Mathematical Software*, 39(3), 2013. 158
- [HRC60] G. Hilst, J. Russo, and Travelers Weather Research Center. *An Objective Extrapolation Technique for Semi-conservative Fields with an Application to Radar Patterns*. Travelers Insurance Companies technical memorandum. Travelers Insurance Companies, 1960. 43
- [HS81] B. Horn and B. Schunk. Determining optical flow. *Artificial Intelligence*, 17 :185–203, 1981. 51, 52
- [HvG12] L. Howard and J. von Goethe. *Sur les modifications des nuages : Suivi de Goethe, La forme des nuages selon Howard*. Météos, Documents. Editions Hermann, 2012. 25
- [ID12] Peter Michael Inness and Steve Dorling. *Operational weather forecasting*. John Wiley & Sons, 2012. 43
- [IH06] A. Ines and J. Hansen. Bias correction of daily gcm rainfall for crop simulation studies. *Agricultural and Forest Meteorology*, 138 :44–53, 08 2006. 95
- [JMW<sup>+</sup>98] J. Johnson, P. Mackeen, A. Witt, E. Mitchell, G. Stumpf, M. Eilts, and K. Thomas. The Storm Cell Identification and Tracking Algorithm : An Enhanced WSR-88D Algorithm. *Weather and Forecasting*, June 1998. 48
- [KN05] H. Kyznarová and P. Novák. Development of cell-tracking algorithm in the czech hydrometeorological institute. *Proceedings of WSN05*, pages 1–5, January 2005. 50
- [KN09] H. Kyznarová and P. Novák. CELLTRACK — Convective cell tracking algorithm and its use for deriving life cycle characteristics. *Atmospheric Research*, 93(1) :317 – 327, 2009. 4th European Conference on Severe Storms. 50
- [LASJ<sup>+</sup>99] S. Lapczak, E. Aldcroft, M. Stanley-Jones, J. Scott, P. Joe, P. Rijn, M. Falla, A. Gagne, P. Ford, K. Reynolds, and D. Hudak. Canadian national radar project. In *29th Conf. Radar Met.*, pages 327–330, 01 1999. 48
- [LDT86] F.-X. Le Dimet and O. Talgarand. Variational algorithms for analysis and assimilation of meteorological observations : theoretical aspects. *Tellus*, 1986. 56, 59
- [Lep15] Y. Lepoittevin. *Estimation de la dynamique à partir des structures observées dans une séquence d'image*. PhD thesis, Université Pierre et Marie Curie, 2015. 17

- [LH15] Y. Lepoittevin and I. Herlin. Modeling high rainfall regions for flash flood nowcasting. In *IEEE Workshop on the Analysis of Multitemporal Remote Sensing Images*, Annecy, July 2015. 56
- [LH16] Y. Lepoittevin and I. Herlin. Regularization terms for motion estimation - links with spatial correlations. In *Proceedings of the 11th Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications - Volume 4 : VISAPP, (VISIGRAPP 2016)*, pages 456–464. INSTICC, SciTePress, 2016. 61
- [Lio71] J.-L. Lions. *Optimal Control of Systems Governed by Partial Differential Equations*. Springer-Verlag, 1971. 56
- [LK81] B. Lucas and T. Kanade. A iterative image registration technique with an application to stereo vision. In *Proc. of 7th International Joint Conference on Artificial Intelligence*, pages 674–679, Vancouver, Canada, 1981. 51
- [LL04] P. Li and E. Lai. Short-range quantitative precipitation forecasting in hong kong. *Journal of Hydrology*, 288(1) :189 – 209, 2004. Quantitative Precipitation Forecasting II. 45
- [LSJ95] L. Li, W. Schmid, and J. Joss. Nowcasting of motion and growth of precipitation with radar over a complex orography. *Journal of Applied Meteorology*, 34(6) :1286–1300, 1995. 45, 48
- [LZ94] S. Laroche and I. Zawadzki. A variational analysis method for retrieval of three-dimensional wind field from single-doppler radar data. *Journal of the Atmospheric Sciences*, 51(18) :2664–2682, 1994. 54
- [Mar09] S. Marladel. *Fondamentaux de météorologie*. Edit. Cépaduès, seconde édition edition, 2009. ISBN : 9782854288513. 89
- [Mer16] F. Mercier. *Assimilation variationnelle d’observations multi-échelles : Application à la fusion de données hétérogènes pour l’étude de la dynamique micro et macrophysique des systèmes précipitants*. PhD thesis, Université Paris-Saclay, 2016. 38, 40
- [MJS00] S. Mecklenburg, J. Joss, and W. Schmid. Improving the nowcasting of precipitation in an alpine region with an enhanced radar echo tracking algorithm. *Journal of Hydrology*, 239(1) :46 – 68, 2000. 46
- [MP48] J. Marshall and W. Palmer. The distribution of raindrops woth size. *Journal of meteorology*, 1948. 41
- [MSR<sup>+</sup>03a] C. Mueller, T. Saxen, R. Roberts, J. Wilson, T. Betancourt, S. Dettling, N. Oien, and J. Yee. Ncar auto-nowcast system. *Weather and Forecasting*, 18(4) :545–561, 2003. 45

- [MSR<sup>+</sup>03b] C. Mueller, T. Saxen, R. Roberts, J. Wilson, T. Betancourt, S. Dettling, N. Oien, and J. Yee. Ncar auto-nowcast system. *Weather and Forecasting*, 18(4) :545–561, 2003. 45, 48
- [Nov07] P. Novak. The czech hydrometeorological institute’s severe storm nowcasting system. *Atmospheric Research*, 83(2) :450 – 457, 2007. European Conference on Severe Storms 2004. 46
- [PJ00] M. Parker and R. Johnson. Organizational modes of midlatitude mesoscale convective systems. *Monthly Weather Review*, 128(10) :3413–3436, 2000. 103
- [PTMG05] J. Parent, P. Tabary, and M. M. Guimera. The panthere project and the evolution of the french operational radar network and products : rain-estimation, doppler winds and dual-polarisation. In *32nd Conference on Radar Meteorology*, 2005. 105
- [RG78] R. Rinehart and E. Garvey. Three-dimensional storm motion detection by conventional weather radar. *Nature*, 05 1978. 44
- [RH15] E. Rabiei and U. Haberlandt. Applying bias correction for merging rain gauge and radar data. *Journal of Hydrology*, 522 :544 – 557, 2015. 95
- [RY89] R. Rogers and M. Yau. *A Short Course in Cloud Physics*. Elsevier Science, 1989. 24
- [SC91] A. Staniforth and J. Côté. Semi-Lagrangian integration schemes for atmospheric models—a review. *Monthly Weather Review*, 119(9) :2206–2223, 1991. 87, 155
- [SMJ00] W. Schmid, S. Mecklenburg, and J. Joss. Short-term risk forecasts of severe weather. *Physics and Chemistry of the Earth, Part B : Hydrology, Oceans and Atmosphere*, 25(10) :1335 – 1338, 2000. First European Conference on Radar Meteorology. 46
- [SMK02] W. Schmid, A. Mathis, and U. Keller. Nowcasting the risk of snowfall and freezing rain with radar and ground data. In *New Challenges for Winter Road Service. XIth International Winter Road Congress*, pages 1–7, January 2002. 46
- [Smo83] P. Smolarkiewicz. A simple positive definite advection scheme with small implicit diffusion. *Monthly Weather Review*, 111 :479–487, March 1983. 143
- [Spu00] Kvetoslav R. Spurny. Atmospheric condensation nuclei p. j. coulier 1875 and j. aitken 1880 (historical review). *Aerosol Science and Technology*, 32(3) :243–248, 2000. 24

## BIBLIOGRAPHIE

---

- [SW05] W. Schmid and M. Wüest. Verifying warnings for point precipitation. *Atmospheric Research*, 77(1) :347 – 353, 2005. Precipitation in Urban Areas. 46
- [Tik63] A. Tikhonov. Regularization of incorrectly posed problems. *Sov. Math. Dokl.*, 4 :1624–1627, 1963. 60
- [TS01] M. Temperton, C. Hortal and A. Simmons. A two-time-level semi-lagrangian global spectral model. *Quarterly Journal of the Royal Meteorological Society*, 127(571) :11–127, 2001. 87
- [TXZ<sup>+</sup>19] Z. Tu, W. Xie, D. Zhang, R. Poppe, R. Veltkamp, B. Li, and J. Yuan. A survey of variational and CNN-based optical flow techniques. *Signal Processing : Image Communication*, 72 :9–24, 2019. 53
- [WW17] W. Woo and W. Wong. Operational application of optical flow techniques to radar-based rainfall nowcasting. *atmosphere*, 02 2017. 45
- [YA91] T. Yabe and T. Aoki. A universal solver for hyperbolic equations by cubic-polynomial interpolation i. one-dimensional solver. *Computer Physics Communications*, 66 :219–232, 09 1991. 143
- [ZBLN97] C. Zhu, R.H. Byrd, P. Lu, and J. Nocedal. L-BFGS-B : Algorithm 778 : L-BFGS-B, FORTRAN routines for large scale bound constrained optimization. *ACM Transactions on Mathematical Software*, 23(4) :550–560, 1997. 60