



HAL
open science

Approche objet pour la détection, le suivi et la prévision à très courte échéance des systèmes convectifs de mésoméchelle

Gabriel Arnould

► To cite this version:

Gabriel Arnould. Approche objet pour la détection, le suivi et la prévision à très courte échéance des systèmes convectifs de mésoméchelle. Sciences de la Terre. Université de Toulouse, 2024. Français. NNT : 2024TLSEP082 . tel-04841084

HAL Id: tel-04841084

<https://theses.hal.science/tel-04841084v1>

Submitted on 16 Dec 2024

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.

Doctorat de l'Université de Toulouse

préparé à Toulouse INP

Approche objet pour la détection, le suivi et la prévision à très
courte échéance des systèmes convectifs de mésoéchelle

Thèse présentée et soutenue, le 22 octobre 2024 par

Gabriel ARNOULD

École doctorale

SDU2E - Sciences de l'Univers, de l'Environnement et de l'Espace

Spécialité

Océan, Atmosphère, Climat

Unité de recherche

CNRM - Centre National de Recherches Météorologiques

Thèse dirigée par

Thibaut MONTMERLE et Lucie ROTTNER

Composition du jury

Mme Cécile MALLET, Présidente, Université de Versailles Saint-Quentin-en-Yvelines

M. Alain PROTAT, Rapporteur, Australian Bureau of Meteorology

M. Daniel SEMPERE-TORRES, Rapporteur, Universitat Politècnica de Catalunya

Mme Caroline MULLER, Examinatrice, Institute of Science and Technology Austria

M. Urs GERMANN, Examineur, MeteoSwiss

Mme Clotilde AUGROS, Examinatrice, Toulouse INP

M. Thibaut MONTMERLE, Directeur de thèse, Toulouse INP

Mme Lucie ROTTNER, Co-directrice de thèse, Météo-France

Membres invités

M. Jean-Marc Moisselin, Météo-France

Remerciements

Dans la vie, rares sont les occasions d'exprimer formellement sa gratitude à l'égard de ceux qui nous apprécient et nous soutiennent. L'aboutissement d'un doctorat en est une, et cette section se veut être le vecteur de mes remerciements.

Ils se dirigent en premier lieu vers mes rapporteurs et examinateurs de thèse : Cécile, Alain, Daniel, Caroline, Clotilde et Urs, avec qui j'ai apprécié échanger le jour de ma soutenance. Leurs compliments m'ont ému et ont appuyé ma motivation à poursuivre mes activités de recherche autour de la convection profonde. Les retours avisés de mes rapporteurs m'ont également permis d'enrichir la version finale de ce manuscrit.

Je souligne ensuite l'écoute et la rigueur de mes encadrants. Dans sa formulation, le sujet initial offrait des libertés que j'ai pu exploiter pour épanouir mes idées. Ils m'ont accordé leur confiance et donné de précieux conseils afin d'améliorer la pertinence et la qualité de mon projet. De plus, ils n'ont cessé de valoriser mon travail. Lucie, Jean-Marc, Thibaut : un grand merci à vous trois ! Je me suis senti à l'aise et porté à vos côtés.

Je salue également l'attention des membres de mon comité de suivi : Philippe A., dont j'ai apprécié les conseils et encouragements pendant la dernière répétition de mon oral ; Michaël K., professeur passionné et passionnant avec qui je me ravis de poursuivre les échanges autour de la convection ; Urs, un homme si chaleureux qui m'a offert l'opportunité de découvrir l'équipe radar et *nowcasting* de MétéoSuisse, à Locarno ou dans le monastère de Bigorio.

De plus, je remercie l'aide bienvenue et spontanée de ces encadrants non officiels qui ont suivi le déroulement de ma thèse depuis les origines. Je pense à Isabelle, dont la patience et la gentillesse ne firent jamais défaut pour répondre à mes (nombreuses) sollicitations autour de l'algorithme OSIRIS. Je pense aussi à Arnaud, à sa disponibilité naturelle, à son parcours de thèse exemplaire qui fut pour moi une source d'inspiration. Puis il y a Philippe C., co-bureau attentionné, plein de justesse dans ses remarques, plein de bonté dans sa manière de les exprimer.

Enfin, je souhaite rendre hommage aux encadrants de mes précédents stages scientifiques. Leur rencontre m'a motivé à intégrer le monde de la recherche. Juan puis Ingrid, Isabelle et Yann, merci à vous !

*

Sur le plan professionnel, le principal enseignement de ma thèse fut l'importance et le plaisir d'échanger avec les agents de mon équipe et des autres services.

Je pense d'abord à ma petite équipe PI composée de personnalités attachantes, drôles et talentueuses. Ce fut un plaisir d'analyser les situations météo sur Synopsis avec Michaël C.,

de discuter des actualités avec Adrien... et de décoder ses diaboliques contrepèteries ! J'ai apprécié la paisible compagnie d'Isabelle et de Renaud pour tenir la permanence de l'équipe, certains soirs, dans le silence et l'obscurité des couloirs désertés. Je garderai de bons souvenirs de Fred, de son humour et de sa sagesse philosophe, et des échanges avec Philippe sur des sujets aussi variés que la météo, l'Histoire, le sport, les voyages, les tortues et le jardinage... Ce fut aussi une chance de côtoyer Ronan, expert en éclairs et en photos d'orages, de débriefer chacune de mes présentations et réunions avec Jean-Marc, de partager ces quelques jours dans le Tessin avec Thibaut, y compris dans la terrible grimpette du Monti di Motti ! Enfin, mention spéciale à Nicolas qui, aidé de Thibaut, a assuré jusqu'à la fin de ma thèse le maintien de mon futur poste dédié à AROME-PI. C'est promis, j'apporterai une galette en janvier ! Chers membres de PI, je suis ravi de rester à vos côtés.

Par ailleurs, je salue les relations entretenues avec les autres équipes, par exemple GMME et Clotilde qui m'a aiguillé vers la conférence ECSS à Bucarest au cours de laquelle j'ai largement étendu les perspectives de mon sujet. Je citerai aussi les échanges avec le GMAP, notamment Arnaud et Clément qui m'ont fait bénéficier de leur expérience en statistiques et apprentissage profond, les rencontres avec Joris et Météorage, le regard métier de mes amis prévisionnistes, en particulier Fabrice, Pierre-Louis et Dorian. Je remercie aussi l'équipe MDR de MétéoSuisse pour son accueil amical dans les bureaux de Locarno.

Par ailleurs, ma thèse n'a pas échappé aux problèmes informatiques et interrogations techniques. Issues de divers services, à l'occasion d'un simple échange de mails, d'une réunion informelle ou d'une entrevue sur le pas d'une porte, plusieurs personnes m'ont fait profiter d'un peu de leur temps et de leur expérience. Je leur témoigne ici toute ma reconnaissance : Véronique, toujours enthousiaste à dépanner mes expériences OLIVE ; Olivier, qui offre volontiers un cours de stats privé ; Léa et Bruno, dont le dynamisme et le regard critique en matière d'apprentissage profond sont précieux pour nos activités de prévision immédiate ; Ingrid, Yann et Ryad, mes référents AROME incontournables ; Fleur et Dominique, pour la riche bibliographie sur les MCSs que vous m'avez conseillée en début de thèse.

*

L'aboutissement de cette thèse doit beaucoup à mon entourage professionnel mais aussi aux personnes qui m'ont soutenu en dehors de la thèse. Je pense à mes amis de météo, notamment Dorian, avec qui j'aime discuter sur les affaires du monde ; Rémi, dont j'apprécie le calme et la sympathie lors de ses escales à Toulouse ; Thomas, un être plein de ressources qui vous enchante par ses récits exotiques ; Jean, sa joie de vivre retentissante et communicative ; Léna, sans qui je n'aurais osé me lancer dans l'enseignement du Python ; Léonard, égrenant chaque matin sa bonne humeur dans nos couloirs ; Pierre, avec qui il fait bon courir les midis en discutant des fleurs sauvages ; Danaé, qui gentiment venait prendre de mes nouvelles, toquant à mon bureau, une petite tasse de thé à la main... sans oublier Tom, Matthias, Flore, Argan, Jules, Agathe, Maroua, Scarlett, Erwan et Maxandre, dont la proximité égaye mon cadre de vie à Météo-France. Enfin, il y a Théophile, camarade d'école, compagnon d'aventure sur les chemins d'Alsace, les rails des Pyrénées, les sentiers de Gascogne... hier collègue d'infortune,

dans les vicissitudes de nos thèses respectives, et désormais confrère. Ton humour piquant, ton franc-parler dissimulent une âme pure, soucieuse du bien d'autrui, et des qualités précieuses à qui sait te comprendre. Je suis heureux d'être de ceux-là !

Ces années de thèse furent aussi colorées par de belles amitiés disséminées dans toute la France, même au-delà, à commencer par Julien, mon ami d'enfance depuis le collège de Calvinsson, qui vint régulièrement me rendre visite à Toulouse. . . malgré le risque qu'il encourait d'être battu au Mölkky ! En prépa, je tombai sur Tony et Florian. . . des amis pour la vie. Durant les mois les plus éprouvants de la thèse, j'ai rêvé des voyages que nous programmions de réaliser, à Genève, en Alaska ou sur les mers australes. . . dès que vous êtes prêts, je prépare mes valises ! À Paris, je rencontrai Suney, et avec elle la bonté à l'état pur. C'est pour moi une fierté et un bonheur de te connaître, *querida amiga*. Ma route a aussi croisé celle de Roxanne, de Florent et de Sophie, chacun de nous embarqué dans l'aventure du doctorat. . . et, en dépit de la distance, échangeant ces messages d'encouragement et de soutien. Puis il y a Monica, à l'autre bout du monde, dont les signes de tendresse et d'affection me réchauffent régulièrement le cœur. J'ai hâte de vous revoir bientôt.

Enfin, ma petite famille. . . qui s'agrandit pourtant ! Le bonheur procuré par la naissance des petits Kétons fut une source de motivation supplémentaire à la fin de ma thèse. Merci à vous, mes grands cousins et tout-petits-petits cousins ! Vous avez la chance d'avoir des parents admirables, un grand seigneur de Savoie pour Élio, et pour Jules ma cousine Nanou préférée (en même temps, c'est la seule) ! Mes pensées vont aussi vers mon dernier cousin, Yuga, qui m'a offert une démonstration de force et de courage lors du marathon des Jeux Olympiques. J'espère que les occasions seront encore nombreuses de partager de beaux moments comme celui-ci !

Pour finir, ceux avec qui tout a commencé. . . ce dernier paragraphe ne saurait exprimer toute la reconnaissance que je vous dois, ni tout tout l'amour que je vous porte. Babou, mon soleil de Lorraine. Aurélien, mon feu d'artifice aux milliers de couleurs. Mon père et ma mère bien aimés, mes phares qui jamais ne s'éteignent ; chacun à votre manière, par votre histoire, votre charisme et votre bienveillance, vous m'avez offert les clés d'une vie autonome et épanouie. C'était un honneur de vous avoir à mes côtés en ce mardi 22 octobre. Enfin, mes chers tontons, votre présence silencieuse a toujours compté pour moi. Mes derniers songes seront pour vous.

Table des matières

Introduction	13
1 Contexte de la thèse	17
1.1 Les systèmes convectifs de mésoéchelle (MCSs)	18
1.1.1 L'instabilité de flottabilité	19
1.1.2 Préconditionnement et forçages	23
1.1.3 De la cellule au MCS : organisation de la convection à mésoéchelle	26
1.1.4 Schéma conceptuel du MCS	28
1.1.5 Bestiaire des MCSs	31
1.1.6 Enjeux associés aux MCSs	35
1.2 Prévision immédiate de la convection	39
1.2.1 Panorama des méthodes opérationnelles	39
1.2.2 La place du prévisionniste	41
1.3 Les données d'observation	42
1.3.1 Le satellite	42
1.3.2 Le radar	44
1.3.3 Autres observations	46
1.4 L'approche « objet »	47
1.4.1 Etape n°1 : identification	48
1.4.2 Étape n°2 : suivi	50
1.4.3 Étape n°3 : prévision	50
1.5 La prévision numérique du temps	54
1.5.1 L'atmosphère en équations	54
1.5.2 Principes de la prévision numérique	54

1.5.3	Les modèles régionaux non-hydrostatiques	55
1.5.4	Les variables diagnostiques	57
1.5.5	L'assimilation de données	57
1.5.6	Adaptation des modèles à la PI	60
1.5.7	L'approche ensembliste	64
1.5.8	Comportement d'AROME pour la prévision des MCSs	65
1.6	Projet et objectifs de la thèse	65
1.6.1	Objectif du chapitre 2 : développer un réseau de neurones convolutifs pour la détection des MCSs	65
1.6.2	Objectif du chapitre 3 : étudier le cycle de vie des MCSs en France	67
1.6.3	Objectif du chapitre 4 : évaluer l'apport du modèle AROME pour la PI des MCSs	68
2	Détection des MCSs par réseaux de neurones convolutifs	69
2.1	Introduction	70
2.2	Comprendre le fonctionnement du U-Net	70
2.2.1	De l' <i>IA</i> au <i>deep learning</i> : précisions de vocabulaire	70
2.2.2	Réseau de neurones convolutifs	71
2.2.3	Architecture du U-Net	75
2.2.4	Le processus d'entraînement	81
2.3	Développement d'un U-Net pour la détection des MCSs dans des images simulées par AROME	85
2.3.1	Constitution des jeux de données	85
2.3.2	Analyse des jeux de données et normalisation	87
2.3.3	Préréglage des hyperparamètres	90
2.3.4	Sélection de la « meilleure » configuration	95
2.3.5	Analyse du U-Net sélectionné	98
2.4	Évaluation et comparaison avec d'autres méthodes de segmentation d'images	102

2.4.1	Méthode alternative n°1 : un simple seuillage	103
2.4.2	Méthode alternative n°2 : algorithme <i>watershed</i>	103
2.4.3	Méthode alternative n°3 : identification à deux rayons de recherche	103
2.4.4	Comparaison objective sur le jeu de test	105
2.4.5	Comparaison sur des études de cas	107
2.5	Un second U-Net dédié aux images observées	109
2.5.1	Jeux de données d'observation	110
2.5.2	Réglage des hyperparamètres	111
2.5.3	Évaluation du U-Net OBS	112
2.6	Conclusions et perspectives	115
3	Cycle de vie et environnement des MCSs en France	119
3.1	Introduction	120
3.2	Cadre de l'étude et données utilisées	120
3.2.1	Période et domaine	120
3.2.2	Données simulées	121
3.2.3	Données observées	121
3.2.4	Détection des MCSs et construction des trajectoires	122
3.2.5	Sélection des trajectoires pertinentes et complètes	123
3.2.6	Distinction des MCSs méditerranéens quasi-stationnaires	124
3.3	Caractérisation des MCSs en France	124
3.3.1	Distribution spatiale et saisonnière	125
3.3.2	Cycle diurne	127
3.3.3	Caractérisation des trajectoires	127
3.3.4	Limites et potentiels du U-Net pour le suivi des MCSs	128
3.3.5	Cycle de vie des attributs géométriques	128
3.3.6	Cycle de vie de l'activité convective	130

3.3.7	Conclusions	131
3.4	Évolution de l'environnement convectif	132
3.4.1	Aperçu de l'environnement synoptique	132
3.4.2	Deux méthodes pour décrire l'environnement de mésoéchelle	133
3.4.3	Analyse statistique	136
3.4.4	MCS du 4 juin 2022 : un système linéaire continental	141
3.4.5	Discussion : impact du MCS sur son environnement	146
3.4.6	Discussion : impact de l'environnement sur le MCS	148
3.5	Zoom sur les MCSs méditerranéens quasi-stationnaires	151
3.5.1	Aperçu de l'environnement synoptique	151
3.5.2	Analyse statistique	151
3.5.3	MCS du 20 novembre 2018 : une ligne stationnaire sur le Gard	153
3.5.4	Conclusions	157
3.6	Conclusions et perspectives	157
4	Apport du modèle AROME-PI pour la prévision immédiate des MCSs	161
4.1	Introduction	162
4.2	Méthode d'évaluation	162
4.2.1	Données observées	162
4.2.2	Prévisions par extrapolation	163
4.2.3	Prévisions numériques AROME et AROME-PI	163
4.2.4	Intérêts d'une approche objet	164
4.2.5	Appariement des MCSs observés et prévus	165
4.3	Apport d'AROME-PI sur l'extrapolation	167
4.3.1	Panorama des scores	167
4.3.2	Sensibilité des scores au cycle de vie	169
4.4	Apport d'AROME-PI sur AROME-PROD	170

Table des matières	11
<hr/>	
4.4.1 Panorama des scores	170
4.4.2 Raisonnement par trajectoire	171
4.5 Apport des réseaux AROME-PI consécutifs	173
4.5.1 Le dernier réseau est-il toujours le meilleur?	173
4.5.2 Conception d'une carte synthétique pour le prévisionniste	177
4.6 Conclusions et perspectives	178
5 Conclusions et perspectives pour la prévision immédiate des MCSs en France	183
5.1 Un réseau de neurones convolutifs pour détecter les MCSs	184
5.2 Comprendre le cycle de vie des MCSs en France pour aiguiller des stratégies de prévision immédiate	185
5.3 L'apport du modèle AROME pour la prévision immédiate des MCSs	186
5.4 Perspectives pour l'anticipation des MCSs à 6 h d'échéance	187
Acronymes	195
Annexe	211
Bibliographie	213

Introduction

L'orage est un terme générique qui regroupe un ensemble de phénomènes météorologiques potentiellement violents. Ils résultent d'un déséquilibre dans la répartition verticale des masses d'air et se traduisent par de puissants courants ascendants, dits convectifs, de plusieurs dizaines de mètres par seconde. En se condensant, la vapeur d'eau qu'ils transportent donne d'importantes précipitations. Les orages peuvent s'accompagner de foudre, de grêle, de fortes rafales de vent et provoquer des inondations et des glissements de terrain. Ils constituent donc un enjeu majeur pour la sécurité des personnes et des biens. En 2022, le coût économique attribué aux orages dans le monde est estimé à 45 milliards de dollars ([Munich Re, 2024](#)). Les principaux secteurs impactés concernent les transports, notamment l'aviation, l'énergie et la distribution d'électricité, l'agriculture, le bâtiment, l'événementiel, les loisirs, ainsi que la sécurité civile.

Les orages sont fréquents en France. Ils sont responsables de près d'un quart des épisodes de vigilance orange émise par Météo-France entre 2018 et 2022 (communication [Météo-France 2023](#)). La plupart de ces épisodes impliquent des orages de grande dimension appelés *systèmes convectifs de mésoéchelle* ou *mesoscale convective systems* en anglais (abrégiés *MCSs*¹, [Houze 2018](#)). Un contexte très dynamique et/ou très instable favorise le développement de ces systèmes durables qui, organisés sur une à plusieurs centaines de kilomètres, multiplient le nombre de dégâts potentiels. La catastrophe la plus récente s'est produite le 18 août 2022, quand un MCS a balayé la Corse et provoqué des rafales proches de 200 km/h (Figure 1). 28 personnes ont été blessées, cinq sont décédées. Si les systèmes tropicaux et nord-américains ont fait l'objet de nombreuses études, le cycle de vie des MCSs est encore peu documenté sur l'Europe de l'ouest, notamment en dehors de la zone méditerranéenne.

Pour prévenir des risques et mettre en place des mesures de sécurité, une anticipation du phénomène est indispensable. Aujourd'hui, cette anticipation doit beaucoup à la prévision numérique. À Météo-France, le modèle AROME de résolution kilométrique permet d'estimer le risque orageux à 24 voire 48 h d'échéance. Cependant, l'instabilité convective entraîne des écoulements de petite échelle dont l'évolution fortement non-linéaire limite leur prévisibilité. Une prévision détaillée de la localisation, de la temporalité et de l'intensité d'un phénomène convectif est généralement impossible au-delà de quelques heures. En-deçà, la plupart des services météorologiques s'appuient sur des stratégies de *prévision immédiate* dont l'objectif est de fournir des informations régulières et actualisées sur l'évolution de la convection à très court terme. Ces stratégies reposent principalement (1) sur l'observation de divers paramètres météorologiques, issus notamment des radars et d'instruments embarqués dans les satellites, (2) sur la prévision numérique du temps.

La séquence temporelle des dernières images observées permet de caractériser les phénomènes convectifs, d'en estimer la violence et d'en extraire une tendance sur les premières échéances. Une lecture « objet » peut être adoptée. Elle consiste à identifier les systèmes

1. La définition des abréviations et acronymes employés dans ce mémoire est accessible à la page 195.




FIGURE 1 – À gauche : front de rafale d’un MCS en approche d’Ajaccio, le 18/08/2022 vers 0600 UTC (photo de Jérémy Gaudin). À droite : structures nuageuses observées à la même heure par le canal visible (texture) et le canal infrarouge (couleurs en transparence) du radiomètre SEVIRI, depuis le satellite MSG. Ajaccio est indiquée par le point rouge.

convectifs comme des zones cohérentes dont on extrait des propriétés pertinentes pour le suivi et l’anticipation du phénomène : sa croissance, sa vitesse, des statistiques caractérisant son intensité ou son environnement. Or ces approches se basent uniquement sur l’observation ; leurs performances se dégradent rapidement avec les échéances, notamment pour les systèmes dont la dynamique est pilotée par des effets locaux. L’apprentissage machine ou l’apprentissage profond offrent des opportunités pour fusionner plusieurs sources de données, gérer les relations non-linéaires entre les paramètres et, *in fine*, accroître l’anticipation. Cependant, au-delà de quelques heures, la prévision numérique devient indispensable. À Météo-France, les prévisions du modèle AROME-PI sont obtenues après mise à jour de la dernière prévision AROME disponible par assimilation des observations les plus récentes. Ces prévisions sont disponibles rapidement et tiennent compte des changements dynamiques et thermodynamique liés à la convection. De plus, les modèles déterministes peuvent être complétés par des *ensembles* de prévisions qui livrent une information probabiliste sur l’évolution à venir du phénomène et de sa dangerosité. Or le coût numérique et le temps de mise à l’équilibre des champs limitent l’exploitation des modèles sur les premières échéances. Aux algorithmes de prévision immédiate s’ajoute enfin le travail d’expertise du prévisionniste, néanmoins contraint par des délais serrés.

L’objectif de la thèse est d’améliorer la prévision immédiate des MCSs en France à partir d’une approche « objet ». Le projet est schématisé sur la Figure 2 et reprend les stratégies introduites ci-dessus. La première repose sur les objets détectés dans des images observées. Une partie de la thèse consistera à identifier des prédictifs informatifs sur l’évolution du système, qu’ils soient liés à l’objet ou à son environnement, lesquels pourront alimenter un algorithme de prévision basé notamment sur une méthode statistique. La seconde stratégie s’intéresse aux MCSs détectés dans la prévision numérique AROME-PI. Ici, le but sera de mesurer à quel point le suivi des MCSs simulés par un ou plusieurs réseaux successifs permet

d'améliorer l'anticipation du phénomène jusqu'à 6 h d'échéance.

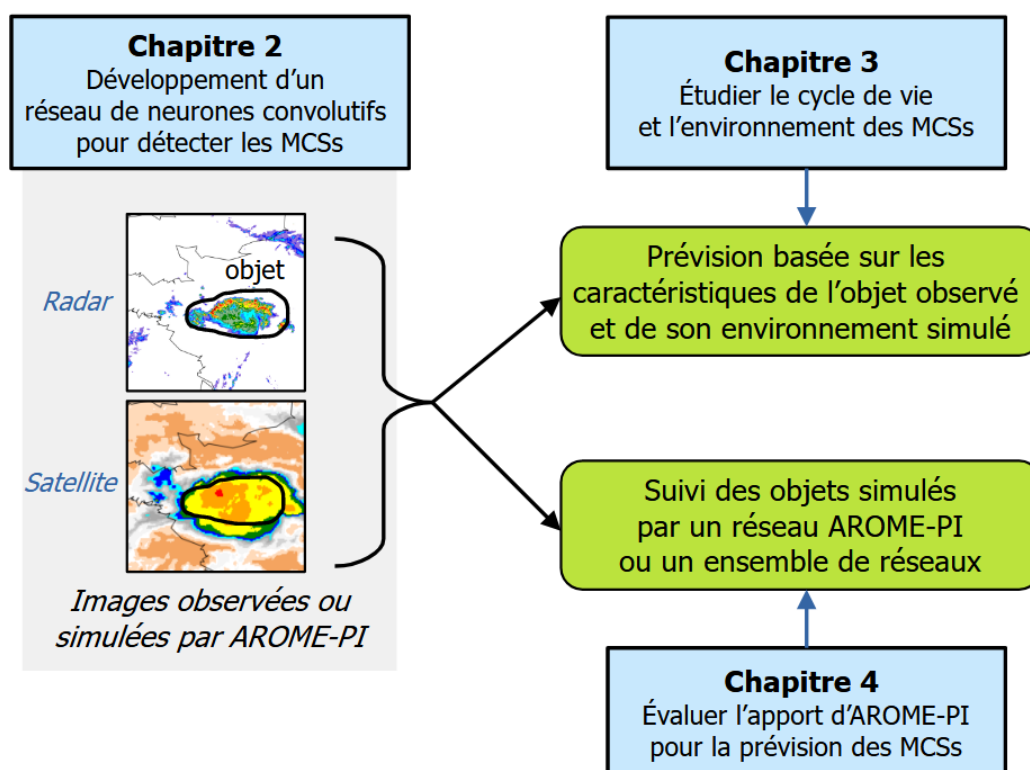


FIGURE 2 – La thèse en un schéma : objectifs généraux (en vert) et objectifs de chaque chapitre (en bleu).

Le chapitre 1 présente les connaissances actuelles concernant les MCSs et les méthodes employées pour la prévision immédiate de la convection. L'attention se porte principalement sur les observations radar et satellite, l'approche « objet » et les modèles de prévision numérique capables de simuler explicitement la convection. Le modèle AROME, sa configuration AROME-PI et les techniques d'assimilation associées sont introduits à cette occasion. Le chapitre se termine par une reformulation plus précise des objectifs de la thèse.

Au chapitre 2, une méthode d'apprentissage profond est développée puis évaluée pour identifier des objets MCS dans des images observées et simulées par AROME. Elle repose sur l'utilisation combinée de plusieurs données d'entrée au sein d'un réseau de neurones convolutifs. On démontre sa plus-value par rapport à des approches non statistiques, en partie basées sur un seuillage des images. La méthode de détection est ainsi validée pour répondre aux principaux objectifs de la thèse dans les chapitres suivants.

Le chapitre 3 montre les résultats d'une étude statistique menée sur des situations de vigilance météorologique entre 2018 et 2022, durant lesquelles plus de 150 MCSs ont été identifiés. On cherche à approfondir la compréhension du phénomène en France afin d'aiguiller des stratégies de prévision immédiate. Les distributions spatiale, diurne et saisonnière des

objets étudiés sont introduits dans un premier temps, puis l'évolution statistique de l'extension et de l'activité convective est analysée afin d'identifier les phases caractéristiques du cycle de vie. Des simulations AROME sont par ailleurs lancées sur chaque situation sélectionnée. Elles permettent de bénéficier de données variées et tridimensionnelles pour comprendre l'influence de l'environnement sur le développement et l'affaiblissement des MCSs. Le cycle de vie des objets simulés est d'abord comparé à celui des objets observés. Deux méthodes sont ensuite développées pour caractériser l'environnement dans un rayon de 100 à 200 km autour de l'objet simulé. La première calcule des données scalaires synthétiques appelées *variables ambiantes* ; la seconde, plus originale, génère des *cartes annulaires* qui échantillonnent les champs AROME à 360° autour de l'objet. Les résultats sont présentés en discriminant les MCSs méditerranéens quasi-stationnaires des autres systèmes. Des éléments de réponse sont apportés aux questions suivantes : quels sont les paramètres pertinents dans l'environnement convectif pour anticiper les phases d'évolution du système ? Réciproquement, dans quelle mesure les MCSs modifient-ils leur environnement durant leur cycle de vie ?

Le chapitre 4 s'intéresse à l'apport du modèle AROME-PI pour l'anticipation des MCSs à 6 h. Les objets observés lors des situations de vigilance servent de références. Ils sont comparés aux objets prévus par deux chaînes AROME opérationnelles à Météo-France : (1) la chaîne de production dont les prévisions longues sont disponibles tardivement à cause des délais d'assimilation ; (2) la chaîne AROME-PI qui assimile moins d'observations mais dont les prévisions à 6 h sont disponibles 30 min seulement après l'heure d'analyse, et ce toutes les heures. Une méthode d'extrapolation des objets observés permet de quantifier l'apport de la prévision numérique sur une simple persistance lagrangienne. Les questions suivantes sont ainsi abordées : à partir de quelle échéance la prévision AROME-PI est-elle meilleure que l'extrapolation pour anticiper la localisation des MCSs ? AROME-PI améliore-t-il les prévisions de la chaîne de production AROME ? Une discussion est également menée sur la pertinence d'un ensemble AROME-PI, constitué des prévisions de différents réseaux valides aux même instants, et sur la façon de valoriser ses sorties auprès des prévisionnistes grâce à une vision synthétique « objet ».

Enfin, une conclusion générale fournit une vue d'ensemble sur les principaux résultats obtenus et les méthodologies développées dans le cadre de la thèse. Cette conclusion est complétée par quatre perspectives concrètes de prévision immédiate des MCSs en France.

Contexte de la thèse

Sommaire

1.1	Les systèmes convectifs de mésoéchelle (MCSs)	18
1.1.1	L'instabilité de flottabilité	19
1.1.2	Préconditionnement et forçages	23
1.1.3	De la cellule au MCS : organisation de la convection à mésoéchelle	26
1.1.4	Schéma conceptuel du MCS	28
1.1.5	Bestiaire des MCSs	31
1.1.6	Enjeux associés aux MCSs	35
1.2	Prévision immédiate de la convection	39
1.2.1	Panorama des méthodes opérationnelles	39
1.2.2	La place du prévisionniste	41
1.3	Les données d'observation	42
1.3.1	Le satellite	42
1.3.2	Le radar	44
1.3.3	Autres observations	46
1.4	L'approche « objet »	47
1.4.1	Étape n°1 : identification	48
1.4.2	Étape n°2 : suivi	50
1.4.3	Étape n°3 : prévision	50
1.5	La prévision numérique du temps	54
1.5.1	L'atmosphère en équations	54
1.5.2	Principes de la prévision numérique	54
1.5.3	Les modèles régionaux non-hydrostatiques	55
1.5.4	Les variables diagnostiques	57
1.5.5	L'assimilation de données	57
1.5.6	Adaptation des modèles à la PI	60
1.5.7	L'approche ensembliste	64
1.5.8	Comportement d'AROME pour la prévision des MCSs	65
1.6	Projet et objectifs de la thèse	65
1.6.1	Objectif du chapitre 2 : développer un réseau de neurones convolutifs pour la détection des MCSs	65
1.6.2	Objectif du chapitre 3 : étudier le cycle de vie des MCSs en France	67
1.6.3	Objectif du chapitre 4 : évaluer l'apport du modèle AROME pour la PI des MCSs	68

La thèse est animée par la volonté d'améliorer l'anticipation des MCSs à très courte échéance en France. Ce chapitre en présente le contexte sous-jacent. Il résume les connaissances actuelles sur la formation et le cycle de vie des MCSs (section 1.1) avant d'introduire les stratégies existantes en matière de prévision immédiate de la convection (section 1.2) : observations (section 1.3), suivi des systèmes convectifs définis comme des « objets » (section 1.4), prévision numérique du temps et modèle AROME-PI utilisé à Météo-France (section 1.5). La dernière section (1.6) positionne les motivations de la thèse vis-à-vis de ce contexte. Les trois objectifs identifiés sont alors les suivants : (1) proposer une nouvelle méthode de détection des MCSs à partir d'un réseau de neurones convolutifs, (2) examiner le cycle de vie des MCSs en France pour aiguiller des stratégies de prévision, (3) évaluer l'apport du modèle AROME-PI pour l'anticipation des MCSs à 6 h d'échéance.

1.1 Les systèmes convectifs de mésoéchelle (MCSs)

Un système convectif de mésoéchelle (MCS) résulte de l'agrégation de nuages convectifs de type *cumulonimbus*, formant une seule entité et dont les précipitations couvrent une zone continue d'au moins 100 km dans une direction horizontale (Houze, 2018). Le nom de MCS tient à la nature et à la dimension du phénomène.

- La **convection** désigne un transport de matière résultant d'un déséquilibre hydrostatique de l'atmosphère, ou *instabilité de flottabilité* : une masse d'air relativement dense surmonte une autre masse d'air moins dense. Dans le cas de la convection humide et profonde, ou convection orageuse, ce transport implique la formation de nuages et s'effectue sur toute l'épaisseur de la troposphère, parfois jusqu'à 12 km aux moyennes latitudes.
- En météorologie, les phénomènes de **mésoéchelle**, ou « moyenne échelle » (Figure 1.1), occupent une dimension spatio-temporelle de plusieurs dizaines à plusieurs centaines de kilomètres et de plusieurs heures. Le MCS est donc d'une échelle supérieure à la simple cellule orageuse (échelle *aérologique* ≈ 10 km, ≈ 1 h) mais d'une échelle inférieure au cyclone tropical ou à la perturbation des moyennes latitudes (échelle *synoptique* ≈ 1000 km, plusieurs jours).

Les fondamentaux de la convection orageuse sont introduits dans la partie 1.1.1. Ils sont nécessaires pour comprendre l'initiation des cellules convectives (partie 1.1.2) et la façon dont celles-ci s'organisent en MCS (partie 1.1.3). La section 1.1.4 dresse le portrait du MCS en phase de maturité tandis que la section 1.1.5 décrit la diversité des systèmes rencontrés aux moyennes latitudes. Enfin, la section 1.1.6 s'intéresse aux MCSs en France et démontre la pertinence de leur étude et de leur appréhension pour la sécurité des personnes et des biens.

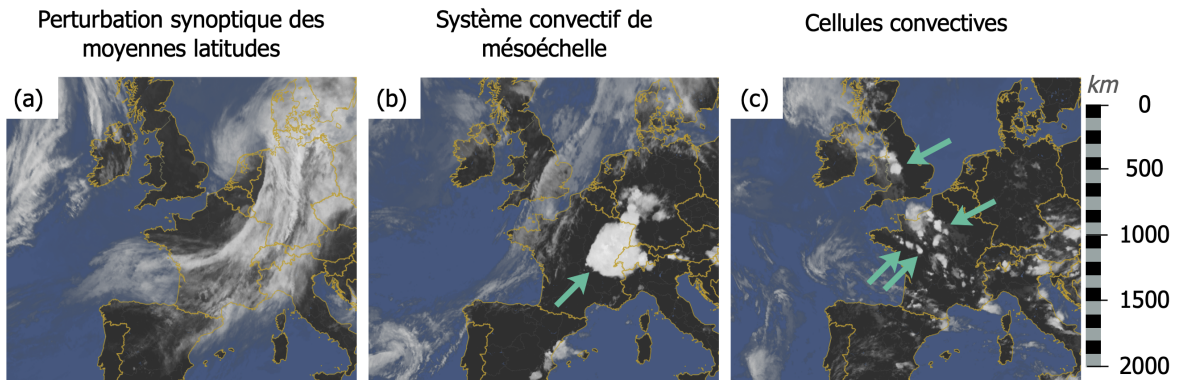


FIGURE 1.1 – Phénomènes météorologiques (a) d’échelle synoptique, (b) de mésoéchelle et (c) d’échelle aérologique. Images satellite infrarouge extraites des archives [Infoclimat](#).

1.1.1 L’instabilité de flottabilité

Plusieurs notions de météorologie en rapport avec l’instabilité d’une masse d’air sont introduites ici. Pour plus de détails, le lecteur pourra se référer à [Malardel \(2009\)](#) et [Markowski et Richardson \(2010\)](#).

L’équilibre hydrostatique

L’atmosphère est un fluide constitué majoritairement de gaz : c’est l’air. On considère souvent l’atmosphère comme un ensemble de « particules de fluide ». La particule n’a pas d’existence physique. Il s’agit seulement d’une vision de l’esprit visant à faciliter l’étude de l’atmosphère dans un cadre théorique. L’état d’une particule est caractérisé par trois grandeurs : sa densité, sa pression et sa température.

Dans une atmosphère au repos, une particule est soumise à deux forces orientées verticalement : le poids, lié principalement à la force d’attraction terrestre, et la force de pression. Selon la troisième loi de Newton, l’accélération verticale subie par la particule $\frac{Dw}{Dt}$ multipliée par sa densité ρ est égale à la somme des forces qui s’y exercent. Son formalisme mathématique est donné par l’équation (1.1).

$$\rho \frac{Dw}{Dt} = -\rho g - \frac{\partial p}{\partial z} \quad (1.1)$$

avec g la gravité terrestre et $\frac{\partial p}{\partial z}$ le gradient vertical de pression. Quand poids et forces de pression s’égalisent, la particule ne subit aucune accélération sur la verticale. Elle est dans un équilibre qu’on dit *hydrostatique*.

L'instabilité de flottabilité

L'équilibre hydrostatique peut être rompu si la pression p et surtout la densité ρ de la particule évolue par rapport à la pression \bar{p} et la densité $\bar{\rho}$ d'un environnement en équilibre hydrostatique, où $0 = -\bar{\rho}g - \frac{\partial \bar{p}}{\partial z}$. Si cette évolution se traduit par une perturbation de pression p' et de densité ρ' telles que $p = \bar{p} + p'$ et $\rho = \bar{\rho} + \rho'$, l'équation (1.1) pour la particule devient, après réajustement :

$$\frac{Dw}{Dt} = -\frac{\rho'}{\rho}g - \frac{1}{\rho} \frac{\partial p'}{\partial z} \quad (1.2)$$

Le terme $-\frac{\rho'}{\rho}g$ est appelé *flottabilité*, notée B . Elle traduit le fait qu'une particule moins dense ou plus « légère » que son environnement ($\rho' < 0$) acquiert une accélération verticale positive, capable d'initier un mouvement ascendant.

L'équation d'état $p = \rho RT$ lie la pression p , la température T et la densité ρ d'une particule, avec R une constante dépendant des constituants de l'air. Elle permet d'écrire la flottabilité comme une fonction de T et de sa perturbation T' par rapport à l'environnement hydrostatique : $B \approx g \frac{T'}{T}$, en négligeant le terme lié à la perturbation de pression. Une particule plus chaude que son environnement a donc une flottabilité positive qui lui permet de s'élever. Cependant, la pression chute avec l'altitude et les échanges d'énergie que la particule connaît alors avec son environnement modifient sa température. Pour comparer son état thermodynamique à celui de son environnement durant son ascension, il est plus commode d'utiliser sa *température potentielle* θ . Déduite de l'équation d'état et de la première loi de la thermodynamique, θ correspond à la température qu'aurait n'importe quelle particule amenée adiabatiquement (sans échange de chaleur) au niveau de pression standard p_0 de 1000 hPa. C'est une variable conservative : la θ d'une particule se conserve lors d'une ascendance adiabatique. Elle s'écrit :

$$\theta = T \left(\frac{p_0}{p} \right)^{\frac{R}{c_p}} \quad (1.3)$$

où c_p désigne la capacité calorifique de l'air à pression constante. Puisque θ est une fonction de T , la flottabilité de la particule peut aussi être approchée par $g \frac{\theta'}{\theta}$. Une particule s'élève si elle a une θ plus importante que celle de son environnement. On dit alors qu'elle est dans un état d'*instabilité absolue*. Or cet état est rare dans l'atmosphère où la θ tend plutôt à augmenter avec l'altitude. Il peut survenir au voisinage d'un sol surchauffé par le rayonnement solaire en journée. La particule se soulève mais se refroidit avec l'altitude plus vite que son environnement. Elle s'immobilise donc rapidement. Ces ascendances éphémères relèvent de la convection « peu profonde ». Si elles maintiennent en vol vautours et parapentistes, elles ne suffisent généralement pas à initier la convection orageuse. Pour cela, un autre ingrédient est nécessaire : l'eau.

De la nécessité de l'eau

Même en-dessous du point d'ébullition, de l'eau est présente dans l'atmosphère à l'état de gaz. C'est la *vapeur d'eau*. La plupart a simplement été expulsée des surfaces d'eau liquide en contact avec l'air à cause de l'agitation moléculaire. Or l'eau atmosphérique ne reste pas indéfiniment à l'état gazeux. Pour une certaine quantité de vapeur présente dans l'air, il existe une température en-deçà de laquelle l'eau se condense. L'air est alors *saturé*. La température et la quantité de vapeur à saturation sont liées par des relations semi-empiriques (p. ex. [Bolton 1980](#)), construites en intégrant l'équation de Clausius-Clapeyron.

L'importance de la vapeur d'eau pour la convection orageuse est double. D'abord, l'eau est plus légère que les autres constituants de l'air. Par conséquent, une particule est d'autant moins dense qu'elle contient une forte quantité de vapeur d'eau. Mais surtout, l'eau libère de la chaleur en se condensant. Cette chaleur dite *latente* limite le refroidissement d'une particule saturée au cours de son ascendance. Sa θ augmente, si bien qu'une nouvelle variable conservative est nécessaire pour suivre son trajet thermodynamique. En France, on utilise la θ^*w , *température potentielle pseudo-adiabatique du thermomètre mouillé*. Elle indique la température qu'une particule aurait si on la soulevait adiabatiquement jusqu'à son niveau de saturation avant de la descendre jusqu'au niveau p_0 de 1000 hPa de manière « pseudo-adiabatique », en la maintenant saturée et en évacuant l'eau condensée. La θ^*w est d'autant plus forte que la température et le contenu en vapeur d'eau de la particule sont importants. L'effet de la condensation sur la convection orageuse est détaillé ci-après.

La CAPE

Le trajet thermodynamique d'une particule impliquée dans la convection orageuse est schématisé par la ligne pointillée rouge sur le diagramme de la Figure 1.2, appelé *émagramme*. La courbe noire représente le *profil* de l'atmosphère libre (caractérisant l'air clair), c'est-à-dire son état thermodynamique à différentes altitudes. La température est indiquée par les lignes obliques bistres. Ce profil est typique d'une situation orageuse. Au sol, vers 1000 hPa, une particule est ici à 20°C (cercle rouge). Lorsque la particule s'élève, elle suit une iso- θ représentée par la ligne verte en trait plein. Sa température devient inférieure à celle de son environnement. Une force extérieure est donc nécessaire pour vaincre la flottabilité négative qui s'exerce (voir partie 1.1.2). Si cette force existe (flèche pointillée noire), la particule suit son iso- θ jusqu'à son *niveau de condensation* (NC), là où la vapeur d'eau qu'elle contient commence à condenser. Ce niveau dépend de sa θ'_w (voir croix verte). La condensation libère de la chaleur au sein de la particule. Sa θ augmente et son trajet vertical suit désormais la courbe plus « pentue » de son iso- θ'_w (ligne pointillée verte). Une fois atteint son *niveau de convection libre* (NCL), au croisement de la courbe noire, la particule devient plus chaude que son environnement. Sa flottabilité positive la force à s'élever... du moins tant qu'elle contient de la vapeur d'eau à condenser et que son environnement reste plus froid. Si elle atteint le sommet de la troposphère, on parle de convection orageuse.

La condensation de la vapeur en gouttelettes d'eau liquide rend l'ascendance visible sous la forme d'un nuage : le cumulonimbus. Lorsque la particule revient à la même température que son environnement, elle atteint son *niveau de flottabilité neutre* (NFN ou P_{top}). L'énergie cinétique emmagasinée lui permet encore de s'élever de quelques kilomètres, jusqu'au niveau $P_{top\ bis}$, mais la convection est rapidement stoppée. Le NFN se situe souvent à la limite de la troposphère et de la stratosphère (la tropopause), là où l'absorption des ultraviolets par l'ozone stratosphérique réchauffe l'atmosphère et stabilise son profil. Bloqué, le courant ascendant s'étale horizontalement et donne au cumulonimbus sa forme d'enclume caractéristique.

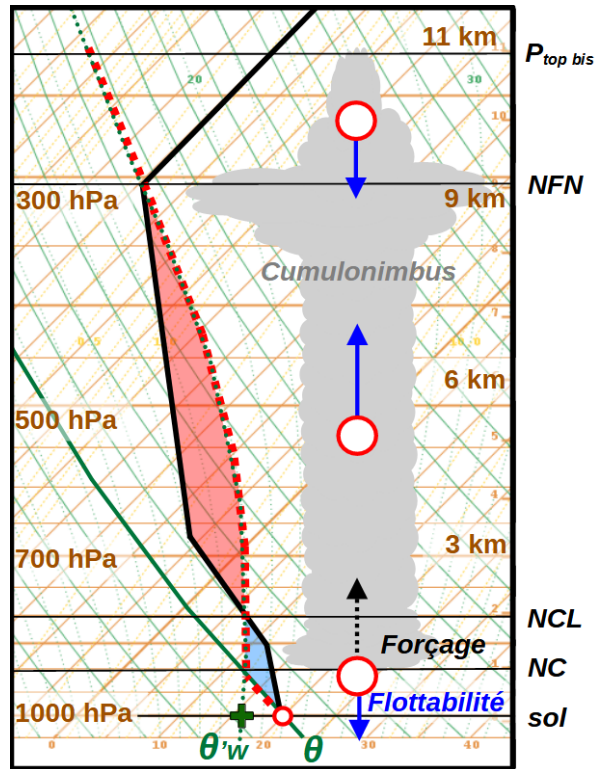


FIGURE 1.2 – Trajectoire d'une particule sur un émagramme (ligne pointillée rouge), depuis le sol jusqu'au sommet de la troposphère. Sur l'axe des ordonnées, l'altitude est donnée en km (à droite) ou en hPa (à gauche). La courbe d'état figure en noir. La surface rouge (bleue) est proportionnelle à la CAPE (CIN). Le nuage est schématisé en gris à droite de la figure, ainsi que la particule et son bilan des forces sur la verticale à trois instants de son ascendance.

Comme souvent dans l’atmosphère, la particule initiale n’est pas absolument instable. Elle le devient à condition qu’une force extérieure la soulève jusqu’à son NCL. La particule est donc *conditionnellement instable*. L’instabilité conditionnelle est d’autant plus forte que la particule est humide, avec beaucoup d’eau à condenser, et chaude relativement à son environnement d’altitude.

De nombreux indices ont été développés pour quantifier l’instabilité conditionnelle, la plupart basés sur des formules empiriques impliquant des écarts de températures et d’humidités mesurées en basses couches et en altitude (Sénési et Thepenier, 1997). Ils sont de plus en plus supplantés par la variable CAPE (*Convective Available Potential Energy* ou *Énergie Potentielle Convective Utilisable*) introduite par Moncrieff et Green (1972). Celle-ci intègre les forces de flottabilité positive exercées sur la particule entre son NCL et son NFN :

$$CAPE = \int_{z=NCL}^{z=NFN} B dz \quad (1.4)$$

Par construction de l’émagramme, elle est proportionnelle à l’aire rouge de la Figure 1.2. Plus la CAPE est forte, plus la particule ayant franchie son NCL dispose d’une énergie importante pour accélérer vers le haut. Cependant, l’accélération calculée par la CAPE néglige trois facteurs : (1) l’entraînement d’air ambiant au sein de la particule, réduisant sa flottabilité, (2) la surpression dynamique freinant la particule durant son ascension, (3) le second terme du membre de droite dans l’équation 1.2, lié à la perturbation dynamique de pression.

Par ailleurs, l’intégrale des forces de flottabilité négatives qui s’exercent sur la particule en-dessous de son NCL inhibent son ascension. Il s’agit de la CIN (pour *Convection INhibition*) dont l’aire bleue de la Figure 1.2 est proportionnelle. Plus la CIN est importante, moins le déclenchement de la convection est probable.

Le développement des MCSs est associé à de fortes valeurs de CAPE, comme l’ont montré des études menées aux États-Unis (Trapp, 2013), en Chine (Cui *et al.*, 2023), en Europe du Nord (Punkka et Bister, 2015) ou en Méditerranée (Ricard *et al.*, 2012).

1.1.2 Préconditionnement et forçages

Seules certaines conditions météorologiques présentent un profil thermodynamique tel qu’illustré sur la Figure 1.2, avec une CAPE importante et une CIN réduite. Aux moyennes latitudes, quatre situations *préconditionnent* généralement l’atmosphère à la convection orageuse :

- En journée, le rayonnement solaire réchauffe la surface qui restitue sa chaleur aux particules d’air sus-jacentes. La convection peu profonde qui s’ensuit permet d’homogénéiser la chaleur dans les basses couches et réduit la CIN progressivement.
- Les ascendances impliquées dans les circulations agéostrophiques sont de l’ordre de quelques centimètres par seconde. Elles ne sont pas produites par l’instabilité de flottabilité mais par des effets dynamiques, en lien avec les accélérations horizontales de l’air et la rupture

des équilibres de grande échelle (équilibre du vent thermique). On les rencontre notamment à l'avant des thalwegs, creux de pression en altitude (Lackmann, 2015). Ces ascendances soulèvent une large tranche d'atmosphère, pas assez pour que les particules atteignent leur NCL mais suffisamment pour que, par refroidissement adiabatique, l'air s'humidifie et la CIN se réduise. Les MCSs se développent très régulièrement à l'avant d'un thalweg, tant aux États-Unis (Yang *et al.*, 2017; You et Deng, 2023) qu'en Chine (Cui *et al.*, 2023), en Scandinavie (Punkka et Bister, 2015) ou en Europe de l'ouest (Lewis et Gray, 2010; Nuissier *et al.*, 2008). La Figure 1.3 illustre cette configuration synoptique sur la France.

- Les couloirs de vent fort en altitude, appelés *jets*, développent aussi de faibles ascendances en entrée droite et sortie gauche. Celles-ci peuvent creuser des dépressions en surface qui pilotent alors le transport d'humidité en basses couches et favorise la convection (Uccellini et Johnson, 1979). You et Deng (2023) ont montré que les jets d'altitude avaient un rôle marginal dans le développement des MCSs aux États-Unis. Ils sont par contre souvent associés aux systèmes méditerranéens (Ricard *et al.*, 2012).
- Le transport (ou advection) différentiel d'un air chaud et humide en basse couche et d'un air froid en altitude augmente l'instabilité conditionnelle de l'atmosphère. Cette configuration est propice aux MCSs (Trapp, 2013; Lewis et Gray, 2010). Elle est fréquente au niveau des perturbations synoptiques des moyennes latitudes. Sur la Figure 1.3, une dépression de surface se creuse à l'avant d'un thalweg et pilote un flux subtropical chaud et humide sur le pays, favorisant la formation de MCSs.

Une fois l'atmosphère préconditionnée, une force est encore nécessaire pour soulever les particules jusqu'à leur NCL. Elle doit être suffisamment importante pour s'opposer à la CIN. On parle de *forçage* ou de *mécanisme de soulèvement*.

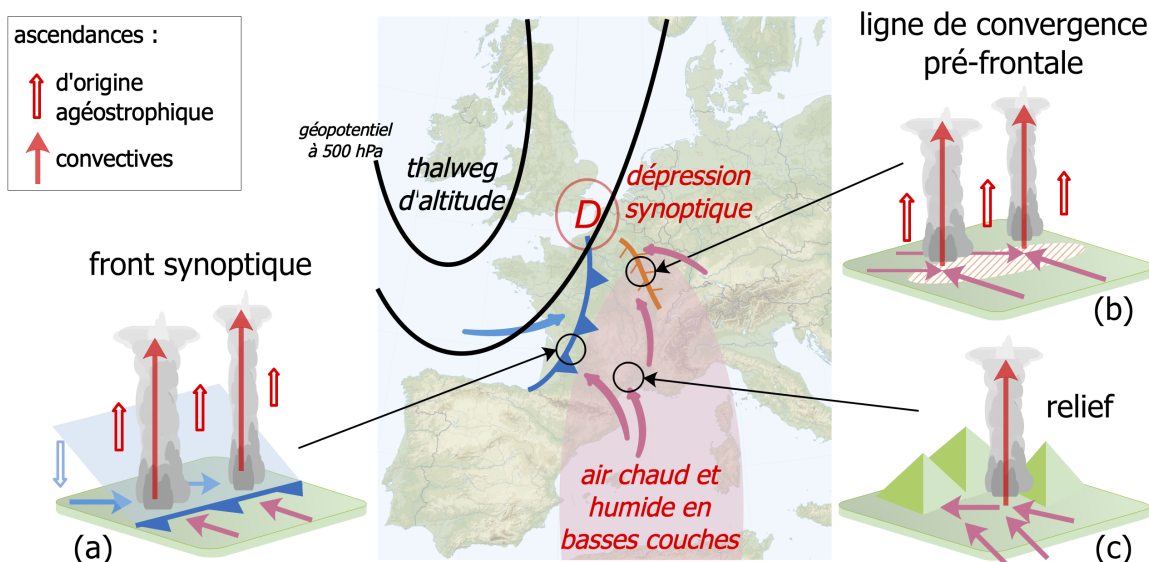


FIGURE 1.3 – Représentation très schématisée d'une situation synoptique propice à la formation des orages en France, avec trois origines possibles de forçage.

On peut distinguer trois types de forçages :

- Le *soulèvement orographique direct* du flux de basses couches au niveau des reliefs est notamment impliqué dans les épisodes de fortes pluies en Méditerranée (Goulet, 2015; Miglietta et Davolio, 2022).
- Les *ondes de gravité atmosphériques* correspondent aux oscillations verticales d'une masse d'air stable. Celles ci peuvent être générées lorsque le flux est perturbé par un relief (Kirshbaum *et al.*, 2018) ou un nuage convectif déjà formé, notamment pour les MCSs, encourageant de nouveaux développements convectifs à l'avant du système (Houze, 2004).
- Les *zones de convergence des vents* en basses couches provoquent des ascendances par conservation de la masse.

Ces *zones de convergence des vents* ont elles-mêmes des origines multiples :

- Quand le vent varie avec l'altitude, la convection peu profonde peut s'organiser sous forme de *rouleaux horizontaux* avec des branches convergentes et divergentes (Trapp, 2013).
- Le chauffage différentiel de deux surfaces adjacentes induit des *convergences de brise*. C'est le cas sur le littoral, entre la mer et la terre (Trapp, 2013), ou en montagne, entre les versants exposés et l'atmosphère alentour (Kirshbaum *et al.*, 2018).
- Le *relief* fait converger le flux incident par effet de barrière (comme sur la Figure 1.3c), de contournement ou de canalisation (Kirshbaum *et al.*, 2018; Khodayar *et al.*, 2021). Les îles peuvent avoir le même impact (Khodayar *et al.*, 2021; Miglietta et Davolio, 2022).
- Le flux converge au niveau des *dépressions de surface* creusées par les ascendances de grande échelle, notamment pour les MCSs méditerranéens (Lee *et al.*, 2017; Khodayar *et al.*, 2021; Miglietta et Davolio, 2022). Les lignes de convergence pré-frontales, à l'avant des fronts froids, sont aussi fréquemment impliquées dans la formation des MCSs linéaires (Figure 1.3b). Elles peuvent être liées à des anomalies d'altitude, associées à de petits thalwegs secondaires (Calas, 2013), ou bien aux ascendances des circulations agéostrophiques causées par l'advection d'air chaud depuis les plateaux ibériques et nord-africains (Dahl et Fischer, 2016).
- Les *fronts synoptiques* se caractérisent par un autre type d'instabilité atmosphérique, dite *barocline*, qui développe aussi des mouvements verticaux (Malardel, 2009). Certes faibles par rapport aux ascendances convectives, ils peuvent déclencher la convection orageuse (Trapp, 2013). D'après You et Deng (2023), 45 % des MCSs printaniers sont initiés par un forçage frontal aux États-Unis. L'importance des fronts se vérifie aussi en Grande Bretagne et sur le Golfe de Gascogne (Lewis et Gray, 2010) ainsi qu'en Méditerranée (Nuissier *et al.*, 2008; Lee *et al.*, 2016). En France, Morel (2001) souligne que les MCSs frontaux se développent dans un environnement de CAPE modeste et de forte CIN, d'où la nécessité du forçage pour initier la convection (Figure 1.3a). L'activité frontale semble aussi prolonger la durée de vie des MCSs déjà formés (Coniglio *et al.*, 2010; Lombardo et Colle, 2012).
- Primordiale pour le développement et le maintien des MCSs, l'interaction entre le *courant de densité* des orages déjà formés et l'air environnant fait l'objet de la prochaine section.

1.1.3 De la cellule au MCS : organisation de la convection à mésoéchelle

Lorsque, dans un environnement conditionnellement instable, un forçage soulève des particules jusqu'à leur NCL, une cellule convective se développe. Elle se caractérise par deux *courants* verticaux opposés (Malardel, 2009), illustrés sur la Figure 1.4a :

- Le *courant ascendant* correspond aux particules d'air chaud et humide, forcées de s'élever par la flottabilité positive.
- Quand la vapeur d'eau du courant ascendant se condense, des gouttelettes se forment, grossissent par collision-coalescence et précipitent. En tombant, certaines gouttes s'évaporent du fait de l'intrusion d'air sec environnant dans le nuage. À l'inverse de la condensation, l'évaporation capte de la chaleur latente. L'air se refroidit alors, devient plus dense que son environnement et, soumis à une flottabilité négative, accélère vers le bas. Il forme le *courant subsident*. Ce dernier s'étale en surface et produit ce qu'on nomme un *courant de densité* ou une *plage froide*.

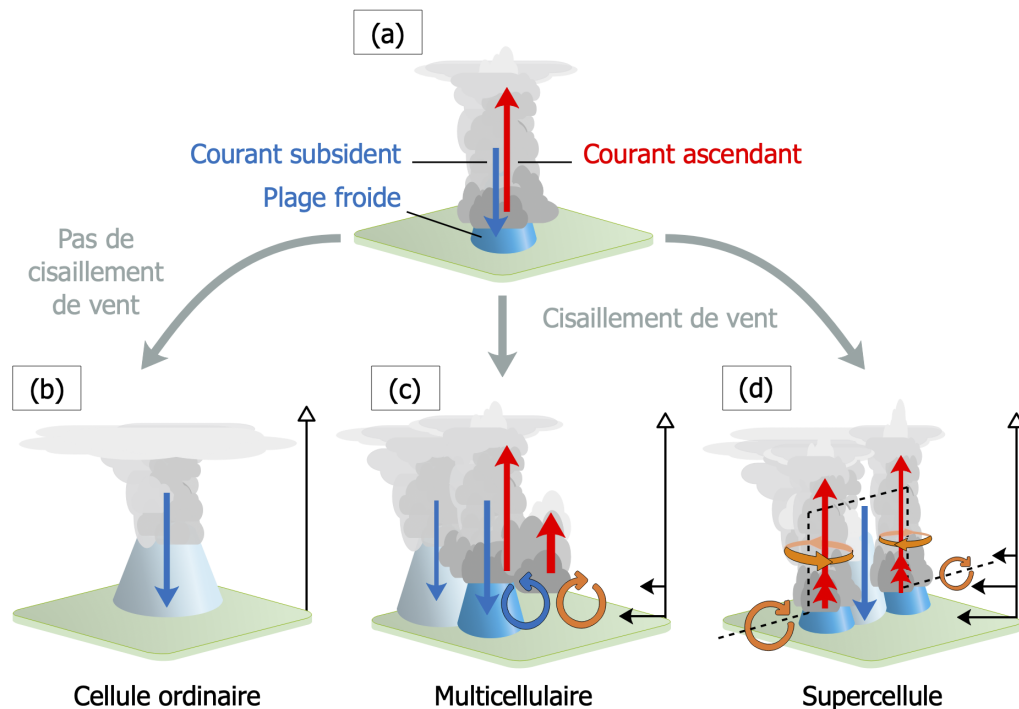


FIGURE 1.4 – Trois évolutions possibles d'une cellule convective. Le profil de vent sur les sous-figures (c) et (d) correspond au flux relatif au mouvement de la cellule.

Un MCS naît de la fusion de plusieurs cellules convectives et de leurs plages froides respectives. Fritsch *et al.* (2001) ont identifié deux modes de formation :

- Les *MCSs de Type 1* (Figure 1.5a) résultent de l'agrégation rapide de nombreuses cellules qui se développent simultanément sur une vaste zone de forçage. Le forçage est souvent linéaire, typiquement le long de fronts synoptiques (Doswell, 2001). Ces MCSs sont fréquents dans l'environnement barocline des moyennes latitudes.

- Les *MCSs de Type 2* (Figure 1.5b) se forment plus lentement, par fusion progressive des plages froides. Ils évoluent dans un environnement moins dynamique et sont majoritaires aux latitudes tropicales et subtropicales.




FIGURE 1.5 – Organisation ou non de la convection à mésoéchelle. Schéma inspiré de [Markowski et Richardson \(2010\)](#).

Dans les environnements propices aux MCSs de Type 2, l'organisation de la convection dépend principalement du *cisaillement vertical de vent*, c'est-à-dire de la variation du vent horizontal avec l'altitude, en module et/ou en direction. Sans cisaillement, les courants ascendants et subsidents se superposent. L'étalement de la plage froide coupe alors l'air chaud et humide qui alimente la cellule, interrompant ses ascendances et entraînant sa dissipation (Figure 1.4b). Ces *cellules ordinaires* ont une durée de vie courte. Il faut donc un environnement très instable, avec une faible CIN, pour que la convergence au niveau des plages froides puisse initier de nouvelles cellules et, peut-être, former un MCS. À l'inverse, un cisaillement (trop) important n'est à priori pas favorable à la convection orageuse car il brasse l'air et dilue les ascendances convectives ([Markowski et Richardson, 2010](#)). Cependant, si la cellule parvient à se développer, le cisaillement lui donne une inclinaison qui sépare le courant subsident du courant ascendant. De plus, le cisaillement génère du tourbillon horizontal (flèches orange sur la Figure 1.4) qui interagit avec la plage froide. Selon le rapport entre la CAPE et le cisaillement, deux évolutions sont alors possibles ([Weisman et Klemp, 1982](#)) :

- **Orage multicellulaire.** L'équilibre entre le tourbillon de l'environnement et le tourbillon généré par le gradient de densité au niveau de la plage froide favorise de nouvelles ascendances. La cellule initiale se dissipe mais est remplacée par une nouvelle cellule en aval du cisaillement, et ainsi de suite (Figure 1.4c).
- **Orage supercellulaire.** Le courant ascendant fait basculer le tourbillon de l'environnement qui adopte une composante verticale. Un *mésocyclone* apparaît et une dépression se forme en son centre, par équilibre cyclostrophique ([Malardel, 2009](#)). Celle-ci accentue

les ascendances et prolonge l'activité convective. Si l'axe du tourbillon horizontal est perpendiculaire à la direction de la cellule, un basculement par « roulis » s'opère de part et d'autre et produit deux mésocyclones (Figure 1.4d). La supercellule se divise alors en deux cellules filles (Markowski et Richardson, 2010). Le processus peut se répéter sur plusieurs générations.

Les MCSs de Type 2 se développent donc généralement à partir d'orages supercellulaires ou, le plus souvent, multicellulaires (Markowski et Richardson, 2010). Si les cellules se forment le long d'une ligne de forçage, la fusion des plages froides est favorisée lorsque le cisaillement de l'environnement est parallèle à la ligne (Figure 1.5b). Dans le cas contraire, les cellules peuvent rester isolées (Figure 1.5c).

Outre la fusion des plages froides, trois autres mécanismes interviennent dans l'agrégation spontanée de la convection à mésoéchelle (Muller et Abramian, 2023) : (1) le refroidissement radiatif dans une atmosphère sèche, en dehors de la zone nuageuse, est défavorable aux ascendances, (2) au contraire, le MCS humidifie son environnement et limite les effets de l'entraînement à proximité, (3) les ondes atmosphériques générées par le système provoquent des mouvements ascendants capables d'initier de nouvelles cellules.

Les MCSs modifient leur environnement de part leur taille et leur durée. Ils créent donc une circulation de mésoéchelle participant à leur maintien (Houze, 2018). Les processus impliqués sont décrits dans la prochaine partie.

1.1.4 Schéma conceptuel du MCS

Des campagnes de mesures menées depuis les années 1970 sur les MCSs tropicaux, notamment la campagne GATE à l'ouest de l'Afrique ou la campagne TOGA-COARE sur le Pacifique, ont les premières permis de caractériser les processus dynamiques et thermodynamiques à l'œuvre au sein d'un système mature (Houze, 2018). Même s'ils ont de nombreux points communs avec les MCSs tropicaux, les MCSs des moyennes latitudes ont reçu une attention particulière lors des campagnes conduites aux États-Unis (Brooks *et al.*, 2019), en particulier la campagne PRE-STORM d'où provient le modèle conceptuel du MCS linéaire. Dès les années 1980-90, les simulations numériques ont aussi affiné la compréhension du phénomène.

La figure 1.6 propose une revue schématique des circulations de mésoéchelle susceptibles de concerner un MCS mature, particulièrement un MCS de Type 2. Il s'agit là d'une vue idéalisée et rares sont les systèmes à présenter tous les éléments illustrés.

Régions convectives et stratiformes

En phase mature, le MCS se caractérise par deux régions distinctes (Houze, 1997). Dans la *région convective*, de jeunes cellules se développent au niveau de puissants courants ascen-

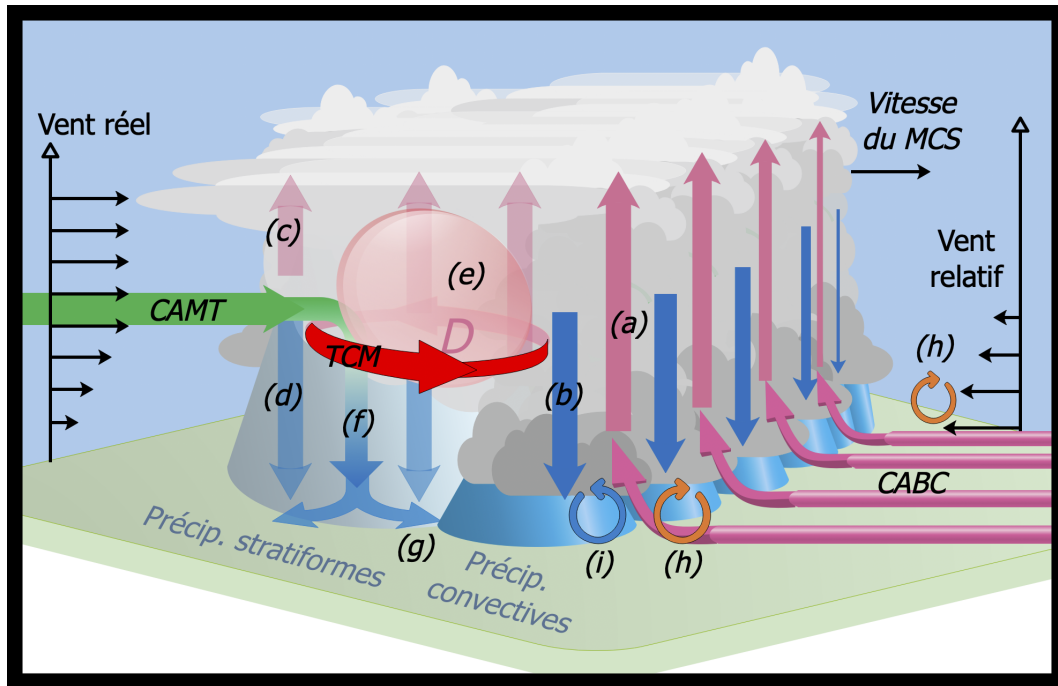


FIGURE 1.6 – Schéma conceptuel du MCS. Les éléments annotés sont décrits dans le texte.

dants (Figure 1.6a) et forment des précipitations, dites *convectives*, qui alimentent le courant subsident et la plage froide du système (Figure 1.6b). La *région stratiforme* est formée quant à elle de toutes les cellules les plus anciennes, en phase de dissipation. De faibles courants ascendants persistent en altitude, là où la flottabilité est encore positive (Figure 1.6c), et de nombreuses particules de glace continuent de se former, de grossir par diffusion de vapeur et de précipiter. En fondant ou en se sublimant, elles refroidissent la masse d'air qui acquiert alors une flottabilité négative. Elles forment donc un vaste courant subsident (Figure 1.6d). Au sol, les hydrométéores non évaporés donnent des précipitations faibles à modérées que l'on dit *stratiformes*. Si des MCSs sans précipitations stratiformes ont été documentés (Galus *et al.*, 2008; Zheng *et al.*, 2013), la coexistence de régions convectives et stratiformes est un point commun à la majorité des systèmes observés, tant sous les tropiques qu'aux moyennes latitudes (Houze, 2018).

Source de chaleur à mésoéchelle et circulations en moyenne troposphère

Dans les cellules agrégées des régions convectives et stratiformes du MCS, la condensation de vapeur d'eau au niveau des courants ascendants libère en continue une forte quantité de chaleur latente (Figure 1.6e). Cette source quasi permanente de chaleur à mésoéchelle provoque un déséquilibre dans la répartition des masses d'air au sein de l'atmosphère. L'air se dilate en moyenne troposphère, là où le chauffage est le plus important. Par conséquent, une large dépression apparaît sous la zone de chauffage. Une circulation horizontale de mésoéchelle se met alors en place pour la combler et participe au maintien du MCS :

- La convergence liée à la dépression favorise les ascendances (Maddox, 1980).
- Un courant d'afflux de moyenne troposphère (*descending rear inflow*, CAMT sur la Figure 1.6) est accéléré par la dépression. Sa direction est pilotée par celle du vent de l'environnement (Kingsmill et Houze Jr., 1999). Ce courant sec favorise l'évaporation des précipitations et intensifie les subsidences de la région stratiforme. Acquéran ainsi une composante verticale (Figure 1.6f), il peut atteindre les basses couches et même renforcer la plage froide des subsidences convectives (Figure 1.6g).
- La durée des MCSs est suffisamment longue pour que la rotation de la Terre, via la force de Coriolis, modifie le flux dirigé vers la dépression. Ce flux adopte alors une rotation cyclonique et forme un *tourbillon convectif de mésoéchelle* (*Mesoscale Convective Vortex*, TCM sur la Figure 1.6). Les TCM sont plus fréquents aux moyennes latitudes car la force de Coriolis y est plus marquée (Houze, 2004). Si le MCS évolue dans un environnement barocline, un TCM puissant peut renforcer les gradients thermiques et augmenter localement l'instabilité barocline de l'atmosphère. En réaction, une circulation agéostrophique se développe avec des ascendances qui favorisent le maintien du MCS (Raymond et Jiang, 1990). Il faut noter qu'un TCM peut se former autrement, pour les MCSs linéaires, quand le tourbillon horizontal associé au cisaillement de l'environnement est basculé au niveau des ascendances et produit une circulation cyclonique et anticyclonique de part et d'autre de la ligne (Markowski et Richardson, 2010; Schumacher et Rasmussen, 2020). On parle alors de *tourbillons de fin de ligne* (ou *bookend vortices*).

Circulations en basses couches

Le courant d'afflux de basses couches (CABC sur la Figure 1.6), chaud et humide, alimente les ascendances convectives. Lorsque le flux est fort, il prend la forme d'un *jet de basses couches* (*low-level jet*, Markowski et Richardson 2010). Le CABC n'est pas forcément cantonné à la couche limite de surface. Il peut se développer sur plusieurs kilomètres d'épaisseur et même être déconnecté de la surface dans le cas des MCSs d'atmosphère libre (Houze, 2018).

Enfin, l'interaction entre la plage froide des subsidences convectives et le courant d'afflux joue un rôle clé dans le maintien des MCSs de Type 2 (Trapp, 2013). La convergence créée constitue un forçage permanent qui permet aux particules d'atteindre leur NCL. Lorsque l'environnement est cisailé en basses couches, la théorie dite *RKW* de Rotunno *et al.* (1988), à l'origine établie pour les MCSs linéaires, insiste sur « l'équilibre » entre plage froide et courant d'afflux. Cet équilibre se traduit par l'existence de deux tourbillons horizontaux d'amplitude comparable mais de sens opposé, le premier produit par le cisaillement de l'environnement (Figure 1.6h), le second par la différence de densité entre la plage froide et son milieu (Figure 1.6i), la superposition des deux assurant alors le redressement des ascendances et le maintien du MCS. Cet équilibre explique aussi l'orientation de certains systèmes linéaires (Robe et Emanuel, 2001; Abramian *et al.*, 2022). Des climatologies menées aux États-Unis (Jirak et Cotton, 2007), en Chine (Cui *et al.*, 2023) et en Europe du Nord (Punkka et Bister, 2015) ont relevé l'importance du cisaillement de basses couches dans l'environnement des MCSs étudiés.

Maintien du système

En bref, la libération de chaleur latente par condensation au niveau des ascendances convectives et stratiformes produit des circulations de mésoéchelle qui à leur tour, par l'intermédiaire du CAMT, du TCM, du CABC ou de la plage froide, contribuent à renforcer les ascendances, la condensation et la production de chaleur. Ces boucles de rétroaction positive entretiennent le MCS et expliquent l'étonnante longévité de ce phénomène convectif. Les circulations de mésoéchelle assurent aussi un formidable brassage de la masse d'air en redistribuant l'énergie accumulée en basses couches sur toute la colonne d'atmosphère (Houze, 2018).

Le déclin du MCS s'amorce lorsque les ascendances convectives cessent. Plusieurs thèses ont été avancées pour en expliquer la raison. Selon la théorie RKW, le maintien des systèmes linéaires est assuré par l'équilibre entre plage froide et courant d'afflux. Cette théorie a néanmoins été débattue (Gale *et al.*, 2002; Stensrud *et al.*, 2005). Selon Coniglio *et al.* (2007), elle explique davantage l'initiation des MCSs linéaires que la continuité des systèmes déjà matures pour lesquels le cisaillement en altitude semble jouer un rôle plus important. Grâce à lui, les ascendances restent droites, inclinées au-dessus de la plage froide, et sont donc renforcées (Coniglio *et al.*, 2006). Par ailleurs, Gale *et al.* (2002) et Coniglio *et al.* (2010) ont trouvé que la dissipation des MCSs aux États-Unis était associée à l'affaiblissement du CABC. Lombardo et Colle (2012) ont dressé le même constat pour des systèmes linéaires sur la côte est américaine, ainsi que Ricard *et al.* (2012) pour les événements de fortes pluies en Méditerranée. De manière générale, la longévité du MCS dépend d'un ingrédient sans lequel il ne pourrait pas même exister : le maintien d'un environnement instable (Houze, 2004).

Les résultats précédents valent surtout pour les MCSs de Type 2. Les systèmes de Type 1 ont reçu moins d'attention mais semblent principalement pilotés par l'évolution du forçage externe dont ils dépendent (Schumacher et Rasmussen, 2020).

1.1.5 Bestiaire des MCSs

Outre la distinction entre systèmes de Type 1 et de Type 2, d'autres taxinomies des MCSs existent. La Figure 1.7 en propose une revue, illustrée sur la Figure 1.8 par des situations observées en France. Bien que ces taxinomies aient été établies aux États-Unis, la littérature internationale s'en est emparée (p. ex. Zheng *et al.* 2013; Surowiecki et Taszarek 2020). Elles sont basées sur des observations satellite ou radar qui seront détaillées dans la section 1.3. Les premières permettent de caractériser la couverture nuageuse du système, les secondes l'organisation de ses précipitations. Catégoriser les MCSs est utile pour un prévisionniste car certaines formes sont associées à des épiphénomènes dangereux tels que le vent violent ou les fortes pluies.

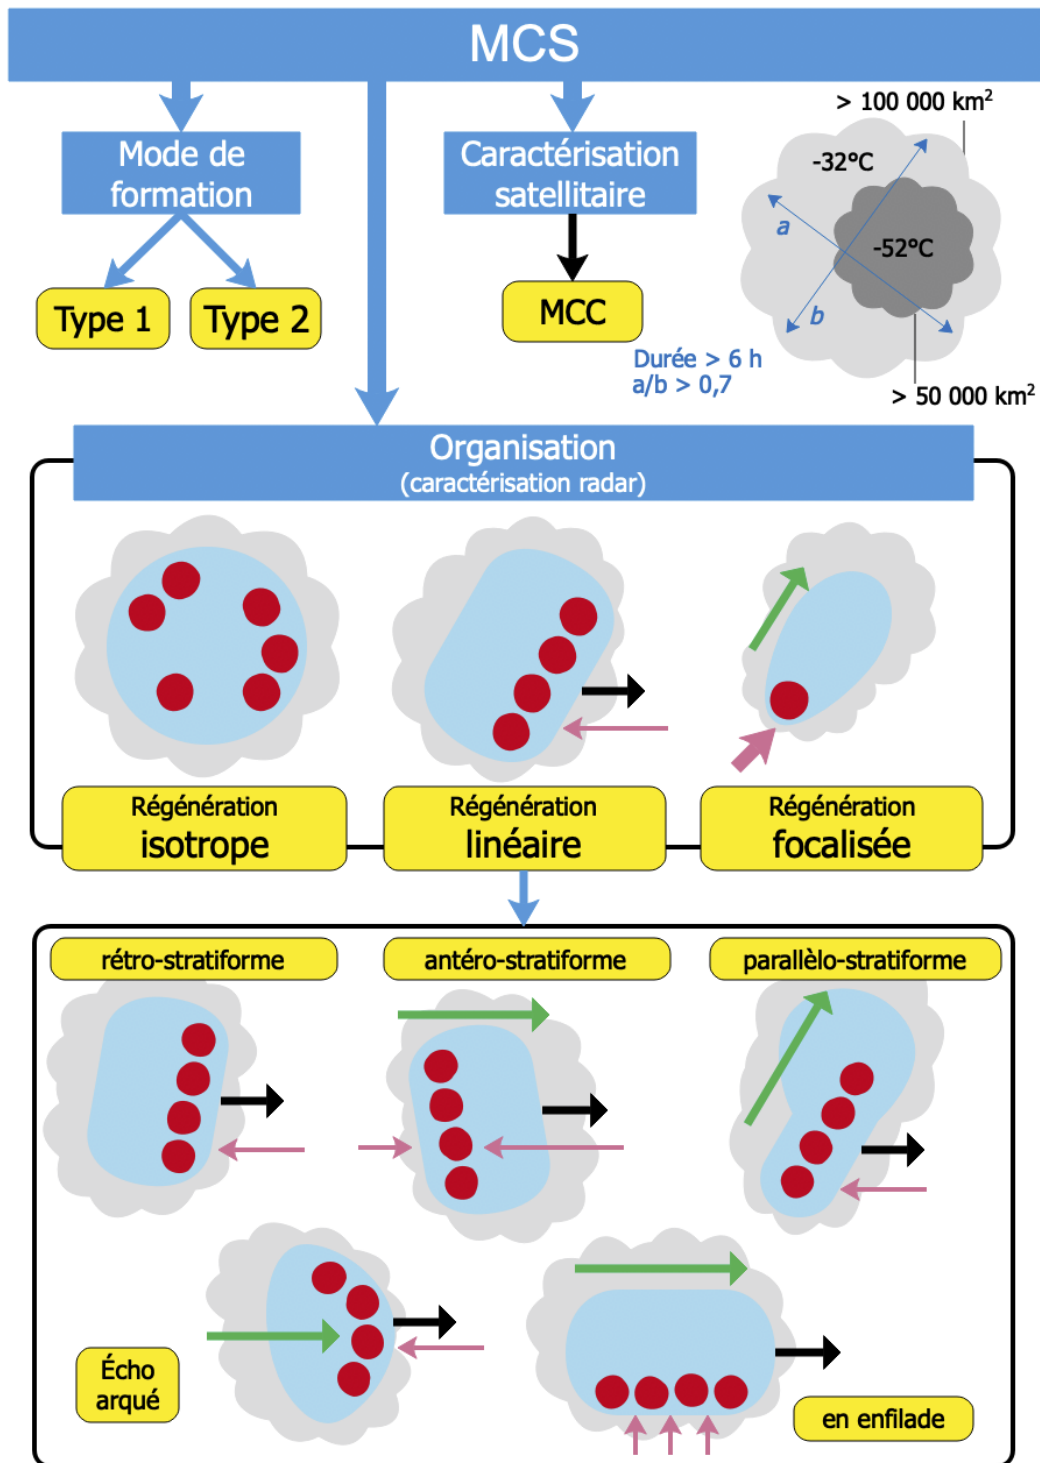


FIGURE 1.7 – Bestiaire des MCSs. Les contours gris, bleus et rouges symbolisent respectivement l'étendue de la couverture nuageuse, des précipitations stratiformes et des précipitations convectives. Pour certaines organisations, les flèches roses et vertes donnent une idée approximative du CABC et du flux d'altitude, tous deux relatifs au déplacement du système (flèches noires).

Le complexe convectif de mésoéchelle (MCC)

La première caractérisation des MCSs à partir d'images observées revient à Maddox (1980). Il définit le *complexe convectif de mésoéchelle* (ou MCC pour *Mesoscale Convective Complex*, Figure 1.8c) sur la base de critères subjectifs devant être remplis pendant au moins 6 h : les « critères de Maddox ». Le MCC est reconnaissable par une large enclume quasi circulaire (rapport d'aspect supérieur à 0,7), où la température de brillance infrarouge (TB) mesurée par satellite est inférieure à -32°C sur au moins $100\,000\text{ km}^2$. Un cœur froid (TB inférieure à -50°C) occupe également une surface minimale de $50\,000\text{ km}^2$. Ces systèmes sont plutôt de Type 2, se formant dans une atmosphère calme, bien à l'aval d'un talweg d'altitude. Leur vitesse est donc lente ce qui, combiné à leur taille, constitue une menace de fortes précipitations et d'inondations. Ils sont fréquents la nuit, quand le jet de basses couches qui les alimente n'est pas affaibli par la turbulence diurne (Markowski et Richardson, 2010). Un TCM s'y développe souvent. Des MCSs répondant précisément aux critères de Maddox restent rares en Europe (Doswell, 2001).

Les MCSs linéaires

On peut aussi distinguer les MCSs selon la disposition des précipitations convectives sur l'image radar.

Les systèmes se régénérant selon un axe à peu près linéaire ont été les plus étudiés. Il s'agit des *systèmes convectifs quasi linéaires* (SCQL ou QLCS pour *quasi-linear convective systems*, Figure 1.8a,b,d,e,f,h). Le terme vieilli de *ligne de grains* est encore employé même si, à l'origine, il renvoyait seulement à une augmentation brutale du vent en surface (Doswell, 2001). Les SCQL peuvent être de Type 1 ou 2 et répondre aux critères du MCC. Ils doivent leur disposition à un forçage linéaire comme un front synoptique (plutôt de Type 1) ou toute autre ligne de convergence (plutôt de Type 2).

Parker et Johnson (2000) ont proposé une sous-classification basée sur la localisation de la région stratiforme par rapport à la ligne convective. L'advection des hydrométéores par le flux d'altitude relatif au système détermine la position des précipitations stratiformes par rapport à la ligne convective (voir Figure 1.7). Le cas classique correspond aux SCQL « rétro-stratiformes » (ou TS pour *Trailing Stratiform*, Figure 1.8d) mais, quand le vent d'altitude est fort, la région stratiforme se développe en parallèle ou vers l'avant de la ligne convective selon la direction du flux. On parle alors de SCQL « parallèle-stratiforme » (ou PS pour *Parallel Stratiform*, Figure 1.8a,h) ou de SCQL « antéro-stratiforme » (ou LS pour *Leading Stratiform*) pour lequel Parker et Johnson (2004) proposent une nouvelle subdivision basée sur l'orientation du courant d'afflux de basses couches. Parker et Johnson (2000) soulignent qu'un même MCS peut connaître plusieurs organisations sur son cycle de vie. Enfin, Schumacher et Johnson (2005) caractérisent le SCQL « en enfilade » (ou TL/AS, *Training Line-Adjoining Stratiform*), fréquent au niveau des fronts quasi-stationnaires. La ligne convective, étirée dans la direction du déplacement, est propice aux forts cumuls de pluie.

Les SCQL évoluant dans un environnement dynamique développent fréquemment un puissant CAMT que l'on connaît aussi sous le nom de *jet d'afflux arrière* (ou RIJ, *Rear Inflow Jet*). Parfois renforcé par les tourbillons de fin de ligne, il peut atteindre la surface et provoquer de fortes rafales de vent. Ce phénomène se traduit souvent par un *écho arqué* sur l'image radar (Davis *et al.*, 2004) car le jet vient courber la ligne convective. L'écho arqué peut occuper une seule portion de la ligne (p. ex. Montmerle *et al.* 2000), plusieurs portions – on parle alors d'écho ondulant ou *LEWP* pour *Long Echo Wave Pattern* (Markowski et Richardson, 2010) – et même la ligne entière, comme c'est le cas sur le schéma de la Figure 1.7 et sur la Figure 1.8d,h.

Les MCSs à régénération focalisée

Pour les MCSs à régénération focalisée, l'alimentation en air chaud et humide se concentre dans une zone réduite. La région convective prend alors la forme d'une seule cellule imposante se régénérant en permanence, tandis que la région stratiforme s'étend en aval du flux d'altitude (Figure 1.8g). Sur l'image satellite, l'enclume s'étire *en panache* (Calas, 2013) où l'on reconnaît parfois la forme d'un « V » (McCann, 1983; Lee *et al.*, 2017), créée par la diffluence du flux au niveau des ascendances convectives. La régénération permanente de nouvelles cellules suit le schéma de l'orage multicellulaire, bien que ce dernier occupe une échelle plus petite. Ces MCSs sont typiquement à régénération rétrograde, autrement dit la vitesse de déplacement du système, pilotée par le flux d'altitude, est opposée à la vitesse de propagation selon laquelle les nouvelles cellules se régèrent. Les américains parlent de *Back-Building systems* (BB, Schumacher et Johnson 2005) que certains auteurs catégorisent d'ailleurs comme des SCQL (p. ex. Cui *et al.* 2021). Lorsque les vitesses de déplacement et de propagation se compensent, le MCS apparaît quasi-stationnaire et les cumuls de pluie peuvent être extrêmes.

Ces MCSs sont le propre des épisodes de fortes pluies en Méditerranée, largement documentés par la campagne HyMeX (Drobinski *et al.*, 2014; Ducrocq *et al.*, 2014). Ils se forment généralement à l'avant d'un thalweg et/ou d'un front froid peu mobiles, pilotant un jet de basses couches durable de sud-est à sud-ouest (Nuissier *et al.*, 2008; Ricard *et al.*, 2012) dont l'instabilité conditionnelle est garantie par l'apport en air doux et humide depuis la mer Méditerranée. Il peut être renforcé par une dépression de surface, creusée par les ascendances de grande échelle à l'avant du thalweg. Sa convergence au niveau des reliefs côtiers initie très souvent la convection (Khodayar *et al.*, 2021). Son organisation dépend alors de quatre facteurs : la force du jet de basses couches, le flux d'altitude, la plage froide et la géométrie du relief (Miglietta et Rotunno, 2014; Miglietta et Davolio, 2022). Si le flux est trop important à tous les niveaux, le forçage vient uniquement du relief et le phénomène méditerranéen prend la forme de précipitations orographiques intenses et durables, avec quelques orages noyés dans la masse. Un flux d'altitude moins marqué est davantage favorable aux MCSs car les ascendances restent droites et la convection se déplace assez lentement pour qu'une plage froide puisse se développer. Elle peut ainsi jouer le rôle de « montagne virtuelle » et forcer les nouvelles cellules à l'aval du relief, sur la plaine côtière (Ducrocq *et al.*, 2008; Khodayar *et al.*, 2021). La théorie RKW explique alors la stationnarité du système par un équilibre entre la plage froide et le jet de basses couches (Miglietta et Rotunno, 2014). L'apport d'hu-

midité à tous les niveaux est également crucial pour prévoir la localisation et l'intensité de la convection (Lee *et al.*, 2016, 2017; Khodayar *et al.*, 2021).

Les MCSs à régénération isotrope

Les MCSs à régénération isotrope entrent en quelque sorte dans la case « autre » de la caractérisation radar. Gallus *et al.* (2008) parlent de MCSs *non-linéaires*, Calas (2013) et Tazarek *et al.* (2020) décrivent des MCSs *circulaires* ou *en amas* (*cluster*). Ces systèmes sont généralement de Type 2. Ils peuvent être composés d'un ensemble de supercellules désorganisées dans une masse d'air très instable (Figure 1.8c). Les plus grands remplissent les critères satellitaires du MCC. À l'inverse, tous les MCCs n'ont pas une organisation en amas sur l'image radar, certains montrant plutôt des précipitations en lignes.

1.1.6 Enjeux associés aux MCSs

Régions touchées

D'après les climatologies satellitaires, les MCSs se rencontrent dans le monde entier, spécifiquement entre 60° Sud et 60° Nord (Feng *et al.*, 2021). Sur les continents des moyennes latitudes, les régions les plus concernées sont le centre des États-Unis, l'est de la Chine, le nord de l'Argentine et l'Europe centrale. D'après Morel et Senesi (2002b), les MCSs sont aussi fréquents en Europe de l'ouest et en France, notamment du sud-ouest au nord-est du pays (Figure 1.9). Les MCSs continentaux ont préférentiellement lieu durant l'été, en après-midi et en soirée, quand les basses couches sont les plus chaudes et les plus instables. Le même constat s'applique aux autres régions des moyennes latitudes. Dans les Grandes Plaines, les MCSs se maintiennent même jusqu'au petit matin grâce au renforcement nocturne du jet de basses couches (Markowski et Richardson, 2010; Schumacher et Rasmussen, 2020). En Méditerranée, les MCSs sont plus fréquents à l'automne et en hiver, en particulier sur les reliefs côtiers (Kolios et Feidas, 2009; Da Silva et Haerter, 2023).

Même si des régions et périodes sont climatologiquement plus concernées que d'autres, la Figure 1.8 montre que les MCSs peuvent avoir lieu partout en France, en toute saison. Ils couvrent un large éventail de tailles, d'organisations convectives et de situations synoptiques (Calas, 2013) : convection frontale (Figure 1.8f), pseudo-frontale (a) ou pré-frontale (c), marais barométrique ou faible cyclonisme en surface avec thalweg ou goutte froide en altitude (d,e,g,h), convection en air froid post-frontale (b).

Épiphénomènes violents

Les enjeux liés à la prévision des MCSs sont doubles : hydrologiques et sécuritaires. Dans certaines régions du monde, comme aux États-Unis, les MCSs représentent plus de 50 % des précipitations annuelles, jusqu'à 70 à 80 % aux latitudes tropicales (Feng *et al.*, 2021).

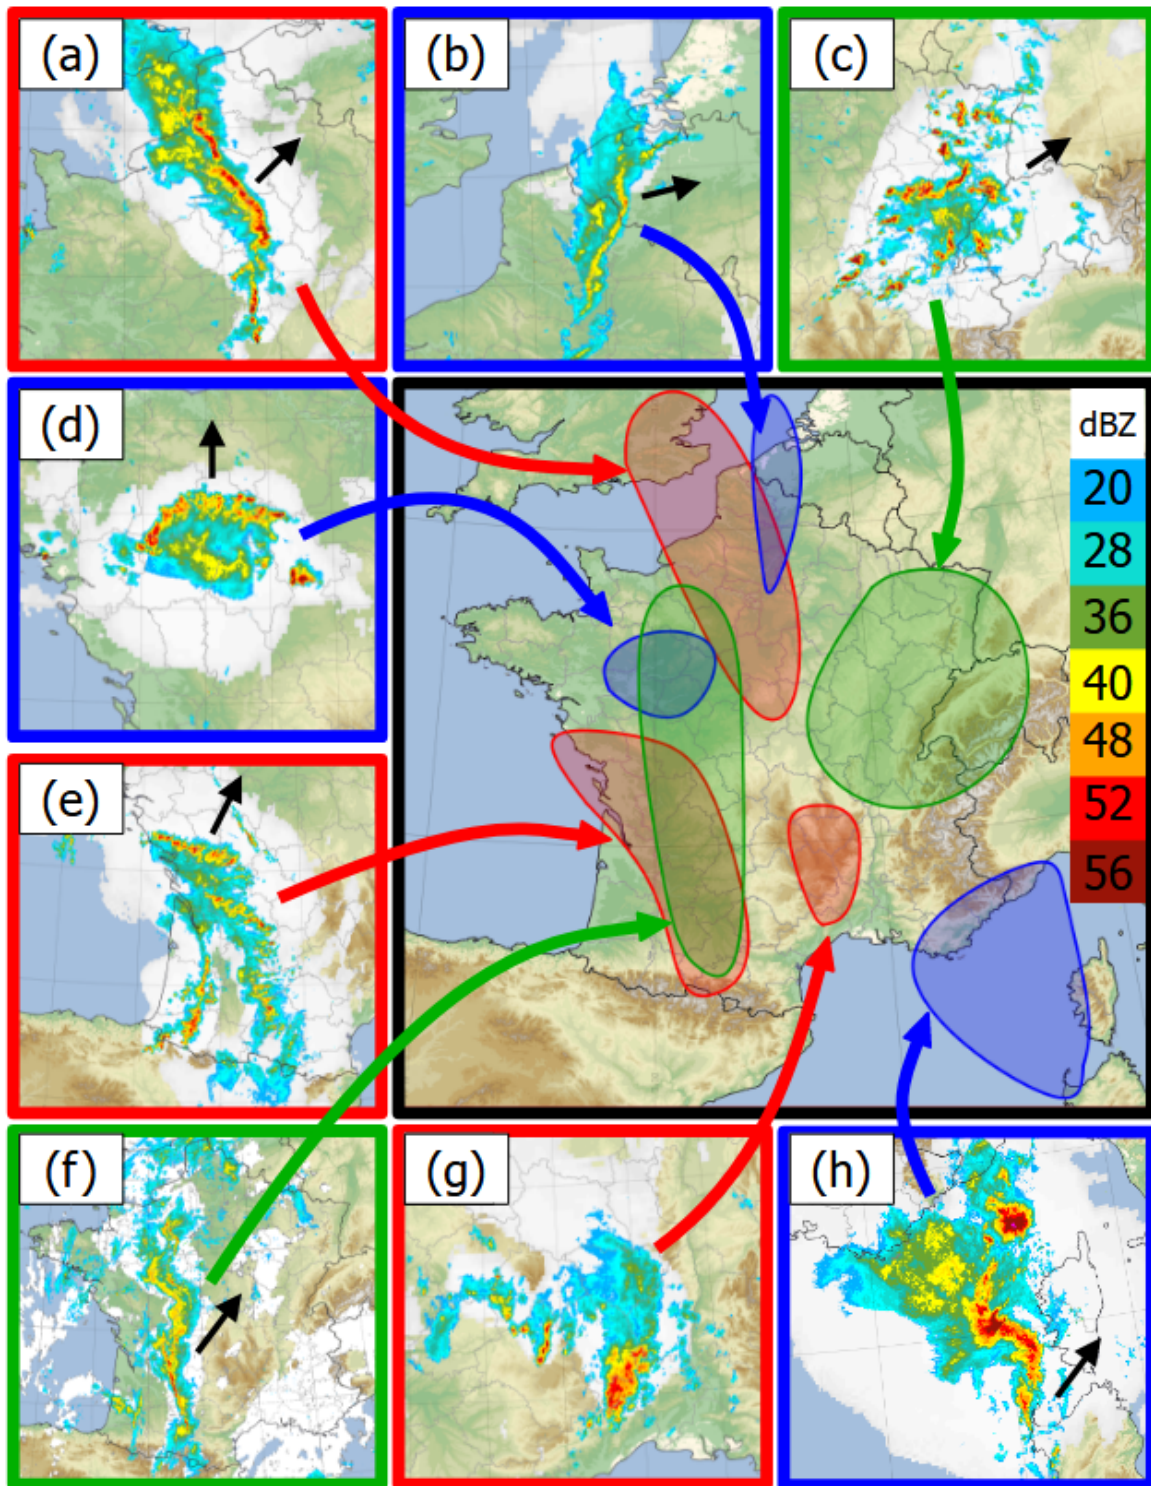


FIGURE 1.8 – Exemples de MCSs observés en France : (a) SCQL parallèle-stratiforme, le 18/06/2023; (b) SCQL rétro-stratiforme avec écho ondulant, le 03/01/2014; (c) MCC en amas, le 11/07/2023; (d) SCQL rétro-stratiforme avec écho arqué, le 26/05/2018; (e) deux SCQL, le 28/08/2018; (f) SCQL frontal de Type 1, le 27/04/2024; (g) MCS quasi-stationnaire à régénération focalisée, en « V », le 19/09/2020; (h) SCQL parallèle-stratiforme avec écho arqué, le 18/08/2022. L'échelle de couleurs indique les précipitations convectives (réflectivités radar $\gtrsim 40$ dBZ) et stratiformes ($\lesssim 40$ dBZ). La zone blanche estime le contour du nuage (TB inférieure à -30 °C sur l'image satellite). Les flèches noires donnent le sens de déplacement du système.




FIGURE 1.9 – Distribution spatiale des MCSs en Europe sur cinq saisons convectives (avril à septembre) de 1993 à 1997 (en nombre de MCSs observés par pixel). Les MCSs ont été détectés dans les images satellite de température de brillance du canal infrarouge. Figure extraite de [Morel et Senesi \(2002b\)](#).

En France, 20 à 40 % des précipitations estivales sont produites par des MCSs ([Da Silva et Haerter, 2023](#)). Cette proportion atteint 70 % dans le sud-est à l'automne. Cependant, les motivations de cette thèse tiennent davantage aux risques que les MCSs représentent pour la sécurité des personnes et des biens. En effet, ils s'accompagnent souvent des cinq épiphénomènes dangereux associés aux orages ([Schumacher et Rasmussen, 2020](#)) :

- **Pluie et inondations.** Les cumuls de pluie dépendent de l'intensité des précipitations, favorisée par des contenus élevés en vapeur d'eau dans l'atmosphère, mais surtout de leur durée ([Markowski et Richardson, 2010](#)). Certains MCSs produisent donc des cumuls importants à l'échelle d'un bassin versant, provoquant des inondations. Il s'agit notamment des systèmes peu mobiles, quasi-stationnaires ou « en enfilade ». La taille du phénomène augmente l'emprise de la zone de risque. Les MCSs quasi-stationnaires méditerranéens constituent la plus grande menace. À titre d'exemple, le système du 19/09/2020 (Figure 1.8g) a produit des pluies continues durant près de 10 h sur les Cévennes gardoises, donnant près de 700 mm par endroits ([Kreitz, 2021](#)). Depuis les années 1990, les épisodes méditerranéens ont fait plus de 100 victimes en France ([Goulet, 2015](#)).
- **Fortes rafales de vent** (non tornadiques). Les MCSs linéaires peuvent donner des rafales supérieures à 90 km/h en surface, notamment s'ils évoluent dans un environnement très instable, avec un cisaillement marqué sur toute la troposphère, parallèle à la ligne et susceptible de former un puissant jet d'afflux arrière ([Cohen et al., 2007](#)). Une masse

d'air sèche en moyenne troposphère favorise aussi l'évaporation des précipitations et la formation d'un courant de densité vigoureux (Markowski et Richardson, 2010; Kreitz, 2024). Les échos arqués sont fréquemment impliqués (Figure 1.8d,h). Johns et Hirt (1987) parlent de *derecho* pour désigner un phénomène associé à de violentes rafales sur une zone longue d'au moins 400 km. Fery et Faranda (2024) ont répertorié 38 derechos en France, de mai à septembre, entre 2000 et 2022. Parmi eux, on note les cas du 28/08/2018 et du 18/08/2022 (Figure 1.8f,h), le second ayant produit des rafales supérieures à 200 km/h sur la Corse (Kreitz, 2023). Plus rares, des derechos ont aussi lieu en hiver quand le contexte synoptiques est très dynamique (Figure 1.8b, Mathias *et al.* 2019).

- **Grêle.** Les plus gros grêlons (diamètre > 5 cm) sont plutôt associés aux supercellules qui précèdent la formation d'un MCS (Markowski et Richardson, 2010) ou évoluent dans les systèmes moins organisés, comme celui de la Figure 1.8c.
- **Tornado.** Une part non négligeable des tornades américaines se forment dans les MCSs linéaires (Schumacher et Rasmussen, 2020), notamment au niveau des tourbillons de fin de ligne où le cisaillement de basses couches est marqué (Markowski et Richardson, 2010). Elles sont néanmoins de faible intensité. Plusieurs tornades ont été observées lors du derecho du 03/01/2014 (Mathias *et al.*, 2019). Comme pour la grêle, les violentes tornades attribuées aux MCSs sont plutôt liées aux supercellules qui le composent ou le précèdent.
- **Foudre.** Les MCSs présentent une activité électrique importante mais les victimes de la foudre sont surtout liées aux orages isolés ou peu organisés qui peuvent être difficiles à appréhender par le grand public (Schumacher et Rasmussen, 2020). Sur 56 accidents de foudroiement ayant eu lieu en France ces dernières années, 13 % concernent des MCSs (Schmitt et Kreitz, 2022).

Les MCSs sont fréquents en France et peuvent causer d'importants dégâts humains et matériels. Déployer des mesures de protection avant l'arrivée du système permet de limiter les risques mais ces efforts nécessitent une anticipation suffisamment précise et précoce du MCS. La section suivante propose un état de l'art des méthodes de suivi et de prévision des phénomènes convectifs, en mettant l'accent sur les premières échéances.

1.2 Prévision immédiate de la convection

1.2.1 Panorama des méthodes opérationnelles

L'atmosphère est un système dynamique chaotique. Sa prévisibilité est donc limitée. Autrement dit, la connaissance précise de son état actuel ne permet pas, passée une certaine échéance, de prévoir son état futur avec la même précision. Du fait de l'instabilité de flottabilité et de la non-linéarité des processus physiques impliqués, cette échéance est réduite à quelques heures lorsqu'on s'intéresse à des phénomènes convectifs de mésoéchelle ou d'échelle inférieure (Hohenegger et Schar, 2007). Une prévision précise de la convection n'est donc possible qu'en-deçà d'une certaine échéance, généralement 6 h, en supposant une connaissance toute aussi précise du temps présent : c'est le propre de la *prévision immédiate* (PI) ou *now-casting*, telle que définie par l'Organisation Météorologique Mondiale (Wang et al., 2017). Sa chaîne de fonctionnement est présentée sur la Figure 1.10 et détaillée ci-après.

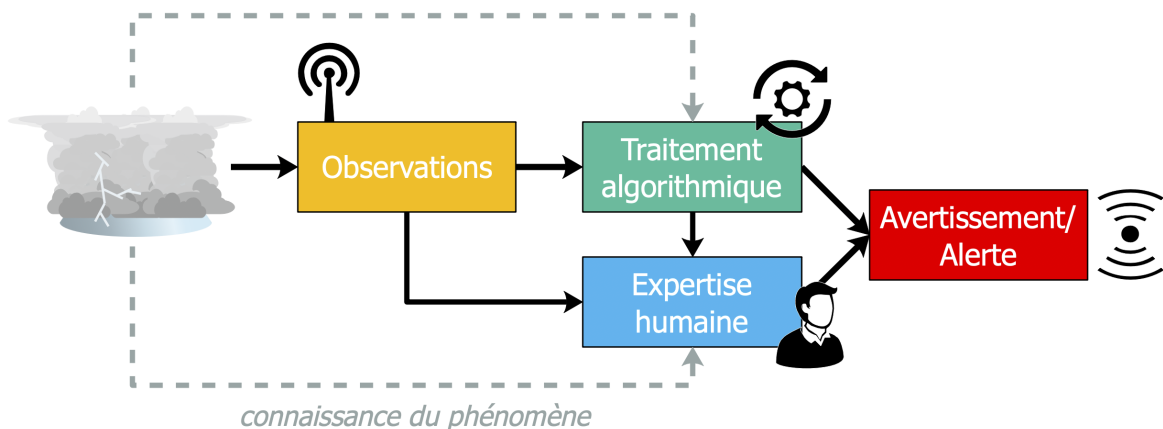


FIGURE 1.10 – La chaîne de la prévision immédiate.

Dans une revue récente, Bojinski et al. (2023) parlent de la PI comme de la « dernière ligne de défense » dont les services météorologiques disposent pour informer de l'état en cours ou à venir d'une situation convective. Parmi les principaux destinataires, on trouve les acteurs privés, notamment dans les secteurs du transport, de la construction et de l'événementiel, la sécurité civile œuvrant à la préservation des personnes et des biens, ainsi que le grand public. La communication donne lieu à des productions régulières ou bien à des alertes diffusées lorsqu'un phénomène à enjeux est observé ou imminent. Leur efficacité dépend alors de leur précision et de leur précocité.

Comme l'illustre la Figure 1.11, la stratégie employée aujourd'hui pour la PI opérationnelle varie selon l'échéance visée.

- Les **observations** de l'atmosphère les plus pertinentes pour la PI sont abordées dans la section 1.3. Elles sont à la base de chaque stratégie de prévision. La simple communica-

tion des données observées est déjà une stratégie en elle-même, par exemple lorsqu’une alerte est déclenchée sur un dépassement de seuil. C’est le principe du système APIC de Météo-France qui envoie un message aux mairies lorsque les quantités de précipitations relevées sur une commune dépassent un seuil climatologique (Olivier Piotte et Organde, 2020).

- L’**extrapolation des observations** est possible en déduisant une tendance du suivi temporel des observations passées. L’échéance pour laquelle les performances d’une telle prévision restent acceptables dépend de l’échelle du phénomène (Germann *et al.*, 2006) : une demi-heure pour une cellule, plusieurs heures pour un MCS. Lorsque l’observation est « spatialisée », c’est-à-dire sous forme d’image, la tendance repose sur un champ de déplacement \mathbf{u} déduit des dernières images observées. Par exemple, dans la méthode VET (variational echo tracking, Laroche et Zawadzki 1994; Germann et Zawadzki 2002) adaptée à la PI des précipitations, le calcul de \mathbf{u} repose sur la minimisation d’une fonction coût quantifiant l’écart entre les précipitations mesurées aux points \mathbf{x} à l’instant t et les précipitations rétroadvectées linéairement aux points $\mathbf{x} - \mathbf{u}.dt$ à l’instant $t - dt$, le tout pondéré par la qualité de la mesure. L’algorithme *NowTrack* de MétéoSuisse repose quant à lui sur un calcul de corrélations croisées, où \mathbf{u} est estimé à partir des positions des couples d’imagettes les plus corrélées dans deux images successives (Sideris *et al.*, 2014). D’une observation spatialisée, on peut aussi extraire des zones pertinentes comme le contour d’un système convectif sur une image observée. En appariant ces *objets* détectés dans des images successives grâce à un *algorithmes de suivi*, on peut déduire une vitesse de déplacement à partir de laquelle advecter l’objet. Cette méthode est particulièrement adaptée aux orages dont le déplacement diffère du flux moyen de l’environnement. L’approche « objet » est détaillée dans la section 1.4.
- Les progrès de la **prévision numérique du temps** (PNT) en font une approche de plus en plus pertinente pour la PI de la convection. Elle est le sujet de la section 1.5.
- La **PI sans couture** (*seamless nowcasting*) propose une prévision continue entre le temps de l’observation et 6 heures d’échéance, voire plus, en tirant le meilleur parti des stratégies présentées ci-dessus : l’extrapolation sur les premières heures et la PNT par la suite. Afin d’assurer une continuité temporelle, chaque stratégie est généralement pondérée selon l’échéance, typiquement en fonction de leurs performances récentes. À MétéoSuisse, le produit *NowPrecip* pour la PI des précipitations utilise un coefficient de corrélation (Sideris *et al.*, 2020). Le produit équivalent à Météo-France, *PIAF*, repose quant à lui sur un score statistique (Lovat, 2019).

Enfin, les modèles d’**apprentissage profond** (*deep learning*) concurrencent de plus en plus les approches historiques basées sur l’extrapolation voire les modèles de PNT. Ils sont entraînés pour établir des relations statistiques entre des champs observés, y compris des relations non linéaires, et en déduisent l’évolution sur les prochaines heures d’échéance. Pour la PI des précipitations, les méthodes à l’état de l’art reposent sur des réseaux de neurones récurrents (modèle *MetNet-2* de Espeholt *et al.* 2022), des réseaux antagonistes génératifs (modèles *DGMR* de Ravuri *et al.* 2021 et *NowcastNet* de Zhang *et al.* 2023), des modèles de diffusion (modèle *LDCast* de Leinonen *et al.* 2023a) ou plus récemment des modèles à base de transformeur (modèles *MetNet-3* de Andrychowicz *et al.* 2023 et *GPTCast* de Franch *et al.*

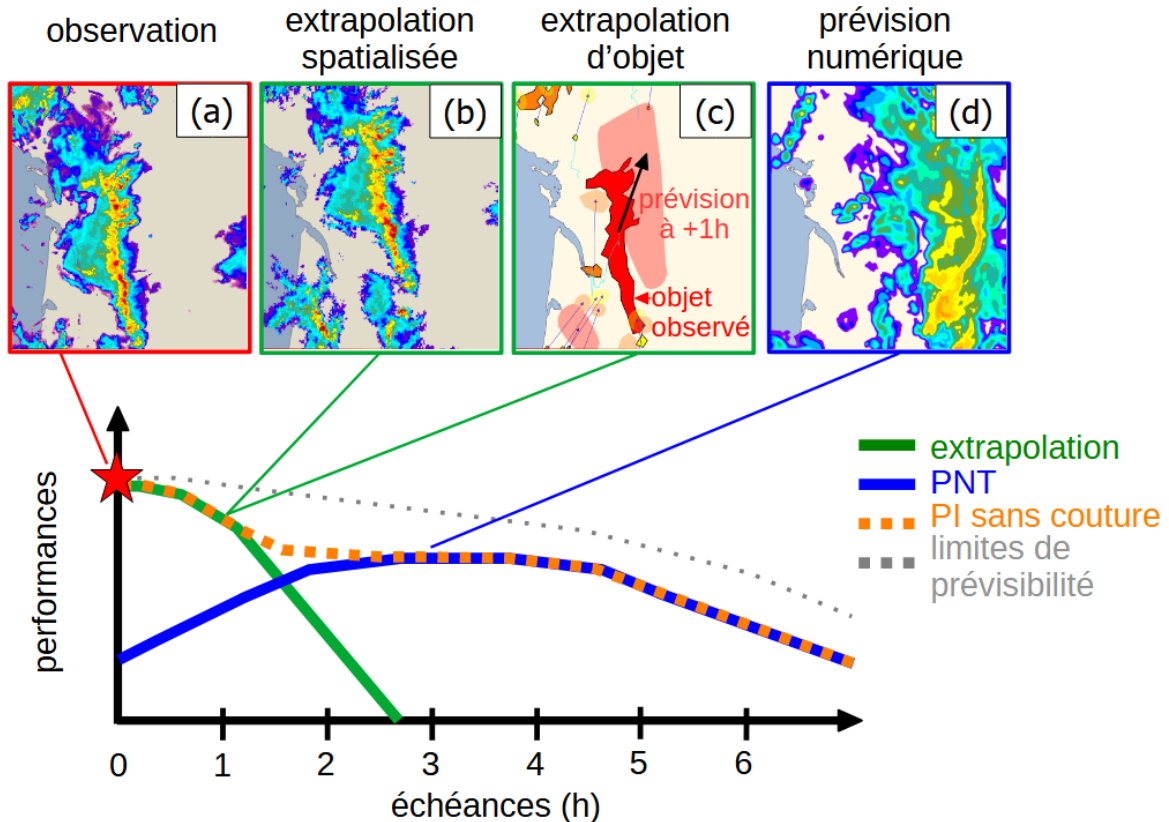


FIGURE 1.11 – Évolution schématique de la qualité de la PI en fonction de l'échéance (d'après [Germann *et al.* 2006](#) et [Bojinski *et al.* 2023](#)) avec quelques exemples de production : (a) un MCS observé sur l'image radar, (b) extrapolation du système « pixel par pixel » à 1 h par l'algorithme 2PIR de Météo-France, (c) identification du système sous forme d'un objet que l'on extrapole à 1 h à partir de sa vitesse observée (produit SRO de Météo-France), (d) réflectivités prévues à 3 h par le modèle AROME-PI. Non montrés ici, d'autres facteurs influencent la qualité de la PI en plus de l'échéance, notamment la densité des observations et la résolution spatiale et temporelle de la prévision.

2024). Du fait de leur nouveauté, ces approches sont encore peu utilisées en opérationnel.

1.2.2 La place du prévisionniste

Selon [Wang *et al.* \(2017\)](#), la PI de meilleure qualité repose sur l'alliance entre outils algorithmiques et expertise du prévisionniste. Celle-ci se traduit par l'expérience humaine, une connaissance préalable de la situation de grande échelle et la maîtrise des schémas physiques conceptuels tels que ceux décrits dans la section 1.1 pour les MCSs ([Saïx et Roulet, 2014](#)).

Cependant, le travail d'expertise ralentit nécessairement la chaîne de la PI, au point que certaines productions sont aujourd'hui entièrement automatisées. C'est le cas des alertes géné-

rées à partir des objets orageux extrapolés par l'algorithme TRT à MétéoSuisse (Hering *et al.*, 2015) ou par l'algorithme SRO à Météo-France. D'après Bojinski *et al.* (2023), la plus-value du prévisionniste en matière de PI reposera de plus en plus sur le contrôle des productions et le conseil aux usagers. Les prévisionnistes continueront cependant de jouer un rôle central au-delà des échéances de la PI, notamment via la diffusion de la vigilance météorologique à 1 ou 2 jours d'échéance. Ce zonage du risque permet la mobilisation préliminaire des moyens d'action déployés en cas d'alerte.

1.3 Les données d'observation

Les observations les plus pertinentes pour la PI de la convection doivent être précises, disponibles rapidement et dotées d'une couverture spatio-temporelle adaptée, avec une résolution au moins de l'ordre de quelques kilomètres et de quelques minutes. Les mesures satellite, radar et foudre constituent donc un trio idéal (Wang *et al.*, 2017). Elles sont introduites ci-après et illustrées sur la Figure 1.12.

1.3.1 Le satellite

Parmi les instruments à bord des satellites, les *radiomètres* mesurent l'énergie d'une onde électromagnétique incidente dans plusieurs bandes de fréquences, les *canaux* du radiomètre. Deux types de canaux sont particulièrement étudiés :

- Les canaux du spectre visible mesurent le rayonnement solaire réfléchi par la surface ou les nuages.
- Les canaux du spectre infrarouge mesurent notamment le rayonnement émis par la surface et l'atmosphère. Grâce à la fonction de Planck, on peut en déduire la température de la source émettrice, assimilée à un corps noir (Malardel, 2009). On parle aussi de *température de brillance* (TB). Le canal 10,8 μm estime bien la température des sommets nuageux et peut ainsi détecter les sommets élevés, très froids, des cumulonimbus. (Figure 1.12a). Par ailleurs, la vapeur d'eau contenue dans l'air absorbe le rayonnement associé à certaines longueurs d'onde, par exemple autour de 6 μm . Les canaux associés permettent d'estimer l'humidité sur de larges tranches d'atmosphère en ciel clair.

Les satellites géostationnaires sont particulièrement utilisés en PI. Ils sont situés sur l'orbite éponyme, à environ 36 000 km d'altitude, ce qui leur confère une vitesse de rotation égale à celle de la Terre. Ils observent donc un disque terrestre en permanence. L'organisation européenne pour l'exploitation des satellites météorologiques, EUMETSAT, opère les satellites géostationnaires MSG (Météosat Seconde Génération, Figure 1.12d). Son radiomètre imageur SEVIRI (Schmid, 2000) fournit des mesures de TB sur l'Europe à une résolution de 3 à 5 km environ selon la latitude.

EUMETSAT réunit 8 centres de travail occupés à valoriser les données satellite : les *SAFs* (*Satellite Application Facilities*). Le *Nowcasting SAF* (NWC SAF) développe des produits

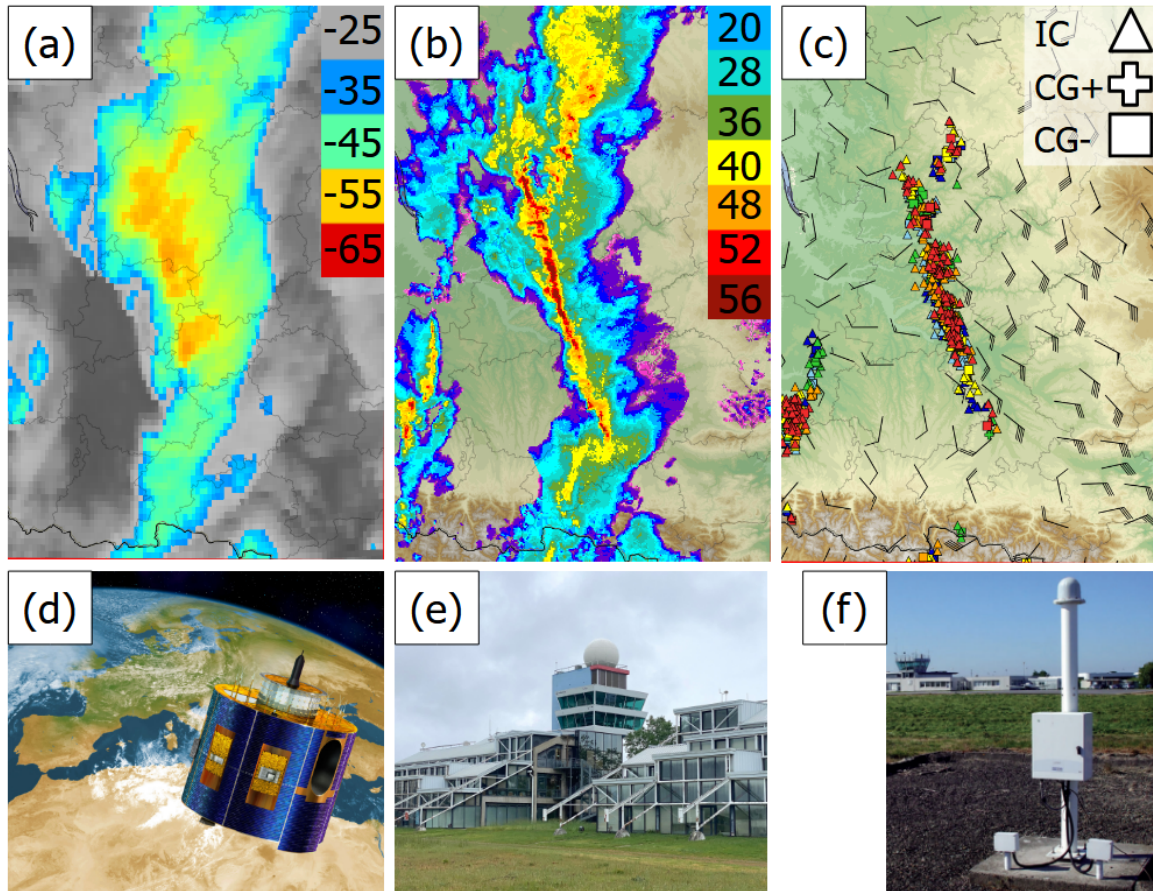


FIGURE 1.12 – Trois observations d'un même MCS sur le sud-ouest de la France (le 27/04/2024 à 1600 UTC) et leurs instruments de mesure respectifs : (a) température de brillance du canal 10,8 μm mesurée par le radiomètre SEVIRI (en $^{\circ}\text{C}$) et (d) satellite MSG hébergeant SEVIRI (source : *European Space Agency*) ; (b) mosaïque de réflectivités SERVAL mesurées par le réseau ARAMIS (en dBZ) et (e) radar de Toulouse protégé par son radome sphérique blanc ; (c, marqueurs colorés) position des éclairs détectés par le réseau Météorage et (g) un capteur du réseau (source : [Royet 2023](#)). Sur la sous-figure (c) sont également affichées les barbules du vent à 10 mètres mesuré par les stations de surface du réseau RADOME.

dédiés à la PI comme le RDT (*Rapidly Developing Thunderstorm*) pour le suivi « objet » des orages détectés dans des images de TB 10,8 μm (voir section 1.4), le CI (*Convection Initiation*) pour l'identification des pixels nuageux ayant la plus forte probabilité d'évoluer en convection orageuse ou les produits iSHAI combinant plusieurs canaux SEVIRI à des données PNT pour estimer le contenu en eau et l'instabilité de l'atmosphère en ciel clair. L'intérêt des images satellite pour la PI repose aussi sur l'identification de structures nuageuses fréquemment associées à des épiphénomènes violents en surface, tels que les sommets protubérants (ou *overshooting tops*, p. ex. [Reynolds 1980](#)) et les signatures en « V » (p. ex. [McCann 1983](#)).

1.3.2 Le radar

Malgré son coût d'installation et de maintenance, le radar (Figure 1.12e) est l'instrument idéal pour le suivi des précipitations en PI. Il est doté d'un émetteur et d'un récepteur. L'antenne de l'émetteur concentre une onde électromagnétique micro-onde dans un angle réduit, le *faisceau*. Lorsque l'onde rencontre une cible comme des précipitations, une partie du signal est rétrodiffusée puis détectée par le récepteur. On parle d'*écho radar*. Deux informations y sont alors extraites (Doviak et Zrníć, 1993) :

- La **distance aux précipitations** est estimée par le temps séparant l'émission de la réception du signal, sachant que la vitesse de l'onde radar est proche de celle de la lumière. On en déduit son altitude en considérant l'angle du faisceau par rapport au nord géographique (l'*azimut*) l'angle du faisceau par rapport au sol (l'*élévation*) et la courbure de la Terre.
- L'**intensité des précipitations** est quantifiée par un *facteur de réflectivité* (ou simplement *réflectivité*) $z = CPr^2$, où r désigne la distance au radar, P la puissance reçue et C une constante dépendant des propriétés instrumentales comme la puissance du signal émis. Une formulation logarithmique Z de la réflectivité est communément utilisée et désignée sous le même nom par abus de langage. Son unité est le dBZ. La réflectivité est une mesure instrumentale qui ne doit pas être confondue avec le taux de pluie réel R (en mm/h). Il est toutefois possible d'estimer R à partir de la *loi Z-R* : $z = aR^b$, où a et b sont des coefficients déterminés empiriquement, liés à la distribution de taille des gouttes et au type de précipitations (convectives ou stratiformes).

En balayant l'atmosphère sur plusieurs angles d'élévation et selon chaque azimut, un radar localise les précipitations et quantifie leur intensité dans un rayon de quelques centaines de kilomètres. Or l'atténuation du signal par les gaz atmosphériques et les précipitations diminuent la qualité de la mesure au-delà d'une portée qui dépend de la longueur d'onde. Le réseau ARAMIS de radars français est mixte (Tabary *et al.* 2013, Figure 1.13) : il comporte des radars en bande S (longueur d'onde de 10 cm), C (5 cm) et X (2 cm). Plus la longueur d'onde est faible, plus le signal est sujet à l'atténuation. Or les bandes S sont onéreux du fait de leur antenne imposante. Ils sont donc implantés dans le sud-est, là où l'enjeu lié aux précipitations convectives est le plus important. Le reste du pays est couvert par des bandes C. Des bandes X complètent le réseau dans certaines zones de relief (Beck et Bousquet, 2013).

En combinant les mesures de chaque radar, on peut spatialiser l'observation des précipitations à l'échelle d'un territoire sous forme de *mosaïque*. Les mosaïques 3D projettent les réflectivités à différents niveaux d'altitude, généralement sur une grille de coordonnées cartésiennes. Par exemple, le produit IRMA utilise une grille de résolution horizontale 2×2 km et de résolution verticale 500 m, avec des données disponibles jusqu'à 12 km d'altitude (Scovell *et al Sakka*, 2016). La Figure 1.14a montre une coupe verticale des réflectivités 3D IRMA réalisée au sein d'un MCS linéaire. Elle illustre bien les différentes régions du système décrites dans la partie 1.1.4 ainsi que leur caractérisation radar rencontrée dans la littérature (voir p. ex. Houze 2018). Dans les tours convectives, au nord, des réflectivités supérieures à 45 dBZ sont mesurées jusqu'à 7 km d'altitude. Les précipitations sont plus faibles au sud, dans la zone stratiforme (< 40 dBZ en basses couches), mais des réflectivités supérieures à 40 dBZ

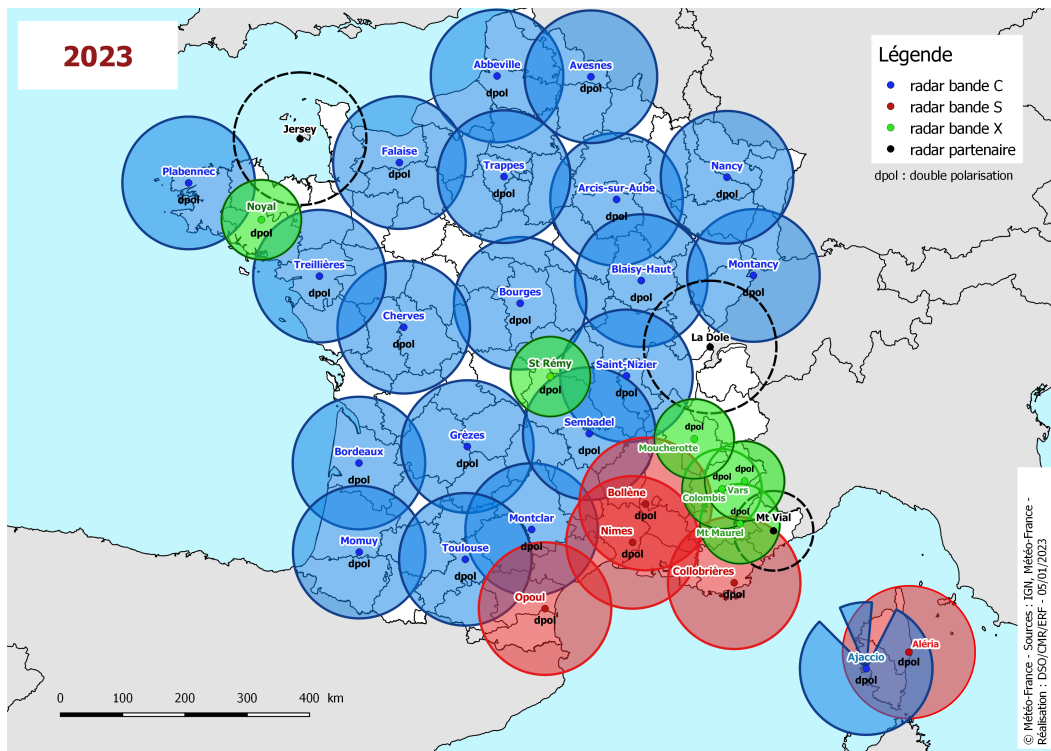


FIGURE 1.13 – Radars du réseau français ARAMIS et de réseaux étrangers pris en compte dans la mosaïque de réflectivités SERVAL en 2023. Source : Météo-France/DSO/CMR.

sont encore observées vers 3 km. Cependant, ce phénomène de *bande brillante* ne traduit pas l'intensité réelle des précipitations mais indique la présence d'hydrométéores glacés en fusion, dont la réflectivité est particulièrement forte. Les données de réflectivités 3D sont particulièrement utiles pour discriminer les précipitations convectives des précipitations stratiformes (Starzec *et al.*, 2017; Dixon et Romatschke, 2022).

Pour faciliter l'analyse, les données 3D sont aussi synthétisées sous forme de mosaïques 2D. Celle du produit IRMA correspond aux réflectivités maximales rencontrées sur chaque colonne (Figure 1.14b). À Météo-France, la mosaïque 2D la plus utilisée provient du système SERVAL (Figure 1.12b, Tabary *et al.* 2013; Météo-France/DSO/CMR 2018). Elle est disponible toutes les 5 min à une résolution horizontale de 1×1 km. À chaque point de la grille 2D correspond la réflectivité au niveau d'élévation le plus bas, ce qui permet de filtrer une partie des virgæ (précipitations s'évaporant avant de toucher le sol). Cependant, quand des données issues de plusieurs radars sont disponibles en un même point, on conserve la plus forte. Aucune donnée n'est renseignée pour les points situés à plus de 250 km de tout radar. L'atténuation du signal est en partie prise en compte et des traitements spécifiques permettent d'identifier certains échos non météorologiques (Figueras i Ventura *et al.*, 2012).

Les radars du réseau ARAMIS sont maintenant équipés de la double polarisation. Leur antenne émettent deux ondes, l'une polarisée horizontalement, l'autre verticalement. Le si-

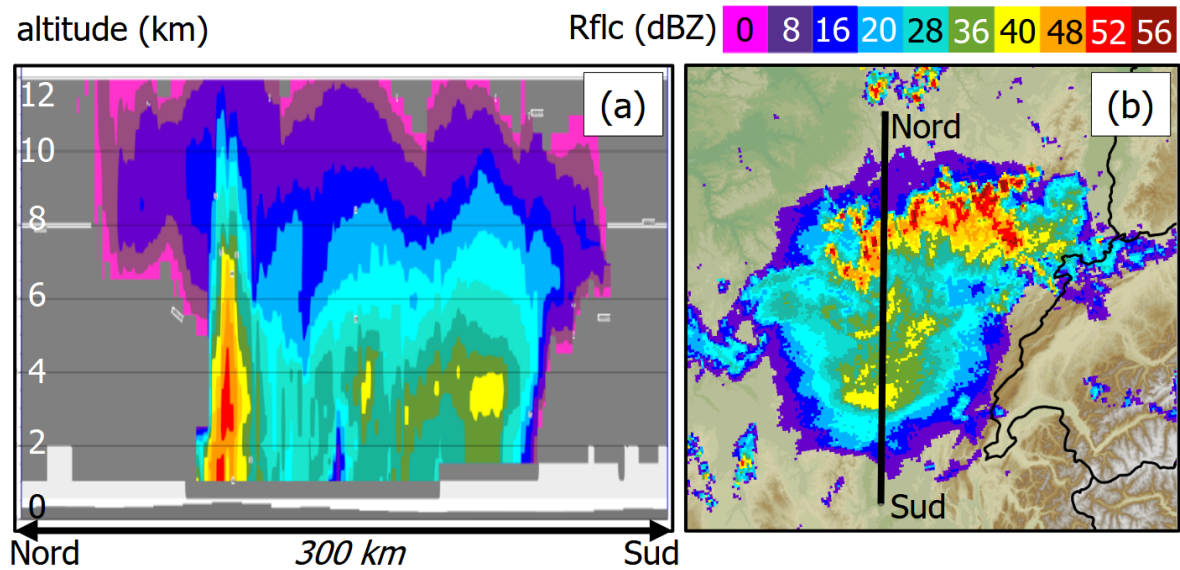


FIGURE 1.14 – (a) Coupe verticale réalisée dans le sens de déplacement d’un MCS (du sud vers le nord) à partir de la mosaïque de réflectivités 3D IRMA. (b) Le même MCS visualisé sur la mosaïque 2D IRMA, avec l’axe de la coupe en trait noir. Observation du 14/08/2024, à 0000 UTC.

gnal reçu informe donc sur la forme des particules. Il améliore l’identification des échos non météorologiques et de certains types d’hydrométéores comme la grêle ou les gouttes aplaties témoignant de fortes ascendances (Figueras i Ventura et Tabary, 2013; Kumjian, 2013a,b). Par ailleurs, l’analyse du décalage de fréquence entre l’onde émise et l’onde reçue permet, par effet Doppler, de déduire la vitesse de la cible dans l’axe du faisceau. Dans les zones de précipitations, la circulation 3D du vent peut être restituée de manière précise en combinant la mesure Doppler de radars rapprochés avec l’équation de continuité (p. ex. Scialom et Lemaître 1990). Cette approche est toutefois limitée lorsqu’elle est appliquée à un réseau opérationnel comme ARAMIS où les radars sont très espacés ; elle permet seulement d’accéder à la circulation à mésoéchelle (Bousquet *et al.*, 2008).

1.3.3 Autres observations

La télédétection des éclairs permet d’identifier les régions les plus actives d’un système convectif (Figure 1.12c). Les données sont disponibles en flux quasi continu. Son intérêt en PI tient aussi au suivi temporel de l’activité électrique, au sein d’un objet par exemple, dont de brusques variations appelées *sauts électriques* (ou *lightning jumps*) peuvent précéder la survenue d’épiphénomènes violents (Schultz *et al.*, 2009). Le transfert d’électrons résultant de la collision entre hydrométéores au sein des ascendances convectives électrisent un cumulonimbus. Les décharges de courant déclenchées pour neutraliser les zones de charges opposées constituent l’éclair (Malardel, 2009). Elles émettent un rayonnement électromagnétique dans plusieurs fréquences dont les plus basses (VLF, *Very Low Frequency*) sont interceptées par

les capteurs d’un réseau au sol (Figure 1.12f). Fort d’une centaine de capteurs, celui de Météorage couvre une grande partie de l’Europe. On en déduit la localisation de l’éclair par triangulation, ainsi que son intensité, sa polarité (+ ou -) et sa nature (nuage-sol CG ou nuage-nuage/intra-nuage IC), le tout avec une grande précision (Schulz *et al.*, 2016).

Contrairement aux observations télédéteectées, les mesures *in situ* ont une couverture spatiale plus lâche et irrégulière. Les *stations de surface* mesurent les paramètres de base comme les cumuls de précipitations, la température et l’humidité à 2 mètres ou le vent à 10 mètres. Organisées en réseau suffisamment dense, elles peuvent mettre en évidence une ligne de convergence (bien visible sur la Figure 1.12c) et indiquer les zones privilégiées d’initiation de la convection (Wang *et al.*, 2017). Elles informent aussi sur l’étalement de la plage froide, élément clé lors du suivi des MCSs méditerranéens (Saïx et Roulet, 2014), ainsi que sur certains épiphénomènes comme les rafales de vent ou les forts cumuls de pluie. Une fois combinées avec des mosaïques de réflectivités, les mesures pluviométriques peuvent aussi être spatialisées sous forme de *lame d’eau*, comme pour le produit français ANTILOPE (Laurantin, 2008), qui estime en chaque point du territoire la quantité d’eau cumulée par unité de surface sur une période donnée. Le réseau RADOME de Météo-France (Guillou, 2018) compte aujourd’hui 600 stations en métropole. Par ailleurs, les *observations participatives* ou *opportunes*, issues des objets et véhicules connectés, des stations privées ou des réseaux sociaux, suscitent de part leur nombre un intérêt grandissant pour la PI (Hintz *et al.*, 2019). Des contrôles de qualité sont toutefois nécessaires (Mandement et Caumont, 2020). Il faut enfin évoquer les *mesures d’altitude*. Celles-ci ont trois origines principales (Wang *et al.*, 2017) : (1) les radiosondages, (2) les données AMDAR et AIREP des avions en vol et (3) les profileurs de vent tels que les LIDAR. Si elles permettent d’évaluer l’instabilité et le cisaillement de l’environnement pré-convectif, la discontinuité de la mesure limite leur utilisation en PI. En France, cinq sites seulement procèdent à des radiosondages.

1.4 L’approche « objet »

Dans un champ ou une image, un *objet* est une zone cohérente au sein de laquelle les données de chaque point de grille ont des propriétés communes. En plus des coordonnées géographiques de son contour, un objet se définit par ses *attributs*, propriétés intrinsèques synthétisant l’information qu’il contient. Il en existe trois types (Lakshmanan et Smith, 2009) : (1) morphologiques (aire, longueur, rapport d’aspect, etc), (2) spatiaux (statistiques déduites des valeurs de chaque point de grille dans l’objet, comme la moyenne, le maximum, etc) et (3) temporels (variation d’un attribut au sein d’un même objet suivi dans le temps, vitesse de l’objet, etc). On peut ajouter un dernier type : l’attribut de fusion, par exemple un niveau de violence estimé à partir d’autres attributs (p. ex. Hering *et al.* 2015; Imbert 2021).

Plusieurs produits dédiés à la PI de la convection sont basés sur une approche « objet ». Elle est aussi employée en recherche pour sa capacité à condenser un grand nombre d’informations. La Table 1.1 dresse un inventaire non exhaustif des travaux menés sur l’étude ou la PI des MCSs à partir d’une telle approche.

L'approche « objet » se divise en trois étapes : (1) identification, (2) suivi et (3) prévision pour des applications opérationnelles. Ces trois étapes sont détaillées ci-après.

1.4.1 Etape n°1 : identification

L'identification d'objets au sein d'un champ relève de la *segmentation d'images*. Plusieurs méthodes existent pour les systèmes convectifs, le plus souvent à partir des réflectivités radar (Rflc) ou de la température de brillance satellite d'un canal infrarouge (TB).

Seuil fixe

Les objets convectifs définis par un seuil fixe sont constitués de l'ensemble des pixels contigus dont l'intensité dépasse le seuil. Pour des MCSs, celui-ci est généralement supérieur à 30 dBZ en Rflc ou inférieur à -30°C en TB (voir Table 1.1). Parfois, les images sont lissées au préalable pour être adaptées à l'échelle du phénomène (Lakshmanan *et al.*, 2009) : un lissage fin pour détecter des cellules, un lissage marqué pour des MCSs. Facile à mettre en œuvre, le seuillage fixe est fréquemment employé. Il permet d'identifier des objets convectifs de 32 à 48 dBZ pour le service ASPOC dédié à la gestion du trafic aérien français (Parent du Châtelet, 2003). La méthode de Kolios et Feidas (2012a) pour la PI des MCSs en Méditerranée repose sur un seuil fixe à -45°C dans des images de TB. Or le choix d'un seuil unique a trois défauts principaux : (1) la non-détection de systèmes convectifs peu intenses, (2) la réunion de plusieurs systèmes disjoints en un seul objet, (3) la fausse détection de systèmes non convectifs. En mode recherche, le dernier défaut peut être atténué par l'élimination des objets dont les attributs sont en-deçà d'un certain seuil. Pour les MCSs il s'agit souvent des objets plus petits que 100 km et de durée inférieure à 3 h (voir colonne *Filtres éventuels* dans la Table 1.1).

Seuil adaptatif

Un *seuillage adaptatif* est une méthode plus robuste car chaque objet est défini par un seuil qui lui est propre. L'algorithme associé est généralement itératif. De petits objets, les « graines », sont d'abord identifiés par un seuil très intense. Ils sont ensuite grossis en abaissant le seuil pas à pas... jusqu'à ce qu'une des deux conditions suivantes soit remplie : (1) un seuil plancher a été atteint, (2) des objets séparés s'appêtent à fusionner. Plusieurs outils opérationnels emploient cette méthode, notamment le RDT (*Rapidly Developing Thunderstorm*) pour la détection des systèmes convectifs dans des images satellite plein disque de TB (Morel, 2001; Autonès et Claudon, 2022) ou le produit TRT utilisé à MétéoSuisse pour le suivi des cellules dans l'image radar (Hering *et al.*, 2004). Fiolleau et Roca (2013) utilisent un algorithme *de partage des eaux* (ou *watershed*) pour définir les objets jusqu'au seuil plancher sans entraîner de fusion. Pour cela, l'algorithme crée une frontière artificielle qui maintient les deux objets séparés jusqu'au seuil plancher. L'approche *watershed* est également employée dans le module en accès libre *tobac* (Heikenfeld *et al.*, 2019), adapté à tous types d'images

météorologiques. Celui-ci offre aussi la possibilité d'utiliser deux images de nature différente pour (1) définir les « graines » de l'algorithme itératif et (2) identifier les objets. Enfin, le centre météorologique allemand DWD propose une méthode originale pour ses objets KONRAD3D (Werner *et al.*, 2023) : des objets temporaires sont détectés à 37 dBZ et la moyenne des pixels à l'intérieur donne le seuil des objets finaux.

Approche statistique

Une méthode statistique peut améliorer le post-traitement ou l'identification même des objets. Haberland *et Ashley* (2018a) entraînent un modèle d'apprentissage machine qui, à partir d'une douzaine d'attributs radar et morphologiques, classe des objets détectés par seuillage en cinq catégories : « vrais » MCSs, groupes de cellules désorganisées, cyclones, précipitations synoptiques et échos de sol. Arbogast *et al.* (2016) se passent de seuil en définissant des objets de précipitations de manière statistique, par l'ensemble des pixels contigus dont l'environnement sur l'image présente une distribution de valeurs similaire. Courbot *et al.* (2020) décrivent les MCSs d'une image TB comme des sommes de fonctions gaussiennes ellipsoïdes 2D. Leurs paramètres sont déterminés en minimisant l'erreur entre la vraie image et l'image artificielle construite à partir de ces fonctions. Ces deux approches demandent toutefois un temps de calcul important.

Les méthodes d'apprentissage profond pour la segmentation d'images gagnent en popularité. Les plus performantes utilisent des réseaux de neurones convolutifs (RNC) capables d'identifier des motifs caractéristiques dans les images traitées. Pour cela, les RNC reposent sur des opérations de convolution entre l'image et des matrices de petite taille, généralement 3×3 , appelées *filtres*. Les coefficients sont appris par un processus d'entraînement sur une base de données de référence. Les RNC ont déjà été appliqués à la détection de structures météorologiques, notamment pour les rivières atmosphériques (Liu *et al.*, 2016), les fronts synoptiques (Liu *et al.*, 2016; Biard *et Kunkel*, 2019; Lagerquist *et al.*, 2019) ou les cyclones tropicaux (Liu *et al.*, 2016; Kumler-Bonfanti *et al.*, 2020). Mounier *et al.* (2022) s'intéressent à des systèmes convectifs des moyennes latitudes en détectant des échos arqués dans les champs de Rflc prévus par chaque membre de la prévision d'ensemble AROME. L'inconvénient de l'apprentissage profond tient au nombre important de données nécessaires pour l'entraînement. Cette contrainte peut être prohibitive si la base de référence est construite manuellement. Cependant, certains RNC comme le U-Net sont conçus pour être performants sur de petits jeux d'entraînement (Ronneberger *et al.*, 2015). Ces raisons motiveront le choix de cette approche pour identifier les MCSs durant la thèse (voir section 1.6).

Enfin, dans un cadre de recherche, des auteurs préfèrent définir le contour des objets à la main (voir Table 1.1). L'expertise humaine améliore la qualité de la détection mais la méthode est chronophage et ne peut être répliquée.

1.4.2 Étape n°2 : suivi

Un algorithme de suivi (ou *tracking*) apparie des objets identifiés dans une suite temporelle d'images. Les objets appariés forment alors une *trajectoire*. [Lakshmanan et Smith \(2010\)](#) passent en revue la plupart des méthodes existantes, certaines combinant plusieurs des approches mentionnées ci-dessous.

- Le **suivi par recouvrement** : deux objets sont appariés si leurs contours s'intersectent. C'est l'une des méthodes les plus courantes et les plus robustes.
- Le **suivi par distance minimale** : on mesure la distance séparant les centres de gravité d'un objet au temps t et des objets à $t + 1$ situés dans un certain rayon de recherche. L'objet à t est apparié à l'objet à $t + 1$ le plus proche.
- Les approches basées sur la **méthode « hongroise »** ont une interprétation mathématique du problème d'appariement ([Munkres, 1957](#)). Les objets à t sont liés aux objets à $t + 1$ par des arêtes, le tout formant un *graphe biparti*. À chaque arête est associé un poids, fonction de la distance entre les centres de gravité mais aussi de la comparaison entre certains attributs. Ces poids constituent une fonction coût dont la minimisation doit aboutir à un couplage optimal. La méthode est notamment employée par TITAN ([Dixon et Wiener, 1993](#)), l'un des algorithmes les plus populaires pour le suivi des objets convectifs.
- Non mentionnée, la **segmentation 3D** de [Fiolleau et Roca \(2013\)](#) se passe d'une étape de suivi car les objets sont directement identifiés dans le champ tridimensionnel que constitue la superposition d'images 2D consécutives.

1.4.3 Étape n°3 : prévision

En opérationnel, le suivi des objets convectifs fournit des informations pour anticiper leur déplacement et même l'évolution de leur intensité sur les toutes prochaines échéances.

Extrapolation sur les prochaines heures

L'appariement des objets permet d'en déduire une vitesse. Son calcul s'appuie souvent sur la distance séparant les centres de gravité des objets appariés à t et $t + 1$. Des stratégies existent pour lisser les valeurs obtenues, notamment via des combinaisons linéaires avec les vitesses précédentes (p. ex. [Morel et Senesi 2002a](#); [Kolios et Feidas 2012b](#)). Rétroactivement, le calcul des vitesses permet d'améliorer l'algorithme de suivi car l'objet à t peut être advecté à $t + 1$ pour augmenter ses chances d'appariement ([Lakshmanan et Smith, 2010](#)).

En mode PI, les objets détectés dans l'observation peuvent être advectés à partir de cette vitesse, généralement jusqu'à 1 h. Cette advection est souvent linéaire, autrement dit la direction ne change pas avec l'échéance. Éventuellement, l'incertitude est prise en compte en appliquant un facteur de dilatation à l'objet extrapolé. Dans l'algorithme TRT, celui-ci est proportionnel à l'écart-type des vitesses passées ([Hering et al., 2015](#)). Cependant, la PI par extrapolation n'est pas performante lorsque la dynamique du phénomène varie fortement,

notamment dans les phases de croissance ou de dissipation (Wang *et al.*, 2017), ou lorsqu'un forçage orographique influe sur son évolution (Bojinski *et al.*, 2023).

Prévision des attributs

La PI des attributs est plus délicate. Ceux-ci restent généralement fixes pour les objets advectés ou bien varient linéairement selon la tendance passée (Autonès et Claudon, 2022). Pour Shehu et Haberlandt (2021) la prévision d'un objet observé suit l'évolution des objets passés les plus ressemblants, archivés dans une base de données. D'autres auteurs proposent des équations d'évolution standards, inspirées d'études climatologiques sur le cycle de vie du phénomène. Leurs paramètres sont déduits des tendances observées de l'objet. Kolios et Feidas (2012b,a) prévoient ainsi la durée, l'aire et certains attributs satellite associés à des MCSs méditerranéens à partir d'une équation triangulaire, avec une phase de croissance suivie d'une phase de décroissance. Ils obtiennent des résultats correctes jusqu'à 45 min d'échéance. Dans Wilhelm *et al.* (2023), l'aire d'un objet radar évolue selon une équation parabolique. Les auteurs cherchent à améliorer sa paramétrisation en intégrant des informations de PNT sur l'instabilité ou le flux de l'environnement. Cependant, les attributs observés restent les meilleurs prédicteurs à l'échelle de la cellule. Nisi *et al.* (2014) adoptent une approche plus physique. L'évolution de l'activité convective correspond aux solutions analytiques d'une équation de conservation reliant les attributs à des termes de forçages externes, comme le relief ou la CAPE. Les performances sont limitées car les facteurs non-linéaires ne sont pas pris en compte. Les modèles statistiques issus d'un apprentissage machine peuvent résoudre ce problème. Ils ont aussi l'avantage de gérer un grand nombre de prédicteurs simultanément. Dans le projet COALITION-3, Hamann *et al.* (2019) entraînent un modèle de forêt aléatoire pour prévoir l'indice de violence des objets TRT. Près de 8000 prédicteurs sont considérés en entrée : des attributs issus du radar, du réseau foudre Météorage, du satellite MSG ainsi que des métadonnées topographiques et des statistiques de PNT pour caractériser l'environnement. Des approches similaires ont été développées sur les États-Unis pour la prévision de grêle (Gagne *et al.*, 2017), de fortes rafales de vent (Lagerquist *et al.*, 2017), de violence convective (Mecikalski *et al.*, 2021) ainsi que de réflectivités et d'activité électrique (Leinonen *et al.*, 2022).

La PI « objet » reste toutefois sensible aux artefacts d'identification et de suivi. En effet, si l'appariement entre objets n'est pas pertinent, l'évolution temporelle des attributs risque d'être bruitée et de dégrader la prévision (communication personnelle avec MétéoSuisse). Ces raisons justifient l'engouement actuel porté autour de l'approche statistique « spatialisée ». Lagerquist *et al.* (2020) entraînent un RNC pour prévoir l'occurrence de tornade à 1 h. Leurs principales données d'entrée sont des images radar centrées sur une cellule convective. Une analyse du réseau de neurones montre que celui-ci est sensible aux caractéristiques 2D des supercellules. Leinonen *et al.* (2023b) abandonnent complètement l'approche objet et développent un *réseau de neurones récurrents* pour prévoir des champs d'activité électrique, de probabilité de grêle et un cumul de précipitations à 1 h d'échéance. Les données d'entrée sont des champs observés, des métadonnées topographiques et des champs de PNT. Les résultats sont encore modestes, les champs de sortie bruités, mais l'arrivée de nouvelles architectures

comme les *modèles de diffusion* ouvre des perspectives prometteuses ([Leinonen et al., 2023a](#)).

En parallèle, l'approche « objet » reste appréciée des prévisionnistes et des chercheurs car elle offre une lecture synthétique d'une information spatialisée, se rapprochant ainsi de la vision humaine.

Référence(s)	Méthode d'identification	Filtres éventuels	Cadre de l'étude
Machado <i>et al.</i> (1998)	seuil fixe (TB < -28°C)	L > 200 km, TB _n < -55°C	Cycle de vie des MCSs aux Amériques
Morel et Senesi (2002a,b)	seuil fixe (TB < -45°C)	A > 1000 km ² , discrimination basée sur le gradient de TB périphérique	Climatologie des MCSs Européens avec l'algorithme <i>ISIS</i>
Kolios et Feidas (2009)	seuil fixe (TB < -45 °C)	A > 100 km ² , D > 2 h	Climatologie des MCSs en Méditerranée
Coniglio <i>et al.</i> (2010)	manuel (Rfc > 35 dBZ)	L > 100 km, D > 5 h, Rfc _x > 50 dBZ	Étude des MCSs linéaires aux États-Unis
Fiolleau et Roca (2013)	seuil itératif <i>watershed</i> (TB < -38°C)	-	Suivi des MCSs tropicaux avec l'algorithme TOOCAN
Punkka et Bister (2015)	manuel (Rfc > 18 dBZ)	L > 100 km, D > 3 h, Rfc _x > 40 dBZ	Environnement des MCSs en Finlande
Haberlie et Ashley (2018a,b)	seuil fixe (Rfc > 40 dBZ) et inclusion d'une région stratiforme alentour (Rfc > 20 dBZ)	L > 100 km, D > 3 h, Rfc _x > 50 dBZ, Classification par apprentissage machine	Climatologie des MCSs aux États-Unis
Rigo <i>et al.</i> (2019)	seuil fixe (Rfc > 12 dBZ)	A > 10 000 km ² , D > 3 h, Rfc _x > 35 dBZ	Climatologie des MCSs en Méditerranée
Courbot <i>et al.</i> (2020)	décomposition d'une image TB en fonctions gaussiennes	-	Académique
Chen <i>et al.</i> (2020)	seuil itératif (TB < -23°C)	A > 10 000 km ² , D > 3 h, Aire Lame d'eau 1 h > 0.2 × A	Cycle de vie des MCSs en Chine
Cheeks <i>et al.</i> (2020)	seuil fixe (TB < -52°C)	A > 30 000 km ² , D > 3 h, sans précipitations hivernales	Climatologie des MCSs aux États-Unis
Feng <i>et al.</i> (2021)	seuil itératif (TB < -32°C)	A > 800 km ² et seuils sur les précipitations satellite IMERG	Base de données mondiale de MCSs
Moumier <i>et al.</i> (2022)	RNC appliqué aux Rfc	-	Détection d'échos arqués dans AROME
Da Silva et Haerter (2023)	seuil fixe (précipitations IMERG > 2 mm/h)	L > 100 km, présence de foudre	Climatologie des précipitations liées aux MCSs en Europe
Cui <i>et al.</i> (2023)	seuil fixe (Rfc > 35 dBZ)	rapport d'aspect > 5, L > 100 km, D > 3 h	Environnement des MCSs linéaires en Chine

TABLE 1.1 – Quelques approches « objet » développées pour l'étude des MCSs. Abréviations de la colonne **Filtres éventuels** : A (aire du MCS), L (longueur du MCS), D (durée de la trajectoire), Rfc_x (Rfc maximales dans l'objet), TB_n (TB minimale dans l'objet).

1.5 La prévision numérique du temps

Cette section présente la prévision numérique du temps (PNT) telle qu'elle est notamment appliquée de manière opérationnelle à Météo-France. Le modèle régional AROME-France est ici introduit avec sa déclinaison AROME-PI, dédiée à la PI. Sa résolution spatiale, sa dynamique et ses paramétrisations physiques permettent une représentation explicite des systèmes convectifs et en font un outil de base pour l'étude des MCSs et de leur environnement durant la thèse.

1.5.1 L'atmosphère en équations

L'état de l'atmosphère est décrit par un lot de variables dites *pronostiques*, liées à la température, à la pression, à la vitesse de l'air (le vent), auxquelles on peut ajouter d'autres paramètres d'intérêt comme le contenu en vapeur d'eau. Ces variables forment les composantes d'un vecteur \mathbf{X} dont la tendance temporelle s'écrit :

$$\frac{\partial \mathbf{X}}{\partial t} = \mathcal{M}(\mathbf{X}) \quad (1.5)$$

\mathcal{M} est un opérateur non-linéaire liant les variables pronostiques entre elles grâce aux équations qui gouvernent l'évolution d'un fluide non visqueux comme l'air : les *équations d'Euler* (Coiffier, 2009). Il s'agit de l'équation d'état et des équations de conservation de la quantité de mouvement, de l'énergie et de la masse (celle de l'air, de la vapeur d'eau et des autres espèces considérées).

À partir d'un état initial $\mathbf{X}(t_0)$ de l'atmosphère, on prévoit l'état au temps $t > t_0$ en intégrant l'équation 1.5 entre t_0 et t . Cependant, la solution analytique des équations d'Euler est inconnue : on ne peut établir mathématiquement un \mathbf{X} qui vérifie l'équation 1.5. La prévision du temps a donc besoin d'une solution numérique (Bauer *et al.*, 2015).

Un *modèle de PNT* est un programme informatique capable de calculer un état futur de l'atmosphère à partir des équations d'Euler. C'est aujourd'hui un outil incontournable du prévisionniste. Trois facteurs expliquent l'essor de la PNT depuis les années 1980 (Bauer *et al.*, 2015) : (1) une meilleure compréhension scientifique des processus atmosphériques pour connaître \mathcal{M} , (2) la multiplication des observations pour déterminer $\mathbf{X}(t_0)$, (3) une explosion des capacités de calcul informatique pour prévoir $\mathbf{X}(t)$. À Météo-France, les modèles opérationnels sont exécutés sur le supercalculateur *Taranis* de la société BULL/ATOS dont la puissance de calcul peut atteindre $10,39^{15}$ flops, c'est-à-dire $10,39^{15}$ opérations par seconde (Météo-France, 2021).

1.5.2 Principes de la prévision numérique

La PNT repose sur la discrétisation de l'espace et du temps : on décrit \mathbf{X} pour une succession de *pas de temps* t et sur un nombre limité de points dans l'atmosphère. Les points

de l'espace sont disposés selon une grille tridimensionnelle adaptée à la géométrie de la Terre (Figure 1.15). Les *niveaux verticaux* de la grille se repèrent généralement par une coordonnée « hybride » qui équivaut à une hauteur au voisinage de la surface, suivant ainsi la forme du terrain, puis à des isobares en altitude. Selon l'horizontale, les *points de grille* sont généralement espacés d'une distance régulière qui fixe la *résolution* du modèle.




FIGURE 1.15 – Domaine du modèle AROME-France (à droite) et représentation schématique de sa grille (à gauche).

L'opérateur \mathcal{M} se divise en deux parties :

- En chaque point de grille i , la *partie dynamique* résout explicitement les équations d'Euler pour décrire l'évolution de \mathbf{X}_i à partir de l'état de l'atmosphère en i et sur les autres points de grilles.
- La *partie physique* calcule une tendance de \mathbf{X}_i liée à des processus de petite échelle, dits « sous-mailles », que la résolution du modèle ne permet pas de décrire explicitement. Cette partie comporte des modèles secondaires appelés *schémas* ou *paramétrisations* physiques. Il y en a autant que de processus sous-mailles susceptibles d'influencer l'évolution de \mathbf{X}_i .

1.5.3 Les modèles régionaux non-hydrostatiques

Deux conditions sont requises pour simuler explicitement la convection orageuse dans la partie dynamique du modèle : (1) une résolution suffisante, de l'ordre du kilomètre ; (2) un jeu d'équations *non-hydrostatiques*, où l'accélération verticale de l'équation 1.1 n'est pas négligée. Il faut donc des variables pronostiques supplémentaires, liées à la vitesse verticale, et un nombre important de points de grille. En raison du coût numérique que cela implique, les modèles couvrant l'intégralité de la planète, dits *globaux*, ne peuvent respecter ces conditions aujourd'hui. Seuls les modèles *régionaux* en sont capables car ils ne couvrent qu'un domaine d'intérêt. Les modèles globaux donnent cependant l'état de l'atmosphère sur les limites latérales et supérieures de la grille régionale.

Depuis 2008, AROME (Applications de la Recherche à l'Opérationnel à MÉSocéhelle) est le modèle non-hydrostatique de Météo-France (Seity *et al.*, 2011). Ses principales caractéristiques sont listées dans la Table 1.2. Son domaine est centré sur la France métropolitaine (Figure 1.15) et le modèle global ARPEGE assure le couplage aux limites. D'autres modèles non-hydrostatiques sont maintenus par des services météorologiques étrangers, comme HRRR aux États-Unis (Dowell *et al.*, 2022), UKV au Royaume-Uni (Milan *et al.*, 2020) ou ICON qui remplace COSMO en Allemagne (Zängl *et al.*, 2015) et bientôt en Suisse. Une revue récente est proposée par Dowell *et al.* (2022).

pas de temps	50 s
résolution horizontale	1,3 km
résolution verticale	90 niveaux, de 5 m à 10 hPa
couplage aux bords	modèle global ARPEGE (Courtier <i>et al.</i> , 1991; Pailleux <i>et al.</i> , 2015)
variables pronostiques de contrôle (assimilées)	<ul style="list-style-type: none"> * température T * pression hydrostatique de surface π_s * composantes zonale (ouest-est) et méridienne (sud-nord) du vent horizontal U * contenu spécifique en vapeur d'eau SH (masse volumique de vapeur d'eau divisée par la masse volumique de l'air, aussi appelé <i>humidité spécifique</i>)
autres variables pronostiques	<ul style="list-style-type: none"> * divergence verticale du vent d (liée à la vitesse verticale) * pression non-hydrostatique normalisée \hat{q} * énergie cinétique turbulente TKE * contenu spécifique de cinq espèces d'hydrométéores en suspension (eau liquide q_l et glace nuageuses q_i) ou précipitant (pluie q_r, neige q_s et une espèce appelée graupel q_g, regroupant grésil, grêle et neige fondante)
dynamique	non-hydrostatique, héritée du modèle ALADIN (p. ex. Bubnová <i>et al.</i> 1995). Les équations pronostiques sont écrites dans Bénéard <i>et al.</i> (2010).

TABLE 1.2 – Caractéristiques du modèles AROME en 2022.

Malgré une résolution kilométrique, des processus de petite échelle ne peuvent être résolus explicitement par les modèles non-hydrostatiques. Ils sont donc paramétrés. La partie physique d'AROME provient du modèle de recherche Meso-NH (Lac *et al.*, 2018). Elle concerne les interactions entre l'atmosphère et le rayonnement visible/infrarouge, la convection peu profonde, la turbulence, l'interaction avec la surface (via le schéma SURFEX, Masson *et al.* 2013) et les phénomènes microphysiques, notamment ceux qui dictent les échanges entre les différentes classes d'hydrométéores. Pour AROME, ce processus est géré par le schéma microphysique ICE3 à un moment (Pinty et Jabouille, 1998) qui, dans sa version opérationnelle, ne tient pas compte de la grêle explicitement.

1.5.4 Les variables diagnostiques

Les variables dites *diagnostiques* sont calculées à partir des variables pronostiques, en dehors de la partie dynamique du modèle. Ci-dessous sont détaillées trois variables diagnostiques d'AROME utilisées pendant la thèse :

- La **CAPE** est calculée à partir des variables de température et de l'humidité spécifique en simulatant, pour chaque colonne d'atmosphère, le trajet d'une particule suivant une transformation adiabatique puis pseudo-adiabatique à saturation (comme sur la Figure 1.2). On garde la CAPE associée à la particule la plus instable entre le sol et un niveau de pression égal à 70 % de la pression de surface, ce qui correspond environ aux trois premiers kilomètres. On parle donc aussi de MUCAPE (pour *Most Unstable CAPE*). L'entraînement d'air sec dans la particule est pris en compte via un coefficient fixe, ainsi que la libération de chaleur latente par congélation en-dessous de 0°C. Plus de détails sont disponibles dans [Groenemeijer et al. \(2019\)](#).
- Une **température de brillance** est simulée par le schéma RTTOV¹ ([Saunders et al., 2018](#)). D'abord conçu pour le sondeur du satellite américain Tiros, ce schéma est aujourd'hui adapté à de nombreux instruments. En entrée, il considère des profils verticaux de température et d'humidité spécifique ainsi que la température de surface. Pour accélérer le calcul, ces données sont simplement pondérées et combinées pour produire un rayonnement mesuré par un radiomètre virtuel, comme SEVIRI, et ce pour tous les canaux. Les coefficients de pondération sont calculés au préalable à partir de modèles sophistiqués de transfert radiatif, dits « raie par raie ».
- Les **réflectivités** telles qu'elles seraient mesurées par un radar sont simulées en chaque point de grille par un opérateur détaillé dans [Caumont et al. \(2006\)](#). Il repose sur la distribution estimée des diamètres de plusieurs hydrométéores, fonction des contenus spécifiques q_i , q_r , q_s et q_g . L'atténuation du signal est négligée. Le champ 2D utilisé durant la thèse correspond à la valeur maximale sur chaque profil vertical de réflectivités simulées, entre 0 et 3 km au-dessus du sol.

Les observations simulées sont indispensables aux algorithmes d'assimilation de données (voir prochaine partie) et très utiles pour rapprocher les sorties du modèle d'une réalité mesurable, que ce soit pour la prévision opérationnelle ([Manach, 2002](#)), l'évaluation de la PNT (p. ex. [Skinner et al. 2018](#)) ou l'étude de la convection à partir de simulations numériques.

1.5.5 L'assimilation de données

Principe

Toute prévision requiert un état initial $\mathbf{X}(t_0)$ appelé *analyse*. Celle-ci est obtenue en assimilant les données dont on dispose sur l'état actuel de l'atmosphère : des observations \mathbf{Y} et

1. Les données AROME étudiées pour la thèse correspondent à la version 11 de RTTOV entre 2018 et juin 2022 (cycles 42 et 43 d'AROME) et à la version 12 par la suite (cycle 46).

l'ébauche \mathbf{X}_b , une prévision récente valide à t_0 . Ces deux sources de données sont imparfaites. Les observations sont hétérogènes dans l'espace et le temps et présentent des erreurs liées à l'instrument et à la représentativité de la mesure. L'ébauche est homogène mais, comme toute prévision, elle est forcément éloignée de la réalité. L'analyse est donc la solution du problème d'optimisation $\mathbf{X}(t_0) = \min_{\mathbf{X}} J(\mathbf{X})$ où :

$$\begin{aligned} J(\mathbf{X}) &= \|\mathbf{X} - \mathbf{X}_b\|_{\mathbf{B}^{-1}}^2 + \|\mathbf{Y} - \mathcal{H}(\mathbf{X})\|_{\mathbf{R}^{-1}}^2 \\ &= (\mathbf{X} - \mathbf{X}_b)^T \mathbf{B}^{-1} (\mathbf{X} - \mathbf{X}_b) + (\mathbf{Y} - \mathcal{H}(\mathbf{X}))^T \mathbf{R}^{-1} (\mathbf{Y} - \mathcal{H}(\mathbf{X})) \end{aligned} \quad (1.6)$$

si l'assimilation est effectuée à un instant unique t_0 . \mathbf{X} comporte ici l'ensemble des variables pronostiques assimilées à t_0 , dites *variables de contrôle*, pour chaque point de grille du modèle. AROME en possède cinq (voir Table 1.2). \mathbf{X} est donc un vecteur de très grande dimension, de l'ordre de 10^8 pour AROME. Certaines variables pronostiques ne sont pas assimilées car leur relation avec des observations est trop complexe. Dans $\mathbf{X}(t_0)$, elles proviennent directement de l'ébauche.

Dans le membre de droite des équations 1.6, le premier terme revient à minimiser la différence entre l'analyse et l'ébauche, appelée *incrément*. Cette différence est pondérée par l'erreur estimée de l'ébauche (coefficients diagonaux de la matrice \mathbf{B} , appelée *matrice de covariances des erreurs d'ébauche*) et par les corrélations entre les variables en chaque point de grille (coefficients non diagonaux). Comme le montre Berre (2000), ces dernières permettent d'assurer une cohérence spatiale des champs analysés ainsi qu'une cohérence physique entre les différentes variables de contrôle. Jusqu'à présent, la matrice \mathbf{B} utilisée dans AROME est dite « climatologique », pré-calculée à partir d'un ensemble d'assimilation constitué de situations estivales et hivernales (Brousseau *et al.*, 2011).

Par le second terme, on minimise la différence entre les observations et l'état simulé qu'un *opérateur d'observation* \mathcal{H} convertit dans un équivalent observé. Cette différence s'appelle l'*innovation*. Elle est aussi pondérée par la *matrice de covariances des erreurs d'observation* \mathbf{R} . Celle-ci est généralement considérée comme diagonale, autrement dit les corrélations spatiales entre observations sont négligées. Un écrémage spatial est appliqué pour limiter les effets de cette hypothèse. Les corrélations inter-canaux de l'interféromètre IASI sont néanmoins prises en compte dans AROME.

La fonction J étant quadratique, elle admet un minimum que l'on trouve en résolvant l'équation $\nabla_{\mathbf{X}} J = 0$, laquelle nécessite les calculs du tangent-linéaire et de l'adjoint de chaque opérateur d'observation. La solution de cette équation est connue ; il s'agit du *BLUE* (*Best Linear Unbiased Estimate*). Or son calcul nécessite d'inverser et de stocker des matrices de très grande dimension, de l'ordre de 10^{16} (le carré de la dimension du vecteur \mathbf{X}) ce qui est impossible compte tenu des ressources informatiques. Plusieurs méthodes existent pour contourner le calcul direct du BLUE et sont revues dans Gustafsson *et al.* (2018). Pour AROME, l'approche *variationnelle 3D-Var incrémentale* mise en place dans le modèle ALADIN est toujours employée (Fischer *et al.*, 2005). Le minimum de la fonction J est ici approché par un *algorithme de descente du gradient*². À la différence d'un 4D-Var, toutes les observations

2. Cet algorithme sera expliqué au chapitre 2, partie 2.2.4.

effectuées dans l'intervalle $]t_0 - 30min ; t_0 + 30min]$ sont considérées valides à t_0 .

L'analyse sert ensuite de conditions initiales pour démarrer la prévision. Puisque certaines variables ne sont pas assimilées et proviennent directement de l'ébauche, des déséquilibres physiques peuvent exister entre les champs pronostiques sur les premiers pas de temps et y rendre la prévision inexploitable. Ce problème de *spin-up* est un véritable défi pour l'utilisation de la PNT en prévision immédiate, comme cela sera abordé dans la section 1.5.6.

Assimilation des données radar

Les données radar sont assimilées dans AROME depuis sa mise en opérationnel pour les vitesses radiales Doppler (Montmerle et Faccani, 2009) puis, trois ans plus tard, pour les réflectivités (Wattrelot *et al.*, 2014). En 2020 sont incorporées les données des pays limitrophes dans le cadre du programme européen OPERA (Martet *et al.*, 2022). Le radar fournit aujourd'hui près de 60 % des observations traitées (Figure 1.16), une proportion qui peut fortement augmenter lors des journées pluvieuses. Dans les zones échantillonnées, les réflectivités renseignent sur l'intensité des précipitations et les vitesses radiales permettent d'estimer la circulation de l'air, notamment les zones de convergence ou le cisaillement de basses couches. Ces deux paramètres sont donc pertinents pour l'étude de la convection (Sun *et al.*, 2014; Benjamin *et al.*, 2018).

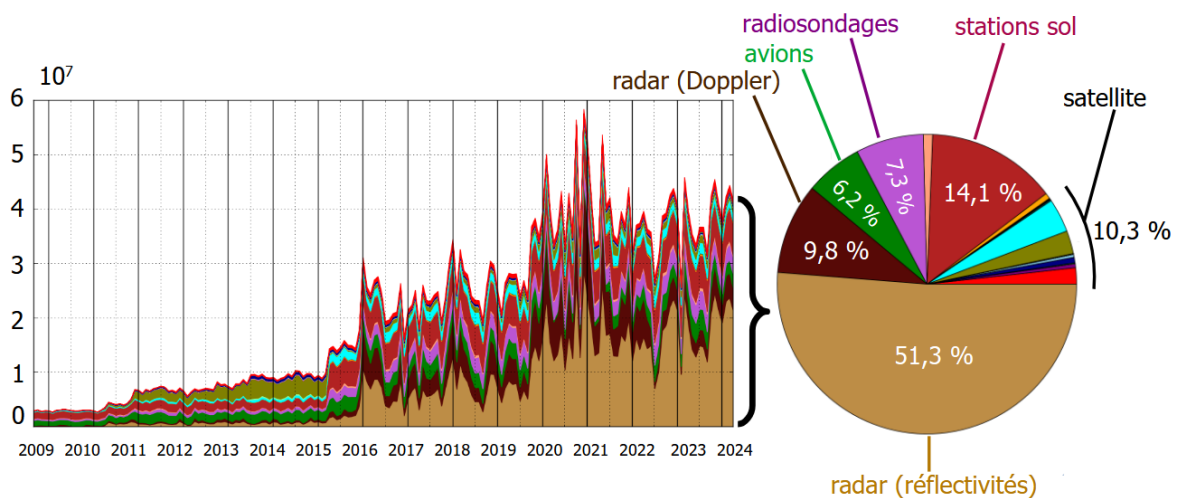


FIGURE 1.16 – Évolution du nombre mensuel d'observations utilisées pour l'assimilation dans AROME depuis sa mise en opérationnel (à gauche) et proportion des observations utilisées en avril 2024 (à droite). Adapté de Météo-France/DirOP/COMPAS.

La vitesse radiale est plus facilement assimilable car elle est directement reliée au vent, une variable de contrôle du modèle. Comme décrit par Montmerle et Faccani (2009), elle doit cependant être simulée par un opérateur d'observation *ad-hoc* qui prend en compte la géométrie de la mesure et le volume effectivement échantillonné. Le tangent-linéaire et

l'adjoint de cet opérateur ont également dû être développés.

L'assimilation des réflectivités (Rflc) est difficile car celles-ci dépendent non-linéairement des paramètres météorologiques (concentration et type d'hydrométéores) et l'opérateur d'observation requis pour les simuler demeure complexe. Des approches plus ou moins sophistiquées ont été développées afin d'assimiler tout ou partie de l'information disponible (pour plus de détails se référer à [Sun et al. 2014](#)). À Météo-France, on privilégie l'approche 1D+3DVar proposée par [Caumont et al. \(2010\)](#) et résumée dans [Mahfouf et al. \(2013\)](#). Elle se décompose en deux étapes :

- des profils d'humidité relative (RH) sont d'abord restitués grâce à une méthode bayésienne 1D (Figure 1.17). Celle-ci vise à combiner linéairement des profils de RH simulés par AROME dans un voisinage de 200 km, chacun étant pondéré par un poids qui dépend de la différence entre le profil de Rflc simulées correspondant (grâce à l'opérateur de [Caumont et al. 2006](#)) et le profil de Rflc observées ;
- ces profils de RH sont ensuite assimilés comme des pseudo-observations dans le 3DVar.

Plusieurs contrôles de qualité sont effectués pour filtrer les artefacts radar et s'assurer que le profil pseudo-observé de RH est cohérent avec l'observation initiale. Au final, la méthode permet de relocaliser des précipitations bien simulées mais au mauvais endroit. En revanche, elle ne permet pas d'en créer à partir de rien. En effet, si AROME reste sec, les profils de Rflc simulées sont trop éloignés des Rflc observées. Dans ce cas, le contrôle de qualité exclut l'observation candidate. S'il peut paraître restrictif, ce choix permet d'éviter l'incorporation de biais humide dans les prévisions.

1.5.6 Adaptation des modèles à la PI

Compte tenu de la prévisibilité limitée de l'atmosphère à l'échelle convective, l'usage de la PNT en PI nécessite un rappel régulier vers les observations ([Wang et al., 2017](#)). Les systèmes cyclés à mises à jour fréquentes sont la solution ([Sun et al., 2014](#)). On parle aussi de *RUC*, pour *Rapid Update Cycle*, du nom du système américain en service au début des années 2000 ([Benjamin et al., 2004](#)).

Un RUC est basé sur des assimilations régulières, typiquement toutes les une à trois heures, à partir des observations les plus récentes et d'une ébauche provenant de la dernière prévision. Comme détaillé dans [Brousseau et al. \(2016\)](#), la chaîne opérationnelle AROME-France est ainsi basée sur deux cycles distincts (Figure 1.18) :

- Un **cycle d'assimilation** horaire (le RUC). Celui-ci enchaîne à cadence horaire les assimilations 3D-Var et les prévisions 1 h qui servent d'ébauches aux réseaux suivants. Chacune de ces nouvelles prévisions est appelée *réseau* ou *run*. Pour le réseau à l'heure h , toutes les observations contenues dans la fenêtre $]h-30 \text{ min} ; h+30 \text{ min}]$ sont considérées. Ce système pallie l'absence de dimension temporelle dans le 3D-Var car la mise à jour horaire permet de réduire la fenêtre d'assimilation. Cependant, des observations ne sont effectivement exploitables qu'après un certain délai d'attente appelé *cut-off*, parfois de quelques heures,

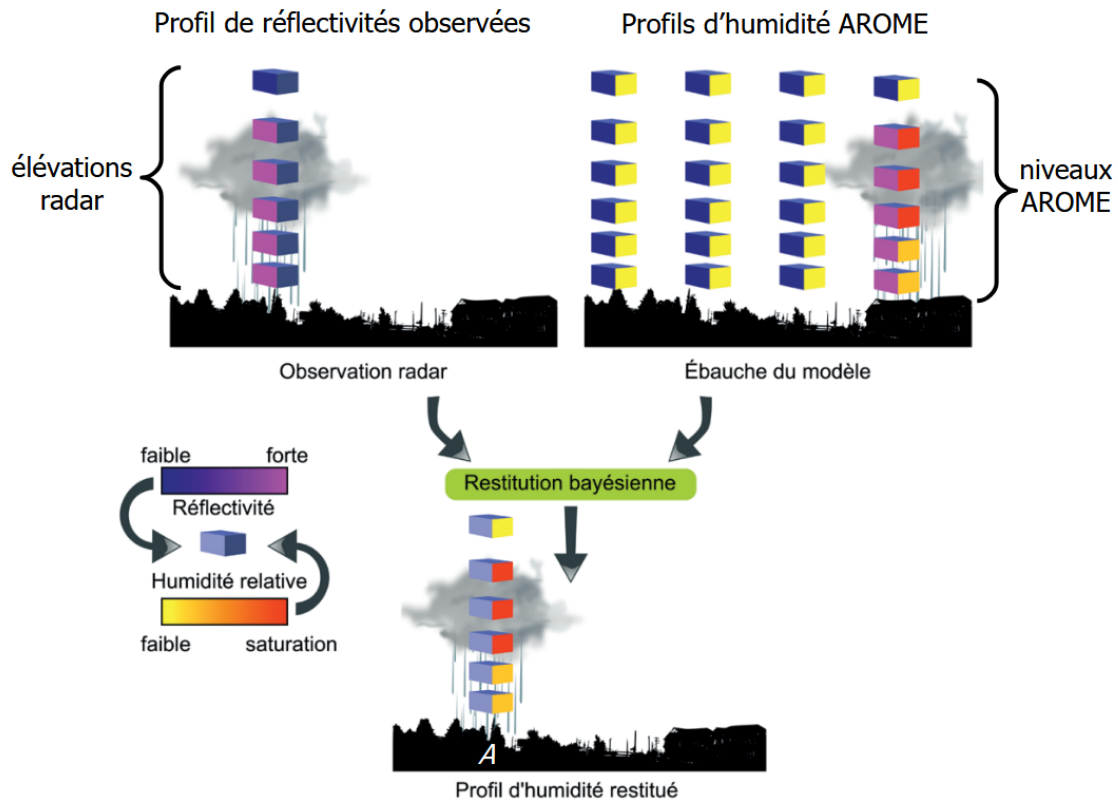


FIGURE 1.17 – Schéma décrivant la restitution d'un profil d'humidité pseudo-observé au point *A* par combinaison des profils d'humidité d'AROME alentour (face droite des cubes), pondérés par la différence entre les réflectivités simulées et observées (face gauche des cubes). Adapté de Mahfouf *et al.* (2013).

du fait du temps requis pour la réception, le traitement et la mise à disposition des données. Or ces observations, notamment satellite, permettent d'améliorer significativement l'analyse (Gustafsson *et al.*, 2018). Ce délai d'attente est nécessaire et acceptable dans une configuration de PNT. En revanche, il retarde le calcul des analyses AROME dont les heures de disponibilité sont ainsi très irrégulières tout au long de la journée (voir Figure 1.18).

- Un **cycle de production**. Il fournit des prévisions longues toutes les 3 h, jusqu'à 51 h d'échéance dans sa version actuelle. Celles-ci sont initialisées à partir des analyses du cycle d'assimilation. L'analyse du réseau h d'assimilation sert d'état initial à la prévision du réseau h de production. La prévision est aussi corrigée en fonction de l'analyse du réseau $h + 1$ d'assimilation grâce à la méthode de l'IAU (*Incremental Analysis Update*). Elle consiste à ajouter sur un certain nombre de pas de temps une portion de la différence (incrément) entre l'analyse de ce réseau $h + 1$ et son ébauche.

Cependant, trois problèmes freinent l'utilisation des RUC pour la PI opérationnelle.

- **Problème n°1 : des observations en retard**. Comme mentionné plus haut, le *cut-off*

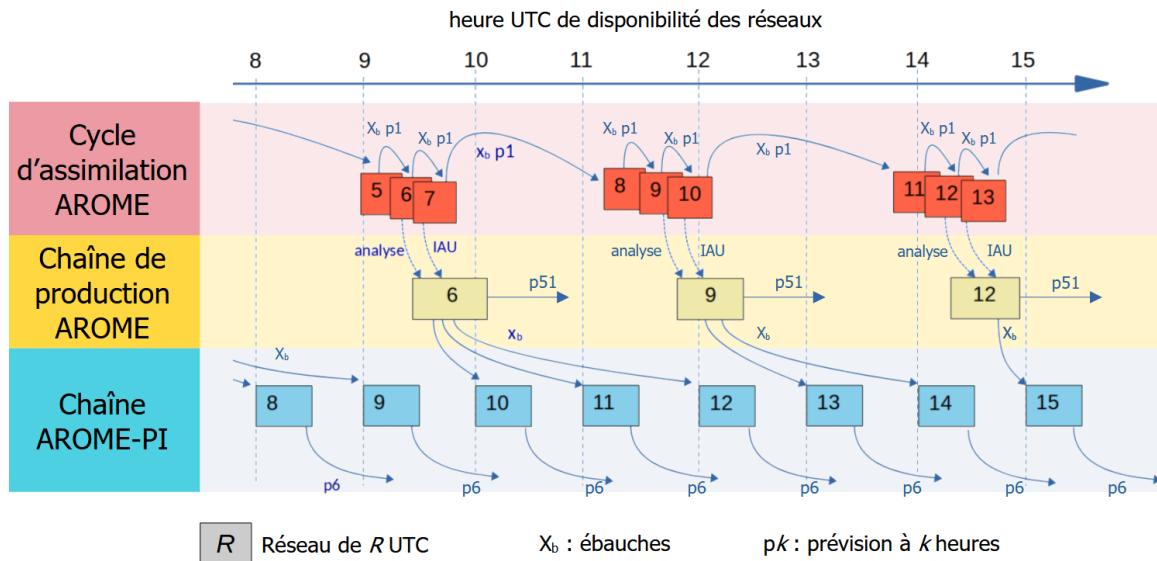


FIGURE 1.18 – Chaînes opérationnelles du modèle AROME en 2022. Schéma adapté de Thibaut Montmerle.

retarde la disponibilité des analyses et des prévisions. Selon le réseau AROME, il varie aujourd’hui entre 25 min et 4 h.

- **Problème n°2 : le temps de calcul** de l’assimilation puis de la prévision, notamment pour AROME dont le coût numérique est important.
- **Problème n°3 : le *spin-up***. Il désigne le temps nécessaire au modèle pour que les champs pronostiques analysés se mettent en équilibre avec les champs cyclés, directement hérités de l’ébauche, comme les quantités d’hydrométéores. Pour un modèle régional, le *spin-up* peut durer 1 à 2 h. Il a été raccourci à 45 min environ dans AROME grâce à un meilleur équilibre des champs analysés obtenu en calibrant la matrice \mathbf{B} depuis un ensemble d’assimilation (Brousseau *et al.*, 2016).

Face à ces contraintes, les services météorologiques doivent trouver un compromis entre la qualité de la prévision, la rapidité et la régularité de la mise à disposition (Bojinski *et al.*, 2023). À Météo-France, ce compromis est incarné par la chaîne AROME-PI (Figure 1.18) qui fournit toutes les heures une prévision à 6 h d’échéance. L’article de référence est de Auger *et al.* (2014) mais des modifications ont été apportées depuis. Aujourd’hui, AROME-PI traite les trois problèmes de la manière suivante.

- **Solution au problème n°1** : la fenêtre d’assimilation est réduite à $[h-10 \text{ min} ; h+10 \text{ min}]$. Les observations en retard ne sont donc pas considérées, notamment les données satellite. Par conséquent, les principales observations assimilées sont les mesures de surface ainsi que les vitesses radiales et les Rflc radar. En raison du manque d’observations, la chaîne AROME-PI n’est pas cyclée. Cela évite un appauvrissement des ébauches successives qui dégraderait la prévision dans le temps (Auger *et al.*, 2014). L’ébauche correspond donc à la prévision du dernier réseau disponible dans la chaîne de production d’AROME, laquelle

a bénéficié de son côté des nombreuses observations prises en compte dans le cycle d'assimilation. On peut donc voir AROME-PI comme une mise à jour de la dernière prévision AROME disponible.

- **Solution au problème n°2** : les prévisions sont accessibles 20 min seulement après l'heure du réseau. De plus, les champs de sortie sont disponibles à pas de 15 min plutôt que 1 h, ce qui permet un meilleur suivi temporel de la convection.
- **Solution aux problèmes n°3** : comme évoqué plus haut, les travaux de [Brousseau et al. \(2016\)](#) avaient déjà permis de réduire le *spin-up* dans la chaîne d'assimilation d'AROME. Avec AROME-PI, on considère aujourd'hui les prévisions exploitables dès 30 min d'échéance.

Des scores objectifs quantifient l'apport d'AROME-PI sur les prévisions de la chaîne de production utilisées comme ébauches et disponibles aux mêmes instants. La Figure 1.19 affiche les scores de contingence pour l'évènement « cumuls de précipitations supérieurs à 2 mm en 1 h », moyennés sur la France en 2022. AROME-PI améliore le taux de bonnes détections et réduit le taux de fausses alarmes de l'évènement sur toutes les échéances. Ses scores tendent toutefois à converger vers ceux d'AROME, l'impact positif de la mise à jour s'affaiblissant au fil des échéances. Des résultats similaires sont obtenus pour les rafales de vent (non montrés). D'autres configurations AROME-PI ont été testées : IAU sur les premiers pas de temps, cyclage des réseaux AROME-PI avec ou sans rappel sur les prévisions de la chaîne de production, etc. Cependant, aucune n'est parvenue à battre la configuration opérationnelle.

Par ailleurs, des scores calculés « point de grille par point de grille » reflètent la qualité générale du modèle mais ne sont pas toujours pertinents pour évaluer sa capacité à simuler des phénomènes convectifs particuliers. Pour cela, il vaut mieux identifier des objets dans les champs observés et simulés avant de les comparer via des scores adaptés ([Davis et al., 2009](#)).

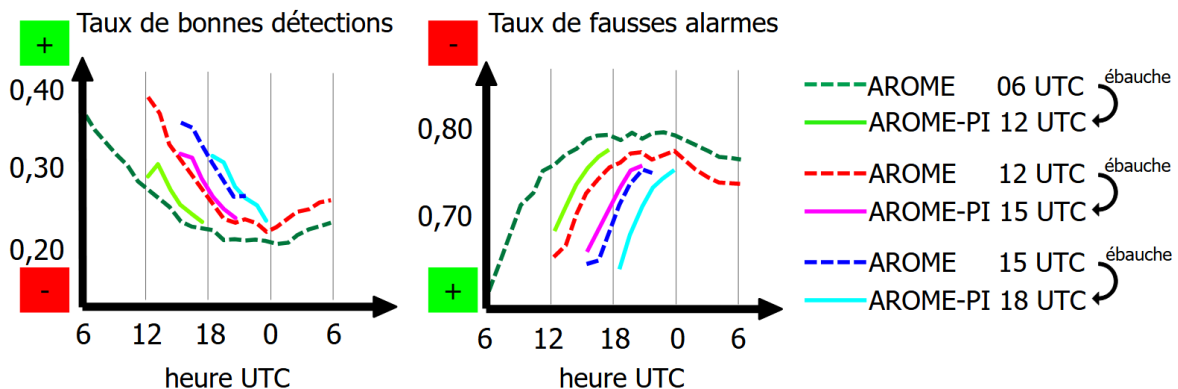


FIGURE 1.19 – Performances des prévisions AROME-PI (traits pleins) et des prévisions AROME utilisées comme ébauches (traits pointillés) en 2022 : (a) taux de bonnes détections et (b) taux de fausses alarmes pour les cumuls horaires de précipitations supérieurs à 2 mm. La référence est la lame d'eau ANTILOPE de Météo-France ([Laurantin, 2008](#)). Scores calculés par l'équipe DirOP/COMPAS de Météo-France.

1.5.7 L'approche ensembliste

Enfin, l'information probabiliste permet une meilleure prise en compte de l'incertitude intrinsèque aux phénomènes convectifs, des erreurs de prévision et d'analyse. L'approche dite *ensembliste* consiste à lancer, pour chaque réseau à t_0 , un ensemble de prévisions dont la distribution au temps $t > t_0$ est censée estimer l'incertitude sur l'état futur de l'atmosphère. Ces prévisions sont appelées *membres* et diffèrent par les perturbations ajoutées à l'analyse, au couplage sur les bords ou en surface et aux paramétrisations physiques. À Météo-France, le modèle de prévision d'ensemble basé sur AROME (PE-AROME) est typiquement utilisé pour les échéances supérieures à 12 h (p. ex. [Bouttier et al. 2016](#)). Il contient aujourd'hui 17 membres.

Cependant, la prévision d'ensemble représente un coût numérique difficilement compatible avec les délais et la haute fréquence des productions requis en PI. Une alternative consiste à générer un ensemble à partir des prévisions issues de réseaux successifs. En effet, si ces derniers sont suffisamment rapprochés, on peut interpréter chaque analyse comme un état perturbé des conditions initiales. On parle d'ensemble par *décalage temporel* ou *time-lagging*. Plusieurs applications apparaissent en PI :

- exploiter la moyenne de l'ensemble pour un paramètre particulier ;
- calculer des probabilités d'occurrence d'un phénomène convectif ou un dépassement de seuil de précipitations.
- proposer des visualisations synthétiques de la dispersion de l'ensemble via des cartes « confettis » (*paintballs*) où des objets orageux détectés dans les différents membres sont superposés sur la même figure, comme dans [Mounier et al. \(2022\)](#). Ce mode de représentation inspirera le produit synthétique développé pour les MCSs au chapitre 4.

Des ensembles par *décalage temporel* ont déjà été expérimentés. [Lu et al. \(2007\)](#) évaluent un ensemble composé des 12 derniers réseaux du modèle RUC. La moyenne de l'ensemble est meilleure que la prévision déterministe du dernier réseau pour la prévision à 3 h de paramètres synoptiques. [Raynaud et al. \(2015\)](#) démontrent aussi la plus-value de cette approche pour les prévisions de précipitations à partir d'un super-ensemble composé des trois derniers réseaux de la PE-AROME, néanmoins difficilement exploitables en PI. [Osinski et Bouttier \(2018\)](#) réunissent les 6 derniers réseaux AROME-PI pour une prévision des fortes réflectivités à destination de l'aviation. Cet ensemble est encore étendu par la prise en compte d'une tolérance temporelle, en sélectionnant pour chaque échéance t les prévisions à $t-15$, t et $t+15$ min de chaque réseau, et par l'ajout de nouveaux membres issus des dernières prévisions du cycle de production AROME et de la PE-AROME. Les performances restent modestes par rapport à celles d'un seul réseau mais elles sont pertinentes dans un secteur économiquement sensible aux prévisions météorologiques. Par ailleurs, des travaux sont en cours à Météo-France pour compléter le produit grand public *Pluie dans l'Heure*. Aujourd'hui, ce dernier prévoit de façon déterministe un risque de pluie sur chaque commune à 1 h. Ses échéances seront bientôt étendues à 3 h grâce aux sorties probabilistes d'un pseudo-ensemble de prévisions PIAF successives, fusionnant extrapolation d'image et équivalent prévu par AROME-PI (voir partie 1.2.1), et de prévisions PIAF perturbées spatialement.

1.5.8 Comportement d'AROME pour la prévision des MCSs

Par sa résolution kilométrique et son jeu d'équations non-hydrostatiques, AROME est censé représenter l'évolution de la convection à mésoéchelle. D'après [Brousseau *et al.* \(2016\)](#), le nombre de grands systèmes convectifs détectés dans les champs prévus (objets de Rflc > 40 dBZ dont l'aire dépasse 1000 km²) est similaire à celui qui est observé dans les images radar. Par ailleurs, il n'existe pas d'étude rapportant de manière exhaustive les performances d'AROME pour la prévision des MCSs. [Fourrié *et al.* \(2015\)](#) soulignent ses capacités à simuler un MCS méditerranéen lors de la campagne HyMeX. Le modèle reproduit également le jet d'afflux arrière, la plage froide et le tourbillon de mésoéchelle associé à un MCS observé en Pologne ([Kolonko *et al.*, 2022](#)) ainsi que l'écho arqué qui a frappé la Corse en août 2022 ([Kreitz, 2024](#)).

Cependant, quelques biais ont été constatés depuis la mise en opérationnel. AROME sous-estime l'extension de la région stratiforme, comme noté par [Caumont *et al.* \(2006\)](#) sur un cas méditerranéen. Il tend aussi à générer des plages froides trop importantes, notamment quand la couche limite est sèche ([Brousseau *et al.*, 2016](#)).

1.6 Projet et objectifs de la thèse

La section 1.1 a rappelé les enjeux associés aux MCSs en France et les sections suivantes ont présenté les approches existantes pour la prévision immédiate de la convection. En particulier, l'approche « objet » montre trois avantages : (1) elle est adaptée au suivi de structures cohérentes comme les MCSs, (2) elle facilite la fusion d'une grande quantité d'informations synthétisées sous la forme d'attributs, (3) elle est appréciée des prévisionnistes, un atout pour développer un outil de PI utile à l'opérationnel. Comme énoncé dans les trois parties suivantes, cette mise en contexte du sujet permet d'affiner les objectifs de la thèse et de préciser la méthodologie employée pour y répondre.

1.6.1 Objectif du chapitre 2 : développer un réseau de neurones convolutifs pour la détection des MCSs

Les réseaux de neurones convolutifs (RNC) sont conçus pour reconnaître des motifs particuliers à l'intérieur des images. Des études récentes, mentionnées dans la partie 1.4.1, ont souligné la pertinence des RNC pour la détection des structures météorologiques comme les cyclones tropicaux, les fronts synoptiques ou les échos arqués. Le chapitre 2 montre qu'un RNC est aussi adapté à l'identification des MCSs dans des images observées et des champs prévus par AROME. Plusieurs raisons motivent ce choix.

- **Une méthode supposée plus robuste.** Les principaux paramètres du RNC sont appris de manière statistique à partir d'un grand nombre de données. C'est la différence majeure avec la plupart des méthodes de détection décrites dans la partie 1.4. Ces dernières s'appuient généralement sur des seuils arbitraires qui, bien que guidés par une connaissance

du phénomène ou des études climatologiques préalables, ne sont pas forcément adaptés à toutes les situations. De plus, un RNC est potentiellement moins susceptible aux changements de calibration impactant les données, notamment les observations, car ses règles de décision sont plus diversifiées. Par exemple, celles-ci peuvent s'appuyer sur la reconnaissance de motifs 2D comme des gradients ou des textures qui, comparés à la valeur même des données, sont moins affectés par de tels changements.

- **Traitement simultané de plusieurs types de données.** Un RNC peut exploiter l'information issue de plusieurs sources de données, des images radar et satellite typiquement, alors qu'une approche par seuillage est généralement conçue pour n'en traiter qu'une seule. Certes, des post-traitements peuvent introduire des données complémentaires. [Chen et al. \(2020\)](#) et [Feng et al. \(2021\)](#) définissent des MCSs dans des images TB mais conservent seulement ceux dont les précipitations associées répondent à certains critères. Malgré la complexité des méthodes, la combinaison des données reste limitée.
- **Extraction de caractéristiques 2D.** Les poids du RNC ont une organisation bidimensionnelle, leur permettant d'extraire les caractéristiques spatiales des images d'entrée. Un RNC peut donc être sensible au contexte de mésoéchelle ainsi qu'à des formes ou des contrastes, autant d'éléments permettant de différencier un MCS d'autres systèmes météorologiques.
- **Gestion des non-linéarités.** Grâce à des fonctions d'activation non-linéaires, les informations issues de plusieurs sources de données et de plusieurs zones de l'image sont combinées selon des règles qui dépendent étroitement du contexte.
- **Rapidité à l'exécution.** Une fois développé, l'algorithme s'exécute très rapidement, une condition nécessaire pour une utilisation en PI.

Pour faciliter le développement du RNC, seules des images 2D de réflectivités (Rflc) et de température de brillance infrarouge (TB) sont considérées en entrée. Ces variables sont des marqueurs de la convection orageuse et sont donc fréquemment employées pour identifier des objets MCS, comme indiqué dans la partie 1.4 et la Table 1.1. Les fortes Rflc témoignent souvent de précipitations convectives tandis que les faibles valeurs de TB sont associées à des sommets nuageux froids, donc élevés, caractérisant l'enclume des cumulonimbus. Par ailleurs, ces variables sont complémentaires. Leur usage simultané permet de limiter la détection erronée d'objets « non MCS », par exemple des précipitations synoptiques intenses mais non convectives (forte Rflc mais sommets nuageux plus chauds) ou de larges nuages cirriformes en altitude (Rflc nulles mais TB très basse). Enfin, ces champs sont disponibles à la fois dans les observations et les sorties d'AROME, ce qui permet d'adapter la méthode aux MCSs observés et simulés.

Par ailleurs, des contraintes pratiques conditionnent le recours à un réseau de neurones convolutifs. Ses performances dépendent en grande partie de la base d'entraînement, du nombre et de la qualité des images qu'elle contient. Pour créer la référence, ces images devront être analysées une par une en y identifiant les MCSs à la main. Ce travail d'annotation, subjectif et fastidieux, est un défi majeur que les avantages présentés dans cette section encouragent à relever.

1.6.2 Objectif du chapitre 3 : étudier le cycle de vie des MCSs en France

La partie 1.4 a décrit plusieurs approches pour anticiper le comportement d'un objet convectif sur les prochaines échéances : extrapolation du contour, évolution des attributs paramétrée par leur tendance passée, fusion de données observées et de PNT via un modèle statistique. Comme dans [Kolios et Feidas \(2012a\)](#), une étude préalable du phénomène permet d'aiguiller la stratégie à adopter. C'est le deuxième objectif de la thèse.

La méthode mise au point au chapitre 2 permet d'identifier des MCSs sur une sélection de situations fortement convectives entre 2018 et 2022. Les systèmes sont étudiés à partir d'images observées mais aussi de simulations AROME afin d'explorer leur environnement dynamique et thermodynamique sur toute la troposphère. Il apparaît donc nécessaire d'évaluer au préalable les capacités du modèle AROME à représenter le cycle de vie des MCSs de façon réaliste. En somme, ce chapitre doit répondre à trois sous-objectifs :

1. **Caractériser les différentes phases d'évolution des MCSs en France**, notamment à l'aide de données quantifiant les précipitations (Rflc) ou l'extension verticale du phénomène (TB). Les résultats sont comparés à des climatologies de référence.
2. **Évaluer AROME** en comparant d'un point de vue statistique le cycle de vie des MCSs simulés avec celui des MCSs observés. On complète ainsi les rares travaux déjà menés sur le sujet (voir partie 1.5.8) afin d'améliorer l'appréhension du modèle pour la prévision des MCSs.
3. **Identifier dans l'environnement des MCSs les paramètres qui ont le plus d'impact sur leur cycle de vie**. Plusieurs auteurs se sont penchés sur l'environnement de formation des MCSs aux moyennes latitudes (voir section 1.1). Cependant, seules quelques études américaines se sont intéressées à l'influence de l'environnement sur le cycle de vie. Depuis la théorie RKW, fondée sur l'équilibre entre plage froide et cisaillement de basses couches (partie 1.1.4), de nouveaux ingrédients ont été mis en évidence pour expliquer le maintien des MCSs : force et direction du courant d'afflux, cisaillement d'altitude, persistance d'une masse d'air très instable (partie 1.1.4). Ces ingrédients valent pour des MCSs linéaires évoluant sur le centre des États-Unis. Il est donc difficile de les transposer directement à l'Europe de l'ouest dont le relief et le climat diffèrent des conditions rencontrées dans les Grandes Plaines américaines. À l'exception des systèmes méditerranéens, les MCSs européens ont reçu peu d'attention sur la façon dont l'environnement influence leur cycle de vie. Le dernier sous-objectif cherche à combler une partie de ce vide.

Les réponses apportées doivent permettre de renforcer la compréhension des MCSs en France et de proposer des stratégies de PI adaptées aux données disponibles : observations radar, satellite et modèles de PNT.

1.6.3 Objectif du chapitre 4 : évaluer l'apport du modèle AROME pour la PI des MCSs

La section 1.5 a décrit le potentiel et les limitations de la PNT pour la PI de la convection. Un modèle non-hydrostatique, une grille à résolution kilométrique et une assimilation fréquente des observations cherchent à décrire l'état de l'atmosphère avec la meilleure précision afin de prévoir la dynamique du phénomène. Une prévision exploitable doit aussi être disponible rapidement. Pour AROME-PI, cette contrainte impose une réduction du *cut-off*, qui restreint le nombre d'observations assimilées, et l'absence de cyclage entre les réseaux, les ébauches provenant des prévisions de la chaîne de production AROME à plusieurs heures d'échéance. Les scores standards calculés sur les paramètres de surface montrent ainsi que la plus-value d'AROME-PI se vérifie surtout pour les premières heures de prévision.

Cependant, des études récentes introduites dans la partie 1.5.7 montrent que l'approche ensembliste par décalage temporel des réseaux peut améliorer les performances à moindre coût. Aucun travail n'a toutefois spécifiquement démontré la pertinence d'une configuration AROME déterministe ou ensembliste pour la PI des MCSs.

Au chapitre 4, les MCS observés sur une sélection de situations convectives sont comparés objectivement aux MCSs identifiés dans les prévisions AROME-PI valides aux mêmes dates. Trois objectifs sont ainsi définis :

1. quantifier l'apport de la prévision AROME-PI sur une simple extrapolation des objets détectés dans les observations ;
2. quantifier l'apport d'AROME-PI par rapport à la chaîne de production AROME pour la prévision des MCSs ;
3. comparer les performances des réseaux AROME-PI consécutifs, valides au même instant, afin d'estimer la pertinence d'un ensemble de réseaux AROME-PI pour la prévision probabiliste des MCSs.

Détection des MCSs par réseaux de neurones convolutifs

Sommaire

2.1	Introduction	70
2.2	Comprendre le fonctionnement du U-Net	70
2.2.1	De l' <i>IA</i> au <i>deep learning</i> : précisions de vocabulaire	70
2.2.2	Réseau de neurones convolutifs	71
2.2.3	Architecture du U-Net	75
2.2.4	Le processus d'entraînement	81
2.3	Développement d'un U-Net pour la détection des MCSs dans des images simulées par AROME	85
2.3.1	Constitution des jeux de données	85
2.3.2	Analyse des jeux de données et normalisation	87
2.3.3	Préréglage des hyperparamètres	90
2.3.4	Sélection de la « meilleure » configuration	95
2.3.5	Analyse du U-Net sélectionné	98
2.4	Évaluation et comparaison avec d'autres méthodes de segmentation d'images	102
2.4.1	Méthode alternative n°1 : un simple seuillage	103
2.4.2	Méthode alternative n°2 : algorithme <i>watershed</i>	103
2.4.3	Méthode alternative n°3 : identification à deux rayons de recherche	103
2.4.4	Comparaison objective sur le jeu de test	105
2.4.5	Comparaison sur des études de cas	107
2.5	Un second U-Net dédié aux images observées	109
2.5.1	Jeux de données d'observation	110
2.5.2	Réglage des hyperparamètres	111
2.5.3	Évaluation du U-Net OBS	112
2.6	Conclusions et perspectives	115

2.1 Introduction

Un réseau de neurones convolutifs (RNC) d'architecture « U-Net » est développé pour détecter des MCSs dans des images radar et satellite observées ou simulées par le modèle AROME. Les données considérées sont les réflectivités (ci-après abrégées Rflc) et la température de brillance du canal infrarouge 10,8 μm (ci-après abrégée TB). La description et l'évaluation de cette approche statistique font l'objet de ce chapitre.

Dans la section 2.2 est décrit le fonctionnement du U-Net, l'architecture de RNC utilisée ici. Une première application aux images simulées par AROME est décrite dans la section 2.3, puis évaluée et comparée à des méthodes non statistiques dans la section 2.4. Adaptée de la précédente, une deuxième application aux images observées est introduite dans la section 2.5.

2.2 Comprendre le fonctionnement du U-Net

2.2.1 De l'IA au *deep learning* : précisions de vocabulaire

La détection automatique de MCSs dans des images météorologiques est une tâche relevant de l'*intelligence artificielle* (IA). Bien que largement employée, cette expression est ambiguë car la définition précise de l'*intelligence* ne fait pas consensus (Legg et Hutter, 2007). D'après un bulletin du [Ministère de l'Enseignement supérieur, de la Recherche et de l'Innovation \(2019\)](#), l'IA vise à développer des logiciels capables d'imiter des mécanismes de réflexion humaine. Legg et Hutter (2007) insistent notamment sur la capacité d'adaptation à des environnements différents ou, dans un cadre algorithmique, à des données variables en entrée. De tels logiciels encodent des fonctions qui, à partir d'une ou plusieurs données d'entrée X , renvoient une ou plusieurs données de sortie Y . Ces fonctions sont dotées de *paramètres* qui peuvent être fixés par un programmeur humain à partir de ses connaissances préalables sur le sujet — c'est l'approche « symbolique » de l'IA — ou bien ajustés automatiquement. C'est le principe de l'*apprentissage automatique* (*Machine Learning*) dont la première démonstration est attribuée à Rosenblatt (1958). Dans le cas de l'apprentissage automatique *supervisé*, la fonction est exécutée sur un ensemble de données d'entrée et la confrontation des sorties obtenues avec des « sorties » de référence permet de modifier les paramètres de manière itérative en vue d'améliorer les performances de l'algorithme. On dit que les paramètres sont *entraînables*.

Opéré sur un grand nombre de données, l'apprentissage automatique peut traiter des problèmes complexes et fixer les paramètres de fonctions à priori inconnues. Avec la multiplication des observations et des champs numériques prévus ou réanalysés, la météorologie est une discipline riche en données. Son sujet d'étude, l'atmosphère et la convection en particulier, est aussi très complexe, régi par une dynamique non-linéaire. L'apprentissage automatique y est donc fréquemment employé, par exemple pour prévoir l'évolution d'objets orageux à partir de l'observation de leurs attributs (McGovern *et al.* 2017; Hamann *et al.* 2019, voir partie

1.4.3). [McGovern et al. \(2023\)](#) propose une revue des applications récentes de l'apprentissage automatique pour le suivi et la prévision de la convection.

Dans le langage courant, l'expression *IA* fait souvent directement référence à l'apprentissage profond (*Deep Learning*). Il s'agit d'une branche de l'apprentissage automatique où la fonction à paramétrer est constituée de plusieurs couches d'opérations, généralement organisées en *réseau de neurones artificiels*.

2.2.2 Réseau de neurones convolutifs

L'élément de base : le neurone

La plupart des méthodes d'apprentissage profond se basent sur le *neurone artificiel*, schématisé sur la Figure 2.1a. Cette fonction élémentaire combine de façon linéaire des entrées numériques scalaires x_i , en assignant un *poids* w_i à chacune d'elle. Une autre valeur scalaire, le *biais* b , est ajoutée à cette somme pondérée des x_i puis une *fonction d'activation* non-linéaire σ est appliquée au résultat ([Nielsen, 2015](#)). Mathématiquement, la fonction du neurone s'écrit :

$$\sigma \left(\sum_i (w_i x_i) + b \right)$$

La non-linéarité de la fonction d'activation signifie qu'une petite variation de la somme pondérée des x_i et du biais peut produire une valeur très différente en sortie. Le neurone est d'autant plus *activé* que sa sortie est grande.

Les réseaux de neurones

Dans les réseaux de neurones *entièrement connectés*, les neurones sont organisés en couches successives (Figure 2.1b). Les neurones d'une même couche ne sont pas connectés mais combinent les sorties de chaque neurone de la couche précédente. Par convention, la première couche est constituée des données d'entrée et la dernière couche des données de sortie. Les couches intermédiaires sont dites *cachées*; plus il y en a, plus le réseau est *profond*.

Chaque connexion que le neurone j tisse avec les neurones i de la couche précédente est affectée d'un poids w_{ij} . Au neurone j est également associé un biais b_j . Tous les poids w_{ij} et les biais b_j du réseau constituent les *paramètres* de ce dernier. Ils sont déterminés automatiquement lors du processus d'apprentissage qui sera détaillé dans la section 2.2.4.

Par exemple, [Alexiuk et al. \(2000\)](#) ont développé un réseau de neurones afin de déterminer si des objets détectés dans l'image radar étaient associés à l'un des 4 épiphénomènes redoutés : grêle, fortes pluies, vent violent et tornade. Les données d'entrée forment un vecteur de 22 attributs scalaires de l'objet (taille, vitesse, divers indices de convection, etc) et la sortie est

un vecteur à 4 composantes, chacune d'elle indiquant la probabilité de comporter un des 4 épiphénomènes. Des approches analogues ont été suivies par Lakshmanan et Smith (2009) et Lagerquist *et al.* (2017) pour la prévision de foudre et de fortes rafales de vent respectivement.

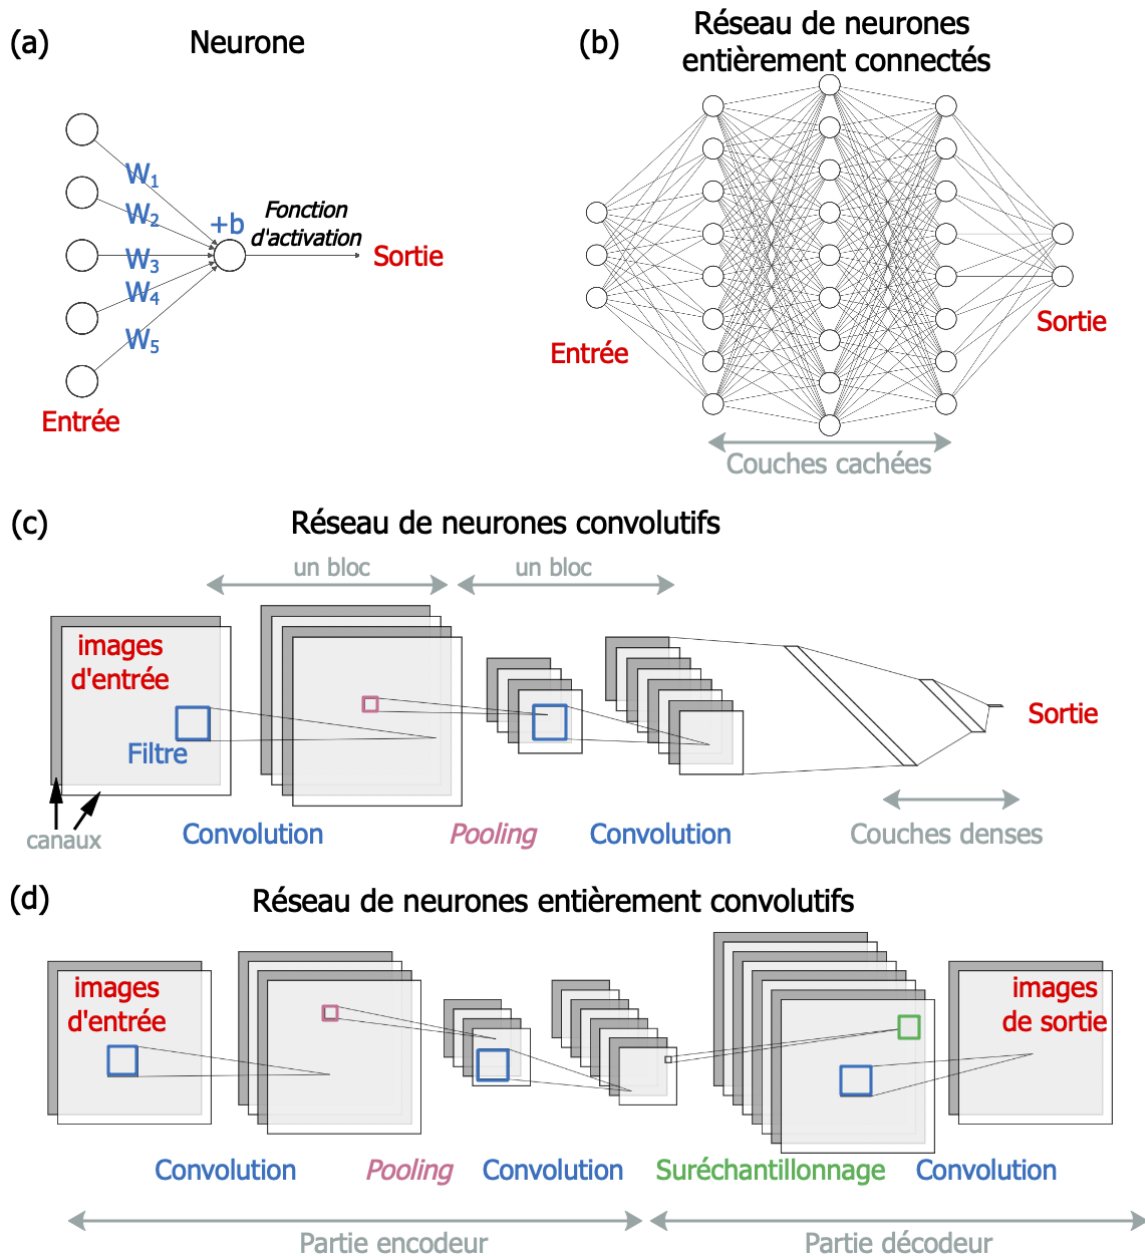


FIGURE 2.1 – Vocabulaire et architectures de l'apprentissage profond. Les schémas ont été créés à partir du site <http://alexlenail.me/NN-SVG/LeNet.html>.

Les réseaux de neurones sont également utiles pour le traitement d'images dont les applications en météorologie sont multiples (Ebert-Uphoff et Hilburn, 2020) :

— **Classification d'images**. Il s'agit par exemple d'associer des images satellite à une classe

d'orage « intense » ou « non intense » (Cintineo *et al.*, 2020b).

- **Segmentation d'images.** L'algorithme découpe l'image en différentes zones, chacune d'elles correspondant à une classe différente : « écho arqué » ou non (Mounier *et al.*, 2022), « cyclone » ou non (Kumler-Bonfanti *et al.*, 2020), etc.
- **Émulation d'images.** On cherche à produire un type d'image à partir d'un autre, par exemple un indicateur de convection (Lee *et al.*, 2021) ou un champ de réflectivités (Berthomier et Perier, 2023) à partir d'images satellite dans l'infrarouge, application utile pour les régions dépourvues de radars.
- **Prévision.** On prévoit par exemple un risque de grêle (GagneII *et al.*, 2019) ou de tornade (Lagerquist *et al.*, 2020) à une heure d'échéance à partir d'images centrées sur des objets orageux. La sortie peut aussi être une image, notamment lorsqu'on prévoit l'évolution d'un champ à partir d'une séquence temporelle observée du même champ, à laquelle on peut aussi ajouter d'autres prédicteurs. Cette approche est courante pour la prévision immédiate de réflectivités (Ravuri *et al.*, 2021; Leinonen *et al.*, 2023a).

L'objet de ce chapitre relève de la **segmentation d'images** car il s'agit de distinguer les pixels appartenant à la classe « MCS » des autres pixels « non MCS ». Comme pour chaque étude mentionnée ci-dessus, l'architecture qui s'impose est un *réseau de neurones convolutifs*.

Les réseaux de neurones convolutifs

Les réseaux de neurones entièrement connectés peuvent traiter n'importe quelle donnée d'entrée, du moment que celle-ci prend la forme d'un vecteur (donnée 1D). Ainsi, pour appliquer ce type de réseau à une donnée 2D comme une image, il faut que celle-ci soit préalablement « aplatie ». Une image de $L \times H$ pixels donnera par exemple un vecteur de $L \times H$ composantes. Ce procédé soulève trois problèmes : (1) l'information 2D est dégradée alors qu'elle pourrait servir à l'interprétation de l'image, notamment via la reconnaissance de contours ou de contrastes ; (2) puisque les poids sont liés à chaque composante du vecteur, les performances du réseau sont sensibles à la moindre déformation ou translation de l'image d'entrée qui modifie l'agencement des composantes ; (3) pour une image, le vecteur de $L \times H$ composantes est de très grande dimension, ce qui multiplie le nombre de paramètres entraînaibles, complexifie le réseau et augmente le risque de surapprentissage. Les performances du réseau de neurones s'en trouvent donc limitées.

Pour palier ces trois problèmes, LeCun *et al.* (1989, 1998) introduisent le *réseau de neurones convolutifs* (RNC, Figure 2.1c,d). Dans un RNC, les poids connectant les neurones de deux couches successives sont partagés entre tous les neurones de ces couches. De plus, la disposition des neurones respecte la topologie des données d'entrée. S'il s'agit d'images, les neurones sont disposés sur des plans. Ceux-ci peuvent être assimilés à des images dont les pixels sont les neurones qui le composent. Les poids sont alors organisés sous forme de matrices $n \times n$ appelées *filtres* ou *noyaux* (auxquelles s'ajoute le biais). Pour une couche convolutive donnée, le filtre parcourt les pixels de positions (x, y) sur l'image en entrée. Les $n \times n$ pixels alentour sont alors transformés pour donner le pixel de position (x, y) sur l'image en sortie.

L'opération correspondante est appelée « convolution », d'où le nom du réseau. Ses détails seront fournis dans la section 2.2.3 (Figure 2.4). Les filtres sont typiquement initialisés avec des poids aléatoires. Cependant, au terme de l'apprentissage, la disposition des poids ajustés dans chaque filtre peut rendre sa sortie sensible à certaines caractéristiques de l'image d'entrée, comme des contrastes, des maxima, etc. Puisque les filtres sont partagés entre tous les pixels d'une couche, une même caractéristique peut être extraite sur plusieurs régions de l'image. Les images générées par les filtres de convolution sont donc appelées *cartes de caractéristiques* (*feature maps*). Une couche de convolution donnée peut comprendre plusieurs filtres $n \times n$ générant autant de cartes de caractéristiques en sortie, chacun pouvant extraire une caractéristique différente sur l'image traitée. Par ailleurs, lorsqu'il y a plusieurs images d'entrée, le filtre est constitué d'autant de *canaux* $n \times n$, chaque canal s'appliquant à une image.

À la différence d'un réseau entièrement convolutif, les poids ne dépendent pas des positions de chaque pixel car les filtres sont partagés entre tous les pixels de l'image en entrée. Le réseau est donc invariant aux translations des images. Le partage des poids réduit aussi considérablement le nombre de paramètres entraînaibles.

Des opérations de *regroupement* (on parlera plutôt de *pooling*) peuvent intervenir entre plusieurs couches de convolution et diminuent la dimension des images. Leur rôle est triple : (1) ne conserver que l'information la plus « pertinente », (2) permettre aux filtres des couches suivantes de connecter des régions alors éloignées sur l'image initiale, (3) réduire la quantité de données à traiter, ce qui facilite l'apprentissage. La répétition de ces opérations de convolution et de *pooling* encode l'information en de nombreuses petites images. Chaque pixel contient maintenant une information abstraite caractérisant les données d'entrée. Le traitement qui leur est appliqué dépend du type de sortie souhaitée :

- Si la sortie est une valeur unique, typiquement une classe qu'on veut attribuer à une image d'entrée, les images obtenues sont aplaties et concaténées en un seul vecteur. Celui-ci est alors traité par un réseau de neurones entièrement connectés qui s'intègre dans le RNC sous le nom de *couches denses* (Figure 2.1c). Ce type d'architecture est très performante en reconnaissance d'image, comme l'a prouvé le réseau AlexNet (Krizhevsky *et al.*, 2012) dont le succès a largement contribué à la popularité des RNC.
- Si la sortie est aussi une image, par exemple une image segmentée, il faut dès lors inverser le processus et obtenir les dimensions souhaitées tout en conservant l'information pertinente et abstraite issue de l'encodage. Cela est permis par des opérations de suréchantillonnage (Figure 2.1d). De tels réseaux sont dits *entièrement convolutifs* (*fully convolutional networks*, Long *et al.* 2014).

Le choix d'un RNC entièrement convolutifs s'impose alors pour la détection de phénomènes dans des images météorologiques. Yuan *et al.* (2021) proposent une revue des architectures développées depuis 2010. Parmi elles, le U-Net (Ronneberger *et al.*, 2015) est sélectionné afin d'identifier les MCSs dans les images de Rf1c et de TB. Deux raisons motivent ce choix. D'abord, la base de référence utilisée pour l'apprentissage devra être construite à la main, en annotant des MCSs analysés individuellement sur une série d'images. Ce processus chronophage restreindra la taille de la base d'apprentissage. Or le U-Net est réputé pour ses

performances sur de petits jeux de données (Ronneberger *et al.*, 2015). Par ailleurs, le U-Net est fréquemment employé pour identifier des objets dans des images météorologiques. Parmi les études citées à ce sujet dans la partie 1.4.1, Kumler-Bonfanti *et al.* (2020) et Mounier *et al.* (2022) soulignent les performances d’une telle architecture.

2.2.3 Architecture du U-Net

L’architecture du U-Net est ici décrite en s’appuyant sur l’exemple du RNC élaboré dans le cadre de cette thèse (voir section 2.3). Elle est illustrée sur la Figure 2.2. Malgré quelques adaptations, elle suit le schéma original mis au point par Ronneberger *et al.* (2015) pour l’identification de cellules dans l’imagerie médicale. Elle se distingue par :

- une partie *encodeur* et une partie *décodeur* symétriques, conférant au réseau une forme de « U » ;
- des opérations de copie et de concaténation des images de la partie *encodeur* dans les blocs correspondants de la partie *décodeur*.

Les parties *encodeur* et *décodeur* sont composées de plusieurs couches de convolutions regroupées en *blocs*, chaque *bloc* étant séparé par une opération de *pooling* (regroupement) ou de *up-sampling* (suréchantillonnage). Par abus de langage, on parlera aussi de « couche » pour désigner ces deux opérations. Dernière précision de vocabulaire : les images d’entrée ainsi que les images générées par les couches du réseau sont parfois nommées sous le seul nom d’*Image*, et le terme de *canaux* (*channels*) désigne alors les différentes images qui composent cette *Image* (voir Figure 2.1d). Par exemple, l’*Image* d’entrée ici considérée est constituée de 2 canaux : une image de Rflc et une image de TB. Par simplicité, on continuera de parler d’images (« i » minuscule) pour se référer aux canaux et d’*Image* (« I » majuscule) pour désigner l’ensemble.

Partie *encodeur*

Le rôle de la partie *encodeur* est d’extraire dans les images d’entrée les caractéristiques utiles pour l’identification des MCSs. La Figure 2.3 en décrit le principe pour les trois premières opérations du U-Net (zoom n°1 de la Figure 2.2).

Les images d’entrée sont d’abord normalisées afin de concentrer les données dans un intervalle de valeurs raisonnables, typiquement entre 0 et 1. Le réseau est également initialisé avec des poids proches de 0. Cela limite les valeurs des neurones en sortie des couches de convolution, avec pour conséquence un apprentissage plus rapide et plus efficace. En effet, le produit de poids et de données d’entrée trop importants peut poser plusieurs problèmes, notamment : (1) générer des valeurs qui dépassent la limite de précision machine ; (2) accroître indûment la sensibilité du réseau et entraîner des mises à jour excessives qui freinent la convergence de la fonction coût vers un minimum (voir section 2.2.4). De plus, la normalisation permet de concentrer les données des différents prédicteurs dans un intervalle de valeurs

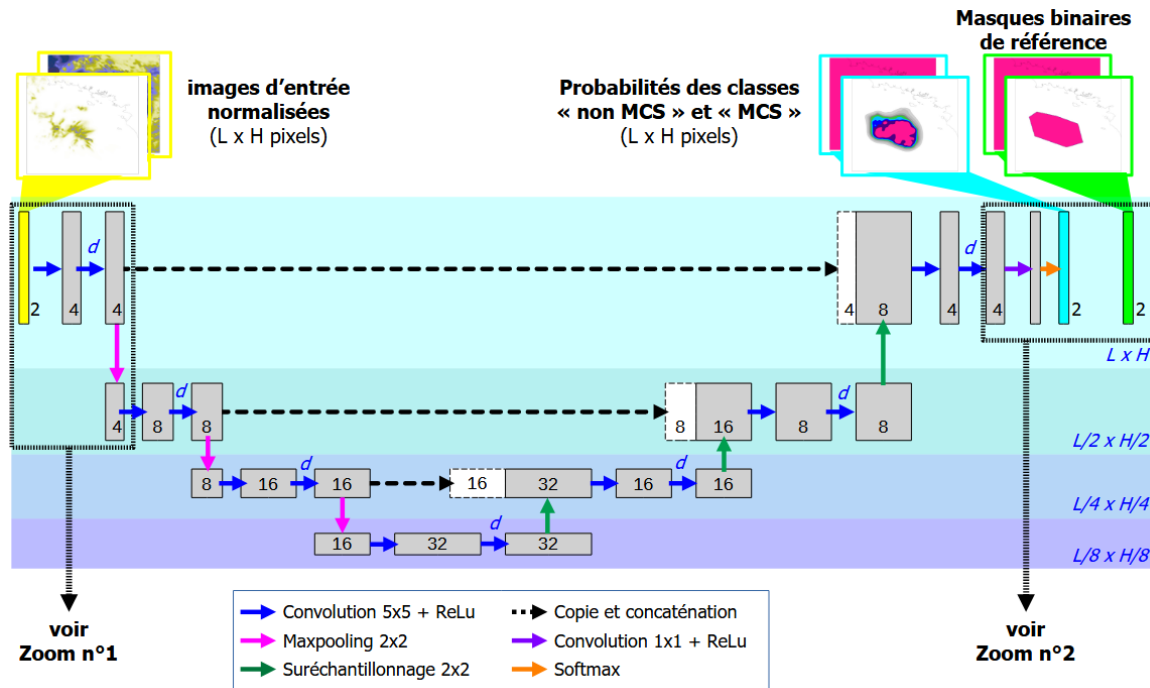


FIGURE 2.2 – Architecture du réseau de neurones convolutifs, type U-Net, élaboré pour l’identification de MCSs dans des images de Rflc et de TB simulées par AROME. Les données sont schématisées par des rectangles. Leur longueur indique la dimension des images, également précisée en bleu à droite de la figure. Leur largeur indique le nombre d’images dans chaque couche, également précisé en noir en bas des rectangles. Les zooms n°1 et 2 font référence aux figures 2.3 et 2.5 respectivement. Les couches affectées par le *dropout* sont suivies de la lettre « d » (voir section 2.3.3).

comparables. Sans cela, la sortie de la première couche de convolution serait dominée par l’image dont les valeurs sont les plus fortes. Il s’agirait par exemple de la TB si celle-ci était en Kelvin et les Rflc en dBZ. Le protocole de normalisation suivi durant la thèse sera détaillé dans la section 2.3.2.

La première couche de convolution comporte 4 filtres. Puisque l’Image d’entrée X contient 2 images X_1 et X_2 , chaque filtre comporte également deux canaux. La taille des filtres est ici de 5×5 . L’application de chaque filtre K_i^1 sur tous les pixels des images d’entrée produit une nouvelle image C_i^1 de la même taille. Les filtres ne sont pas prédisposés à extraire une caractéristique précise car leurs poids sont généralement initialisés avec des valeurs aléatoires. C’est seulement durant l’apprentissage que les poids seront ajustés et que les filtres se spécialiseront. Les images C_i^1 de la Figure 2.3 donnent une idée des caractéristiques extraites par chaque filtre sur les images d’entrée à la fin de l’apprentissage. Leur analyse permet de comprendre le fonctionnement du U-Net et de vérifier que les filtres appris peuvent extraire les propriétés météorologiques d’un MCS :

- le filtre K_1^1 est sensible aux faibles TB (pixels les plus froids) pour les régions situées en

- dehors des zones de précipitations ;
- le filtre K_2^1 est sensible aux faibles TB, aux forts gradients de TB et surtout aux fortes Rflc ;
 - le filtre K_3^1 rend compte uniquement des forts gradients de TB (bord sud du MCS sur l'image) ;
 - le filtre K_4^1 ressemble au filtre K_2^1 mais est plus sensible aux fortes Rflc et souligne moins les forts gradients de TB.

L'Image C^1 ainsi produite comporte 4 images C_i^1 et devient une nouvelle Image d'entrée pour la 2^e couche de convolution, laquelle applique aussi 4 filtres.

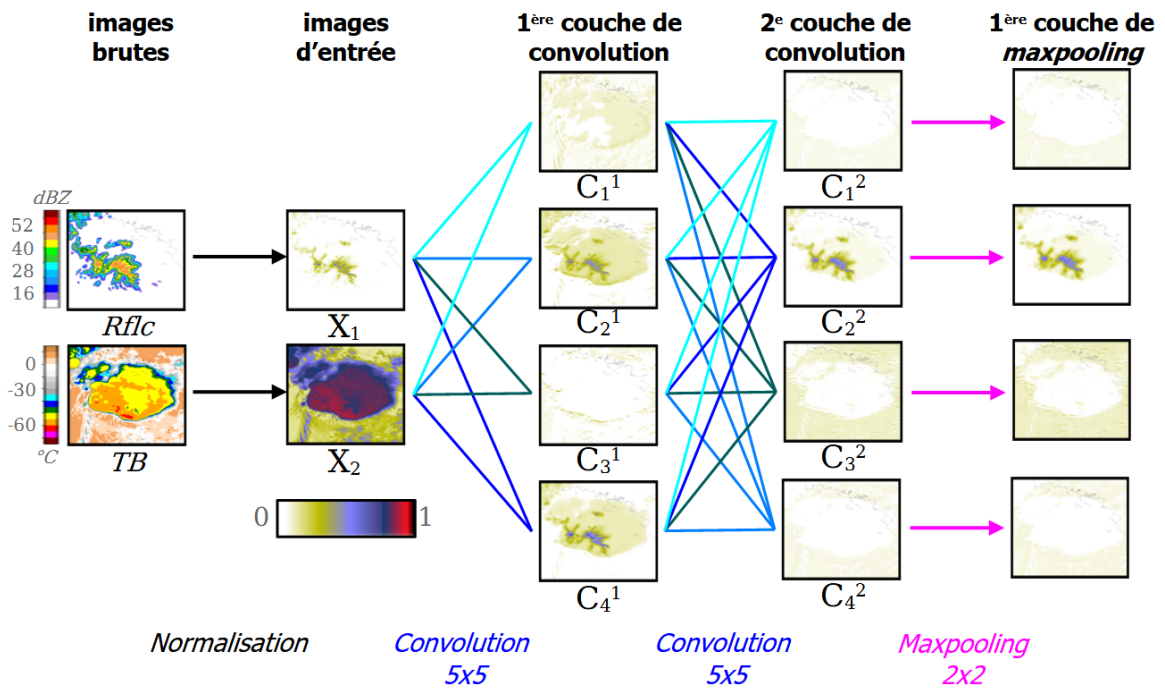


FIGURE 2.3 – Zoom n°1 sur le 1^{er} bloc de convolution du U-Net de la figure 2.2. Les notations sont expliquées dans le texte.

Pour détailler l'opération de convolution, la figure 2.4 zoome sur le 2^e filtre correspondant à la 2^e couche de convolution. Puisqu'il considère 4 images en entrée, son filtre K_2^2 se compose de 4 canaux $K_{2,i}^2$. Le filtre $K_{2,i}^2$ s'applique sur chaque pixel (x, y) de l'image C_i^1 et réalise une somme terme à terme des pixels alentour dans une fenêtre 5×5 , en pondérant chacun par le poids correspondant sur le filtre. Mathématiquement, cette opération se traduit par :

$$a_i(x, y) = \sum_{u=-2}^2 \sum_{v=-2}^2 K_{2,i}^2(u, v) C_i^1(x + u, y + v) \quad (2.1)$$

Les sorties $a_i(x, y)$ de chaque canal $K_{2,i}^2$ sont ensuite additionnées pour donner la sortie

$a(x, y)$ du filtre K_2^2 sur le pixel (x, y) . Une fonction d'activation nommée ReLU (pour *Rectified Linear Unit*) est ensuite appliquée. Cette fonction renvoie $a(x, y)$ si $a(x, y)$ est supérieur au biais b_2^2 du neurone, et 0 sinon. On obtient alors la valeur $C_2^2(x, y)$ du pixel (x, y) sur l'image de sortie C_2^2 . Comme les poids du filtre, le biais est un paramètre entraînable ajusté automatiquement durant l'apprentissage. Plus généralement, la fonction de convolution qui à chaque pixel (x, y) des images j de la couche p associe le pixel (x, y) de l'image i de la couche $p + 1$ prend la forme (Zhang, 2016) :

$$C_j^p(x, y) = \text{ReLU} \left(\sum_j \sum_{u=-2}^2 \sum_{v=-2}^2 (K_{i,j}^p(u, v) C_j^{p-1}(x + u, y + v)) + b_j^p \right) \quad (2.2)$$

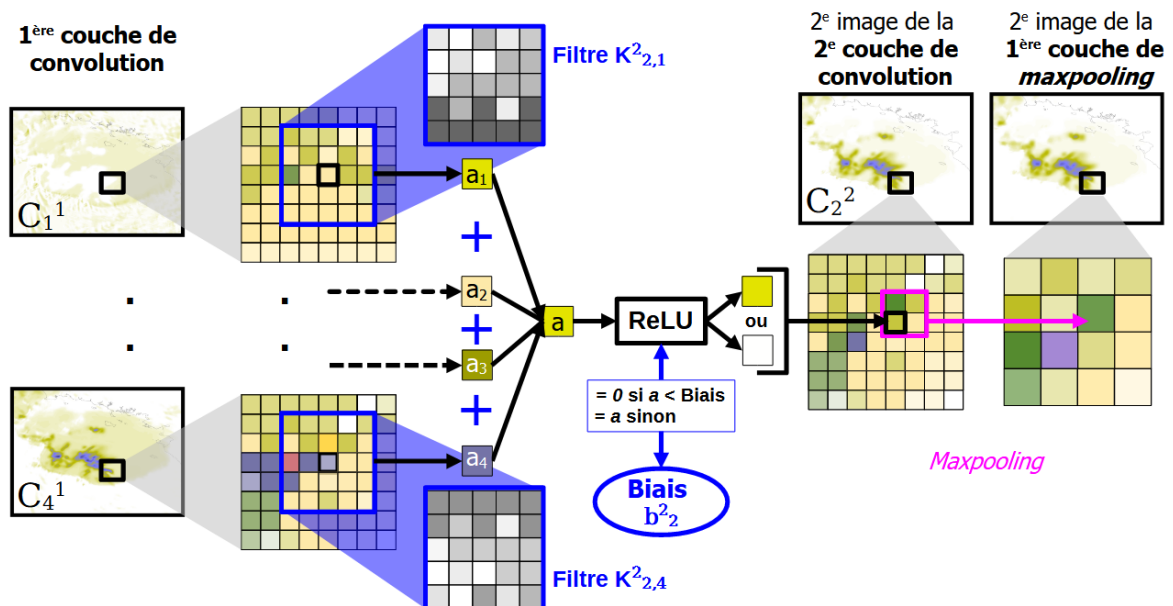


FIGURE 2.4 – Zoom sur l'opération de convolution appliquée aux images de la 1^{ère} couche par le 2^e filtre de la 2^e couche, suivie de l'opération de *maxpooling* associée.

Pour les pixels situés sur les bords, le filtre de convolution 5×5 « sort » en partie de l'image. Faute de valeurs, l'opération de convolution ne peut donc être appliquée. Si certains auteurs font le choix de ne pas traiter les pixels de bord (p. ex. Ronneberger *et al.* 2015), d'autres ont recours à une stratégie dite de *padding* qui consiste à remplacer les pixels manquants par des valeurs arbitraires, typiquement des 0. C'est cette option qui est retenue ici.

Chaque bloc de convolution s'achève par une opération de regroupement (*pooling*) qui divise par deux la taille des images. Cette opération n'implique aucun paramètre entraînable du U-Net ; il s'agit d'une simple transformation. L'opération de *pooling* dont il est ici question est celle de *maxpooling* 2×2 , un choix répandu dans la communauté (p. ex. Krizhevsky *et al.* 2012), notamment du fait de sa simplicité. À chaque groupement de 2×2 pixels contigus sur l'image traitée, on renvoie le pixel de valeur maximale (voir partie droite de la Figure 2.4).

Le choix du maximum favorise la sélection des pixels les plus « pertinents ».

Chaque opération de *maxpooling* inaugure un nouveau bloc constitué de deux couches de convolution successives. Dans l'architecture proposée, le schéma se répète quatre fois. La partie *encodeur* du U-Net comporte donc 4 blocs, si bien que la taille des images du dernier bloc est $4 \times 2 = 8$ fois plus petite que celle des images d'entrée. Enfin, comme dans [Ronneberger et al. \(2015\)](#), le nombre de filtres double à chaque bloc afin d'extraire davantage de caractéristiques depuis des images plus abstraites.

Partie *décodeur*

Le rôle de la partie *décodeur* est de reconstituer les dimensions des images d'entrée pour la détection des MCSs. Chaque bloc est donc à nouveau composé de deux opérations de convolution successives et les opérations de *maxpooling* sont remplacées par l'opération inverse de *suréchantillonnage* 2×2 (ou *upsampling*) : pour chaque regroupement de 2×2 pixels des images du bloc supérieur, on reporte la valeur du pixel correspondant sur les images du bloc inférieur.

Aux images obtenues après suréchantillonnage, on concatène la copie des dernières images du bloc correspondant dans la partie *encodeur* (flèches pointillées sur la Figure 2.2). C'est l'opération de *copie et concaténation*. Cette astuce aide à restituer les informations spatiales perdues lors de l'encodage ([Ronneberger et al., 2015](#)).

Les opérations aboutissant aux images de sortie sont schématisées sur la Figure 2.5. Une dernière opération de convolution est appliquée sur les images de l'avant-dernière couche. Son appellation est abusive car ses filtres sont seulement de dimension 1×1 (1 seul poids). Il y a autant de filtres que de classes désirées en sortie (ici 2, les classes « non MCS » et « MCS »). Pour convertir les images obtenues en champ de probabilité, une fonction dite *softmax* est appliquée à chaque pixel (x, y) des images C_i^{15} de la dernière couche. La valeur du pixel (x, y) sur l'image de sortie Y_i est donc (pour $i \in \{1, 2\}$) :

$$Y_i(x, y) = \text{softmax} \left(C_i^{15}(x, y) \right) = \frac{e^{C_i^{15}(x, y)}}{e^{C_1^{15}(x, y)} + e^{C_2^{15}(x, y)}} \quad (2.3)$$

La fonction *softmax* est couramment utilisée dans les problèmes de classification. On parle de « soft » maximum car l'exponentielle normalisée attribue une valeur proche de 1 pour le pixel $C_i^{15}(x, y)$ de valeur maximale et une valeur proche de 0 pour l'autre.

Combien de paramètres entraînaibles ?

Chaque couche de convolution présente deux types de paramètres : les poids des filtres et le biais. À l'exception de la dernière couche, la taille des filtres est ici de 5×5 et chaque filtre est constitué d'autant de canaux que d'images à considérer dans la couche précédente $p - 1$.

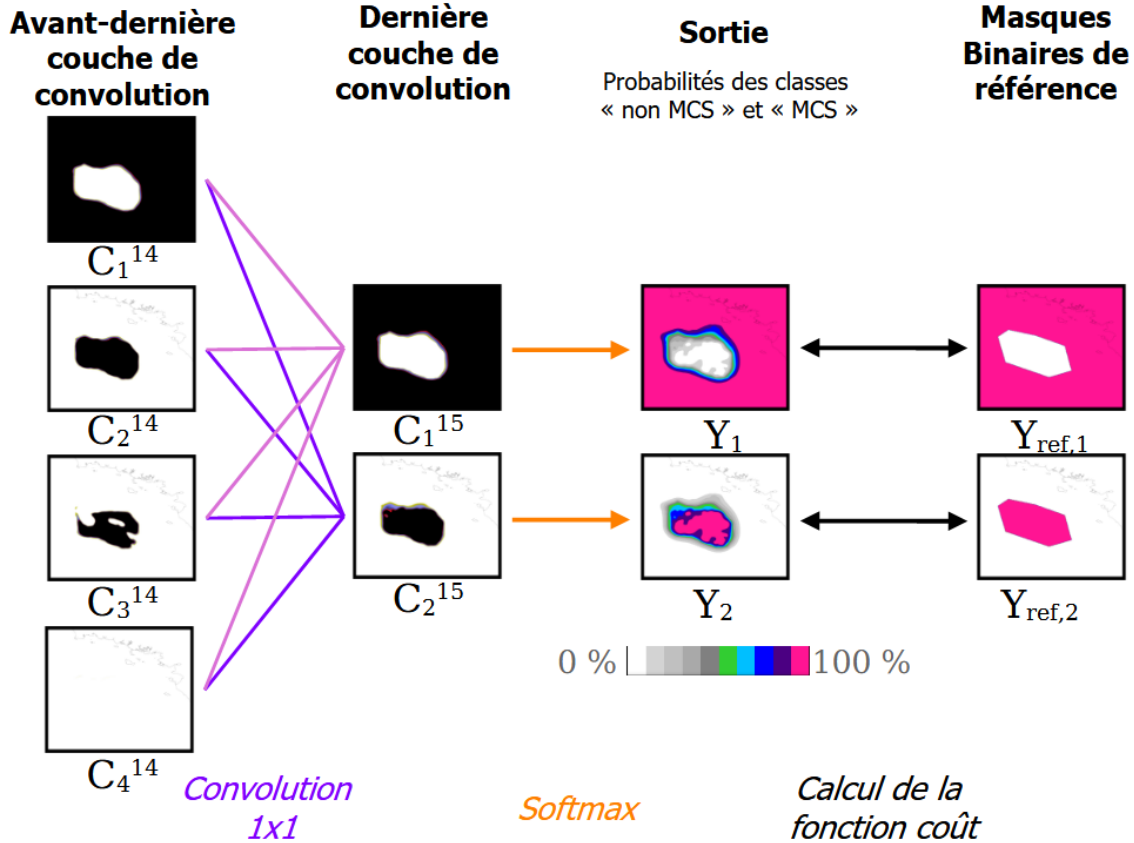


FIGURE 2.5 – Zoom n°2 sur le dernier bloc de convolution du U-Net de la figure 2.2, la production des images de sortie et la comparaison aux masques de référence. Les notations sont expliquées dans le texte.

S'il y en a N_{p-1} , le filtre comporte $5 \times 5 \times N_{p-1}$ poids, auxquels on doit ajouter le biais. De manière générale, si N_p est le nombre de filtres dans la couche p , N_{p-1} le nombre d'images dans la couche $p-1$ et k la taille des filtres, le nombre Q_p de paramètres dans la couche p vaut :

$$Q_p = (N_p \times N_{p-1} \times k^2) + N_p \quad (2.4)$$

Pour la première couche du U-Net étudié ici, on trouve alors $4 \times 2 \times 5^2 + 4 = 204$ paramètres. La Figure 2.6 indique le nombre de paramètres dans les couches suivantes. Le plus grand nombre est observé pour les couches les plus profondes (n°7 à 9) car ce sont celles qui présentent le plus de filtres et le plus d'images en entrée. Au total, on compte 84 786 paramètres. C'est beaucoup si on compare cette approche à une méthode basée sur un simple seuillage, où un seul paramètre (le seuil) suffit généralement. C'est par ailleurs un nombre dérisoire par rapport à d'autres RNC, comme le U-Net de [Ronneberger et al. \(2015\)](#) et ses quelques dizaines de millions de paramètres.

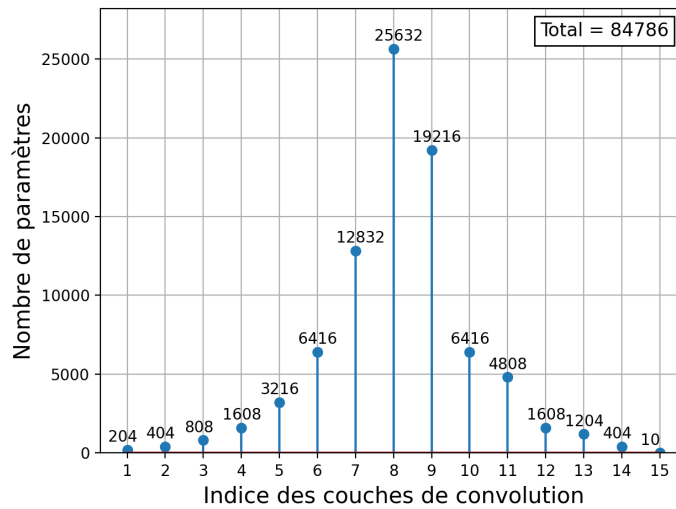


FIGURE 2.6 – Nombre de paramètres entraînés pour chaque couche de convolution du U-Net étudié.

2.2.4 Le processus d'entraînement

Les valeurs des 84 786 paramètres du U-Net sont définies à l'issue de l'*entraînement* (ou *apprentissage*) du réseau. Ce processus repose sur un certain nombre d'itérations à l'issue desquelles les paramètres sont mis à jour.

Jeu d'entraînement et fonction de coût

Un *jeu d'entraînement* est d'abord considéré. Celui-ci se compose de paires d'Images (X, Y_{ref}) . Les Images d'entrée X sont constituées des images de RfC et TB. Les Images de référence Y_{ref} sont des masques binaires, de même taille que X , dont chaque pixel indique son appartenance (1) ou non (0) aux classes à discriminer (ici « non MCS » $Y_{ref,1}$ et « MCS » $Y_{ref,2}$, voir la partie droite de la Figure 2.5).

L'entraînement démarre par une initialisation des paramètres, le plus souvent avec des valeurs aléatoires (Nielsen, 2015). À partir de chacune des Images X , le U-Net génère une Image de sortie Y qui est comparée à l'Image Y_{ref} associée à X . La comparaison entre Y et Y_{ref} est quantifiée par une *fonction de coût*. Il en existe plusieurs, la plus commune étant l'erreur quadratique moyenne (Nielsen, 2015). Cette dernière est généralement réservée aux problèmes de régression. Les problèmes de classification ont souvent recours à l'*entropie croisée* qui pénalise efficacement les erreurs pour des sorties restreintes à l'intervalle $[0; 1]$. Elle s'écrit :

$$\mathcal{L}(Y, Y_{ref}) = -\frac{1}{L \times H} \sum_{(x,y)} \sum_{i=1,2} Y_{ref,i}(x,y) \log(Y_i(x,y) + \epsilon) \quad (2.5)$$

où $L \times H$ est le nombre de pixels (x, y) des images Y_1 et Y_2 constituant Y . ϵ est une très petite valeur (10^{-7}) qui empêche le calcul d'un logarithme en 0. Comme discuté dans la section 2.3.3, l'entraînement du U-Net étudié emploiera une formulation « pondérée » de l'entropie croisée, adaptée aux jeux de données déséquilibrés.

Algorithme de descente de gradient

Si le U-Net est parfait, les images Y et Y_{ref} sont identiques en tous pixels (x, y) , valant soit 0, soit 1. $\mathcal{L}(Y, Y_{ref})$ est alors nulle. De manière générale, plus \mathcal{L} est proche de 0, meilleur est le U-Net. À chaque itération du processus d'entraînement, on cherchera donc à minimiser la fonction \mathcal{L} par une mise à jour adéquate des paramètres. Deux considérations simples rendent cela possible :

- \mathcal{L} étant une fonction de Y , et Y étant elle-même une fonction de tous les paramètres θ_n du U-Net ($n \in \llbracket 1 : 84\,786 \rrbracket$), \mathcal{L} est une fonction de chaque θ_n ;
- $\mathcal{L}(\theta_n)$ peut être réduite en diminuant ou augmentant θ_n selon que la courbe d'évolution de $\mathcal{L}(\theta_n)$ soit respectivement croissante ou décroissante au point $\theta_n(t)$ (valeur de θ_n à l'itération t). La figure 2.7 en illustre le principe. On parlera plutôt de dérivée partielle de \mathcal{L} par rapport à θ_n , $\frac{\partial \mathcal{L}}{\partial \theta_n}$, respectivement positive ou négative.

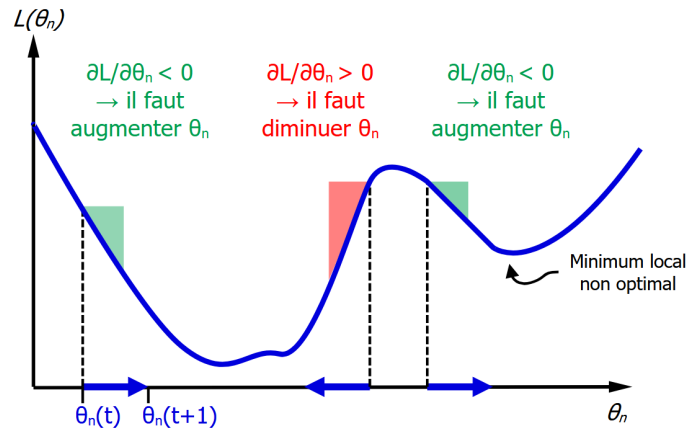


FIGURE 2.7 – Principe de la mise à jour d'un paramètre θ_n du réseau de neurones par l'algorithme de descente de gradient (schéma adapté de Goodfellow *et al.* 2016).

La règle de mise à jour de θ_n à l'itération $t + 1$ en fonction du même paramètre $\theta_n(t)$ à l'itération précédente est donc la suivante :

$$\theta_n(t + 1) \leftarrow \theta_n(t) - \alpha \frac{\partial \mathcal{L}}{\partial \theta_n}(t) \quad (2.6)$$

Cet algorithme de minimisation de \mathcal{L} est dit à descente de gradient (Goodfellow *et al.*, 2016), en référence au vecteur gradient $\nabla \mathcal{L}(\theta)$ constitué de toutes les composantes $\frac{\partial \mathcal{L}}{\partial \theta_n}$. La

valeur α est le *taux d'apprentissage* qui pilote la vitesse de l'entraînement : plus α est grand, plus la mise à jour de θ_n est importante. Il existe de nombreuses versions de l'algorithme de *descente de gradient* dont la plupart se distinguent par la formulation de α (Ruder, 2017) :

- Certaines versions affectent un $\alpha_n(t)$ variable à chaque paramètre θ_n , l'idée étant d'encourager la mise à jour d'un paramètre dont les modifications précédentes ont été faibles. Cela permet d'entraîner l'ensemble du réseau.
- Par ailleurs, La fonction $\mathcal{L}(\theta)$ est une fonction compliquée, rarement convexe, susceptible de comporter des minima locaux dont certains sont peu optimaux (voir Figure 2.7). On peut donc ajouter à l'équation 2.6 un terme d'inertie (*momentum*) qui dope la mise à jour à t si la précédente était importante. Cela confère un certain « élan » à l'algorithme de minimisation et limite le risque de convergence dans un minimum local sous-optimal.

Parce qu'il prend en compte les deux propriétés précédentes, l'algorithme *Adam* (*adaptive moment estimation*, Kingma et Ba 2014) est largement utilisé aujourd'hui.

Algorithme de *propagation arrière*

La dernière inconnue dans l'équation 2.6 est la quantité $\frac{\partial \mathcal{L}}{\partial \theta_n}$. Là encore, l'écriture de \mathcal{L} comme fonction, non pas seulement de Y , mais de chaque opération de convolution menant à Y (voir équation 2.2) permet d'exprimer $\frac{\partial \mathcal{L}}{\partial \theta_n}$ à partir des dérivées partielles $\frac{\partial \mathcal{L}}{\partial \theta_q}$ des paramètres θ_q appartenant aux couches situées en aval de la couche de θ_n , et ce grâce à la *règle de la chaîne*. Le calcul des $\frac{\partial \mathcal{L}}{\partial \theta_n}$ repose donc sur l'algorithme de *propagation arrière* (ou *backpropagation*, Goodfellow et al. 2016), où chaque dérivée partielle est déterminée en remontant le réseau depuis la sortie Y vers l'entrée X .

Batches et epochs

La fréquence de mise à jour des paramètres durant l'entraînement peut être fixée de trois façons :

- pour chaque Image X du jeu d'entraînement (cas de l'équation 2.5). C'est l'algorithme de *descente de gradient stochastique*, caractérisé par une convergence bruitée vers le minimum de \mathcal{L} .
- pour l'ensemble des Images du jeu d'entraînement. La convergence est moins bruitée mais le calcul de \mathcal{L} devient chronophage.
- pour des paquets de m Images X appelés *batches* ou *mini batches*. Un jeu de M Images d'entraînement contient alors M/m *batches*.

La dernière solution est un compromis entre les précédentes, avec un temps de calcul limité et une convergence moins bruitée. Elle est donc couramment employée. Quand l'ensemble des Images ont été utilisées pour mettre à jour les paramètres du U-Net, après M/m itérations, on dit qu'une *epoch* a été accomplie. À chaque *epoch*, les Images sont réparties aléatoirement dans de nouveaux *batches*. La recherche du minimum de \mathcal{L} nécessite généralement une dizaine à plusieurs centaines d'*epochs*.

Le défi de la généralisation

L'apprentissage n'a pas seulement pour objectif d'optimiser les performances du réseau sur le jeu d'entraînement. Il doit aussi éviter le surapprentissage en assurant que ces performances se *généralisent* à de nouvelles données. Des méthodes dites de *régularisation* abordent ce problème (p. ex. [Nielsen 2015](#)). Par exemple, la régularisation L2 complète la fonction coût avec un terme qui pénalise les poids les plus importants. Ceci force l'apprentissage de poids modestes, réduisant ainsi la sensibilité du réseau. La méthode du *dropout* agit quant à elle sur les pixels de certaines couches de convolution ([Srivastava et al., 2014](#)). À chaque *batch*, un taux d de nouveaux pixels sont sélectionnés aléatoirement et fixés à 0. En quelque sorte, une telle perturbation revient à mettre à jour un « nouveau » réseau à chaque itération, ce qui limite le surapprentissage.

2.3 Développement d'un U-Net pour la détection des MCSs dans des images simulées par AROME

Le développement d'un réseau de neurones se divise en trois phases :

1. préparation et analyse des jeux de données (parties 2.3.1 et 2.3.2).
2. entraînement et réglages du réseau (parties 2.3.3 et 2.3.4)
3. évaluation du réseau (partie 2.3.5 et section 2.4)

2.3.1 Constitution des jeux de données

Les images composant les jeux de données sont de dimensions 1648×1048 pixels et sont centrées sur la France métropolitaine (Figure 2.8). Elles correspondent aux champs de Rflc et de TB projetés sur une grille régulière de $0,01^\circ \times 0,01^\circ$, proche de la résolution horizontale d'AROME (1,3 km). Ces variables ont été introduites au chapitre précédent (partie 1.5.4). Le champ 2D de Rflc correspond au maximum sur la colonne, entre 0 et 3 km, des réflectivités diagnostiquées en chaque point de grille.




FIGURE 2.8 – Domaine des images d'entraînement centrées sur la France. Pour le U-Net dédié aux données simulées, le domaine (en bleu foncé) est au cœur de la grille de calcul du modèle AROME (limites en bleu clair). Pour le U-Net dédié aux données observées, le domaine (en rouge foncé) est limité par la portée maximale du réseau radar ARAMIS (en rouge clair).

Les images proviennent de prévisions AROME archivées pour 47 journées entre 2018 et 2021. Plus précisément, elles sont issues de la configuration de prévision immédiate AROME-PI (voire section 1.5) car ses prévisions sont disponibles à fréquence infra-horaire et actualisées

toutes les heures, fournissant ainsi une plus grande quantité de données pour une même journée.

Les 47 journées sélectionnées correspondent à des situations de fortes précipitations, la plupart associées à des MCSs ou à d'autres phénomènes convectifs de plus petite échelle. Par ailleurs, certaines situations sont concernées par des perturbations synoptiques actives mais sans caractère orageux prédominant. Cela permet d'introduire des images ambiguës pour encourager l'apprentissage à se concentrer sur d'autres caractéristiques que les fortes Rflc.

Afin d'entraîner puis d'évaluer le U-net, chaque paire d'images Rflc/TB doit être assortie d'un masque binaire de référence (voir section 2.2.4). Ces masques résultent d'un processus d'*annotation* (ou *labellisation*) durant lequel un expert définit « à la main » les contours des MCSs rencontrés dans chaque paire d'images. L'expert est ici l'auteur de la thèse.

Les images ont été annotées à l'aide du logiciel *Synopsis* développé par Météo-France pour la visualisation et l'analyse des données météorologiques (Lasserre-Bigorry, 2014). Cet outil ergonomique dispose de nombreuses fonctionnalités : zoom dynamique, défilement temporel des images, possibilité de superposer plusieurs champs, de dessiner des contours géographiques, etc. *Synopsis* est donc particulièrement adapté à l'annotation de phénomènes météorologiques. La Figure 2.9 montre l'interface de travail mise en place pour réaliser l'annotation. C'est une tâche chronophage et fastidieuse. Seules les images de Rflc et de TB sont ainsi mises à disposition de l'annotateur afin d'alléger son travail d'analyse. Les contours des MCSs sont tracés à la main puis enregistrés dans un fichier au format adapté (*geojson*). La manière d'annoter est forcément subjective mais s'inspire de la définition de Houze (2018) pour les MCSs (voir section 1.1). Les contours embrassent les zones contiguës de précipitations d'origine convective, fortes à modérées, associées à des sommets nuageux froids de type cumulonimbus. Le logiciel dispose d'un arpenteur permettant de vérifier que les phénomènes identifiés sont longs d'au moins 100 km.

Près de 2300 Images sont ainsi annotées, totalisant plus de 2400 contours de MCS. Comme détaillé dans la Table 2.1, trois jeux de données sont constitués :

- 53 % des images composent le *jeu d'entraînement* utilisé pour mettre à jour les paramètres du U-Net durant l'apprentissage ;
- 23 % forment le *jeu de validation* sur lequel différentes configurations du U-Net sont évaluées afin d'en sélectionner la meilleure (voir partie 2.3.4) ;
- 24 % sont rassemblées dans le *jeu de test* et seront utilisées pour l'évaluation finale de la meilleure configuration sélectionnée sur le jeu de validation (voir section 2.4). On vérifie ainsi que le réseau n'a pas *surappris*, que ses paramètres, ses règles de décision peuvent être généralisés à de nouveaux jeux de données.

Afin d'assurer une stricte indépendance entre les trois jeux de données, leurs Images proviennent de journées différentes (voir Table 2.1). La proportion d'Images dans chaque jeu est similaire à celle que l'on rencontre dans d'autres études (p. ex. Lee *et al.* 2021; Mounier *et al.* 2022).

Cette partition des données en trois jeux indépendants est nécessaire pour développer un

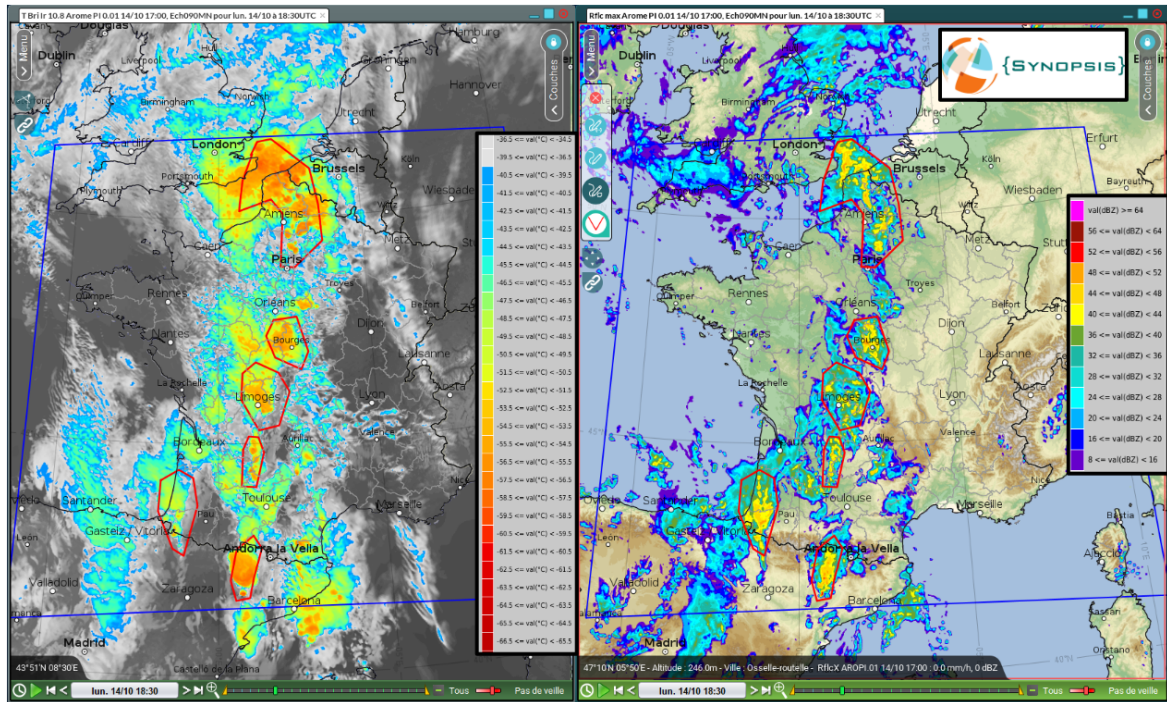


FIGURE 2.9 – Disposition type de l’écran de travail pour l’annotation d’objets MCS à partir du logiciel *Synopsis*. Le champ de Rf1c est affiché à droite, celui de TB à gauche. Le cadre bleu indique les limites du domaine d’entraînement. Les polygones rouges (identiques à gauche et à droite) représentent les contours de MCSs tracés à la main.

algorithme d’apprentissage machine (Goodfellow *et al.*, 2016). Le jeu d’entraînement sert à optimiser les paramètres entraînaables et le jeu de test permet d’évaluer les performances du réseau sur de nouvelles Images. Cependant, l’algorithme présente aussi des paramètres non entraînaables appelés *hyperparamètres*, comme la taille des filtres du U-Net. Ces paramètres peuvent être optimisés en entraînant plusieurs algorithmes de configurations différentes et en les comparant sur le jeu de validation (voir section 2.3.3). Puisque ce jeu de validation sert aussi à optimiser l’algorithme, il ne peut pas être utilisé pour son évaluation finale.

Contraint par le travail d’annotation, le nombre d’Images utilisées reste modeste pour des applications d’apprentissage profond. Cependant, le U-Net est réputé pour ses performances sur de petits jeux de données (Ronneberger *et al.*, 2015), ce que confirmera l’évaluation de la méthode dans la section 2.4.

2.3.2 Analyse des jeux de données et normalisation

Il y a plusieurs avantages à réaliser une analyse statistique des données avant l’entraînement. Ce travail permet de se familiariser avec les images traitées, aiguillant notamment la manière de les normaliser. Il s’agit aussi de vérifier que les distributions relatives aux jeux

	Données AROME				Données observées			
	Entraînement	Validation	Test	Total	Entraînement	Validation	Test	Total
# Journées	27	10	10	47	27	10	10	47
# Images	1210	517	550	2277	1296	480	480	2256
# Objets	1205	636	590	2431	987	479	393	1859

TABLE 2.1 – Composition des jeux de données utilisés pour mettre au point une méthode de détection des MCSs dans les simulations AROME d’une part (section 2.3) et les observations d’autre part (section 2.5).

d’entraînement, de validation et de test sont comparables, afin de ne pas introduire un biais dans l’évaluation de la méthode.

L’analyse statistique des données de Rflc et de TB est résumée sur les Figures 2.10 et 2.11 respectivement. Pour chaque jeu sont représentées les distributions des valeurs associées aux pixels de l’ensemble des images (sous-figures a et b) ou seulement à l’intérieur des MCSs annotés (sous-figures c et d). La distribution réelle des valeurs de Rflc est largement dominée par les pixels sans précipitations (82 à 86 % des données selon le jeu). Ces derniers sont donc exclus des distributions de Rflc afin de rendre la Figure 2.10 plus lisible.

Les distributions de Rflc et de TB sont homogènes entre les trois jeux de données, malgré des TB un peu plus élevées pour les images du jeu de test.

La majorité des valeurs de Rflc se situent entre 15 et 30 dBZ lorsqu’on considère l’ensemble des pixels avec précipitations. La distribution est évidemment plus forte si l’on se restreint aux MCSs annotés. Un peu plus de 25 % des données sont alors associées à des précipitations convectives (> 40 dBZ). Le reste correspond aux précipitations stratiformes, principalement entre 30 et 40 dBZ, traduisant le souci de l’annotateur à se concentrer sur les zones de précipitations fortes à modérées.

Près de la moitié des valeurs de TB se situent entre -20 et 20°C , avec un mode prononcé entre 15 et 20°C (Figure 2.11b) que l’on peut associer aux zones de ciel clair. Les valeurs rencontrées au sein des MCSs correspondent aux minima les plus extrêmes de la distribution calculée sur l’ensemble des pixels, avec près de 75 % des données inférieures à -50°C . Les rares pixels « chauds » ($> 0^\circ\text{C}$) sont liés au tracé forcément grossier de l’annotateur, celui-ci pouvant dépasser de quelques pixels le bord marqué des systèmes nuageux, notamment pour les MCSs en phase de développement.

Avant l’encodage, les pixels (x, y) des images X_i de Rflc et de TB sont normalisés de la façon suivante :

$$X_i(x, y) = \frac{X_i(x, y) - X_{i,min}}{X_{i,max} - X_{i,min}} \quad (2.7)$$

où $X_{i,min}$ et $X_{i,max}$ sont des coefficients fixes, relatifs à chaque type d’image et cor-

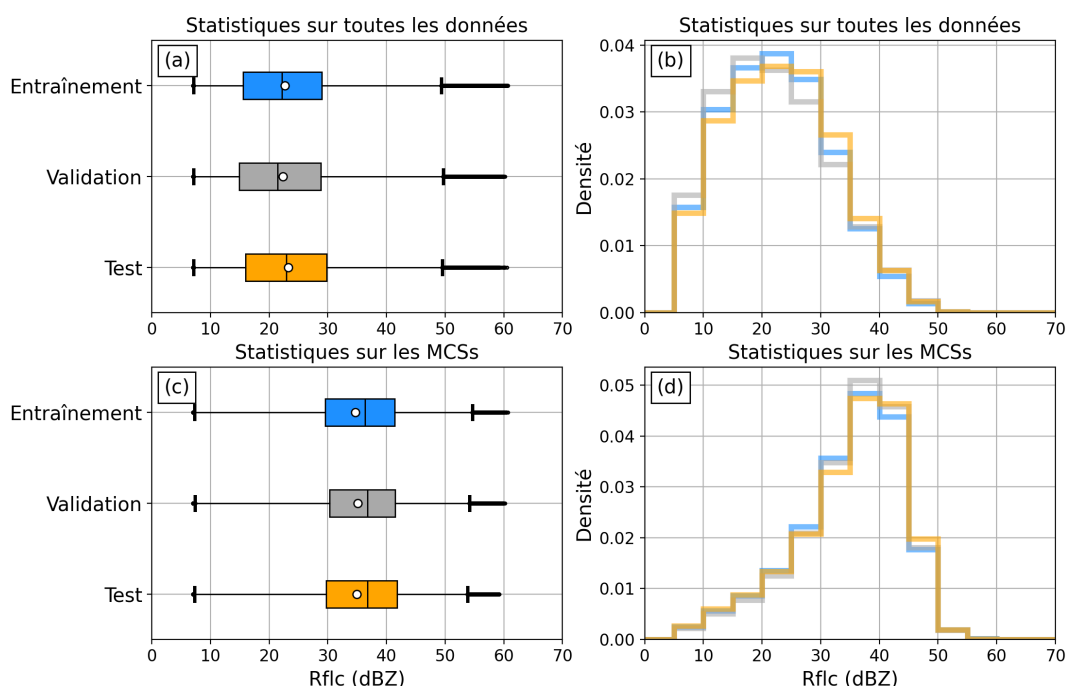


FIGURE 2.10 – Visualisation sous forme de boîtes à moustaches (a,c) et d’histogrammes de densité (b,d) des distributions de Rfcl simulées dans les bases d’entraînement (en bleu), de validation (en gris) et de test (en orange) : (a,b) pour tous les pixels ; (c,d) pour les pixels à l’intérieur des contours de MCS annotés. Sur les boîtes, le rond blanc indique la moyenne et les moustaches correspondent aux quantiles 0,01% et 99,9% des distributions. Les pixels sans précipitations (Rfcl < 7 dBZ soit environ 0.1 mm/h) ont été écartés.

respondant aux extrêmes des distributions exposées plus haut. Pour Rfcl, on choisit ainsi $X_{1,min} = 0$ dBZ et $X_{1,max} = 55$ dBZ (100 mm/h). Pour TB, on fixe $X_{2,min} = -73.15^{\circ}\text{C}$ (200 K) et $X_{2,max} = 27.15^{\circ}\text{C}$ (300 K). Ces coefficients ne sont pas strictement égaux aux valeurs minimales et maximales des jeux de données. Il faut les voir comme des extrêmes lisses, rendant la normalisation moins sensible aux valeurs extrêmes de chaque distribution (Lagerquist *et al.*, 2019). Au final, la plupart des données se situent dans l’intervalle [0, 1].

Enfin, les données normalisées de TB subissent la transformation linéaire $x \rightarrow 1 - x$ afin d’associer les extrêmes d’intérêt (TB basses) aux plus fortes valeurs, comme les extrêmes de Rfcl. Sans cela, les « 0 » ajoutés aux bords des images lors du *padding* (voir partie 2.2.3) pourraient être perçus comme des sommets nuageux très froids alors qu’ils sont de simples artefacts de calcul.

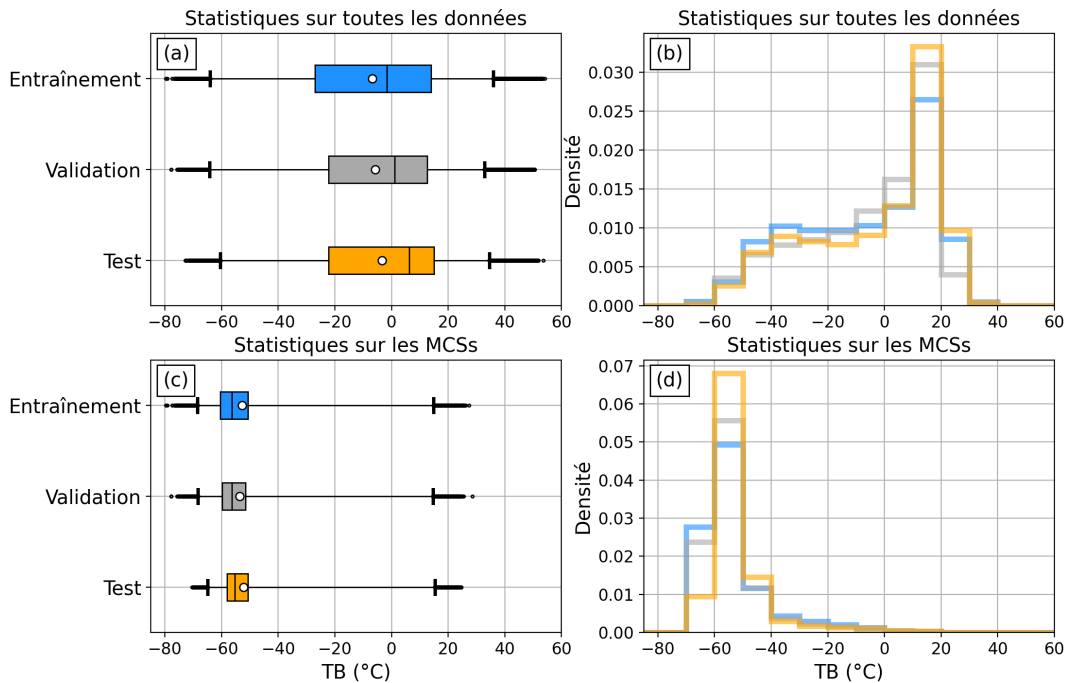


FIGURE 2.11 – Idem Figure 2.10, mais pour les valeurs de TB. Ici, les pixels sans précipitations ont été pris en compte.

2.3.3 Préréglage des hyperparamètres

En plus des paramètres entraînaux, le U-Net présente des paramètres fixes, configurables par l'expérimentateur avant l'apprentissage. Il s'agit des *hyperparamètres*, liés notamment :

- à l'architecture du U-Net, tels que le nombre de blocs, la dimension des filtres, etc ;
- à l'entraînement du U-Net, tels que la pondération de la fonction coût, le nombre d'*epochs*, la taille des *batches*, etc ;
- aux images d'entrée utilisées pendant l'entraînement, en particulier leur taille ou leur unité.

Le choix des hyperparamètres est important car les performances du U-Net dépendent en partie de sa configuration. Si la connaissance du problème permet d'en intuitionner certains, d'autres ont un impact moins prévisible et doivent être ajustés de manière empirique. En résumé, les choix aboutissant à la configuration finale du U-Net sont guidés par trois contraintes : (1) optimiser les performances du réseau, (2) réduire, dans la mesure du possible, le nombre de paramètres entraînaux (principe de parcimonie), (3) économiser les ressources consacrées au calcul et au développement (on ne peut pas tester toutes les configurations possibles).

La Table 2.2 indique la valeur retenue ou les valeurs testées pour un ensemble d'hyperparamètres jugés des plus sensibles. Ces valeurs sont justifiées ci-après.

Hyperparamètre	Valeurs fixées ou testées
Taille des filtres	3 ou 5
Nombre de blocs	4
Nombre de filtres dans la 1 ^{ère} couche	4 ou 8
Dimension des Images d'entraînement	1648 × 1048
Unité des réflectivités	dBZ ou mm/h
Poids de la classe « MCS » dans la fonction coût	3 ou 5
Taux de <i>dropout</i>	0,1
Nombre d' <i>epochs</i>	40
Taille du <i>batch</i>	16

TABLE 2.2 – Hyperparamètres du U-Net entraîné pour détecter des MCSs dans les images simulées par AROME. Les lignes grises correspondent aux hyperparamètres testés sur le jeu de validation.

Taille des filtres de convolution

Deux tailles de filtres sont testées : 3×3 et 5×5 . Le choix se porte généralement sur des filtres de 3×3 (Kumler-Bonfanti *et al.*, 2020; Lee *et al.*, 2021; Mounier *et al.*, 2022) mais Liu *et al.* (2016) suggère que des filtres plus gros sont adaptés aux phénomènes de grande taille, tel que peut l'être un MCS.

Profondeur du réseau




FIGURE 2.12 – Champs récepteurs (carrés colorés vides) associés à des pixels (carrés colorés pleins) des quatre premières couches d'un U-Net aux filtres 5×5 . Du plus petit au plus grand, les champs récepteurs sur l'image d'entrée correspondent au pixel coloré de la 1^{ère} couche de convolution (5×5 pixels), de la 2^e (9×9), de la 1^{ère} couche de *maxpooling* (10×10) et de la 3^e couche de convolution (18×18).

Le nombre de blocs est fixé à 4, un choix motivé par la taille souhaitée du *champ récepteur* (*receptive field*). Le champ récepteur correspond à l'ensemble des pixels des images d'entrée qui interviennent dans le calcul d'un pixel (x, y) des image de sortie (Ebert-Uphoff et Hilburn,

2020). Cet ensemble est ici compris dans un sous-domaine carré des images d'entrée, centré sur le pixel (x, y) . Comme l'illustre la Figure 2.12, la taille du champ récepteur augmente avec le nombre de couches de convolution, selon la taille des filtres, mais surtout avec le nombre de couches de *pooling*, soit le nombre de blocs. La Figure 2.13 montre comment la taille du champ récepteur croît à mesure que l'on parcourt les couches du U-Net, jusqu'à atteindre sa valeur maximale à l'issue de la dernière couche de convolution. Après chaque opération de *pooling* (en rose), le taux de croissance du champ récepteur double car chaque pixel contient dès lors l'information relative à 2×2 pixels sur le bloc précédent. Par exemple, sur la Figure 2.12, les convolutions du premier bloc dilatent le champ récepteur de 2 pixels (voir les deux carrés intérieurs sur l'image d'entrée) tandis que la convolution après *maxpooling* dilate le champ récepteur de 4 pixels (carré extérieur rouge). La notion de champ récepteur reste une limite théorique au rayon d'influence que chaque pixel en entrée exerce réellement sur les pixels en sortie, cette influence tendant à être négligeable au-delà d'un certain *champ récepteur effectif* plus petit. Il n'en demeure pas moins un facteur déterminant pour choisir une architecture adaptée au problème traité (Ebert-Uphoff et Hilburn, 2020).

Le phénomène étudié occupant la mésoéchelle, il convient que le champ récepteur soit de l'ordre de 100×100 km. En gardant l'architecture de base du U-Net, avec 2 couches de convolution dans chaque bloc, et considérant que la résolution des images d'entrée $0.01^\circ \times 0.01^\circ$ est de l'ordre du kilomètre, la taille du champ récepteur est proche de :

- 44×44 km pour un U-Net à 3 blocs avec des filtres 3×3 ;
- 84×84 km pour 3 blocs et des filtres 5×5 ;
- 96×96 km pour 4 blocs et des filtres 3×3 ;
- 184×184 km pour 4 blocs et des filtres 5×5

Il est donc préférable d'opter pour 4 blocs de convolution.

Nombre de filtres dans le premier bloc

Deux valeurs sont testées pour le nombre de filtres dans chaque couche de convolution du premier bloc : 4 et 8. Cet hyperparamètre fixe également le nombre de filtres pour les blocs suivants car, selon l'architecture du U-Net, celui-ci est doublé après chaque opération de *pooling*. Plus le nombre de filtres est important, plus nombreuses sont les caractéristiques potentiellement extraites. Or les valeurs proposées sont faibles si on les compare à la littérature : 16 filtres pour Lee *et al.* (2021), 32 pour Mounier *et al.* (2022), jusqu'à 64 dans l'article de référence sur le U-Net (Ronneberger *et al.*, 2015). Puisqu'on estime que la détection de MCSs est une tâche moins complexe, on considère qu'un petit nombre de filtres est suffisant et limite ainsi le surapprentissage.

Images d'entraînement

Les images utilisées pour l'entraînement n'ont pas été modifiées. Elles sont donc de 1648×1048 pixels, soit un à deux ordres de grandeur supérieurs aux « imagettes » considérées par Lee

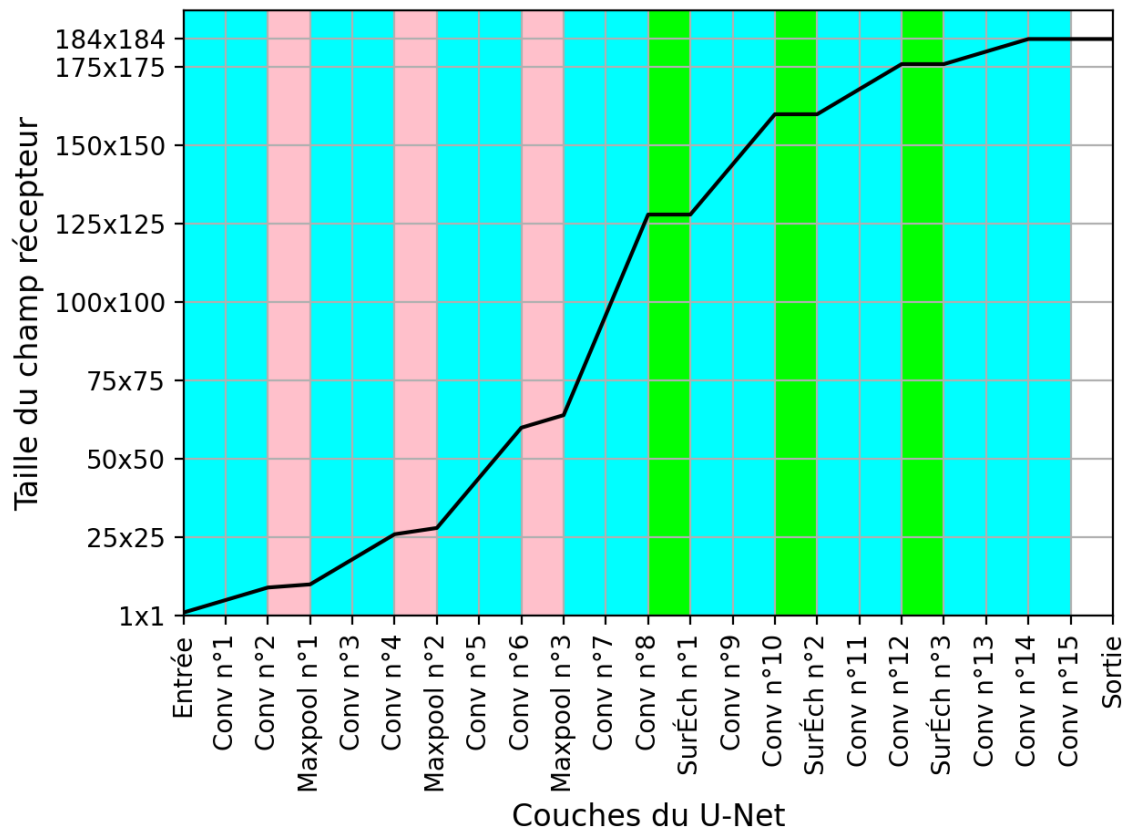


FIGURE 2.13 – Taille du champ récepteur à l'issue de chaque couche d'un U-Net constitué de 4 blocs et de filtres 5×5 . Les couches de convolution (Conv) sont en bleu, celles de *pooling* (Maxpool) en rose et celles de suréchantillonnage (SurÉch) en vert.

et al. (2021) ou Mounier *et al.* (2022). Ces dernières sont extraites dans les images d'entrée, le plus souvent de façon aléatoire, l'objectif étant de diminuer la quantité de données dans chaque *batch* pour accélérer l'apprentissage. Toutefois, cette approche n'est pas vraiment adaptée au cadre de cette étude. En effet, il est préférable que les imagerie soient plus grandes que le champ récepteur du U-Net. Or, si l'on part des dimensions maximales décrites plus haut (184×184 pixels), les imagerie atteignent déjà une taille importante, ce qui réduit leur intérêt. De plus, la méthode des imagerie s'accompagne d'un nouveau lot d'hyperparamètres à ajuster : taille, nombre d'imagerie sélectionnées par image, etc. Cela complexifie le choix d'une configuration optimale. Pour ces deux raisons, la méthode des imagerie n'est pas exploitée ici.

Unité des réflectivités

Deux jeux d'entraînement sont considérés, le premier avec les Rflc en dBZ et le second avec les Rflc en mm/h. En effet, pour des raisons historiques, les données archivées de Rflc

sont en mm/h (voir discussion dans Mounier *et al.* 2022) bien que le champ initial du modèle AROME soit en dBZ. Une loi Z-R de type Marshall-Palmer est utilisée pour la conversion : $Z = 10(\log(a) + b.\log(R))$ avec Z les Rflc en dBZ, R les « Rflc »¹ en mm/h, $a = 200$ et $b = 1,6$. Les Rflc en dBZ étant une transformation logarithmique des Rflc en mm/h, les valeurs normalisées de ces dernières donnent une importance relativement plus grande aux précipitations intenses.

Poids de la classe « MCS » dans la fonction coût

La fonction coût utilisée pour l’entraînement est la fonction d’*entropie croisée pondérée*, une variante courante de la fonction d’*entropie croisée* introduite dans la partie 2.2.4. Un poids β_i est alors associé à chaque terme i de la somme 2.5 afin de pénaliser davantage une classe par rapport à l’autre, notamment si la première est moins représentée dans le jeu de données (Mounier *et al.*, 2022). C’est le cas de la classe « MCS » : il y a en effet beaucoup moins de pixels associés à des MCSs dans les images d’entrée que de pixels qui ne le sont pas. D’ailleurs, après de premiers entraînements sans pondération (non montrés) les U-Nets obtenus étaient incapables de détecter un MCS. Deux poids sont alors testés : 3 et 5, des valeurs comparables à celles de Mounier *et al.* (2022).

Si l’*entropie croisée* ou l’*entropie croisée pondérée* sont fréquemment employées pour la classification et la segmentation d’images météorologiques (Lagerquist *et al.*, 2019; Biard et Kunkel, 2019; Cintineo *et al.*, 2020b; Mounier *et al.*, 2022), il existe d’autres fonctions coût adaptées à des problèmes déséquilibrés. Dans les méthodes *IoU* (*Intersection-Over-Union*), des métriques comme la fonction *Dice Loss* (Sudre *et al.*, 2017) cherchent à calculer un taux de recouvrement entre les aires où l’objet cible a été identifié par le réseau et celles où l’objet cible a été annoté. La fonction *Focal Loss* (Lin *et al.*, 2017) complète l’entropie croisée pondérée pour pénaliser la classe la moins représentée dans le jeu d’entraînement mais aussi les images sur lesquelles le réseau est le moins performant, via l’introduction d’un poids proportionnel à l’écart entre la sortie et la référence, porté à la puissance γ (typiquement égal à 2). La fonction coût peut être vue comme un hyperparamètre à calibrer et dont le choix optimal est difficile à prévoir sans test de sensibilité. Sudre *et al.* (2017) obtiennent des performances similaires sur quatre U-Nets entraînés avec des fonctions coût différentes, dont l’entropie croisée pondérée et la fonction Dice. De façon analogue, Kumler-Bonfanti *et al.* (2020) calibrent avec une fonction coût distincte chacun des quatre U-Nets entraînés pour l’identification de cyclones dans des images satellite. De tels tests de sensibilité n’ont pas été réalisés pendant la thèse. Comme annoncé en introduction de cette section 2.3.3, il est difficile d’évaluer toutes les configurations possibles d’hyperparamètres dans un intervalle de temps raisonnable. D’après la littérature ci-dessus, le recours à l’entropie croisée pondérée apparaît judicieux pour le problème posé. Même s’il est possible qu’une fonction différente aboutisse à de meilleures performances, il a été décidé de concentrer les efforts sur d’autres hyperparamètres.

1. Parler de Rflc en mm/h est un abus de langage. Il faudrait privilégier les termes de « pseudo-Rflc », comme dans Mounier *et al.* (2022) ou de *taux de pluie*. Par simplicité, on continuera cependant d’employer le terme de Rflc pour les deux unités.

Taux de *dropout*

Pour limiter le surapprentissage, un taux de *dropout* $d = 10\%$ a été ajouté dans chaque bloc sur les images d'entrée de la seconde couche de convolution (voir lettre « d » sur la Figure 2.2). De premiers essais ont montré que, pour $10\% < d < 40\%$ la valeur du taux de *dropout* n'avait pas un impact important sur les performances du U-Net.

Dernières précisions

40 *epochs* sont utilisées pour l'entraînement. Ce nombre est suffisant car, d'après des essais préliminaires, la fonction coût converge dès les 5 premières *epochs*. Les *batches* sont composés de 16 images, une quantité limitée qui s'explique par la dimension importante de ces dernières et la capacité restreinte de la mémoire vive. Le U-Net est implémenté en Python à partir du module TensorFlow/Keras (Abadi *et al.*, 2016). L'entraînement est réalisé sur un processeur de type GPU (*Graphical Processing Unit*²). L'algorithme classique *Adam* est choisi pour optimiser la fonction coût (voir partie 2.2.4). Les paramètres du U-Net sont initialisés aléatoirement.

2.3.4 Sélection de la « meilleure » configuration

Toutes les configurations d'hyperparamètres listées dans la Table 2.2 sont évaluées suivant une méthode de recherche dite « par grille » (*grid searching*) couramment employée (p. ex. Kumler-Bonfanti *et al.* 2020; Mounier *et al.* 2022). Avec deux options testées pour chacun des 4 hyperparamètres en gris dans la Table, cela donne $2^4 = 16$ configurations différentes. Par ailleurs, chaque entraînement présente une part d'aléatoire, que ce soit dans l'initialisation des poids ou la répartition des Images au sein des *batches* à chaque *epoch*. Ainsi, pour une même configuration, un apprentissage peut converger vers deux minima locaux différents, le premier relativement optimal, l'autre beaucoup moins. C'est pourquoi 10 entraînements sont lancés pour chaque configuration afin de couvrir davantage la distribution de leurs performances respectives.

Les 160 U-Nets obtenus sont évalués sur le jeu de validation à partir de *diagrammes de performance* (Roebber, 2009). Leur usage est adapté à la comparaison des données binaires (classes « MCS » ou « non MCS »). Ils reposent sur le *taux de bonnes détections* (ou POD pour *Probability Of Detection*), le *taux de fausses alarmes* (ou FAR pour *False Alarm Ratio*) et l'indice de Jaccard (ou CSI pour *Critical Success Index*) calculés à partir de la Table de contingence 2.3 et des équations 2.8. La somme \sum s'applique ici sur tous les pixels *VP*, *FN* ou *FP* rencontrés dans le jeu de validation. Puisque les images de sortie du U-Net comportent des données probabilistes, on considère qu'un pixel est détecté « MCS » s'il dépasse une certaine probabilité $Prob_{min}$ d'appartenir à la classe « MCS ». Par convention, $Prob_{min}$ est fixée à 50 %. Des objets MCS peuvent ainsi être définis à partir des pixels contigus de probabilité

2. de fabrication *Nvidia Tesla V100*

supérieure à 50 %. Par ailleurs, les objets dont la longueur est inférieure à 100 km sont considérés comme du bruit et éliminés pour le calcul des scores. Dans ce chapitre, la longueur est simplement estimée par le grand axe de l'ellipse approchant l'objet.

	pixel annoté « MCS »	pixel annoté « non MCS »
pixel détecté « MCS »	Vrai Positif (VP)	Faux Positif (FP)
pixel détecté « non MCS »	Faux Négatif (FN)	Vrai Négatif (VN)

TABLE 2.3 – Table de contingence pour l'évaluation d'une méthode de détection des MCSs.

$$\begin{aligned}
 POD &= \frac{\sum VP}{\sum VP + \sum FN} \\
 FAR &= \frac{\sum FP}{\sum VP + \sum FP} \\
 CSI &= \frac{\sum VP}{\sum VP + \sum FN + \sum FP}
 \end{aligned} \tag{2.8}$$

Les scores POD, FAR et CSI obtenus par les différentes configurations de U-Net sont présentés sur les diagrammes de performances de la Figure 2.14, chacun discriminant les options d'un des 4 hyperparamètres testés. Les scores POD, 1-FAR et CSI évoluent ici entre 1 (meilleure valeur) et 0 (pire valeur). Les scores POD et 1-FAR mesurent respectivement la capacité à détecter tous les MCSs et la capacité à ne pas détecter des MCSs à tort. Le CSI synthétise les deux propriétés précédentes. Par ailleurs, il faut noter que près de 30 % des 160 U-Nets entraînés ne figurent pas sur les diagrammes car leur CSI est nul. Ces U-Nets « non pertinents » sont la conséquence d'un problème de convergence durant l'entraînement, la fonction coût restant bloquée dans un minimum local sous-optimal.

Sur la Figure 2.14, les U-Nets sont majoritairement répartis sur un arc de cercle qui traduit l'évolution relative classique des scores POD et 1-FAR : si un U-Net manque peu de MCSs, il a aussi tendance à en détecter à tort. Les meilleures configurations affichent un CSI supérieur à 0,6. Les valeurs d'hyperparamètres testées ont un impact limité sur les performances des U-Nets. Cependant, la plupart des U-Nets pertinents considèrent les Rflc en mm/h, unité qui favorise les précipitations intenses (Figure 2.14d).

Puisque les configurations testées ont des performances équivalentes, le choix du « meilleur » U-Net implique une part d'arbitraire. Même si un équilibre entre fausses alarmes et bonnes détections reste nécessaire, la détection des MCSs est prioritaire car elle présente l'enjeu météorologique le plus important. Il est donc convenu de choisir un U-Net doté d'un POD élevé et d'un FAR raisonnable, plutôt que l'inverse. Parmi les U-Nets dont le CSI est supérieur à 0,5 on présélectionne alors une quinzaine de configurations associées aux meilleurs POD. Ces dernières sont ensuite analysées subjectivement sur quelques situations du jeu de validation. L'importance est donnée aux contours peu bruités, à la capacité de séparer des MCSs proches, à celle de ne pas englober des zones stratiformes trop étendues, notamment pour les systèmes noyés dans des perturbations synoptiques.




FIGURE 2.14 – Diagrammes de performance synthétisant les scores obtenus par différentes configurations de U-Net évaluées sur le jeu de validation. Le score CSI apparaît en isolignes. La configuration retenue est marquée d'une étoile (POD=0.88, FAR=0.32, CSI=0.62).

Le U-Net retenu comme étant le plus performant se distingue par un symbole « étoile » sur la Figure 2.14. Son architecture est celle de la Figure 2.2. Ses filtres sont de dimensions 5×5 ; il en comporte 4 dans le premier bloc. Les images de Rflc sont données en mm/h et un poids de 3 a été appliqué à la classe « MCS » dans la fonction coût durant l'apprentissage. Cette configuration est peut-être sous-optimale car l'espace des hyperparamètres n'a pas été exploré de manière exhaustive. Une méthode de recherche plus objective comme l'optimisation bayésienne (Liu *et al.*, 2016) pourrait conduire à une meilleure configuration mais elle n'a pas été testée. Cependant, l'évaluation objective et subjective de la section 2.4 montrera que les

performances du U-Net retenu sont déjà satisfaisantes.

2.3.5 Analyse du U-Net sélectionné

Une analyse plus approfondie du U-Net sélectionné permet d'en comprendre le fonctionnement, d'en cerner les points forts et les défauts, des éléments nécessaires pour indiquer quelques précautions d'emploi et fournir de futures pistes d'amélioration.

Comment caractériser les objets non détectés ou détectés à tort ?

Une évaluation « objet » est utile pour analyser les performances du U-Net selon l'angle du météorologiste plutôt que celui du statisticien. Pour ce faire, on teste l'appariement de chaque objet MCS détecté au seuil $Prob_{min}=50\%$ avec les objets annotés de l'Image d'entrée correspondante. Un appariement a lieu si le pourcentage de recouvrement entre les aires des deux objets est supérieur à 50 %. C'est une simplification des stratégies d'appariement d'objets rencontrées dans la littérature (p. ex. Davis *et al.* 2009). Si un objet MCS détecté par le U-Net n'est apparié avec aucun objet annoté, on dit qu'il est « détecté à tort ». Parallèlement, si un objet annoté n'est apparié à aucun objet détecté par le U-Net, on dit qu'il est « non détecté ».

La Figure 2.15 représente la répartition des objets bien détectés, non détectés et détectés à tort, selon certains attributs des objets annotés (en haut) et des objets détectés par le U-Net (en bas). La Figure 2.15a-c donne ainsi une idée des MCSs responsables des pixels « Faux Négatifs » décrits dans la partie précédente tandis que la Figure 2.15d-f renseigne sur les pixels « Faux Positifs ».

Les MCS annotés non détectés par le U-Net ne semblent pas associés à des extrêmes de Rflc ou de TB particuliers (Figure 2.15a) mais davantage à des objets de petite taille (Figure 2.15b,c), possiblement des systèmes en phase de développement.

De même, les objets détectés à tort sont généralement peu étendus, à la limite du seuil de 100 km (Figure 2.15e,f). Ils peuvent correspondre à des groupes de cellules peu organisées ou des zones de précipitations localement plus intenses au sein de perturbations synoptiques.

Quelle image d'entrée a le plus d'impact sur la sortie du U-Net ?

Les méthodes d'interprétation dites « par occlusion » consistent à masquer artificiellement des données d'entrée pour évaluer leur impact sur la sortie d'un algorithme d'apprentissage automatique. La méthode suivie ici part du formalisme mathématique de L.S. Shapley. Il s'agit d'écrire le résultat d'un modèle f en $X \in \mathbb{R}^N$ comme la somme des contributions Φ_i que chaque composante (ou prédicteur) X_i apporte à la sortie f :

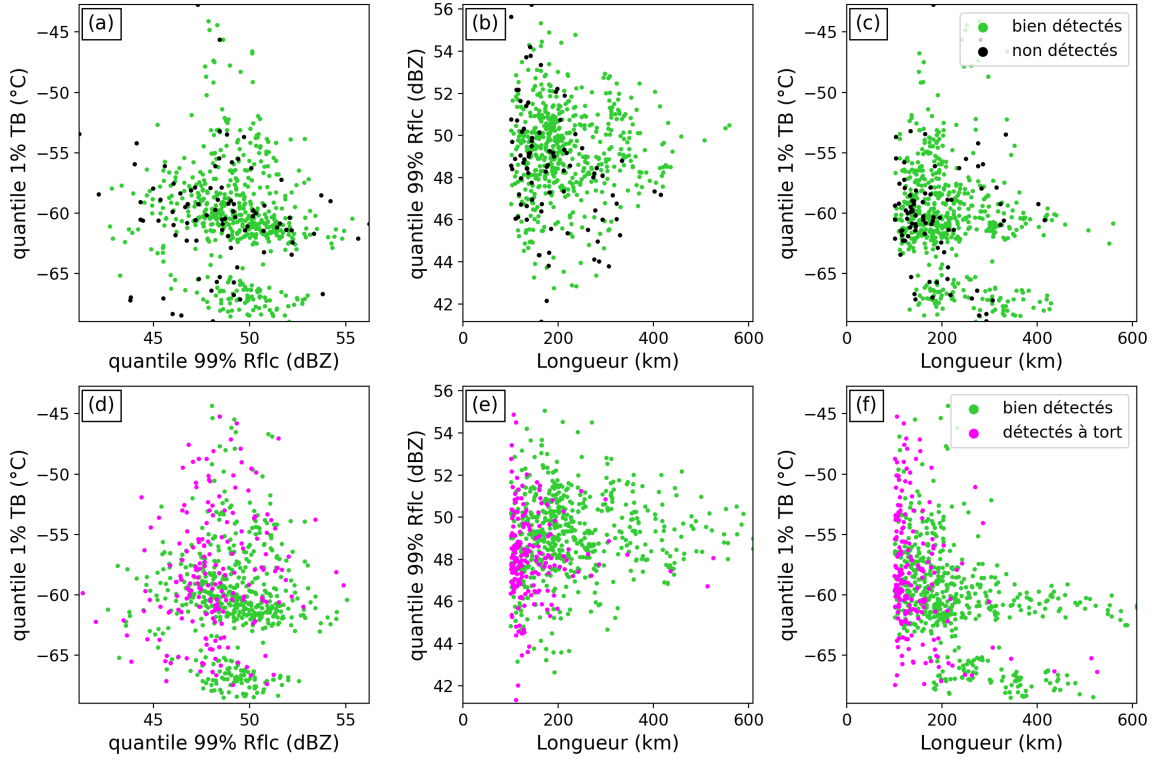


FIGURE 2.15 – Attributs des objets annotés (a-c) et des objets détectés par le U-Net (d-f) sur les Images du jeu de validation. Les objets bien détectés, non détectés et détectés à tort sont affichés en vert, en noir et en rose respectivement. Les attributs renseignés sont la longueur ainsi que les quantiles 1 (99) % des pixels de TB (Rflc) à l'intérieur de chaque objet. Analyse inspirée de Mounier *et al.* (2022).

$$f(X) = \Phi_0 + \sum_{i=1}^N \Phi_i \quad (2.9)$$

avec Φ_0 un terme de biais. Les contributions Φ_i sont appelées *valeurs de Shapley*. On parle aussi de méthode d'attribution additive. Φ_i pourrait naïvement être définie comme la valeur de f calculée à partir du seul prédicteur X_i , les autres étant masqués, mais cela reviendrait à négliger les interactions entre plusieurs prédicteurs dont la contribution mutuelle peut être supérieure à la somme des contributions individuelles. Les Φ_i sont donc calculées à partir de l'ensemble $\{1, 2, \dots, N\} \setminus i$ des coalitions S possibles de prédicteurs excluant X_i , en comparant la sortie $f(X_S)$ correspondante à la sortie $f(X_{S \cup i})$ qui serait obtenue à partir de la même coalition incluant X_i :

$$\Phi_i = \sum_{S \subseteq \{1, 2, \dots, N\} \setminus i} (f(X_{S \cup i}) - f(X_S)) \frac{|S|!(N - |S| - 1)!}{N!} \quad (2.10)$$

La valeur de Shapley Φ_i est donc le résultat d'une moyenne pondérée des contributions d'un prédicteur X_i à la sortie f . Le terme de pondération est la fraction à droite de l'équation 2.10. Il donne plus d'importance (1) aux coalitions S de petite taille, qui quantifient plus directement l'effet individuel d'un prédicteur X_i , et (2) aux coalitions de grande taille, l'idée étant de pondérer davantage l'apport qu'un seul prédicteur représente parmi une coalition de nombreux prédicteurs.

Cependant, deux problèmes se posent lorsqu'il s'agit d'adapter cette méthode aux réseaux de neurones entièrement convolutifs comme le U-Net :

- **1^{er} problème.** Le nombre N de prédicteurs X_i est égal au nombre de pixels dans chaque image d'entrée, multiplié par le nombre d'images d'entrée. N est donc une très grande valeur qui entraîne un nombre plus grand encore de coalitions à tester (2^N). Le coût numérique associé est donc prohibitif.
- **2nd problème.** La sortie du U-Net n'est pas un scalaire mais une image. Dans ce cas, comment définir $f(X)$ dans l'équation 2.10 ?

Pour pallier le 1^{er} problème, [Lundberg et Lee \(2017\)](#) introduisent la méthode *SHAP* en démontrant un théorème selon lequel les valeurs de Shapley Φ_i peuvent être estimées en minimisant l'erreur quadratique R ci-dessous :

$$R = \sum_{S \in \{S_1, S_2, \dots, S_M\}} \left(f(X_S) - \tilde{f}(X_S) \right)^2 \pi_{X'_S} \quad (2.11)$$

avec $\pi_{X'_S}$ un coefficient de pondération adéquate. R quantifie la différence entre la sortie réelle f et la sortie \tilde{f} attendue selon l'équation 2.9, pour un nombre M de coalitions S où certains prédicteurs $X_{S,i}$ sont omis. On a donc $\tilde{f}(X_S) = \Phi_0 + \sum_{i=1}^N \Phi_i \delta_{S,i}$ où $\delta_{S,i} = 1$ ou 0 si le i^e prédicteur est respectivement inclus ou omis dans X_S . Les Φ_i sont alors estimées en résolvant ce problème de minimisation par une régression linéaire pondérée. Certes, la valeur obtenue de Φ_i est une approximation mais, à la différence de l'équation 2.10, seul un échantillon restreint de M coalitions est utilisé pour les calculer.

Par ailleurs, [Dardouillet et al. \(2022\)](#) traitent le 2nd problème en adaptant la méthode de [Lundberg et Lee \(2017\)](#) aux réseaux de neurones entièrement convolutifs. Leur protocole repose sur trois idées :

- diviser les images d'entrée en « super-pixels » afin de réduire le nombre de prédicteurs et faciliter l'interprétation ;
- générer chaque échantillon X_S en masquant les super-pixels de manière aléatoire ;
- s'intéresser uniquement à l'impact des super-pixels sur une portion de l'image de sortie, appelée « région d'intérêt », dont on calcule la moyenne des pixels pour obtenir la valeur scalaire souhaitée $f(X_S)$.

La méthode de [Dardouillet et al. \(2022\)](#) est appliquée sur une image de MCS simulée par AROME et extraite du jeu de validation (Figure 2.16). L'image traitée est un zoom de l'image initiale, centrée sur le nord-est de la France et divisée en 882 super-pixels : 441 pour l'image de Rfc et 441 pour l'image de TB (Figure 2.16d). Les valeurs de Shapley sont renseignées

sur les sous-figures (e) et (f). Elles correspondent aux contributions des super-pixels sur la moyenne de la sortie du U-Net dans la région d'intérêt (carré noir sur la Figure 2.16a). Ainsi, la somme des contributions de Rflc et de TB sur tous les super-pixels des sous-figures (e) et (f), à laquelle s'ajoute un terme de biais Φ_0 non montré, est environ égale à la moyenne du champ de sortie dans la région d'intérêt : c'est le principe de l'équation 2.9. Le nombre M d'échantillons X_S générés pour estimer ces contributions est de 10^5 . Dans chacun de ces échantillons, les super-pixels « omis » ne sont pas réellement omis, car cela est impossible techniquement, mais ils sont remplacés par une valeur neutre égale à la moyenne des données de Rflc ou de TB sur toute l'image. Enfin, si Dardouillet *et al.* (2022) recommandent de définir les super-pixels par un pavage hexagonal des images d'entrée, un pavage carré est ici préféré par simplicité.

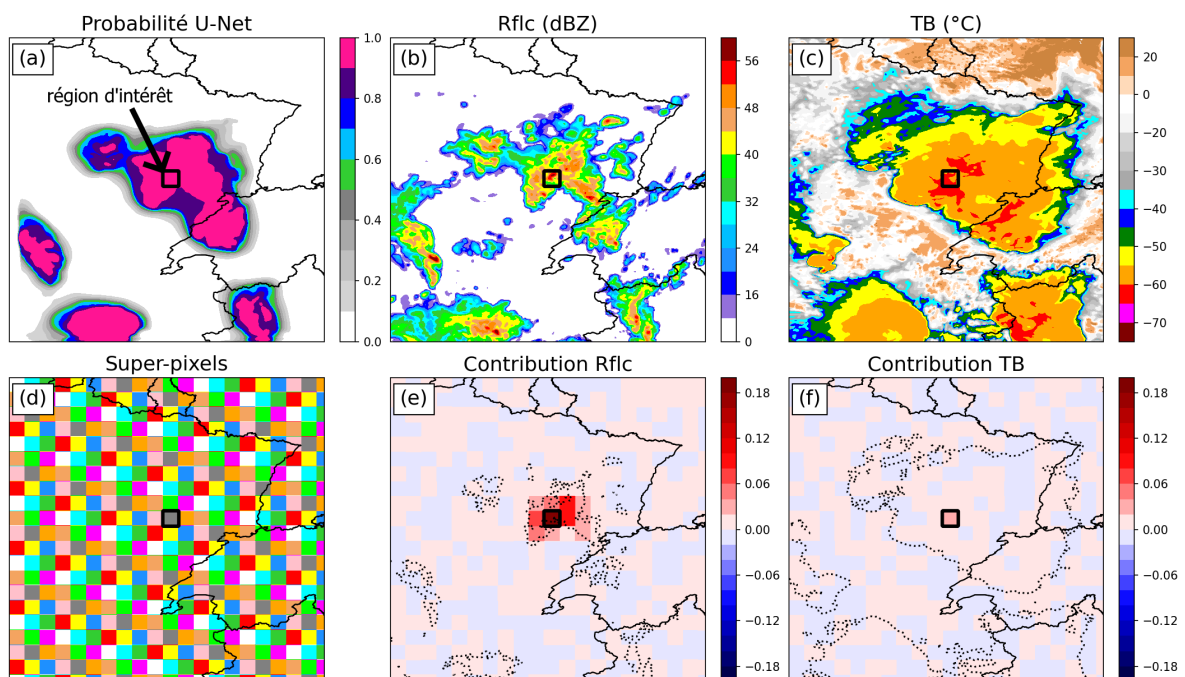


FIGURE 2.16 – Impact des images d'entrée sur la sortie du U-Net dans une zone d'intérêt centrée sur la région convective d'un MCS (carré noir) : (a) champ de probabilité pour la classe « MCS » générée en sortie du U-Net, (b) images de Rflc et (c) de TB, (d) pavage des images d'entrée en super-pixels, (e) contribution des super-pixels de Rflc et (f) de TB à la sortie moyenne dans la zone d'intérêt. Les isolignes 40 dBZ et -45°C sont ajoutées en pointillés sur les sous-figures (e) et (f) respectivement. Situation du 20/06/2021, réseau AROME-PI de 0900 UTC, échéance 270 min.

D'après la Figure 2.16, trois propriétés caractérisent la contribution des images de Rflc et de TB à la sortie du U-Net : (1) les contributions non nulles sont restreintes à un rayon d'une cinquantaine de kilomètres autour de la zone d'intérêt ; (2) ces contributions sont positives, autrement dit l'omission d'un des super-pixels associés conduirait à une diminution de la probabilité moyenne dans la zone d'intérêt ; (3) ici, la contribution des super-pixels de TB est presque nulle. Ce dernier point s'explique par la localisation de la zone d'intérêt, au cœur du

MCS où les Rflc extrêmes suffisent à indiquer la présence d’une activité convective étendue, peu importent les valeurs de TB. Si l’on décale la zone d’intérêt sur une région stratiforme du système (Figure 2.17), la contribution de la TB augmente et devient même prédominante pour les super-pixels où les Rflc sont les plus faibles. Ces conclusions se vérifient sur d’autres situations (non montré).

En somme il apparaît que les données de TB et de Rflc ont toutes les deux un impact sur la sortie du U-Net, même si la contribution des Rflc domine dans les régions de fortes précipitations.

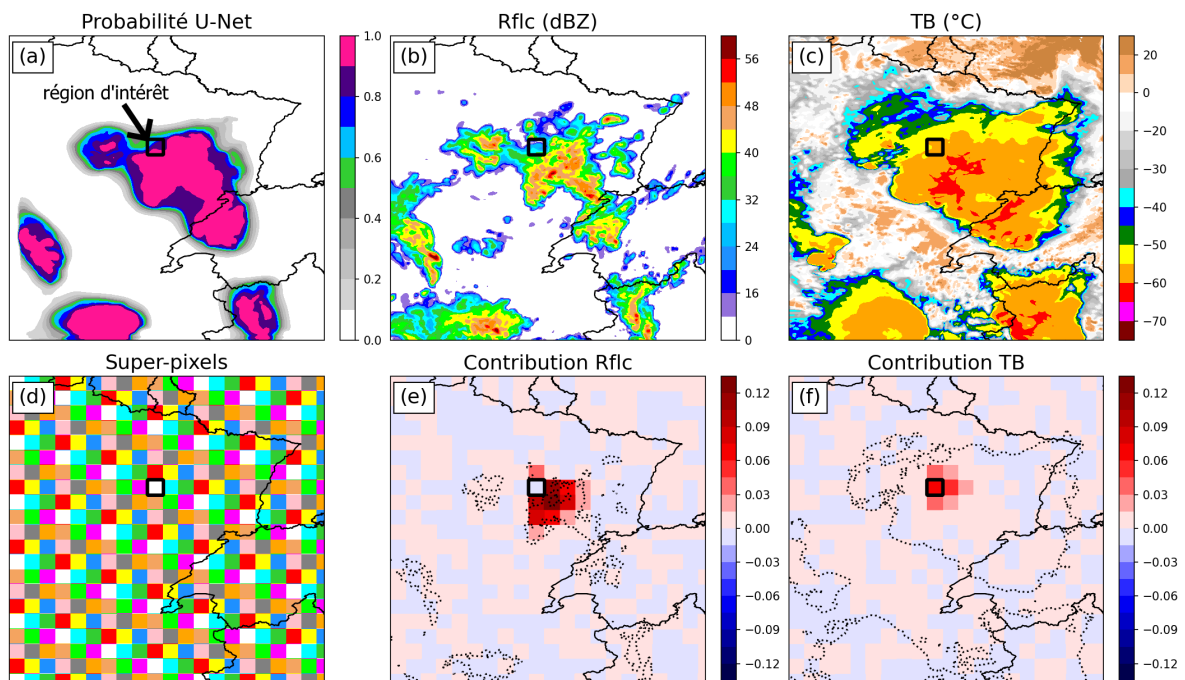


FIGURE 2.17 – Idem Figure 2.16, mais pour une zone d’intérêt centrée sur la région stratiforme du MCS.

2.4 Évaluation et comparaison avec d’autres méthodes de segmentation d’images

Dans la section précédente, un U-Net a été entraîné et configuré pour détecter des MCSs dans des images simulées. Sa robustesse est ici mise à l’épreuve d’un jeu de données test indépendant. On démontre sa plus-value par rapport à trois autres méthodes de segmentation non statistiques et inspirées de la littérature (Figure 2.18). Elles reposent sur des paramètres ajustés en évaluant plusieurs configurations, détaillées dans l’Annexe. À la différence du U-Net, ces paramètres ne sont pas entraînaibles et doivent être fixés manuellement. Il s’agit donc plutôt d’hyperparamètres. Ainsi, le jeu de données utilisé pour calibrer les méthodes non statistiques est le même que celui qui a servi à l’ajustement des hyperparamètre du U-Net, à

savoir le jeu de validation décrit dans la partie 2.3.1.

2.4.1 Méthode alternative n°1 : un simple seuillage

La méthode dite *simple* applique seulement un seuil $Rflc_{min}$ sur une image de Rflc dont les structures ont été préalablement lissées avec un filtre gaussien d'écart-type ν . Les objets dont l'intensité maximale est inférieure à une certaine valeur $Rflc_h$ sont éliminés afin de ne conserver que les phénomènes convectifs. Le simple seuillage est une approche commune que l'on rencontre chez [Rigo et al. \(2019\)](#), [Da Silva et Haerter \(2023\)](#) ou encore [Cui et al. \(2023\)](#) (voir Table 1.1). Après ajustement empirique sur le jeu de validation, les valeurs de $Rflc_{min}$, $Rflc_h$ et ν sont fixées à 30 dBZ, 45 dBZ et 10 respectivement.

2.4.2 Méthode alternative n°2 : algorithme *watershed*

La méthode dite *watershed* emploie deux algorithmes de seuillage adaptatif successifs. Le premier, inspiré de [Lakshmanan et al. \(2009\)](#) et [Feng et al. \(2021\)](#) (Table 1.1), détecte des « systèmes convectifs nuageux » en partant d'un seuil fixé à -55°C dans les images de TB. Tant que ces objets restent de longueur inférieure à l_{min} ou bien ne fusionnent pas avec d'autres objets, ils sont élargis par pas de 5 K jusqu'au seuil plancher TB_{max} . Ils servent alors de graines pour initialiser le second algorithme dit *de partages des eaux* (ou *watershed*), analogue à celui de [Fioleau et Roca \(2013\)](#) (Table 1.1). Celui-ci est appliqué au champ de Rflc et implémenté à l'aide du module Python *scikit-image*. À partir des maxima de précipitations colocalisés avec les « systèmes convectif nuageux », l'algorithme fait grossir des objets jusqu'à un seuil $Rflc_{min}$. Si deux objets se rencontrent durant le processus itératif, l'algorithme impose une frontière artificielle pour les séparer (voir objets 2 et 3 sur la Figure 2.18c). L'idée d'employer deux champs de nature différente pour définir les graines de l'algorithme *watershed* (avec la TB) puis identifier les objets MCS (avec les Rflc) rappelle aussi la méthode implémentée dans le module *tobac* ([Heikenfeld et al., 2019](#)), introduit à la section 1.4.1. Les images de Rflc et de TB sont préalablement lissées par un filtre gaussien d'écart-type ν_{Rflc} et ν_{TB} . Après réglage sur le jeu de validation, les hyperparamètres sont fixés comme suit : $\nu_{Rflc} = 10$, $\nu_{TB} = 10$, $l_{min} = 50$ km, $TB_{max} = -50^\circ\text{C}$ et $Rflc_{min} = 30$ dBZ.

2.4.3 Méthode alternative n°3 : identification à deux rayons de recherche

La méthode à *2 rayons* de recherche est directement adaptée de [Haberlie et Ashley 2018a](#) (Table 1.1). Des cellules convectives (> 20 km²) sont d'abord détectées au seuil de 40 dBZ. Les cellules situées à moins de R_1 km l'une de l'autre sont ensuite fusionnées au sein d'un même « objet convectif ». À celui-ci est greffée une région stratiforme pour former l'objet MCS final. Pour cela, on considère tous les pixels situés au-dessus du seuil $Rflc_{min}$ (< 40 dBZ) dans un rayon de recherche R_2 autour de chaque « objet convectif ». Cette méthode limite l'extension exagérée de certains objets, notamment pour des MCSs frontaux noyés au

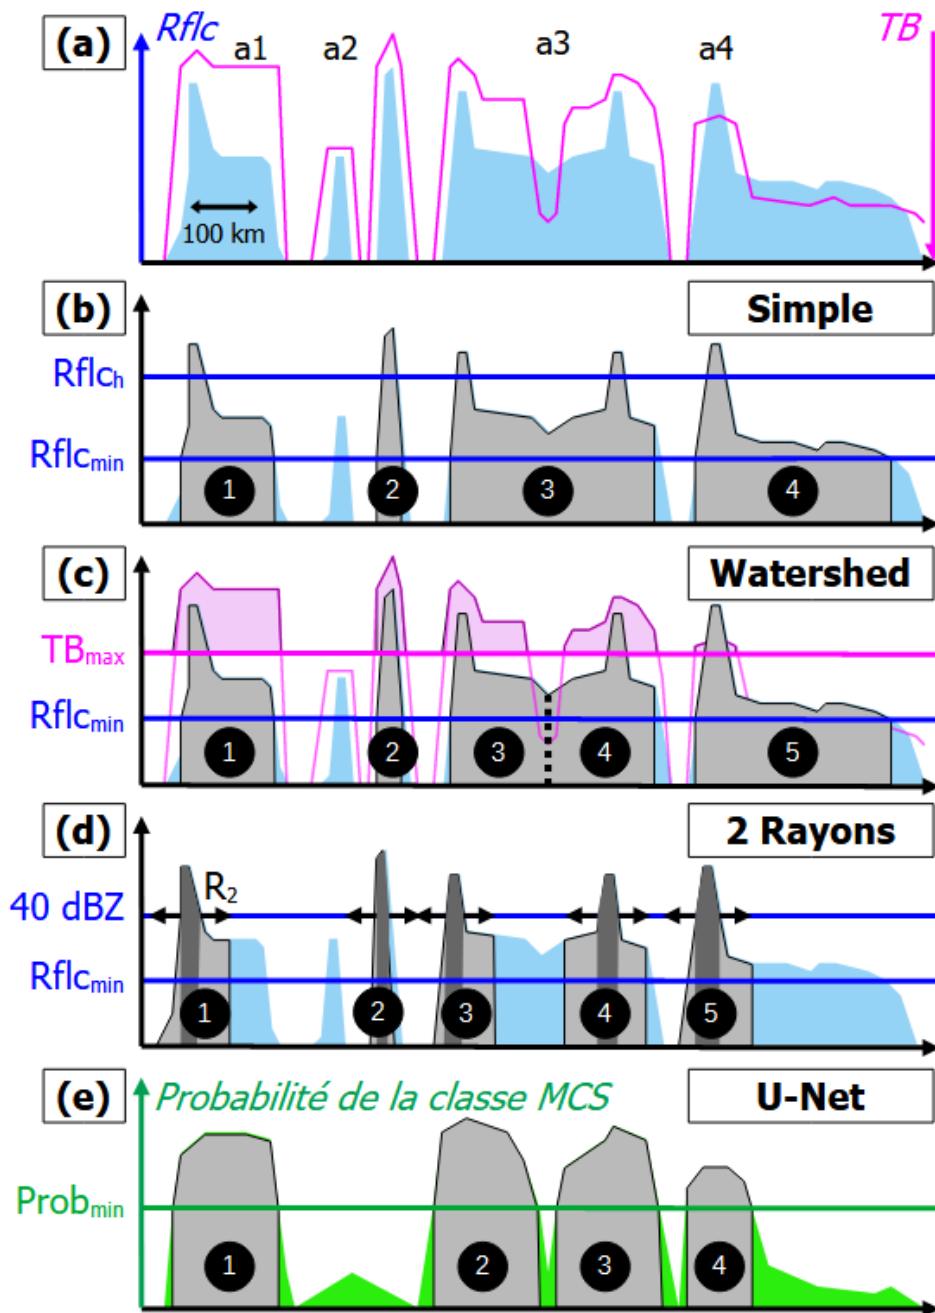


FIGURE 2.18 – Quatre méthodes de segmentation des MCSs : (a) représentation schématique 1D d'un champ de Rf1c et de TB avec (a1) un MCS « classique », (a2) des cellules isolées, (a3) deux MCSs adjacents, (a4) un système convectif noyé dans une perturbation synoptique ; (b) méthode *simple* ; (c) méthode *watershed* ; (d) méthodes à 2 rayons ; (e) U-Net. Les objets détectés figurent en gris et sont numérotés. Les méthodes (b,d) se basent uniquement sur les images de Rf1c, (c,e) sur celles de Rf1c et de TB. Les notations sont détaillées dans le texte.

sein de précipitations synoptiques plus étendues (voir système a4 sur la Figure 2.18). Comme pour les précédentes méthodes, les images de Rflc sont préalablement lissées avec un filtre gaussien d'écart-type ν . La configuration sélectionnée d'hyperparamètres est la suivante : $\nu = 10$, $Rflc_{min} = 30$ dBZ, $R_1 = 24$ km et $R_2 = 48$ km. Par ailleurs, Haberlie et Ashley (2018a) éliminent les MCSs dont la longueur de l'« objet convectif » associé est inférieure à 100 km. Cette condition n'est pas retenue ici car elle induit une baisse en POD pour un FAR équivalent (non montré). De plus, Haberlie et Ashley (2018a) ont recours à un algorithme d'apprentissage machine pour distinguer, parmi les objets obtenus, ceux qui sont de véritables MCSs de ceux qui ne le sont pas. Les données d'entrée sont alors des attributs géométriques et convectifs des objets. Cette seconde approche n'a cependant pas été approfondie durant cette thèse.

2.4.4 Comparaison objective sur le jeu de test

Les trois méthodes de détection décrites ci-dessus sont évaluées et comparées au U-Net à partir d'un diagramme de performance (voir partie 2.3.4). Les scores POD, FAR et CSI des quatre méthodes sont calculés sur le jeu de test qui comprend 550 images sur 10 journées convectives différentes (Table 2.1). Les objets de longueur inférieure à 100 km sont préalablement filtrés.

Les résultats sont affichés sur la Figure 2.19a. Le U-Net présente le meilleur CSI (0,55). Ce score est comparable à celui qui est obtenu sur le jeu de validation, traduisant la robustesse du réseau. Les trois autres approches ont un POD similaire mais détectent davantage de MCSs à tort, en particulier la méthode *simple*. La Figure 2.19a montre aussi les scores du U-Net sur plusieurs niveaux de probabilité $Prob_{min}$ retenus pour définir le contour de l'objet dans les sorties du réseau. On vérifie ainsi que le niveau de 50 % fixé par convention ne sous-estime pas les performances optimales du U-Net sélectionné. Si les niveaux de 60 à 70 % réduisent le FAR et affichent le meilleur CSI, ils dégradent le POD sensiblement, notamment vis-à-vis des autres méthodes. On conservera donc le seuil de 50 % pour identifier les MCSs dans les sorties du U-Net.

Cependant, les scores calculés à partir des pixels peuvent être sensibles aux contours de référence. Puisque ces derniers sont définis manuellement, leur tracé est parfois grossier et ne tient pas compte de certains détails spatiaux. Les scores précédents sont donc complétés par une évaluation « objet » qui respecte une tolérance spatiale. Son protocole est identique à celui de la partie 2.3.5. Des pourcentages de recouvrement sont calculés entre les aires des objets détectés et des objets de référence ; un appariement est validé si le pourcentage dépasse 50 %. On compte ensuite le nombre VP (FN) des objets de référence appariés (non appariés) à un objet détecté, ainsi que le nombre FP des objets détectés non appariés. Les scores de contingence sont ensuite obtenus à partir des équations 2.8 et renseignés sur la Figure 2.19b. Les conclusions auxquelles ils aboutissent sont identiques à celles de l'évaluation menée à l'échelle du pixel. En effet, le U-Net limite le nombre de détections à tort car 62 % des objets identifiés sont effectivement appariés à un objet de référence, contre seulement 27 à 46 % pour les autres méthodes. Ici, le U-Net améliore aussi le POD. 91 % des objets de référence sont

bien appariés à un objet détecté, contre près de 70 à 80 % pour les méthodes non statistiques. En somme, l'ajout d'une tolérance spatiale ne contredit pas l'apport de la méthode U-Net.

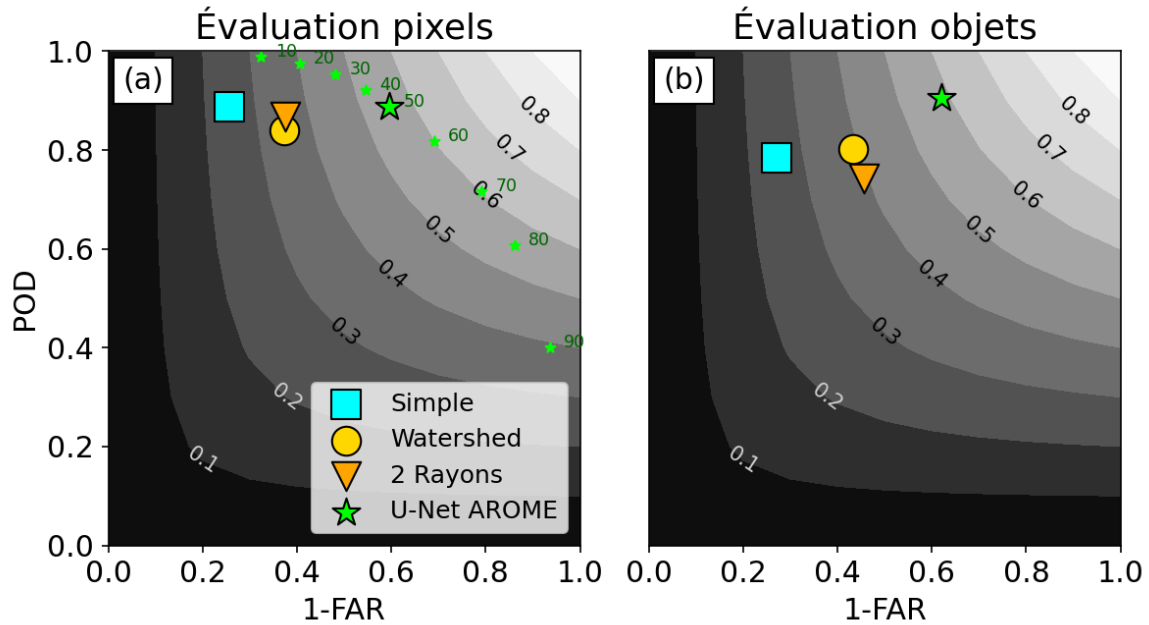


FIGURE 2.19 – Performances obtenues sur le jeu de test par les quatre méthodes de détection des MCSs simulés, (a) évaluées à l'échelle du pixel et (b) évaluées en quantifiant les appariements entre objets détectés et objets de référence. La sous-figure (a) montre aussi les scores du U-Net calculés pour plusieurs niveaux de probabilité $Prob_{min}$ entre 10 et 90 %, comme indiqué à-côté du marqueur correspondant en forme d'étoile. Le score CSI apparaît en isolignes.

Les objets détectés par les quatre méthodes sont caractérisés sur la Figure 2.20. Chacune d'elles identifie un trop grand nombre d'objets par rapport au jeu de référence mais le U-Net minimise cette surdétection. D'ailleurs, si l'on suit le protocole d'appariement énoncé dans la partie 2.3.5, le U-Net a le plus faible taux d'objets détectés à tort (0,38 contre plus de 0,50 pour les autres méthodes, non montré).

Pour la longueur des objets, la distribution propre au U-Net est la plus proche de la distribution de référence (Figure 2.20a). La médiane reste cependant inférieure. Elle reflète la distribution des objets détectés à tort dont la plupart sont de petite taille (non montré), comme discuté dans la 2.3.5. Les objets des autres méthodes sont généralement trop grands. Certaines valeurs situées dans le dernier décile dépassent 1000 km pour le *simple* seuillage et l'algorithme *watershed* (non visibles sur la Figure 2.20a). Ces dimensions sont peu réalistes pour un MCS. Elles concernent typiquement des objets détectés dans les perturbations synoptiques actives, comme sur la situation du 03/10/2021 abordée dans la prochaine partie.

Pour les extrêmes de Rflc et de TB, c'est encore avec le U-Net que les distributions d'attributs entre objets annotés et détectés sont les plus proches (Figure 2.20b,c). L'algorithme

watershed le concurrence sur la TB, sans doute parce qu'il utilise aussi ce prédicteur. Par ailleurs, toutes les méthodes détectent des systèmes dont l'intensité convective est en moyenne plus faible que celle des MCSs annotés.

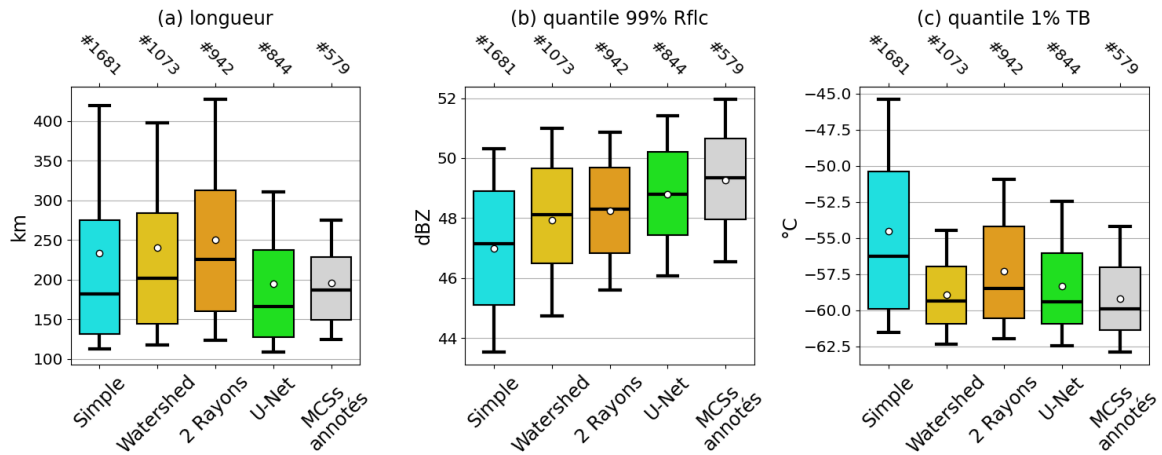


FIGURE 2.20 – Distributions des attributs associés aux objets annotés et aux objets détectés par les quatre méthodes sur le jeu de test : (a) longueur, (b) quantile 99 % des pixels de Rf1c et (c) quantile 1 % des pixels de TB à l'intérieur de chaque objet. Sur les boîtes, le rond blanc indique la moyenne et les moustaches correspondent aux quantiles 10% et 90% des distributions. Le symbole # précise le nombre d'objets dans chaque classe.

2.4.5 Comparaison sur des études de cas

Le comportement de chaque méthode est illustré sur trois situations extraites du jeu de test.

La Figure 2.21 montre une dégradation orageuse d'été classique, où une dépression sur le Golfe de Gascogne pilote un flux de sud, chaud et humide, sur une grande partie de la France. Dans cette atmosphère conditionnellement instable, des MCSs sont simulés par le réseau 1200 UTC d'AROME-PI. Ils évoluent au niveau de deux forçages d'altitude, un premier sur le sud-ouest, l'autre sur la moitié nord. Ces MCSs sont identifiés par chacune des quatre méthodes mais seuls le U-Net et la méthode *watershed* parviennent à discriminer les systèmes adjacents au nord, tels qu'ils ont été annotés. Le U-Net propose également un contour plus réaliste pour l'objet du sud-ouest en séparant le MCS du groupe de cellules évoluant plus au sud. Par ailleurs, comparée à l'annotation, chaque méthode détecte des objets à tort. Ceux dont la longueur dépasse 100 km ne sont néanmoins pas aberrants pour le U-Net. Ils ne sont pas annotés car moins organisés que les autres mais ils présentent en effet des caractéristiques communes aux MCSs. Enfin, le contour des objets détectés par le U-Net est particulièrement lisse. Cet aspect épuré s'accorde davantage avec la vision humaine du phénomène.

La situation de la Figure 2.22 est un exemple typique de systèmes détectés à tort. Un front froid actif concerne alors le pays. Malgré des Rf1c modérées à fortes et de faibles TB, il

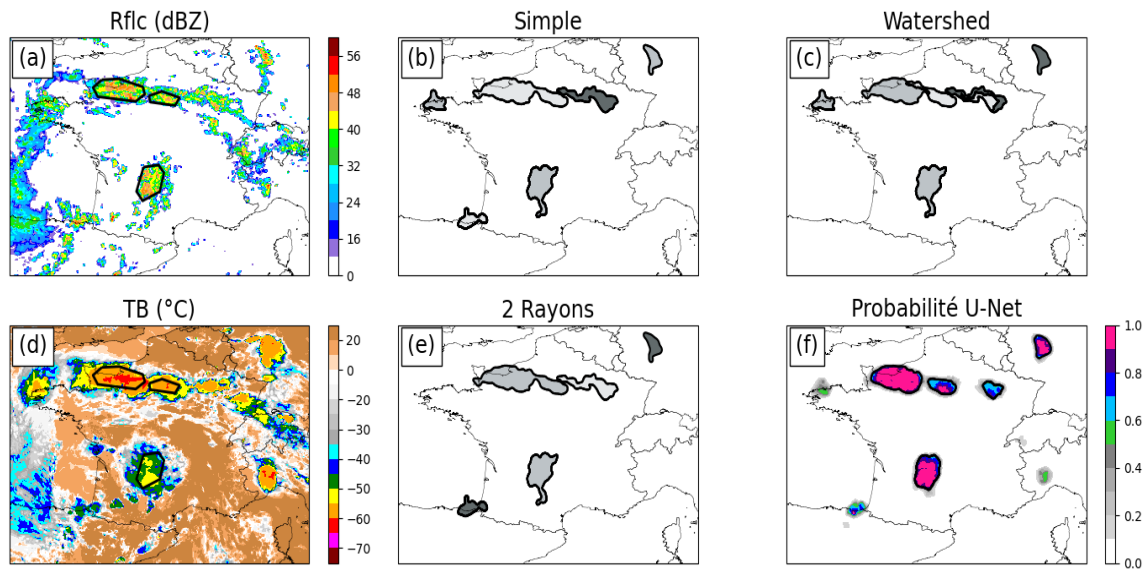


FIGURE 2.21 – Objets MCS détectés (contours noirs) par chacune des quatre méthodes testées sur la situation du 12/08/2020 (réseau AROME-PI de 1200 UTC, échéance 300 min). Seuls les objets de longueur supérieure à 100 km sont considérés. La sous-figure (f) indique aussi le champ de probabilité pour la classe « MCS » généré par le U-Net. Les objets de référence, annotés à la main, sont superposés aux champs de Rf1c et de TB sur les sous-figures (a) et (d).

ne présente pas de caractère convectif. Si chaque méthode détecte des MCSs à tort, la zone identifiée par le U-Net est la moins étendue, confinée à la région de plus faible TB. Le fort gradient de TB associé aux bords des MCSs, qu'on ne retrouve pas ici, est une caractéristique que le U-Net ne semble pas avoir suffisamment apprise.

Quelques heures plus tard, le front froid force le développement d'une ligne convective dans une atmosphère conditionnellement instable sur le sud-est de la France (Figure 2.23). Le U-Net identifie l'objet le plus réaliste. En se concentrant sur les zones de fortes Rf1c et de faibles TB, il isole le système du reste de la perturbation. Les objets détectés par les autres méthodes occupent une zone beaucoup trop vaste, même si l'approche à *2 rayons* limite l'extension du système sur sa partie nord.

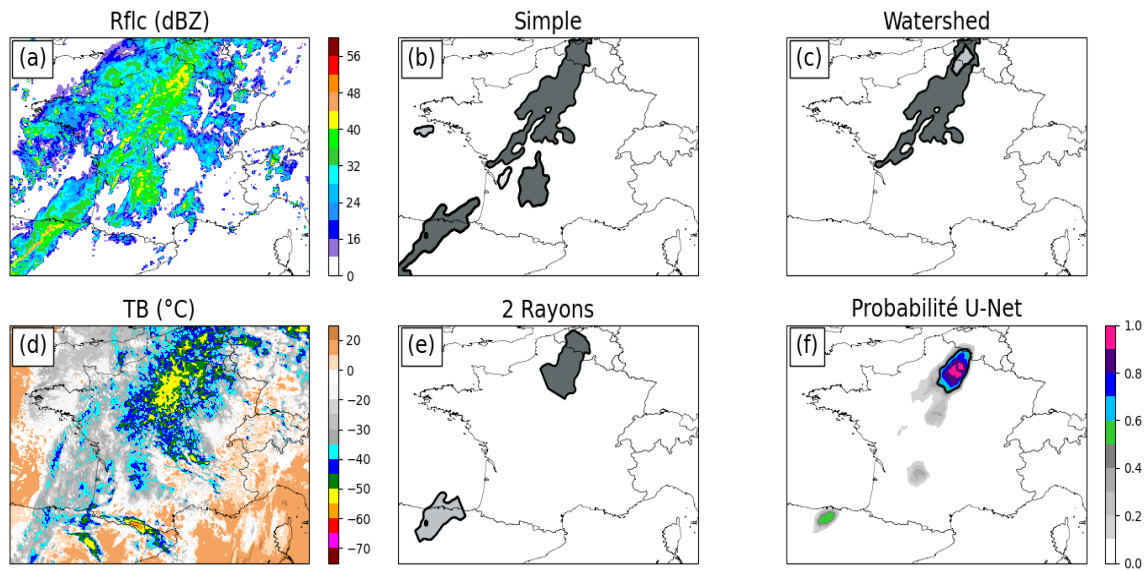


FIGURE 2.22 – Idem Figure 2.21, mais pour la situation du 03/10/2021 (réseau AROME-PI de 0200 UTC, échéance 180 min).

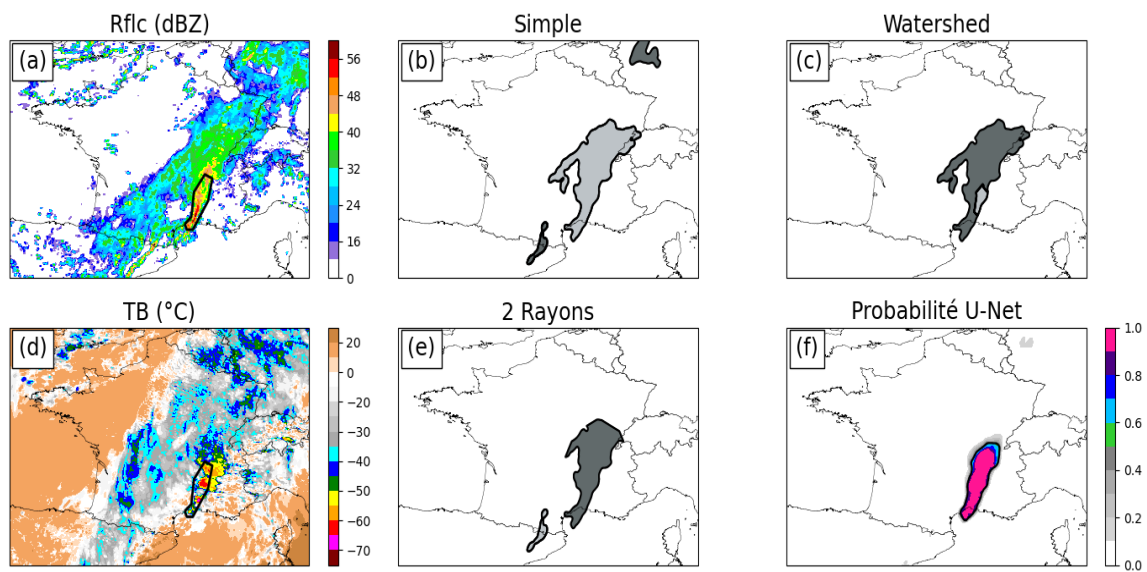


FIGURE 2.23 – Idem Figure 2.21, mais pour la situation du 03/10/2021 (réseau AROME-PI de 1500 UTC, échéance 60 min).

2.5 Un second U-Net dédié aux images observées

La section précédente a montré la plus-value d'un U-Net pour identifier des MCSs dans des images simulées, que l'on nommera dans la suite **U-Net AROME**. L'équivalent pour

des images observées (**U-Net OBS**) est présenté puis évalué ici.

2.5.1 Jeux de données d’observation

Les champs de Rflc et de TB observées proviennent respectivement de la mosaïque radar SERVAl (voir partie 1.3.2) et du radiomètre SEVIRI à bord du satellite MSG (voir partie 1.3.1). Comme pour les données AROME, elles sont projetées sur une grille de $0,01^\circ \times 0,01^\circ$, proche de la résolution native de la mesure observée. Dans cette partie ainsi que dans l’intégralité du manuscrit, les observations sont supposées stables dans le temps, une condition assurant la robustesse de la méthode de détection. Dans SERVAl, le calcul des Rflc 2D et la correction de l’atténuation n’ont pas connu de modifications majeures depuis 2018. La calibration de certains radars du réseau a néanmoins évolué, notamment pour corriger des problèmes de dérive conduisant à des sous-estimations des Rflc observées. Ces changements ont donc pour objectif d’assurer la stabilité de la mesure. Enfin, une panne de radar peut altérer la mosaïque 2D très temporairement mais l’impact de ce type d’évènements est supposé négligeable sur l’étendue de la période d’étude. Par ailleurs, les images de TB sont également stables dans le temps grâce à la calibration Eumetsat (discussions interne).

Afin de disposer d’une donnée de Rflc et de TB en chaque pixel, le domaine des images utilisées est contraint par la couverture du réseau radar ARAMIS. Avec des dimensions de 1104×856 pixels, elles sont plus petites que les images utilisées pour entraîner le U-Net AROME et n’occupent pas la totalité de la France métropolitaine (voir Figure 2.8). Cependant, on suppose que les performances du U-Net OBS seront similaires sur les régions voisines, climatologiquement proches du domaine d’entraînement.

Les images observées composant les jeux d’entraînement, de validation et de test sont extraites des mêmes journées sélectionnées pour construire les bases de données simulées. Le protocole d’annotation est également identique. Plus de 1850 objets MCS sont ainsi définis à partir de 2256 images, des quantités comparables à celles des jeux de données précédents (voir Table 2.1).

Les Figures 2.24 et 2.25 comparent les statistiques des données observées et simulées constituant le jeu d’entraînement, pour les Rflc et la TB respectivement. Les distributions sont proches, les différences pouvant être liées à la nature des données ou à la limitation du domaine pour les images observées. Des résultats similaires sont obtenus sur les jeux de validation et de test (non montrés). Les extrêmes de Rflc sont plus marqués sur les données radar observées, comme noté par [Brousseau *et al.* \(2016\)](#). La cause tient probablement à la formulation du schéma microphysique d’AROME à un moment. À l’inverse, les Rflc des MCSs observés sont en moyenne un peu plus faibles que celles des MCSs simulés.

Certes, le U-Net développé sur les images AROME pourrait simplement être réutilisé pour détecter des MCSs dans les observations. Or les quelques différences rencontrées entre les deux sources de données, notamment sur les Rflc, motivent la décision d’entraîner un U-Net spécialement dédié aux MCSs observés. Les coefficients utilisés pour normaliser les données observées sont identiques aux coefficients introduits pour les données simulées (section 2.3.2),

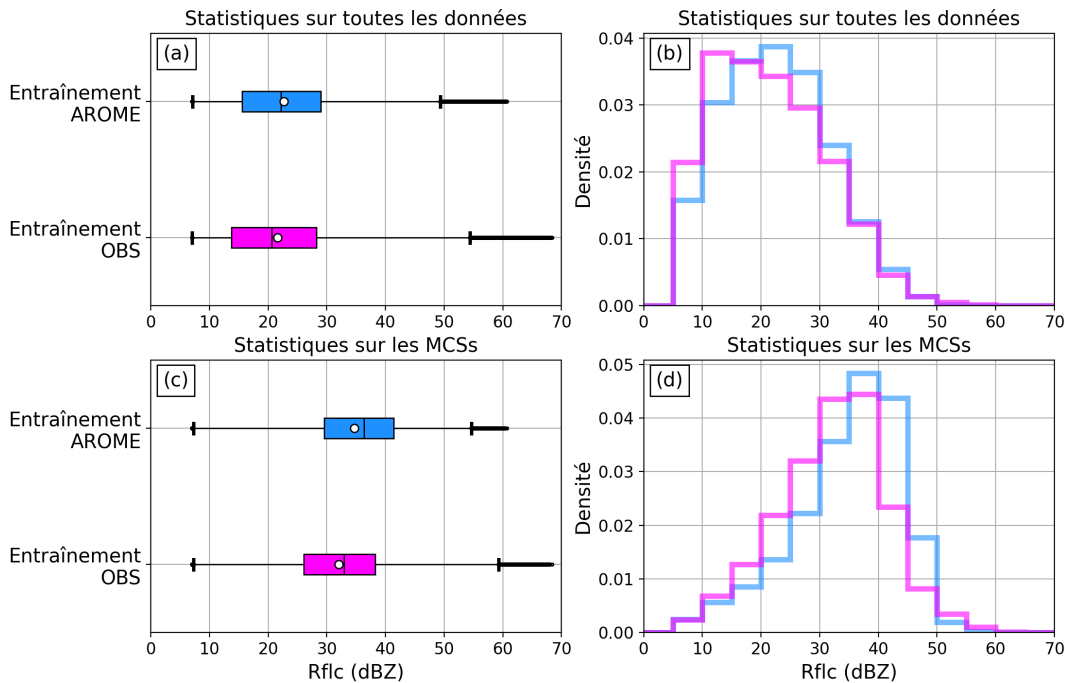


FIGURE 2.24 – Idem Figure 2.10, mais pour les jeux d’entraînement des images AROME (en bleu) et des images observées (en rose).

à savoir : $X_{1,min} = 0$ mm/h, $X_{1,max} = 100$ mm/h, $X_{2,min} = -73.15^\circ\text{C}$ et $X_{2,max} = 27.15^\circ\text{C}$.

2.5.2 Réglage des hyperparamètres

Comme précédemment, plusieurs combinaisons d’hyperparamètres sont testées afin de sélectionner une configuration optimale. En capitalisant sur les résultats de la partie 2.3.3, on réduit par ailleurs le coût d’entraînement et d’analyse. Ainsi, les Rfc sont directement converties en mm/h car des Rfc en dBZ conduisaient à de nombreux U-Nets « non pertinents » sur les images simulées. De plus, la dimension des filtres est fixée à 5×5 afin que les U-Nets OBS et AROME aient le même champ récepteur. Deux valeurs sont testées pour le nombre de filtres dans le premier bloc de convolution (4 ou 8) et le poids de la classe « MCS » dans la fonction coût (3 ou 5). Tous les autres hyperparamètres sont identiques à ceux de la Table 2.2, hormis la dimension des images d’entraînement, ici de 1104×856 . Un léger lissage leur est appliqué (filtre gaussien d’écart-type 1) afin d’atténuer la forte granularité, parfois irréaliste, des mesures observées.

Le protocole d’évaluation est identique à celui de la partie 2.3.4. 10 entraînements sont lancés pour chacune des $2 \times 2 = 4$ configurations d’hyperparamètres. Les U-Nets obtenus sont

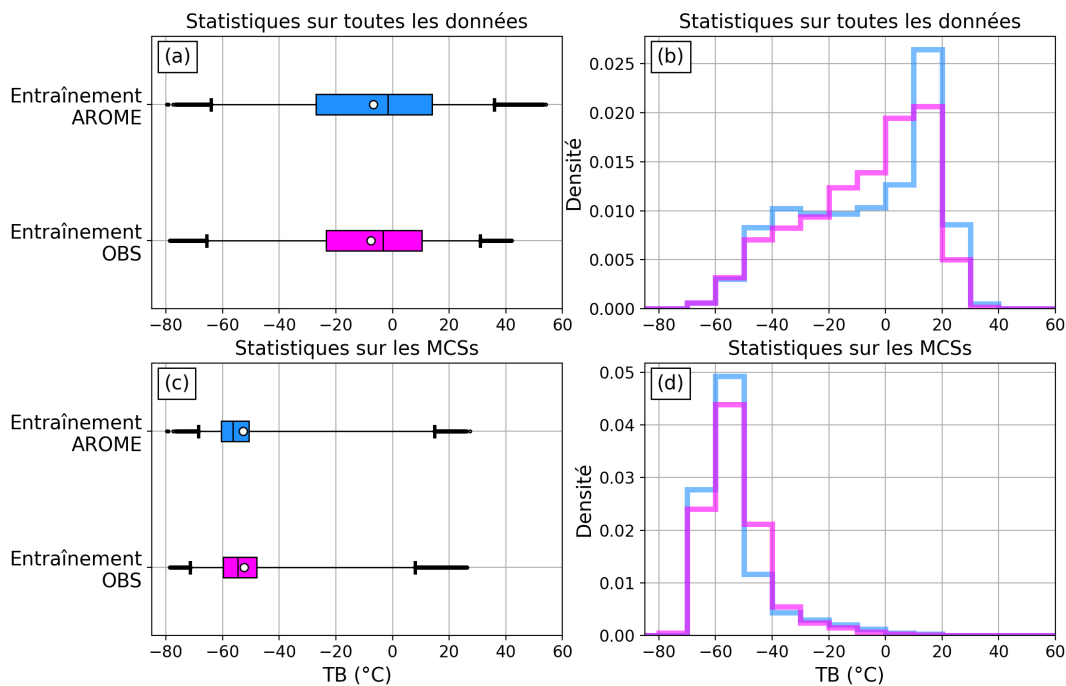


FIGURE 2.25 – Idem Figure 2.11, mais pour les jeux d’entraînement des images AROME (en bleu) et des images observées (en rose).

ensuite comparés sur la base du jeu de validation à l’aide d’un diagramme de performance. Des scores similaires sont constatés pour chaque configuration (non montrés). Les U-Nets les plus performants sont ensuite départagés grâce à une évaluation subjective. Le U-Net OBS finalement choisi diffère du U-Net AROME par le nombre de filtres dans le premier bloc qui est de 8 plutôt que de 4. Cependant, l’analyse du U-Net OBS montre des propriétés semblables à celles du U-Net AROME, exposées dans la partie 2.3.5 : les fausses détections correspondent souvent à de petits objets et l’impact des images d’entrée sur la sortie est dominé par les fortes Rflc (non montré).

2.5.3 Évaluation du U-Net OBS

Évalué sur le jeu de test des données observées, le U-Net OBS obtient un score CSI inférieur à celui que le U-Net AROME présentait sur le jeu de test des données simulées (0.46 contre 0.55). Cela est lié à un FAR plus important. Une évaluation « objet », quantifiant les appariements entre objets observés de référence et objets détectés, mène aux mêmes conclusions (non montré). Les jeux de test n’étant naturellement pas identiques, une comparaison rigoureuse des deux U-Nets reste limitée. On suppose toutefois que les résultats sont révélateurs des performances moyennes de chacun.

Les raisons expliquant les performances inférieures du U-Net OBS par rapport au U-Net AROME n'ont pas été explorées. Deux hypothèses sont néanmoins formulées : (1) les légers décalages temporels entre des images observées de Rflc et de TB dont les mesures ne sont pas synchronisées ; (2) des maxima de Rflc observées plus intenses, rendant le U-Net OBS plus sensible aux groupes de cellules désorganisées.

On teste finalement différents seuils de probabilité pour définir les MCSs observés et minimiser l'écart entre les performances des deux U-Nets. Sur la Figure 2.26, le seuil de 60 % apparaît comme le meilleur compromis. En effet, son CSI est le plus proche du score obtenu pour le U-Net AROME dont le seuil de probabilité a été fixé à 50 %.

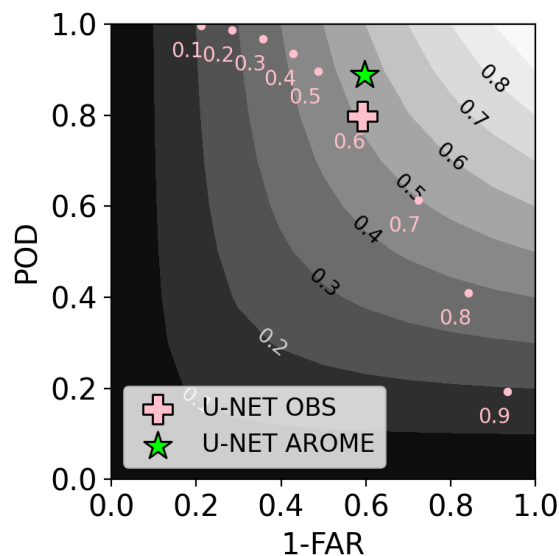


FIGURE 2.26 – Scores obtenus par le U-Net OBS sur le jeu de test des données observées, pour plusieurs seuils de probabilité testés (points) et le seuil de 60 % retenu au final (croix). Le symbole étoile rappelle les scores obtenus par le U-Net AROME sur le jeu de test des données simulées. Le score CSI apparaît en isolignes.

Les performances du U-Net OBS sont finalement évaluées sur quelques études de cas, en reprenant les situations de la partie 2.4.5.

Sur le cas estival de la Figure 2.27, le contour à 60 % englobe correctement les MCSs annotés sur le nord-ouest et le sud-ouest de la France, ainsi que sur l'Allemagne. Malgré des Rflc fortes et étendues, les cellules sur les Alpes ne sont pas détectées, à raison, et le signal correspondant à la cellule italienne reste de longueur inférieure à 100 km. Cependant, l'amas de cellules désorganisées sur le Golfe de Gascogne est détecté à tort tandis que le MCS sur le nord-est est mal identifié, les fortes probabilités se concentrant uniquement sur sa partie la plus active.

Le U-Net OBS est très performant sur la situation synoptique de la Figure 2.28. À raison, il ne détecte aucun MCS malgré plusieurs phénomènes propices aux fausses alarmes : front

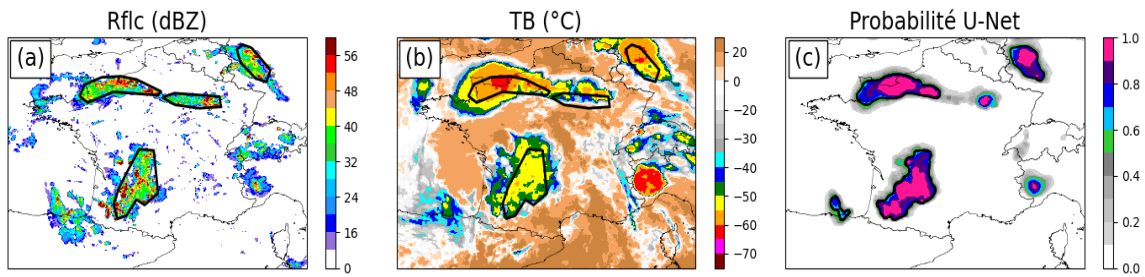


FIGURE 2.27 – Comportement du U-Net OBS sur la situation du 12/08/2020, 1700 UTC. Les MCSs annotés figurent en contours noirs sur les observations de Rf1c (a) et de TB (b). La sous-figure (c) indique le champ de probabilité pour la classe « MCS » avec les objets détectés au seuil de 60 % en contours noirs.

actif sur la moitié nord, cirrus en aval des Pyrénées, précipitations orographiques sur les Cévennes, sans caractère convectif notable.

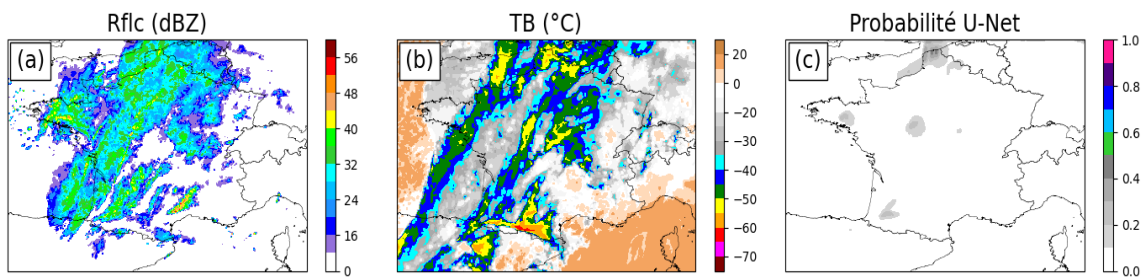


FIGURE 2.28 – Idem Figure 2.27, mais pour la situation du 03/10/2021, 0500 UTC.

Comme pour le U-Net AROME, le U-Net OBS parvient enfin à discriminer raisonnablement la ligne convective du reste de la perturbation sur la Figure 2.29.

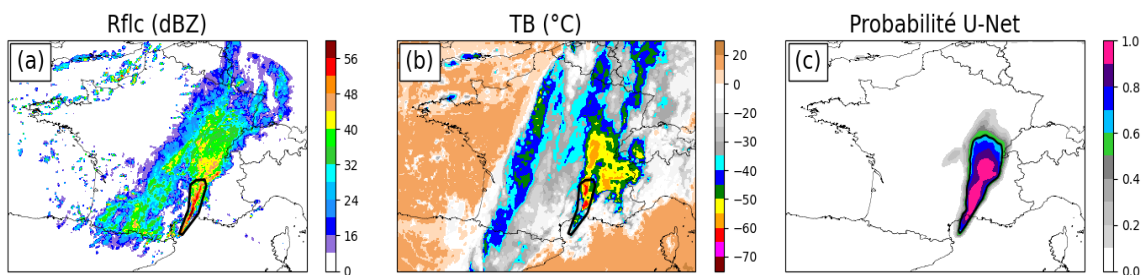


FIGURE 2.29 – Idem Figure 2.27, mais pour la situation du 03/10/2021, 1600 UTC.

2.6 Conclusions et perspectives

Deux réseaux de neurones convolutifs d'architecture U-Net ont été développés pour l'identification des MCSs en France, le premier à partir d'images simulées par AROME, le second à partir d'images observées. Les données d'entrée sont des champs de réflectivités (Rflc) et de température de brillance infrarouge (TB).

Évalué sur un jeu d'images test annotées à la main, le U-Net entraîné sur les données simulées s'est révélé plus performant que d'autres méthodes de segmentation non statistiques. Les principaux avantages du U-Net sont (1) une plus grande robustesse avec moins de fausses détections, (2) une capacité à exploiter les deux images de Rflc et de TB pour apprendre des caractéristiques propres aux MCSs, (3) la génération de contours épurés, un atout pour alimenter des outils de suivi et d'expertise dédiés à la PI.

Certaines limitations du U-Net ont par ailleurs été mises en évidence, appelant plusieurs sources d'amélioration. Celles-ci concernent à la fois les données d'entrée, l'apprentissage et l'architecture du réseau.

- **Comment rendre le U-Net plus robuste ?** Comment diminuer un taux de fausses alarmes encore important et améliorer la détection des MCSs moins intenses ? D'abord en augmentant la taille du jeu d'entraînement et surtout la diversité des situations. Il s'agit notamment d'inclure des cas ambigus comme des perturbations actives (pour les fausses détections) ou des MCSs en phase de dissipation (pour les systèmes moins intenses). Dans la construction de la base de référence, il serait aussi souhaitable de mobiliser davantage d'experts annotateurs afin d'annuler le biais subjectif qu'une personne seule introduit naturellement. Cependant, il peut être délicat de rassembler plusieurs volontaires autour d'une tâche aussi fastidieuse. Par ailleurs, des stratégies d'*augmentation de données* permettraient de générer de nouvelles images à moindre coût (Shorten et Khoshgoftaar, 2019). Beaucoup reposent sur la modification des images initiales, méthode à employer avec précaution pour ne pas rendre la donnée irréaliste. Enfin, de nouveaux prédicteurs peuvent compléter les données d'entrée existantes. Par exemple, les données radar 3D aideraient à mieux distinguer les MCSs des précipitations synoptiques stratiformes tandis que la densité de foudre, généralement très élevée durant la phase de croissance, pourrait améliorer la détection des MCSs en développement.
- **Comment rendre l'apprentissage plus efficace ?** Les performances du U-Net pourraient être améliorées en introduisant des *modules d'attention* au sein du réseau. Ceux-ci consistent à pondérer les images d'entrée de certaines couches selon leur pertinence pour le calcul de la sortie. Par exemple, on souhaiterait que les régions des images sans précipitations ou sans sommets nuageux froids soient faiblement pondérées par rapport aux autres régions. La pondération est automatique et implique de nouveaux paramètres entraînaibles mis à jour durant l'apprentissage. Les *modules d'attention* reçoivent un intérêt grandissant depuis les années 2010. Guo *et al.* (2022), parmi d'autres, proposent une revue des différentes approches. Certaines pondèrent les canaux (*channel attention*) ou des régions de l'Image (*spatial attention*), voire les deux à la fois. C'est le cas du module CBAM (Woo *et al.*, 2018) où la pondération s'effectue en deux temps. D'abord, une opération

de *pooling* réduit les images de chaque canal à une valeur scalaire traduisant le contexte global de l'image. Le vecteur obtenu est transformé par un perceptron multicouches dont les composantes du vecteur de sortie donnent la pondération de chaque canal. Ensuite, les images de chaque canal sont regroupées en une seule image à laquelle on applique un filtre de convolution. Les pixels de l'image résultante donne la pondération de chaque région de l'espace. [Li et al. \(2022\)](#) ont introduit un module CBAM dans les blocs de leur architecture U-Net, ainsi qu'un second module (SENET, [Hu et al. 2019](#)) spécialement dédié à la pondération des canaux. Appliqué à la détection de nuages convectifs dans des images satellite, leur réseau se révèle plus performant qu'un U-Net classique. [Schlemper et al. \(2019\)](#) proposent un autre module (*Attention gate*) où les images des couches profondes, qui contiennent une meilleure information sur le contexte global des données, servent à pondérer les images copiées en entrée de la partie *décodeur*.

- **Comment améliorer la segmentation des MCSs adjacents** que le U-Net, comme beaucoup d'approches par seuillage, tend parfois à réunir en un seul objet ? Une solution consiste à pondérer la fonction coût avec un fort coefficient pour les pixels situés dans le voisinage immédiat des MCSs annotés, méthode employée par [Ronneberger et al. \(2015\)](#). Pondérer de la sorte les précipitations qui ne sont pas associées à des MCSs serait aussi un moyen de réduire les fausses détections. Des opérations en post-traitement sont également possibles.
- **Comment faire en sorte que le U-Net accorde plus d'importance aux images de TB ?** Peut-être en divisant la partie *encodeur* en deux bases de convolution séparées, la première pour les images de Rf/c, la seconde pour les images de TB. Cette méthode a été employée par [Cintineo et al. \(2020a\)](#) pour traiter des données satellite issues d'un radiomètre et d'un imageur d'éclairs. D'autres canaux pourraient aussi compléter la TB à 10,8 μm . Un article récemment publié aborde la détection des MCSs à partir d'un réseau de neurones convolutifs entraîné sur des images satellite ([Krinitskiy et al., 2023](#)). Les auteurs considèrent les canaux à 10,8 et 6,25 μm ainsi que la différence entre les deux. Le signal à 6,25 μm est sensible à l'absorption par la vapeur d'eau et renseigne donc sur l'humidité de l'atmosphère. La différence des canaux à 6,25 μm et 10,8 μm peut indiquer des sommets protubérants (p. ex. [Bedka et al. 2010](#)). Cependant, [Krinitskiy et al. \(2023\)](#) ne précisent pas l'importance de chaque prédicteur satellite. Enfin, l'arrivée prochaine des satellites Météosat Troisième Génération (MTG, [Holmlund et al. 2021](#)) permettra d'accéder à de meilleures mesures de TB et d'améliorer ainsi la détection des MCSs observés. Le nouveau radiomètre FCI sera en effet doté d'une plus grande résolution spatiale et temporelle.
- **Comment diminuer la complexité du U-Net** afin de réduire le temps de calcul à l'entraînement, à l'exécution et surtout limiter le risque de surapprentissage ? [Lu et al. \(2022\)](#) montrent que les performances du U-Net tiennent principalement à sa partie *encodeur*. L'architecture « demi-U-Net » (*half-U-Net*) qu'ils proposent simplifient donc la partie *décodeur* mais conserve les qualités de la méthode. Par ailleurs, le nombre de poids est également réduit si des *convolutions séparables en profondeur* (*depthwise-separable convolutions*) remplacent les convolutions classiques. L'opération de convolution est ici séparée en deux étapes : (1) N_{p-1} filtres $k \times k$ sont appliqués aux images de la couches $p - 1$ pour générer N_{p-1} images intermédiaires puis (2) on réalise N_p convolution 1×1 de celles-ci pour obtenir les N_p images de la couches p . Le nombre de paramètres est donc de

$N_{p-1} \times k^2 + N_p \times N_{p-1}$, auquel il faut ajouter les $N_{p-1} + N_p$ biais des deux convolutions successives. Ce nombre est généralement bien inférieur à celui qu'on obtient avec des convolutions classiques (voir équation 2.4). Avec cette approche, Trebing *et al.* (2021) réduisent d'environ 75 % le nombre de paramètres entraînaibles de leur U-Net. Combiné aux modules d'attention CBAM introduits plus haut, ils obtiennent des performances comparables à celles d'un U-net classique pour la prévision de précipitations et de couverture nuageuse à très courte échéance.

- **Comment améliorer l'extraction des caractéristiques spatiales ?** L'identification des MCSs repose sur une lecture de l'image à plusieurs échelles spatiales : le kilomètre pour repérer les cœurs convectifs, la centaines de kilomètres pour couvrir l'étendue des zones convectives et stratiformes et parfois davantage si le MCS est impliqué dans un forçage synoptique. Le champ récepteur des U-Nets est suffisamment grand (184x184) pour extraire ces informations spatiales mais il nécessite un réseau profond qui grossit sa complexité. Le module ASPP (*Atrous Spatial Pyramid Pooling*) développé par Chen *et al.* (2017a,b) présente trois avantages. (1) Il utilise des convolutions « à trous » (*atrous convolutions*) dont les filtres, au lieu de s'appliquer sur un groupe de pixels contigus, s'appliquent sur des pixels séparés d'un certain pas d'échantillonnage. Plus le pas est grand, plus le champ récepteur du filtre s'élargit. C'est donc un moyen d'accroître la portée spatiale des filtres sans augmenter le nombre de poids ni le coût numérique. (2) Le pas d'une convolution à trous contrôle aussi directement la résolution spatiale des caractéristiques à extraire. (3) Le module ASPP applique en parallèle plusieurs convolutions à trous dotés de pas différents, ce qui permet d'extraire des caractéristiques sur plusieurs échelles spatiales en une seule couche. Intégrer un module ASPP dans les premières couches du U-Net faciliterait ainsi l'extraction des informations spatiales nécessaires à l'identification des MCSs.
- **Peut-on exploiter le contexte temporel** et ainsi mieux tenir compte du cycle de vie du MCS pour une meilleure détection des systèmes en phase de croissance ou de déclin ? C'est possible en considérant des séquences temporelles d'images en entrée. Lee *et al.* (2021) y trouvent un impact positif pour détecter des régions convectives dans des images satellite. Dans ce cas, le choix d'architecture se porte plutôt vers des *réseaux de neurones récurrents* (p. ex. Leinonen 2021) adaptés au traitement d'informations temporelles. Cependant, la multiplication des données d'entrée augmente aussi la complexité de la méthode.

Même s'il existe plusieurs pistes d'amélioration, les scores et diverses études de cas ont montré que les U-Nets actuels étaient capables d'identifier les MCSs de manière satisfaisante. Ces qualités permettent d'envisager des applications pour la PI, en particulier :

- suivre les objets détectés dans des images successives pour en étudier les principales caractéristiques tout au long de leur cycle de vie,
- analyser la pertinence du modèle AROME-PI pour la prévision des MCSs grâce à une évaluation « objet »,
- proposer une visualisation synthétique des prévisions AROME-PI afin de faciliter l'analyse du prévisionniste dans un contexte opérationnel.

Ces applications sont abordées dans les prochains chapitres.

Cycle de vie et environnement des MCSs en France

Sommaire

3.1	Introduction	120
3.2	Cadre de l'étude et données utilisées	120
3.2.1	Période et domaine	120
3.2.2	Données simulées	121
3.2.3	Données observées	121
3.2.4	Détection des MCSs et construction des trajectoires	122
3.2.5	Sélection des trajectoires pertinentes et complètes	123
3.2.6	Distinction des MCSs méditerranéens quasi-stationnaires	124
3.3	Caractérisation des MCSs en France	124
3.3.1	Distribution spatiale et saisonnière	125
3.3.2	Cycle diurne	127
3.3.3	Caractérisation des trajectoires	127
3.3.4	Limites et potentiels du U-Net pour le suivi des MCSs	128
3.3.5	Cycle de vie des attributs géométriques	128
3.3.6	Cycle de vie de l'activité convective	130
3.3.7	Conclusions	131
3.4	Évolution de l'environnement convectif	132
3.4.1	Aperçu de l'environnement synoptique	132
3.4.2	Deux méthodes pour décrire l'environnement de mésoéchelle	133
3.4.3	Analyse statistique	136
3.4.4	MCS du 4 juin 2022 : un système linéaire continental	141
3.4.5	Discussion : impact du MCS sur son environnement	146
3.4.6	Discussion : impact de l'environnement sur le MCS	148
3.5	Zoom sur les MCSs méditerranéens quasi-stationnaires	151
3.5.1	Aperçu de l'environnement synoptique	151
3.5.2	Analyse statistique	151
3.5.3	MCS du 20 novembre 2018 : une ligne stationnaire sur le Gard	153
3.5.4	Conclusions	157
3.6	Conclusions et perspectives	157

3.1 Introduction

Ce chapitre s'intéresse au cycle de vie des MCSs en France. Deux bases de données sont constituées à partir des situations convectives les plus violentes de ces dernières années. La première est composée d'observations radar et satellite, la seconde de champs simulés par AROME. Près de 150 MCSs sont identifiés automatiquement dans chacune d'elle grâce à la méthode de détection décrite au chapitre précédent. L'analyse du suivi temporel de leurs attributs et de leur environnement permet ici :

- de caractériser les différentes phases d'évolution des MCSs en France ;
- d'évaluer AROME en comparant d'un point de vue statistique le cycle de vie des MCSs simulés avec celui des MCSs observés ;
- d'identifier dans l'environnement du MCS les paramètres ayant le plus d'impact sur son cycle de vie.

Le cadre de l'étude et les données utilisées sont détaillés dans la section 3.2. La section 3.3 expose rapidement la distribution spatiale et temporelle des MCSs analysés avant d'examiner l'évolution de leur taille et de leur activité convective après initiation. On précise notamment les capacités du modèle AROME à reproduire le cycle de vie des MCSs observés. Les variables simulées sont plus largement exploitées au sein des sections 3.4 et 3.5. On y caractérise l'environnement des MCSs en phases de développement, de maturité et d'affaiblissement. Les résultats sont présentés en distinguant les MCSs méditerranéens quasi-stationnaires des autres systèmes. Ce chapitre fait également l'objet d'un article accepté dans une revue à comité de lecture ([Arnould *et al.*, 2024](#)).

3.2 Cadre de l'étude et données utilisées

3.2.1 Période et domaine

L'étude se concentre sur la France métropolitaine et les régions frontalières (voir traits pointillés sur la Figure 3.2). Les MCSs y sont identifiés sur une sélection de journées fortement convectives entre mai 2018 et décembre 2022, journées pour lesquelles au moins un département se situe en vigilance orange ou rouge pour les phénomènes « orage » ou « pluie-inondation » impliquant des orages. Déclenchée par Météo-France, la vigilance est une procédure d'avertissement de la population, des autorités et des médias sur un risque météorologique prévu dans les prochaines 24 heures ([Calmet, 2018](#)). Sur une échelle de quatre couleurs, les niveaux supérieurs orange et rouge correspondent aux situations dont l'enjeu pour la sécurité des personnes et des biens est le plus fort. La vigilance est actualisée de manière régulière, deux fois par jour, mais reste modifiable à tout moment selon l'évolution de la situation. Des phénomènes violents non anticipés, notamment convectifs, peuvent ainsi déclencher une vigilance orange dite « sur observation ». Les situations associées, peu prévisibles, sont donc aussi incluses dans la base de données étudiées. En revanche, cette dernière sous-représente les cas de MCSs non violents, ayant lieu hors période de vigilance.

Sélectionner les journées de vigilance orange ou rouge concentre l'étude sur les situations les plus pertinentes du point de vue de la PI et limite la quantité de données à traiter.

3.2.2 Données simulées

Pour chaque journée sélectionnée, on exécute des simulations AROME jusqu'à 24 h d'échéance. Afin de suivre avec précision le cycle de vie des MCSs, les champs de sortie sont produits toutes les 15 min, de manière analogue à ce qui est fait en opérationnel pour AROME-PI. Les caractéristiques du modèle AROME sont décrites dans la partie 1.5. On utilise la version opérationnelle en 2022 (cycle 46). La Table 3.1 liste les variables AROME utilisées pour décrire l'environnement dynamique et thermodynamique. Les variables de cisaillement vertical de vent ne sont pas mentionnées explicitement car elles sont fortement corrélées au vent simulé à différents niveaux, comme noté par [Wilhelm *et al.* \(2023\)](#).

Pour des raisons pratiques, toutes les simulations démarrent de la même heure d'analyse, celle de 0600 UTC. Sur le cycle diurne, elle correspond au creux climatologique de l'activité convective en Europe (p. ex. [Morel et Senesi 2002b](#)). Les simulations de 24 h couvrent ainsi la plupart des MCSs considérés, notamment les systèmes continentaux dont le développement est piloté par le chauffage diurne. Ce choix conduit cependant à une sous-représentation des systèmes méditerranéens qui, davantage sensibles aux conditions synoptiques et à des processus dynamiques locaux, peuvent se former à tout moment de la journée ([Khodayar *et al.*, 2021](#)).

Abréviation	Description
Z_{500}	Altitude du géopotential à 500 hPa
CAPE	CAPE calculée à partir de la particule la plus instable sur les premiers kilomètres de la troposphère (voir description du diagnostic AROME dans la partie 1.5.4)
T_{2m}	Température à 2 m
T_{900} , T_{500} , T_{300}	Température à 900, 500 et 300 hPa
$\theta'w_{900}$	Température potentielle du thermomètre mouillé à 900 hPa
SH_{900} , SH_{500} , SH_{300}	Humidité spécifique (masse volumique de vapeur d'eau divisée par la masse volumique de l'air) à 900, 500 et 300 hPa
U_{10m}	Vent horizontal à 10 m
U_{500} , U_{300}	Vent horizontal à 500 et 300 hPa

TABLE 3.1 – Abréviation et description des principales variables AROME considérées. La CAPE et la $\theta'w_{900}$ sont définies dans la partie 1.1.1.

3.2.3 Données observées

Les observations sur les journées sélectionnées proviennent des images de Rfbc de la mosaïque radar SERVAL (voir partie 1.3.2) et des images de TB mesurée par le radiomètre

SEVIRI à bord du satellite MSG (voir partie 1.3.1). On extrait une image toutes les 15 min afin de construire un jeu de données cohérent avec celui des simulations AROME.

3.2.4 Détection des MCSs et construction des trajectoires

Les réseaux de neurones **U-Net OBS** et **U-Net AROME** décrits au chapitre 2 détectent les MCSs dans les images observées et simulées respectivement.

Les objets détectés dans les images successives sont appariés pour former des *trajectoires*. Pour cela, on utilise l'algorithme *OSIRIS* développé à Météo-France. Il est utilisé en opérationnel pour le suivi d'objets orageux radar, en alimentation du service ASPOC notamment (Parent du Châtelet, 2003), mais a aussi été appliqué à des objets de précipitations simulées par le modèle AROME climat (Caillaud *et al.*, 2021). Hérité de Morel et Senesi (2002a), l'algorithme repose sur la stratégie de *recouvrement* énoncée dans la partie 1.4. La Figure 3.1 en illustre le fonctionnement. Trois étapes sont nécessaires pour appairer un objet détecté au temps t avec un objet détecté sur l'image précédente, à $t - 1$, et pour en estimer une vitesse V_t :

- **Étape (a)**. Chaque objet au temps $t - 1$ est extrapolé linéairement au temps t à partir de sa vitesse V_{t-1} calculée à l'itération précédente. On calcule alors le taux de recouvrement R entre l'objet advecté et l'objet à t . L'objet à $t - 1$ pour lequel R est non nul devient un candidat à l'appariement.
- **Étape (b)**. Deux vitesses intermédiaires \tilde{V}_{CG} et \tilde{V}_{Corr} sont calculées pour l'objet à t à partir de l'objet candidat à $t - 1$. Pour cela, deux méthodes sont en concurrence. La première calcule \tilde{V}_{CG} à partir des distances séparant les **centres de gravité** des objets à t et $t - 1$. \tilde{V}_{CG} peut être irréaliste si les objets ont des formes très différentes. C'est pourquoi la seconde méthode raisonne sur les similitudes de textures entre les images successives. On calcule un taux de **corrélacion** entre les pixels appartenant à deux *fenêtres de calcul* aux dimensions égales, la première centrée sur l'objet à t , la seconde évoluant dans une *fenêtre de recherche* plus large, centrée sur la position de l'objet rétro-advecté à $t - 1$ avec V_{t-1} . La position finale de la seconde fenêtre correspond au taux de corrélation maximal. La vitesse \tilde{V}_{Corr} est alors déduite de la distance séparant les deux fenêtres.
- **Étape (c)**. L'objet à t est rétro-advecté à $t - 1$ avec chacune des deux vitesses intermédiaires \tilde{V}_{CG} et \tilde{V}_{Corr} . Un taux de recouvrement R' est alors calculé avec l'objet à $t - 1$. Si R' est supérieur à un certain seuil, l'appariement est validé et la vitesse associée au taux R' maximum est utilisée pour estimer la vitesse finale V_t de l'objet à t . Comme indiqué sur la Figure 3.1c, V_t est une combinaison linéaire de la vitesse intermédiaire et de la vitesse V_{t-1} . Cela permet de lisser ses variations et réduit le risque de calculer des valeurs irréalistes.

Les étapes (b) et (c) permettent d'améliorer la qualité des appariements et d'affiner le calcul des vitesses. Si un objet à $t - 1$ fissionne en plusieurs objets à t , l'objet à t dont le taux de recouvrement R' est maximal hérite de l'identifiant de trajectoire de l'objet à $t - 1$. Les autres objets initient alors de nouvelles trajectoires. Une règle analogue est appliquée pour gérer les fusions.




FIGURE 3.1 – Schématisation de l'algorithme de suivi *OSIRIS* employé pour appairer deux objets aux pas de temps successifs.

3.2.5 Sélection des trajectoires pertinentes et complètes

Seules les trajectoires *pertinentes* sont étudiées en appliquant les critères suivants :

- La trajectoire doit être incluse totalement ou partiellement dans le domaine d'étude.
- La longueur de l'objet doit être supérieure à 100 km pendant au moins 3 h, en cohérence avec la littérature (voir Table 1.1), de manière à éliminer des trajectoires peu représentatives d'un MCS. Par ailleurs, on inclut dans les trajectoires pertinentes les objets dont la longueur est supérieure à 50 km, cela afin de couvrir davantage les phases d'initiation et de dissipation.
- Comme dans [Da Silva et Haerter \(2023\)](#), la trajectoire des MCSs observés doit aussi présenter une activité électrique. Autrement dit, un des objets qui la composent doit être associé à un ou plusieurs éclairs mesurés par le réseau européen Météorage, introduit dans la partie 1.3.3.

Étudier le cycle de vie des MCSs nécessite aussi l'exclusion des trajectoires incomplètes, ce qui comprend :

- les trajectoires initiées à partir d'une fission d'objets ou les trajectoires achevées par une fusion d'objets.
- les trajectoires interrompues par les limites de validité des images. Il s'agit du domaine de calcul AROME pour les trajectoires simulées ou de la couverture du réseau radar pour les trajectoires observées (voir Figure 2.8). Ce critère est particulièrement restrictif pour les trajectoires observées.
- les trajectoires interrompues par les bornes temporelles des situations étudiées, notamment l'heure de 0600 UTC pour les trajectoires simulées. Ce critère est moins restrictif pour les

trajectoires observées car plusieurs journées de vigilance sont consécutives, ce qui permet de suivre un MCS en fin de nuit et début de matinée. À l'inverse, ce critère exclut de nombreux systèmes simulés, notamment en Méditerranée.

Le nombre de trajectoires pertinentes et complètes s'élève au final à 167 pour les données simulées et 157 pour les données observées, couvrant 114 et 106 journées respectivement. Ces nombres sont proches mais leur comparaison est discutable car les critères employés pour sélectionner les trajectoires complètes ne sont pas aussi restrictifs pour chacune des deux bases de données. Pour une comparaison rigoureuse, il faudrait éliminer les trajectoires observées chevauchant l'heure de 0600 UTC d'une part, et exclure les trajectoires simulées interrompues par la couverture du réseau radar d'autre part. On obtient alors 88 et 133 trajectoires simulées et observées respectivement. Deux raisons peuvent expliquer le faible nombre de trajectoires simulées : (1) les simulations AROME ne sont pas parfaites et peuvent manquer des MCSs, (2) comme mentionné dans la partie 1.5.8, AROME simule des régions stratiformes peu étendues, donnant lieu à des MCSs plus petits et répondant moins facilement aux critères de pertinence. Cependant, cette comparaison rigoureuse des données simulées et observées (non montrée) ne change pas les principaux résultats énoncés dans la section 3.3 à partir des 167 trajectoires simulées et des 157 trajectoires observées.

3.2.6 Distinction des MCSs méditerranéens quasi-stationnaires

Introduits dans la partie 1.1.5, les MCSs méditerranéens quasi-stationnaires (abrégiés MCSs-MedQS) sont principalement contrôlés par un flux maritime de basses couches, souvent en interaction avec le relief (Khodayar *et al.*, 2021). Leur développement atypique incite à les distinguer des autres MCSs, dits « standards » (MCSs-Std), notamment lorsqu'on étudie l'environnement des systèmes dans les sections 3.4 et 3.5.

Une trajectoire MCS-MedQS est définie de manière objective : le système doit se situer majoritairement dans la portion sud-est du domaine d'étude et sa vitesse moyenne doit être inférieure à 10 m/s. Respectivement, on dénombre ainsi 14 et 24 trajectoires MCS-MedQS simulées et observées. Cette quantité est faible mais suffit à mettre en évidence les caractéristiques générales de l'environnement de ces systèmes, comme le montre la section 3.5.

3.3 Caractérisation des MCSs en France

Cette partie décrit les principales caractéristiques des objets MCS étudiés. Il ne s'agit pas d'une climatologie à proprement parler car les MCSs ne sont identifiés que sur un échantillon de journées convectives entre 2018 et 2022. Cependant, le nombre de trajectoires est suffisant pour comparer les résultats avec les climatologies introduites dans la partie 1.1.6.

3.3.1 Distribution spatiale et saisonnière

Les trajectoires pertinentes et complètes sont tracées sur la Figure 3.2, discriminées selon la saison. On constate un cycle saisonnier marqué que confirme la Table 3.2 : le nombre de MCSs augmente rapidement au mois de mai, est maximum en juin, se stabilise durant l’été puis diminue lentement de septembre à novembre. On ne compte presque aucune trajectoire de décembre à avril. Par ailleurs, les distributions saisonnières des MCSs simulés et observés sont très proches.

# Traj.	Jan	Fév	Mars	Avr	Mai	Juin	Juil	Août	Sep	Oct	Nov	Déc
MCSs-Std (AROME)	2	0	0	1	15	45	23	29	19	14	5	0
MCSs-Std (OBS)	0	0	0	1	20	44	18	25	10	11	4	0
MCSs-MedQS (AROME)	0	0	0	0	0	0	1	2	3	4	3	1
MCSs-MedQS (OBS)	1	0	1	1	1	2	1	4	8	2	3	0

TABLE 3.2 – Distributions saisonnières des trajectoires de MCSs simulés et observés (en nombre de trajectoires).

Si les systèmes concernent tout le domaine d’étude, la majorité évoluent le long d’un couloir continental orienté de l’Espagne au nord-est de la France, en accord avec la distribution de [Morel et Senesi 2002b](#) (voir Figure 1.9). Ce couloir est très net en saison estivale (Figures 3.2c,d). De nombreux systèmes se développent alors près du Massif Central, région propice aux forçages orographiques. Les trajectoires concernent davantage la façade ouest du pays au printemps (Figures 3.2a,b) et la façade est à l’automne (Figures 3.2e,f).

Les MCSs-MedQS se développent majoritairement à l’automne (Figures 3.2e,f et Table 3.2). La plupart se situent près des reliefs côtiers, comme observé par [Ricard et al. \(2012\)](#) ou [Kolios et Feidas \(2009\)](#). L’emplacement exact des trajectoires observées diffère beaucoup de celui des trajectoires simulées car seulement deux situations convectives sont communes aux deux bases de données pour les MCSs-MedQS (non montré). Cela est en partie lié aux critères de sélection propres à chaque base faisant que, pour une situation donnée, le MCS peut être exclu d’une base et conservée dans l’autre.

Les distributions spatiales des trajectoires simulées et observées sont proches. Les principales différences s’expliquent par les critères de sélection des trajectoires complètes, plus ou moins restrictifs selon la source des données. On relève peu de trajectoires observées sur le nord-est car les MCSs correspondant évoluent souvent vers la Belgique ou l’Allemagne, sortant ainsi de la couverture radar métropolitaine. En parallèle, la densité de systèmes simulés sur le pourtour méditerranéen est faible, notamment pour les MCSs-MedQS. La raison tient en partie aux bornes temporelles des simulations, comme discuté dans la partie 3.2.2.

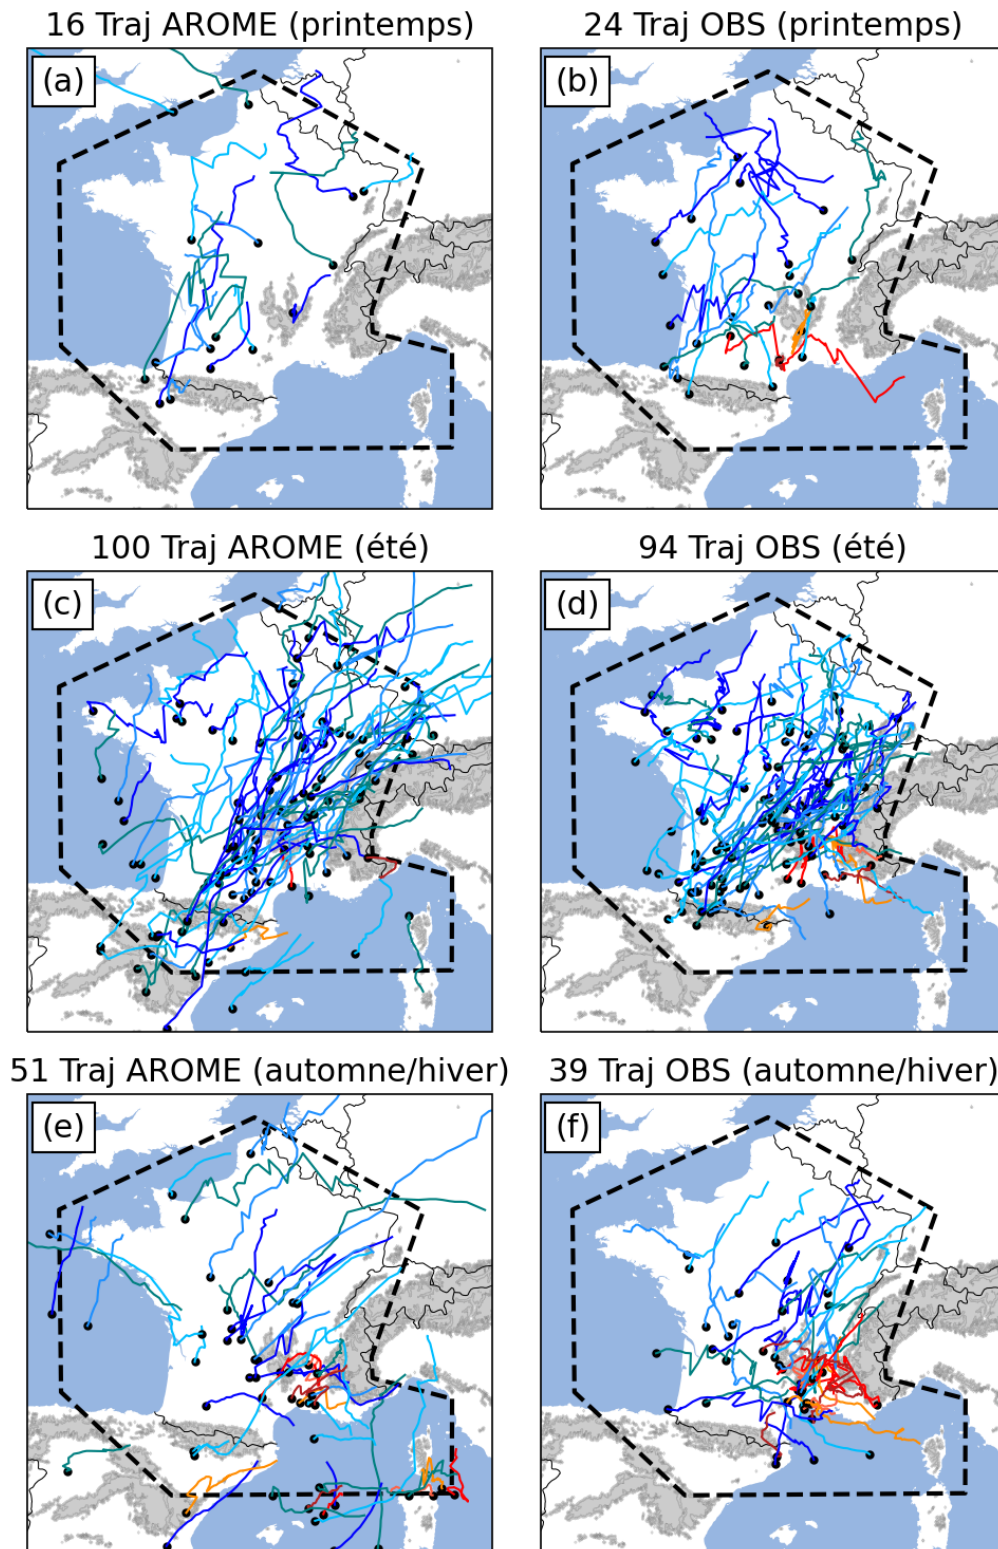


FIGURE 3.2 – Trajectoires complètes de MCSs identifiés dans des simulations AROME (à gauche) et des images observées (à droite) sur les journées de vigilance entre mai 2018 et décembre 2022 : (a,b) de mars à mai, (c,d) de juin à août, (e,f) de septembre à février. Les points noirs indiquent le premier MCS détecté sur chaque trajectoire. Les MCSs-MedQS sont colorés en nuances de rouge, les MCSs-Std en nuances de bleu. Les nuances aident seulement à distinguer les différentes trajectoires. Le trait pointillé délimite le domaine d'étude. Le relief supérieur à 1000 m apparaît en gris. Certaines trajectoires simulées sont coupées sur la figure mais restent comprises dans le domaine de calcul AROME.

3.3.2 Cycle diurne

La plupart des trajectoires débutent dans l'après-midi, entre 1200 et 1800 UTC, et se terminent dans la nuit (Figure 3.3). Ce cycle diurne est moins marqué pour les MCSs-MedQS (non montré).

Les résultats énoncés jusqu'à présent sont cohérents avec les climatologies européennes de [Morel et Senesi \(2002b\)](#) et [Da Silva et Haerter \(2023\)](#). Les auteurs soulignent la prédominance des MCSs continentaux l'été, pilotés par le chauffage diurne des basses couches, et la fréquence plus importante des MCSs méditerranéens durant l'automne, liés davantage aux forçages dynamiques qu'au cycle diurne du rayonnement solaire.




FIGURE 3.3 – Distributions des heures (a) d'initiation et (b) de fin de trajectoire pour les MCSs simulés (en violet) et observés (en vert).

Les distributions des heures d'initiation et de fin des trajectoires sont proches dans l'observation et le modèle. Il faut noter qu'aucune trajectoire simulée n'est initiée en deuxième partie de nuit. Cette proportion anormalement faible s'explique par les limites temporelles des simulations et le seuil de 3 h fixé pour la durée minimale des MCSs. Par exemple, aucune des trajectoires sélectionnées ne peut démarrer entre 0300 et 0600 UTC.

3.3.3 Caractérisation des trajectoires

La moitié des trajectoires simulées durent entre 5 h et 8 h 15, la plus longue étant de 14 h (non montré). Les trajectoires observées durent en moyenne une heure de plus, avec une valeur maximale de 21 h 45. Ces statistiques sont contraintes par le cadre spatio-temporel de l'étude mais restent cohérentes avec les climatologies de [Morel et Senesi \(2002b\)](#) et de [Da Silva et Haerter \(2023\)](#).

À présent, on normalise l'âge des MCSs par rapport à la durée de leur trajectoire, une pratique courante pour comparer le cycle de vie de différents systèmes (Cheeks *et al.* 2020; Chen *et al.* 2020, parmi d'autres). La Figure 3.4 montre ainsi l'évolution de certains attributs selon l'âge relatif des objets sur leur trajectoire.

La vitesse des systèmes est relativement stable durant leur cycle de vie. Le module est souvent compris entre 5 et 20 m/s, autour de 12 m/s en moyenne (Figure 3.4a), des valeurs comparables à ce qui est observé aux États-Unis (Gale *et al.*, 2002; Cheeks *et al.*, 2020). Les vecteurs vitesse dévient peu par rapport au vecteur résultant sur la trajectoire (moins de 20° en moyenne, Figure 3.4b), hormis au début du suivi, quand l'absence d'information sur la trajectoire passée rend l'estimation de la vitesse plus incertaine. Les trajectoires sont donc globalement linéaires, confirmant l'impression visuelle de la Figure 3.2.

Les MCSs simulés sont d'environ 1 m/s plus rapide que les MCSs observés, un biais faible que peut expliquer une tendance du modèle AROME à générer des plages froides trop importantes dans les basses couches continentales (voir partie 1.5.8). La plage froide force alors plus facilement de nouveaux développements convectifs en aval du système, augmentant la composante propagative de sa vitesse.

3.3.4 Limites et potentiels du U-Net pour le suivi des MCSs

L'incertitude du U-Net pour l'identification des MCSs peut être mesurée par la probabilité moyenne de la classe « MCS » dans l'objet. Les U-Nets dédiés aux images simulées et observées affichent des valeurs très proches et relativement stables entre 10 et 90 % du cycle de vie, généralement au-dessus de 0,7 (Figure 3.4c). Cependant, aux extrémités du suivi, les probabilités convergent rapidement vers les seuils de détection assignés au U-Net AROME et au U-Net OBS, respectivement de 0,5 et de 0,6.

Cette analyse confirme la pertinence du U-Net pour suivre les MCSs sur la majeure partie de leur cycle de vie. Comme discuté au chapitre 2, la méthode de détection est néanmoins critiquable sur les phases d'initiation et de déclin, lorsque le système est moins développé.

3.3.5 Cycle de vie des attributs géométriques

Le rapport d'aspect varie peu le long des trajectoires, situé en moyenne autour de 0,5 (Figure 3.4d). Il se définit comme le rapport entre le petit et le grand axe de l'ellipse approchant l'objet. Il vaut 1 pour un objet circulaire mais tend vers 0 si l'ellipse est très « aplatie ». Les valeurs rencontrées évoquent donc une majorité de systèmes quasi linéaires. Il en va ainsi des climatologies de Morel et Senesi (2002b) en Europe, de Haberland et Ashley (2019) aux États-Unis et de Surowiecki et Taszarek (2020) en Pologne.

La taille des MCSs évolue de façon parabolique (Figure 3.4e,f), comme le constatent Machado *et al.* (1998) sur les sous-continentaux américains, Cheeks *et al.* (2020) aux États-Unis et Chen *et al.* (2020) dans l'est de la Chine. Pour la majorité des cas, l'aire et la longueur

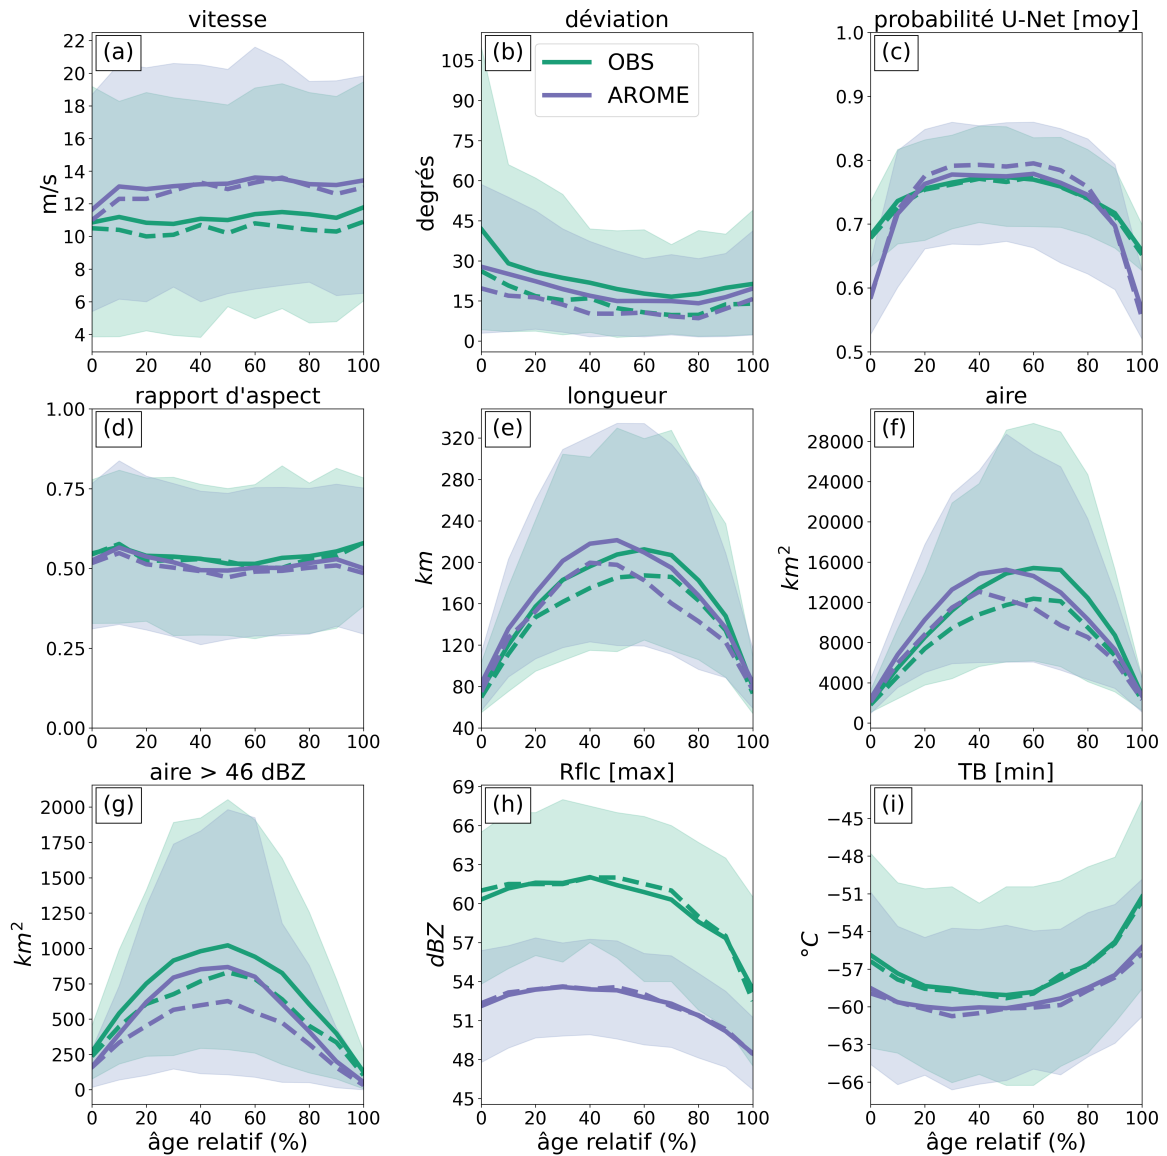


FIGURE 3.4 – Évolution des principaux attributs des objets MCS simulés (en violet) et observés (en vert) sur leur cycle de vie normalisé : (a) module de la vitesse, (b) déviation du vecteur vitesse par rapport à la droite passant par les centres de gravité du premier et du dernier objet détectés, (c) probabilité moyenne de la classe « MCS » générée par le U-Net, (d) rapport d'aspect de l'ellipse approchant l'objet, (e) longueur (c.-à-d. la distance entre les deux points les plus éloignés sur le contour de l'objet), (f) aire, (g) aire de la région avec des Rflc supérieures à 46 dBZ, (h) Rflc maximale, (i) TB minimale. La courbe en trait plein (pointillé) correspond à la moyenne (médiane) de la distribution. Les plages de couleurs délimitent les quantiles 10 et 90 %.

maximales sont atteintes entre 25 et 75 % du cycle de vie (Figure 3.5). L'écart-type des distributions est maximal sur cette période (Figure 3.4e,f) car il reflète celui des durées. En

effet, si tous les MCSs ont à peu près la même taille en phase de développement et de déclin, leur extension maximale est grossièrement proportionnelle à leur durée (non montré). D'après les médianes et moyennes de la Figure 3.4e,f, les MCSs observés et simulés ont une extension maximale similaire, de l'ordre de 200 km pour la longueur et de 12 000-15 000 km² pour l'aire. Puisque tous les MCSs étudiés n'atteignent pas leur extension maximale au même âge relatif, la figure lisse les statistiques réelles de ces extrêmes dont la moyenne (médiane) est environ de 280 (250) km pour la longueur et de 20 000 (15 000) km² pour l'aire (non montré). Ces ordres de grandeur sont cohérents avec les recherches de [Morel et Senesi \(2002b\)](#) et [Da Silva et Haerter \(2023\)](#) qui trouvent respectivement une aire maxiale médiane de 20 000 km² et une aire maximale moyenne de 10 000 km².

En moyenne, les MCSs simulés atteignent leur taille maximale à 50 % du cycle de vie (Figure 3.5). C'est un peu plus tard pour les MCSs observés, notamment si l'on regarde l'aire des objets. Le décalage est moins marqué pour le pic de l'activité convective (voir prochaine partie). Ce biais peut être lié au sous-développement des précipitations stratiformes dans AROME, comme décrit dans la partie 1.5.8. Ainsi, à la différence des MCSs simulés, la taille des MCSs observés dépend davantage de la région stratiforme qui continue généralement de grossir après que l'extension maximale de la région convective a été atteinte.

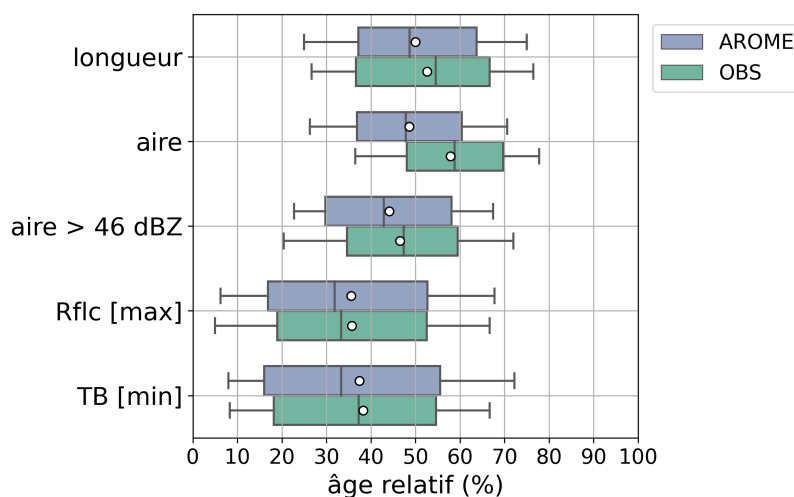


FIGURE 3.5 – Distributions des âges relatifs associés aux statistiques extrêmes que certains attributs atteignent sur le cycle de vie des MCSs étudiés : la valeur maximale pour la longueur, l'aire, l'aire > 46 dBZ et les Rflc-max ; la valeur minimale pour la TB-min. Les moustaches correspondent aux quantiles 10 % et 90 % de chaque distribution et le rond blanc affiche la moyenne.

3.3.6 Cycle de vie de l'activité convective

L'intensité convective suit aussi une évolution parabolique (Figure 3.4h,i) mais culmine plus tôt que la taille (Figure 3.5h,i), en accord avec des climatologies menées sur des MCSs aux

Amériques (Machado *et al.*, 1998), en Chine (Chen *et al.*, 2020) et sur le bassin méditerranéen (Kolios et Feidas, 2012a). En moyenne, le maximum de Rflc dans l'objet (Rflc-max) est atteint vers 35 % du cycle de vie. Il se stabilise jusqu'à 40 à 50 % du cycle de vie, quand les précipitations intenses (Rflc > 46 dBZ) atteignent leur surface maximale (Figures 3.4g, 3.5), puis diminue dans la seconde moitié. Les variations du minimum de TB dans l'objet (TB-min) sont opposées à celles de Rflc-max.

Bien que peu étendue spatialement, une activité convective persiste à la fin du cycle de vie car des précipitations supérieures à 46 dBZ y sont encore mesurées (Figure 3.4g,h). Au terme du suivi, les MCSs sont donc davantage en phase d'affaiblissement que de dissipation. Cela rappelle les difficultés du U-Net à détecter les MCSs déclinants (voir partie 3.3.4).

Les courbes relatives aux objets simulés et observés affichent des tendances similaires mais diffèrent par les valeurs atteintes. Les Rflc-max observées sont près de 10 dBZ supérieures aux Rflc-max simulées. Comme discuté dans la partie 2.5.1, ce biais reflète certainement les erreurs inhérentes au schéma microphysique d'AROME, notamment sa formulation à un moment. Par ailleurs, les valeurs de TB-min sont de quelques °C plus élevées pour les MCSs observées. La résolution plus importante du radiomètre SEVIRI et/ou les biais du schéma RTTOV peuvent en être la cause.

3.3.7 Conclusions

Les caractéristiques des MCSs observés et simulés sont comparables et confirment la capacité d'AROME à modéliser la convection profonde à mésoéchelle.

Par ailleurs, les résultats précédents permettent de diviser le cycle de vie des MCSs en trois phases d'évolution, suivant le schéma que proposent Chen *et al.* (2020) pour les systèmes est-asiatiques.

1. La *phase de développement* s'étend jusqu'au pic de l'activité convective, ici vers 35 % du cycle de vie en moyenne.
2. Durant la *phase de maturité*, de 40 à 60 % du cycle de vie, l'activité convective se maintient et le système atteint son extension maximale.
3. La *phase d'affaiblissement* se caractérise ensuite par la décroissance de la taille et de l'activité convective.

Afin de simplifier l'analyse, les phases de développement, de maturité et d'affaiblissement seront à présent représentées par les âges relatifs de 10, 50 et 80 % respectivement. Ils sont inclus dans la période sur laquelle la méthode de détection est optimale.

L'analyse des MCSs étudiés montre que les attributs liés à la géométrie et à l'activité convective ont un cycle de vie marqué duquel on peut déduire une équation d'évolution standard, avec une phase de croissance puis de décroissance. Kolios et Feidas (2012a) se sont appuyés sur un modèle semblable pour prévoir l'évolution des MCSs en Méditerranée à partir de la tendance passée de leurs attributs. Ses performances sont toutefois limitées à une heure

d'échéance (Kolios et Feidas, 2012b). Mesurer des changements dans l'environnement convectif permettrait une meilleure appréhension de l'évolution du système. Cette problématique est abordée dans la prochaine section.

3.4 Évolution de l'environnement convectif

Grâce aux champs du modèle AROME, on caractérise l'environnement tridimensionnel des MCSs simulés. La majorité des systèmes (MCSs-Std) sont abordés dans cette section, les MCS méditerranéens quasi-stationnaires (MCSs-MedQS) faisant l'objet de la section suivante. On introduit d'abord les conditions synoptiques dans lesquelles les systèmes se développent (partie 3.4.1) avant de mettre au point une méthode pour quantifier l'évolution des conditions au sein de leur environnement immédiat (partie 3.4.2). La partie 3.4.3 expose les résultats statistiques. Un cas illustratif est présenté dans la partie 3.4.4. Enfin, les parties 3.4.5 et 3.4.6 discutent des interactions entre le MCS et son environnement.

3.4.1 Aperçu de l'environnement synoptique

La Figure 3.6 donne un aperçu des conditions synoptiques précédant la croissance des MCSs-Std. Ces cartes « composites » sont obtenues en moyennant, en chaque point de la grille, la valeur des champs associés aux 153 MCSs-Std considérés dans leur phase de développement. La méthode est fréquemment employée pour décrire l'environnement synoptique des systèmes convectifs (p. ex. Ricard *et al.* 2012).

En moyenne, la situation synoptique est marquée par l'approche d'un thalweg d'altitude au large de la côte atlantique (Figure 3.6a). Cette configuration est propice aux ascendances de grande échelle qui préconditionnent l'atmosphère à la convection orageuse (voir partie 1.1.2). Le thalweg pilote un fort flux de sud-ouest sur la France, cohérent avec la direction adoptée par la majorité des trajectoires décrites précédemment (partie 3.3.1). Dans les basses couches, le gradient de $\theta'w_{900}$ sur l'ouest et le nord du domaine (Figure 3.6b) caractérise une atmosphère barocline. Celle-ci est cohérente avec la dynamique d'altitude par l'équilibre du vent thermique. En surface convergent des flux de sud et d'ouest, notamment sur la Catalogne, un large quart sud-ouest de la France et l'embouchure nord de la vallée du Rhône, des régions où démarrent de nombreuses trajectoires (voir Figure 3.2). Ces flux sont pilotés par deux zones dépressionnaires : la première sur le nord-ouest du domaine, certainement liée aux ascendances de grande échelle à l'aval du thalweg d'altitude, et la seconde au nord-est de l'Espagne.

Après avoir parcouru individuellement les synoptiques des 153 MCSs-Std (non montré), on peut affirmer que la Figure 3.6 traduit raisonnablement la grande majorité des situations. Environ les deux tiers correspondent à des MCSs frontaux ou pré-frontaux évoluant dans un environnement analogue. La plupart des cas restants sont attribués à des gouttes froides d'altitude, généralement situées au-dessus de la péninsule ibérique, avec un jet marqué sur

son flanc est.

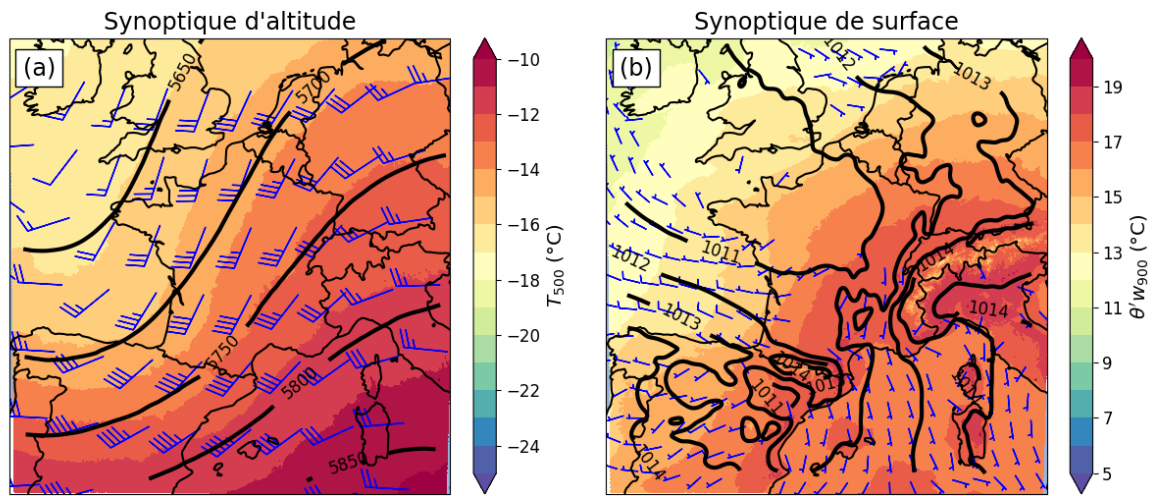


FIGURE 3.6 – Environnement synoptique composite des 153 MCSs-Std en phase de développement : (a) T_{500} (en °C, couleurs), Z_{500} (en m, contours) et U_{300} (en nœuds, barbules); (b) $\theta'w_{900}$ (en °C, couleurs), P_{mer} (en hPa, contours) et U_{10m} (en nœuds, barbules seuillées à 2,5 nœuds).

3.4.2 Deux méthodes pour décrire l'environnement de mésoéchelle

Deux méthodes sont employées pour décrire l'environnement immédiat des MCSs à différentes phases de leur cycle de vie. Elles sont schématisées sur la Figure 3.7 et détaillées ci-dessous.

Variables ambiantes

Extraire des statistiques dans la zone entourant des cellules ou des MCSs est une méthode couramment employée pour caractériser l'environnement convectif (Gale *et al.*, 2002; Zöbisch *et al.*, 2020; Wilhelm *et al.*, 2023). Ici, les champs AROME sont moyennés dans une *zone ambiante* que délimitent le contour de l'objet et un second contour distant de $r = 100$ km (voir les deux contours bleus sur la Figure 3.7b). La valeur obtenue est appelée *variable ambiante*. Pour le vent, elle correspond à la moyenne scalaire des modules en chaque point de grille.

On s'intéresse à la tendance des variables ambiantes sur le cycle de vie des MCSs. Les premières analyses ont montré que cette tendance était à peu près monotone pour toutes les variables étudiées. La tendance ΔX de chaque variable ambiante X est donc calculée par la différence des valeurs mesurées pendant les phases de développement et d'affaiblissement :

$$\Delta X = X_{80\%} - X_{10\%}$$

Afin de comparer des variables évoluant dans des intervalles de valeurs différents, les données sont préalablement normalisées de la façon suivante :

$$X \leftarrow \frac{X - \mu_X}{\sigma_X}$$

où μ_X et σ_X désignent respectivement la moyenne et l'écart-type de la variable X calculés sur l'ensemble des données relatives aux MCSs étudiés. Chaque tendance ΔX se mesure ainsi en unité d'écart-type de la variable ambiante X (Wilks, 1995).

D'après des tests préliminaires, les tendances mesurées sur le cycle de vie montrent une évolution similaire selon qu'on considère une zone ambiante de 50, 100 ou 200 km de large. C'est pourquoi la largeur r est fixée à 100 km.

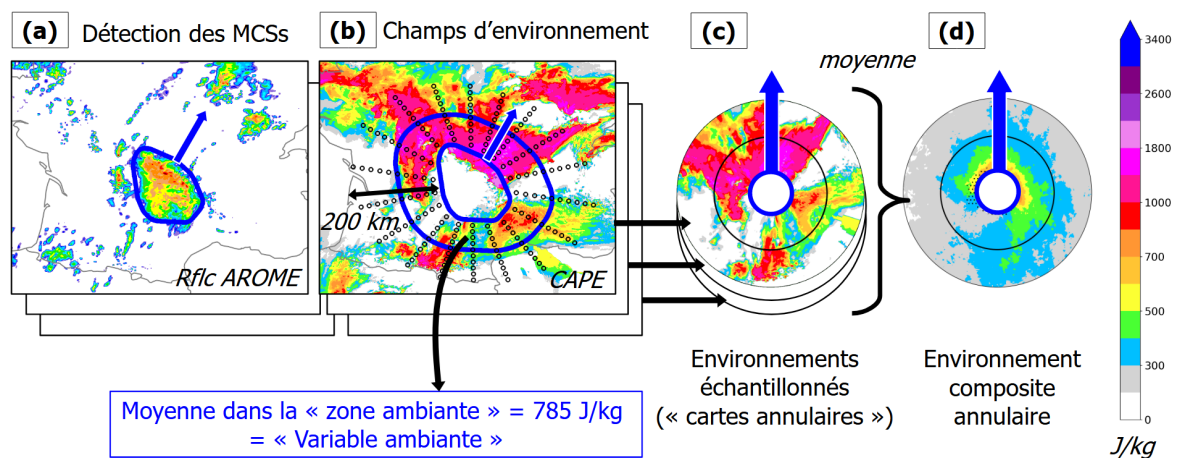


FIGURE 3.7 – Deux méthodes pour analyser l'environnement convectif de mésoéchelle des MCSs simulés (ici sur l'exemple de la CAPE). Les détails sont donnés dans le texte.

En moyenne, près de 40 % des points de grille de la zone ambiante sont associés à des précipitations ($Rflc > 0 \text{ dBZ}^1$), une proportion atteignant 50 % à la fin du cycle de vie (Figure 3.8). Ces précipitations sont liées à d'autres systèmes convectifs, à des perturbations baroclines dans lesquelles les MCSs frontaux sont parfois noyés, ou bien aux MCSs eux-mêmes, notamment à la région stratiforme des systèmes déclinants, sous-détectés par le U-Net, qui s'étend au-delà du contour de l'objet. Les points de grille de $Rflc > 0 \text{ dBZ}$ ne sont pas considérés dans le calcul des variables ambiantes. Ces dernières sont ainsi moins affectées par les processus thermodynamiques locaux, à l'œuvre au sein des systèmes alentour, qui ne caractérisent pas directement l'environnement des MCSs. Par ailleurs, des variables ambiantes peuvent être modifiées par le MCS et ne pas traduire les changements environnementaux d'origine externe. Par exemple, la CAPE est consommée et décroît forcément dans la trace de la trajectoire, à l'arrière du MCS. Or, d'après des tests préliminaires, exclure ou conserver la trace a peu d'impact sur les tendances moyennes obtenues. Par simplicité, on la conservera dans la définition de la zone ambiante.

1. Même si le seuil de détection de la pluie serait plutôt de quelques dBZ pour des Rflc observées, le seuil de 0 permet de bien séparer les précipitations dans le modèle AROME.




FIGURE 3.8 – Proportion de l'environnement associé à des Rflc positives sur le cycle de vie des MCSs étudiés. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.

Cartes composites annulaires

La seconde méthode privilégie l'information spatiale. Pour chaque MCS, quels que soient sa taille ou son aspect, on projette les champs environnants sur une grille standard en forme d'anneau dont le bord intérieur correspond au contour de l'objet. On réalise alors deux échantillonnages :

- un échantillonnage radial, à 1 km de résolution, du contour de l'objet défini comme origine jusqu'à un rayon de 200 km ;
- un échantillonnage angulaire, à 1° de résolution, en considérant pour origine le centre de gravité de l'objet.

Les points de grille échantillonnés sont schématisés sur la Figure 3.7b (par mesure de clarté, seul 1 point sur 20 est affiché). L'échantillonnage nécessite que le contour de l'objet soit convexe. Les contours concaves sont donc remplacés par leur enveloppe convexe. On obtient finalement un champ annulaire de dimensions 200 km \times 360° que l'on représente dans un référentiel polaire centré sur l'objet (Figure 3.7c). Les champs relatifs à chaque MCSs sont ensuite moyennés pour chaque variable et chaque période du cycle de vie afin d'obtenir une *carte composite annulaire* (Figure 3.7d). Les champs sont préalablement orientés dans la direction de propagation du MCS (flèche bleue sur la Figure 3.7) afin de respecter la position relative du système par rapport à son environnement. La direction des vecteurs de vent subit la même opération. À la différence de la première méthode, les moyennes de vent sont ici vectorielles. En revanche, le calcul des composites exclut aussi les points de grille associés à des Rflc positives.

Jirak et Cotton (2007), Coniglio *et al.* (2010) et Cui *et al.* (2021) décrivent également l'environnement des MCSs à partir de cartes composites relatives à la position et à la direction du système. Cependant les composites y sont calculées à partir de champs rectangulaires extraits directement depuis les grilles des sorties numériques. Ces champs ne tiennent donc

pas compte de la morphologie du MCS et contiennent les points de grille situés à l'intérieur de l'objet. Or les MCSs étudiés sont détectés dans des images observées et les modèles utilisés pour caractériser leur environnement ne résolvent pas explicitement la convection. L'environnement obtenu n'est donc pas « contaminé » par le système. Ce n'est plus le cas lorsqu'on caractérise l'environnement avec les champs d'un modèle non-hydrostatique, comme dans le cadre de cette étude, d'où le besoin d'adapter l'échantillonnage à la géométrie de chaque objet.

L'avantage des deux méthodes présentées ci-dessus tient à leur complémentarité. La première définit l'environnement de manière grossière mais condense l'information en une seule *variable ambiante*. Il est donc facile d'analyser sa distribution sur l'ensemble des MCSs étudiés. La seconde méthode répond davantage à l'idée qu'une fraction seulement de l'environnement a un impact sur l'évolution des MCSs. Par exemple, on mesurera plutôt l'instabilité à l'avant du système et la dynamique d'altitude à l'arrière. Les *composites annulaires* permettent cette analyse sur un environnement moyen qu'on suppose représentatif de la majorité des MCSs étudiés. Cette double stratégie est également employée par [McAnelly et Cotton \(1989\)](#) pour examiner les précipitations des MCCs américains.

3.4.3 Analyse statistique

Évolution de la masse d'air dans l'environnement

Parmi les variables ambiantes étudiées, la CAPE normalisée affiche la plus forte baisse sur le cycle de vie des MCSs-Std (en bleu sur la Figure 3.9). Cette tendance concerne plus de trois quarts des MCSs et se situe en moyenne autour d'une unité d'écart-type. D'après la Figure 3.10a, cette baisse est continue entre le début et la fin du suivi, de 560 à 270 J/kg en moyenne. À cause du lissage intrinsèque au calcul, ces valeurs sont bien inférieures aux maxima de l'environnement, de 2000 J/kg en moyenne, mais ces derniers connaissent une tendance similaire, particulièrement marquée sur les deux derniers tiers du cycle de vie (non montré).

Une tendance négative apparaît également pour les autres variables thermodynamiques de basses couches (Figure 3.9), notamment près de la surface où la T_{2m} normalisée connaît une baisse comparable à celle de la CAPE. Cette évolution est moins marquée à 900 hPa. La différence de T_{900} entre la fin et le début de suivi est en effet de 2°C en moyenne alors qu'elle est de 4°C pour la T_{2m} (non montré). Par ailleurs, les distributions des variables SH_{900} et $\theta'w_{900}$ indiquent un assèchement modéré de l'air ambiant. En moyenne, la $\theta'w_{900}$ baisse d'environ 1°C sur le cycle de vie (Figure 3.10b).

La Figure 3.11 renseigne sur l'évolution du champ composite de CAPE et de $\theta'w_{900}$. Les MCSs-Std se développent généralement au centre d'une vaste zone d'instabilité conditionnelle, où les maxima de CAPE et de $\theta'w_{900}$ sont situés à l'avant et à droite du système. Les variables diminuent ensuite sur la totalité de l'environnement mais gardent des valeurs importantes à l'avant immédiat de l'objet. Une zone de CAPE modérée persiste à l'arrière et se décale peu à peu vers la droite. Un gradient gauche-droite de $\theta'w_{900}$ est visible en phase de développement,

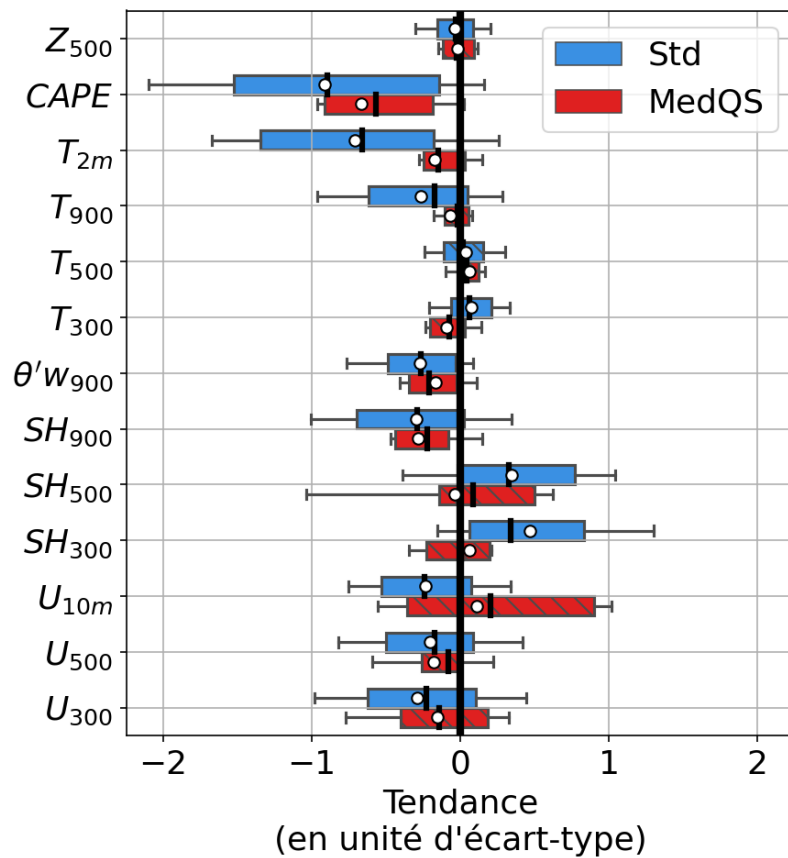


FIGURE 3.9 – Tendances des variables ambiantes calculées entre les phases de développement et d'affaiblissement pour chacun des 153 MCSs standards (MCSs-Std, en bleu) et chacun des 14 MCSs méditerranéens quasi-stationnaires (MCSs-MedQS, en rouge). Les tendances sont mesurées en unité d'écart-type de chaque variable ambiante. Les hachures signalent les évolutions non significatives ($p\text{-value} > 0.05$) selon le test non paramétrique des rangs signés de Wilcoxon (Wilks, 1995) adapté aux données appariées (ici, une variable ambiante calculée à deux phases distinctes du cycle de vie). Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.

à gauche du MCS, et se relâche par la suite. On note aussi un gradient orienté de l'avant vers l'arrière du système, moins marqué mais perdurant sur le cycle de vie. Enfin, la baisse plus prononcée de CAPE et de $\theta'w_{900}$ à l'arrière signale le passage de la plage froide.

La température de la masse d'air évolue peu en altitude mais l'humidité spécifique ambiante affiche une tendance positive très nette (Figure 3.9). Une raison possible tient à l'extension du nuage convectif au-delà du contour de l'objet, comme discuté plus loin (voir partie 3.4.5).

Pour finir, la tendance de Z_{500} est proche de 0 pour la plupart des systèmes. Selon les composites de la Figure 3.14d-f, les MCSs-Std tendent à se déplacer parallèlement à une




FIGURE 3.10 – Évolution de quelques variables ambiantes sur le cycle de vie normalisé des MCSs-Std. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.

isoligne de Z_{500} (5750 m en moyenne).

Évolution du flux dans l'environnement

Pour la majorité des MCSs-Std, le vent ambiant à 10 m, 500 hPa et 300 hPa diminue sur le cycle de vie (Figure 3.9). L'amplitude reste modeste, d'environ un quart d'écart-type de chaque variable normalisée (1 m/s à 10 m et 4 m/s à 300 hPa, Figure 3.10c,d). On retrouve cette évolution sur toute la troposphère (Figure 3.12), à l'exception des niveaux 900 à 800 hPa où la tendance reste nulle voire légèrement positive. En altitude, la décélération est d'autant plus marquée que la vitesse du vent est forte, impliquant une baisse du cisaillement vertical.

Les composites de la Figure 3.13 confirment la tendance négative de U_{10m} . En phase de

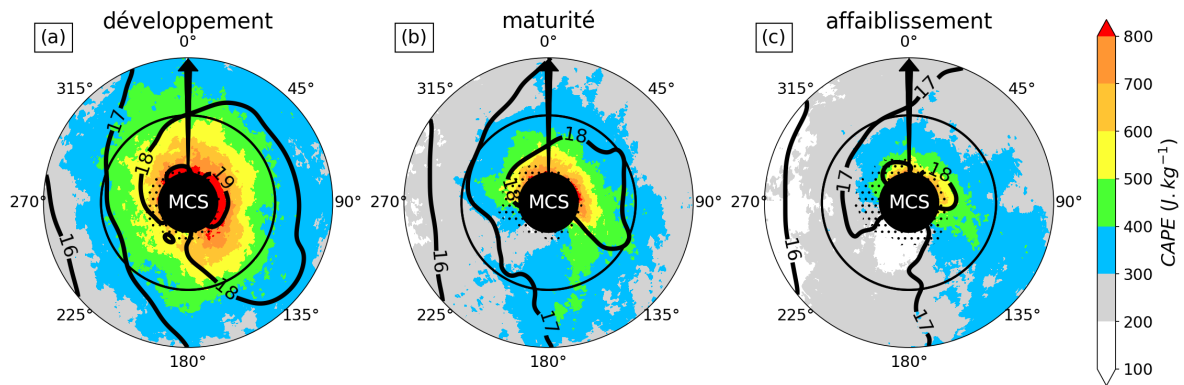


FIGURE 3.11 – Cartes composites annulaires pour les variables CAPE (en J/kg, couleurs) et θ'_{w900} (en $^{\circ}\text{C}$, contours), orientées selon le déplacement des MCSs-Std : en phases (a) de développement, (b) de maturité et (c) d'affaiblissement. L'objet MCS est symbolisé par un rond noir au centre de la carte, la flèche indiquant sa direction de déplacement fixée à 0° . Les distances radiales à l'objet sont repérées par le premier cercle (100 km) et le bord extérieur des composites (200 km). Les pointillés représentent les régions qui traduisent mal l'environnement moyen des MCSs car des RfC positives y sont présentes sur plus de la moitié des échantillons.

développement, l'environnement se caractérise par la convergence et la confluence de deux flux : le premier orienté de l'arrière vers l'avant du système, le second plutôt dirigé de la droite vers la gauche. Cette configuration est moins visible en phase d'affaiblissement. Le flux se renforce légèrement à l'avant mais décroît partout ailleurs, notamment à l'arrière. Des composites similaires sont observées à 900 hPa (non montrées), mais l'affaiblissement du vent est relativement moins marqué. Par ailleurs, on notera que les diagnostics de convergence disponibles en sortie d'AROME n'ont pas été étudiés. Ces champs sont en effet très bruités et donc inadaptés au calcul de moyennes.

En moyenne troposphère, le maximum de U_{500} se situe à l'arrière du système (Figure 3.14d-f). La décroissance du flux concerne ensuite l'ensemble de l'environnement, à l'exception du côté arrière droit où le U_{500} reste à peu près constant.

Sur la Figure 3.14a-c, la distribution spatiale de U_{300} est plutôt homogène en phase de développement, avec toutefois deux maxima : l'un à gauche du système, l'autre à l'arrière, à plus de 100 km de l'objet. Sur le cycle de vie, l'affaiblissement du flux est particulièrement marqué à l'avant ainsi qu'à l'arrière immédiat du système. Cependant, à gauche, le vent se renforce en phase de maturité et se maintient par la suite.

Enfin, le vent moyen à 500 et 300 hPa est orienté de l'arrière vers l'avant du système, quasiment parallèle à sa direction de déplacement. On note cependant une diffuence de U_{300} à l'arrière.

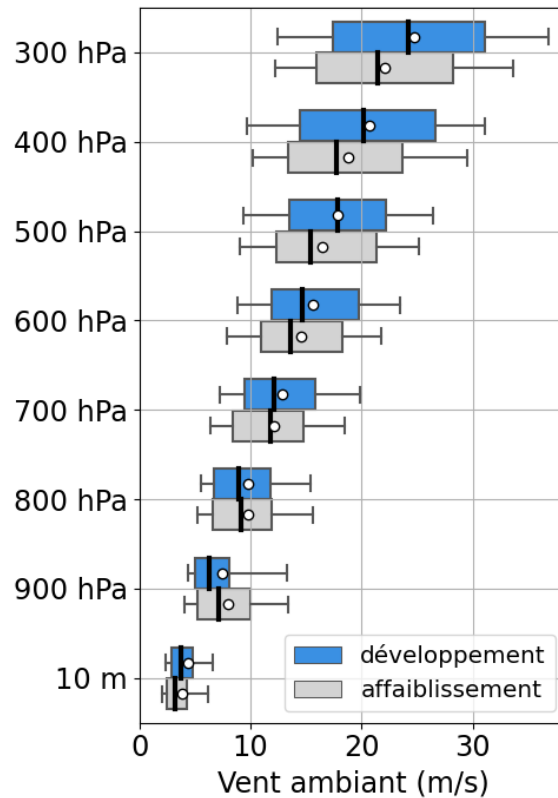


FIGURE 3.12 – Distributions des vents ambiants à différents niveaux durant les phases de développement (en bleu) et d’affaiblissement (en gris) des MCSs-Std. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.




FIGURE 3.13 – Idem Figure 3.11, mais pour le module (en m/s, couleurs) et la direction (flèches) de la variable U_{10m} . La longueur des flèches est proportionnelle au module.

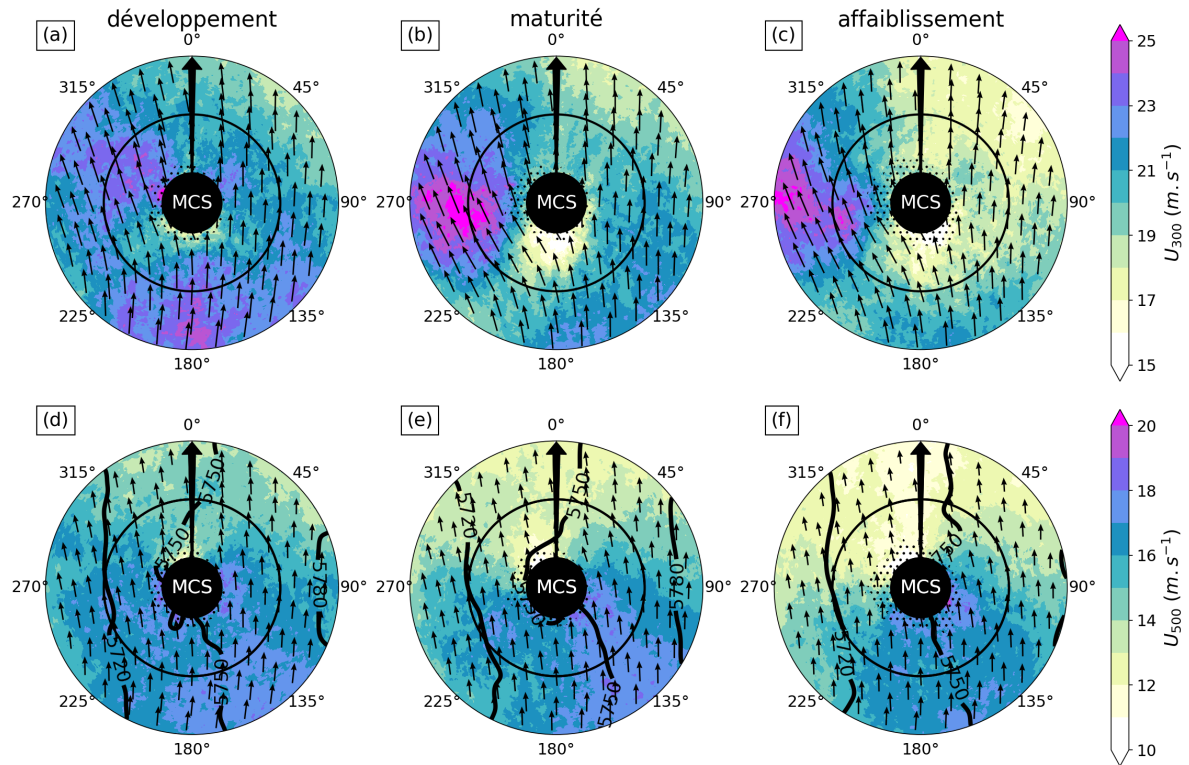


FIGURE 3.14 – Idem Figure 3.13, mais (a)-(c) pour les variables U_{300} et (d)-(f) pour les variables U_{500} et Z_{500} (en m, contours). Le lecteur notera que les intervalles de valeurs diffèrent entre les deux échelles de couleurs.

3.4.4 MCS du 4 juin 2022 : un système linéaire continental

Le cas du 4 juin 2022 illustre les résultats précédents. Ce jour-là, des départements allant du sud-ouest au nord-est sont placés en vigilance orange pour un risque d'orages violents. Des cellules et des supercellules se développent. Certaines fusionnent pour former des MCSs. La simulation AROME propose un scénario analogue. On se concentre ici uniquement sur l'évolution du MCS simulé, en lien avec l'environnement du modèle, sans comparer les résultats aux observations. L'objectif de cette partie est de comparer une situation donnée aux résultats statistiques décrits précédemment. On souligne aussi l'intérêt de certaines variables pour caractériser l'environnement des MCSs dans un contexte de prévision immédiate.

D'après la Figure 3.15, le contexte synoptique se rapproche de l'environnement composite discuté dans la section précédente. Une goutte froide au large de la Bretagne se prolonge en thalweg vers la péninsule ibérique. Le champ de masse dirige un flux de sud-ouest dynamique sur la France. En revanche, la synoptique est calme en basses couches. Une masse d'air chaud et humide occupe une grande partie du territoire. Le MCS se développe au sud des Pyrénées dans l'après-midi puis se dirige vers le nord-est de la France, suivant un axe continental commun à de nombreuses trajectoires étudiées (voir Figure 3.2).

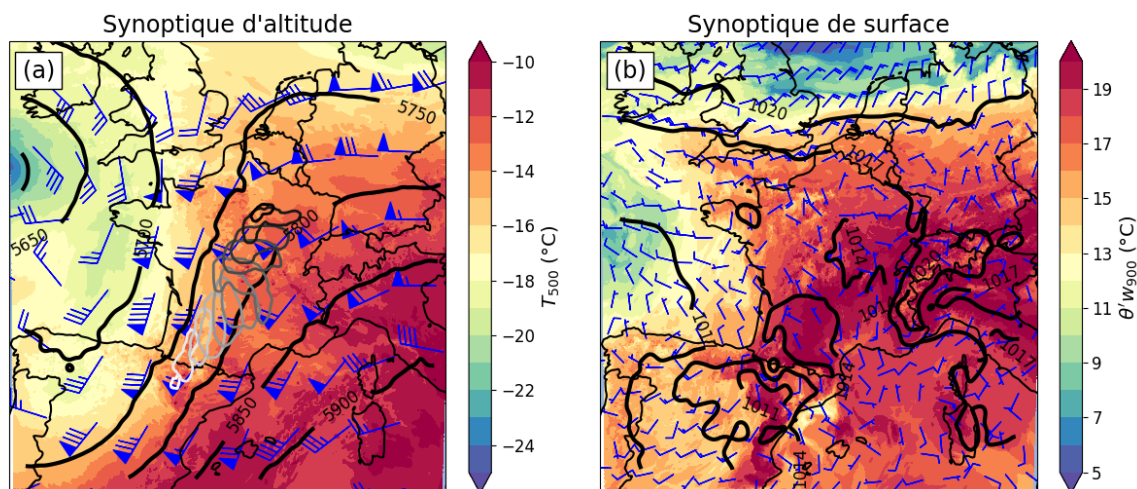


FIGURE 3.15 – Environnement synoptique du MCS simulé le 04/06/2022, à la date de validité de 1600 UTC (phase de développement) : (a) T_{500} (en °C, couleurs), Z_{500} (en m, contours) et U_{300} (en nœuds, barbules) ; (b) $\theta'w_{900}$ (en °C, couleurs), P_{mer} (en hPa, contours) et U_{10m} (en nœuds, barbules seuillées à 2,5 nœuds). La trajectoire du MCS est représentée sur la sous-figure (a), du premier objet détecté (en blanc) au dernier (en noir).

Le cycle de vie du MCS suit le schéma statistique décrit dans la section 3.3. Les extrêmes de Rflc et de TB sont atteints vers 1830 UTC, à 30 % du cycle de vie (Figure 3.16a), marquant la fin de la phase de développement. La surface concernée par des Rflc supérieures à 46 dBZ et la longueur de l'objet continuent de croître durant la phase de maturité, jusqu'à 2000 et 2145 UTC respectivement. L'organisation du système correspond alors au mode « rétrostratiforme » (voir partie 1.1.5), avec une ligne convective perpendiculaire au flux d'altitude, précédant une région de Rflc modérées (Figure 3.17b,k). On notera l'extension de l'enclume au-delà du contour de l'objet (TB à -50°C sur la Figure 3.17b,c).

Le système s'affaiblit sur les trois dernières heures du cycle de vie mais, comme pour la plupart des MCSs étudiés (partie 3.3.6), l'activité convective ne cesse pas tout-à-fait, en témoignent des Rflc maximales supérieures à 50 dBZ à la fin du suivi (Figure 3.16a)

Les tendances de CAPE et de $\theta'w_{900}$ ambiantes sont globalement négatives sur le cycle de vie (Figure 3.16b), en accord avec les résultats statistiques. Les deux variables augmentent cependant jusqu'à 1730 UTC, quand le système rencontre une atmosphère humide et instable sur le sud-ouest de la France, avec une CAPE ambiante atteignant 1000 J/kg et des maxima dépassant 2300 J/kg (Figure 3.17d). Cet apport d'énergie participe à l'intensification de l'activité convective durant la phase de développement. Par la suite, la trajectoire du MCS s'inscrit presque exactement dans le couloir de plus forte CAPE et de la $\theta'w_{900}$ (Figure 3.17e). Au même moment, d'autres systèmes convectifs se développent sur le nord-est et consomment la CAPE à l'avant du système, expliquant en partie la baisse de l'instabilité ambiante.

Le couloir de CAPE nulle sur la Figure 3.17e,f traduit le net refroidissement des basses couches et la stabilisation de la masse d'air après le passage du système. Cet effet n'explique

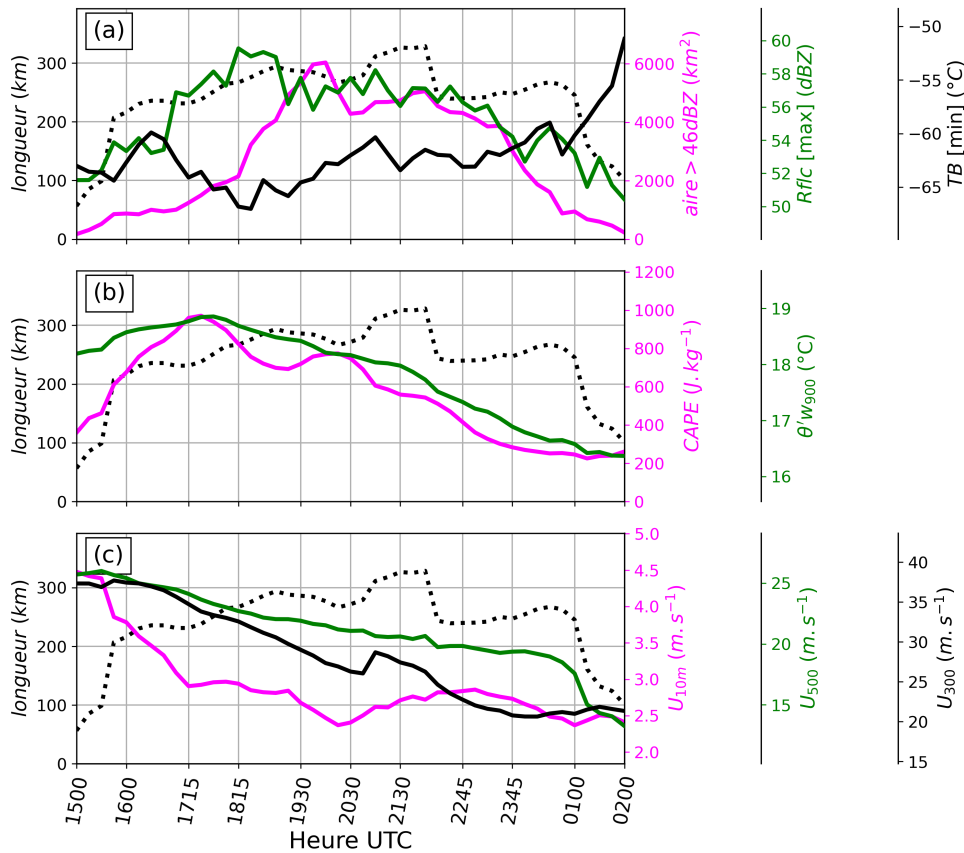


FIGURE 3.16 – Évolution temporelle de divers paramètres liés au MCS simulé le 04/06/2022. (a) Attributs de l'objet : aire avec Rflc > 46 dBZ (rose), Rflc-max (vert), TB-min (noir). (b) Variables thermodynamiques ambiantes : CAPE (rose) et $\theta'w_{900}$ (vert). (c) Variables dynamiques ambiantes : U_{10m} (rose), U_{500} (vert) et U_{300} (noir). La longueur de l'objet est renseignée en trait pointillé.

pas à lui seul la baisse de l'instabilité ambiante car une tendance similaire est mesurée en excluant la trace (non montré).

L'évolution et la distribution spatiale de U_{10m} font aussi écho aux résultats de la partie 3.4.3. Le flux est maximum au début du suivi (Figure 3.16c). Des zones de convergence apparaissent de chaque côté des Pyrénées (Figure 3.17g). Elles sont pilotées par des dépressions de mésoéchelle (Figure 3.17g). La convergence favorise le développement du système, notamment du côté espagnol où la CAPE reste limitée. En phase de maturité, un flux de sud circule dans la vallée du Rhône et converge avec un flux continental de nord-est à l'avant du système (Figure 3.17h). Cette configuration est moins visible en phase d'affaiblissement.

Le MCS se développe dans un environnement dynamique (U_{300} et U_{500} supérieurs à 35 et 25 m/s respectivement, Figure 3.16c), à droite du courant jet d'altitude (Figure 3.17m). Comme pour la plupart des MCSs-Std, le vent ambiant diminue mais la décélération est ici

très marquée (environ 10 m/s sur le cycle de vie). Advecté par le flux, le système se déplace vers le nord-est suivant une isoligne de Z_{500} (Figure 3.17j-l), en cohérence avec les composites de la Figure 3.14d-f.

Plusieurs caractéristiques du flux composite à 300 hPa se retrouvent dans cette situation. En phase de maturité, le courant jet se renforce à gauche du système, à plus de 100 km de l'objet (Figure 3.17n). Le jet adopte aussi une légère courbure anticyclonique. La diffluence du flux à l'arrière du système est également très nette en phases de maturité et d'affaiblissement (Figure 3.17n,o). Enfin, la plus forte baisse de U_{300} concerne l'avant et l'arrière immédiat du MCS.

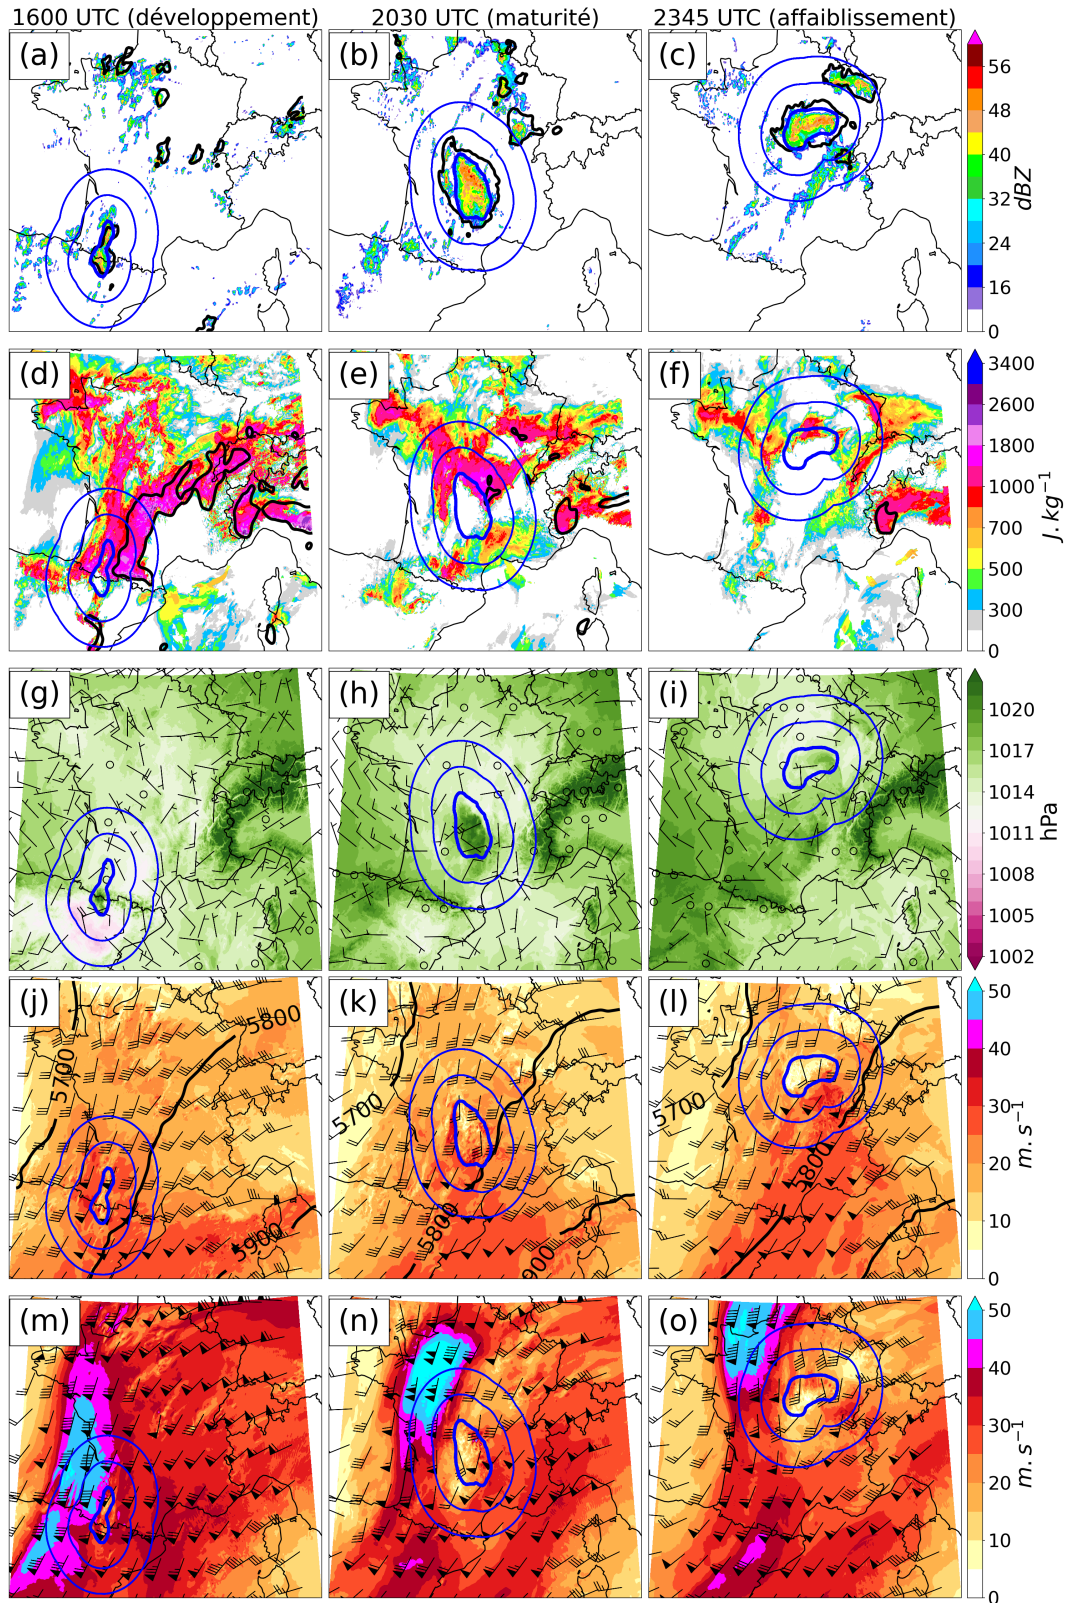


FIGURE 3.17 – Champs AROME correspondant aux phases de développement (à gauche), de maturité (au centre) et d'affaiblissement (à droite) du MCS simulé le 04/06/2022. (a)-(c) Rfic (en dBZ, couleurs) et TB (contours noirs à -50°C); (d)-(f) CAPE (en J/kg , couleurs) et $\theta'w_{900}$ (contours noirs à 20°C); (g)-(i) pression réduite au niveau de la mer (en hPa, couleurs) et U_{10m} (en nœuds); (j)-(l) U_{500} (couleurs en m/s et barbules en nœuds) et Z_{500} (en m, contours noirs); (m)-(o) U_{300} (couleurs en m/s et barbules en nœuds). Les cercles bleus indiquent, de l'intérieur vers l'extérieur, le contour de l'objet, la zone ambiante de largeur 100 km et la zone ambiante de largeur 200 km.

3.4.5 Discussion : impact du MCS sur son environnement

D'un point de vue statistique, certains paramètres caractérisant l'environnement des MCSs-Std évoluent de manière significative sur le cycle de vie. Le cas du 4 juin 2022 illustre la plupart de ces changements. S'il semble évident que l'environnement puisse influencer l'évolution des MCSs, ces derniers en modifient également le profil thermodynamique et la circulation (voir partie 1.1.4). On discute ici de l'impact des MCSs-Std sur les résultats obtenus afin d'identifier plus clairement les ingrédients de l'environnement responsables de leur intensification ou affaiblissement. L'analyse s'appuiera notamment sur des calculs de corrélation entre les tendances des variables ambiantes normalisées (Figure 3.18). On opte pour une corrélation des rangs, via le coefficient de Spearman (Wilks, 1995), car elle est peu sensible aux valeurs aberrantes et permet de mesurer tous types de relations monotones entre les variables.




FIGURE 3.18 – Corrélations (en %) entre les tendances de chaque variable ambiante normalisée sur le cycle de vie. Un coefficient de 1 (−1) correspond à une corrélation (anti-corrélation) parfaite, un coefficient de 0 indique une absence de corrélation. Les valeurs en % sont précisées pour les coefficients supérieurs (inférieurs) à 0,30 (−0,30).

Impact thermodynamique

En altitude, la concentration en particules de glace augmente avec l'extension du nuage, parfois au-delà du contour de l'objet détecté (Figures 3.17b). Leur sublimation cause probablement l'augmentation de l'humidité spécifique ambiante à 500 et 300 hPa. Celle-ci est en

effet corrélée aux tendances du contenu en glace nuageuse ambiante sur les niveaux respectifs (coefficients de +0,52 à 500 hPa et de +0,36 à 300 hPa, Figure 3.18).

Par ailleurs, la consommation continue de l'énergie convective environnante et l'étalement de la plage froide expliquent en partie le refroidissement et l'assèchement des basses couches, notamment à l'arrière du système, visibles sur les composites de CAPE et de $\theta'w_{900}$ (Figure 3.11, puis confirmés par la situation du 4 juin 2022. Comme évoqué dans la partie 3.4.2, ces impacts locaux restent toutefois marginaux dans les tendances des variables ambiantes. Comme expliqué plus loin, d'autres facteurs externes sont en effet impliqués dans l'évolution des conditions thermodynamiques de basses couches.

Impact sur le flux de mésoéchelle

La vitesse moyenne des MCSs (entre 13 et 14 m/s, voir Figure 3.4a) est inférieure à la vitesse moyenne du flux à 300 hPa (en général supérieure à 20 m/s, voir Figures 3.10 et 3.14). Wang *et al.* (2010) montrent que l'interaction entre les ascendances convectives et le vent d'altitude créé de la convergence selon l'axe vertical. Par conservation de la masse, la convergence entraîne une circulation horizontale divergente autour du système, capable de contrer le flux incident. « Bloqué », celui-ci dévie en partie, comme on l'observe au niveau des sommets protubérants des cellules en « V » (McCann, 1983). Cela peut expliquer le ralentissement de U_{300} à l'avant et à l'arrière immédiat du MCS ainsi que la diffuence observée sur les composites (Figure 3.14).

Par ailleurs, plusieurs hypothèses sont formulées pour expliquer l'augmentation de U_{300} à gauche des MCSs-Std. Cette signature évoque d'abord le *jet de mésoéchelle* (*mesoscale jet streak*) qui se développe parfois en altitude, près des MCSs les plus durables et les plus étendus (Markowski et Richardson, 2010). Dans l'hémisphère nord, on le trouve au nord-ouest du système. Il résulte de la superposition du flux d'altitude et de la circulation anticyclonique qui se met en place en réponse à la dilatation de la masse d'air en moyenne troposphère, dans la zone de chauffage (voir partie 1.1.4). Cependant, les composites du tourbillon relatif à 300 hPa (Figure 3.19) traduisent plutôt une circulation composée de deux tourbillons : un tourbillon cyclonique sur le côté droit et un tourbillon anticyclonique, plus marqué, sur le côté gauche. Celui-ci est certainement lié au jet de mésoéchelle mais son origine est incertaine. Elle pourrait faire écho aux travaux de Oertel et Schemm (2021) qui, à partir de simulations numériques, étudient la circulation induite par la convection profonde à l'avant d'un front froid. D'après leurs résultats, le tourbillon horizontal associé au courant jet d'altitude serait basculé au niveau des ascendances convectives, de part et d'autres du système. Enfin, le jet de mésoéchelle pourrait simplement se former par la déviation du flux à l'arrière du MCS, tel que décrit au paragraphe précédent.

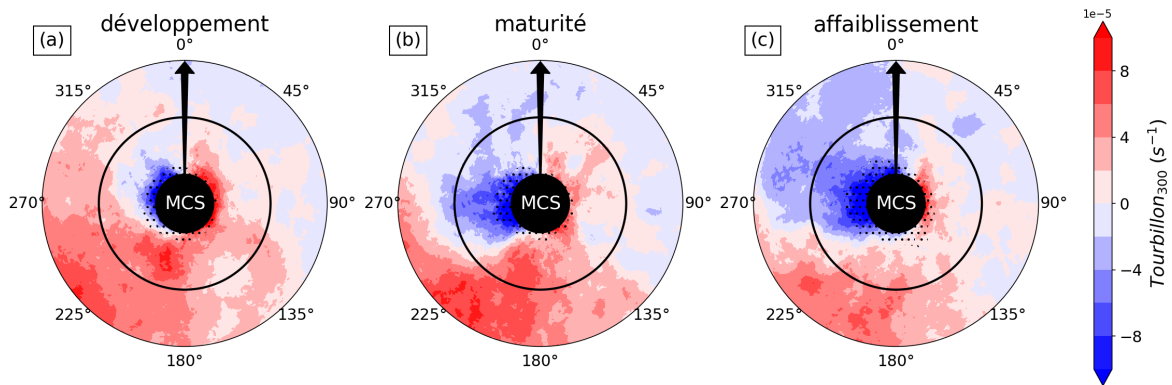


FIGURE 3.19 – Idem Figure 3.11, mais pour la composante verticale du tourbillon relatif à 300 hPa (en $10^{-5} s^{-1}$).

3.4.6 Discussion : impact de l’environnement sur le MCS

Phase de développement : les forçages dynamiques en basses couches

Au cours de cette phase, l’environnement composite se caractérise par une vaste zone d’instabilité conditionnelle (Figure 3.11a) où la convergence du vent de basses couches force le déclenchement de la convection (Figure 3.13a). Dans de nombreux cas, la convergence de basses couches semble d’origine frontale ou pré-frontale. En effet, le gradient de $\theta'w_{900}$ (Figure 3.11a) traduit la proximité de fronts synoptiques, ce que confirme l’analyse des conditions moyennes de grande échelle (partie 3.4.1). La convergence peut aussi être pilotée par des dépressions de mésoéchelle lorsque la situation synoptique est calme en surface, comme pour le MCS du 4 juin 2022.

La convergence de U_{10m} est moins marquée en phases de maturité et d’affaiblissement et son impact sur le cycle de vie est incertain. Une analyse plus approfondie des forçages de basses couches nécessiterait de détailler les interactions entre l’environnement et la plage froide.

Trajectoire du MCS : l’advection par le flux d’altitude

Le flux d’altitude permet d’estimer le mouvement des MCSs-Std. Les résultats précédents montrent que les systèmes se déplacent parallèlement à une isoligne de géopotentiel en moyenne troposphère. Cette tendance est également observée par Maddox (1980) pour les plus gros MCSs américains ou Hagen *et al.* (1999) pour des systèmes convectifs en Allemagne.

D’après la Figure 3.20, le vent ambiant à 650 hPa donne en moyenne la meilleure estimation de la vitesse des MCSs-Std entre 10 et 80 % de leur cycle de vie, période pour laquelle le suivi des objets est optimal. Cette estimation pourrait être affinée en prenant en compte la composante propagative du MCS, liée à la formation de nouvelles cellules dans la zone de

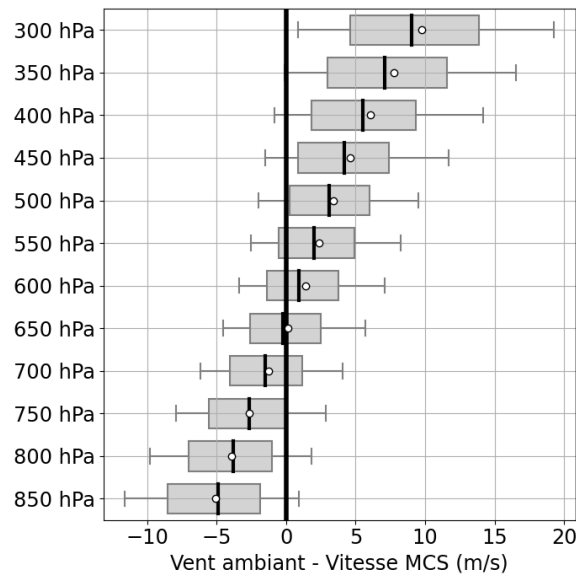


FIGURE 3.20 – Distributions des écarts de modules entre le vent ambiant à différents niveaux et la vitesse des MCSs-Std, de 10 à 80 % du cycle de vie. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.

convergence maximale entre la plage froide et le flux de basses couches (Corfidi *et al.*, 1996; Corfidi, 2003). D'ailleurs, pour deux situations étudiées en France avec un forçage synoptique faible, Calas *et al.* (2000) montrent que le MCS linéaire a tendance à se décaler vers les zones où la CAPE et la convergence sont les plus marquées.

Maintien du MCS : le rôle clé de l'alimentation chaude et humide de basses couches

Dans l'environnement des MCSs-Std, notamment à l'amont, la CAPE diminue fortement tout au long du cycle de vie. L'instabilité joue donc un rôle important dans le maintien du système, comme l'ont montré Jirak et Cotton (2007) et Coniglio *et al.* (2007) aux États-Unis. Parmi les tendances des variables étudiées, celles de $\theta'w_{900}$ et de SH_{900} en sont les plus corrélées (coefficients de +0,52 et de +0,67 respectivement, Figure 3.18). Par conséquent, la CAPE diminue par l'assèchement et le refroidissement des basses couches dont plusieurs raisons sont avancées ci-dessous.

- Sur les composites de la Figure 3.11, la direction du gradient de $\theta'w_{900}$ à l'avant du système est opposée à son déplacement. Les MCSs-Std sont donc généralement advectés vers des régions plus froides, plus sèches, c'est-à-dire moins instables. Il peut s'agir d'une région où la CAPE a été préalablement consommée par d'autres systèmes convectifs, comme dans la situation du 4 juin 2022. Pour d'autres études de cas (non montrées), le système est directement transporté vers une masse d'air synoptique stable, par exemple au niveau d'un front quasi-stationnaire.

- La baisse de la T_{2m} s'explique par le refroidissement nocturne, la plupart des trajectoires démarrant en fin d'après-midi (voir partie 3.3.2). Or, les tendances négatives de T_{2m} et de $\theta'w_{900}$ sont corrélées (+0,63). Certes, les MCSs ne s'affaiblissent pas immédiatement après le coucher du soleil, mais le chauffage diurne des basses couches n'entretient plus l'instabilité ambiante (Houze, 2004).
- En assurant une alimentation permanente du système en air chaud et humide, le flux de basses couches est souvent impliqué dans la longévité des MCSs américains (Gale *et al.*, 2002; Jirak et Cotton, 2007; Coniglio *et al.*, 2010; Lombardo et Colle, 2012). Il permet notamment le maintien de la convection nocturne (Houze, 2004; Markowski et Richardson, 2010). Dans cette étude sur la France métropolitaine, l'impact du flux de basses couches paraît moins clair. Le U_{10m} diminue en moyenne mais cette tendance ne se vérifie pas à 900 et 800 hPa (Figure 3.12). L'alimentation de basses couches serait mieux décrite par le vent relatif au déplacement du système, comme dans Gale *et al.* (2002), ou les flux horizontaux de chaleur et d'humidité, comme dans Ricard *et al.* (2012). Puisque ces paramètres ne sont pas directement disponibles en sortie d'AROME, ils n'ont pas été étudiés durant cette thèse. Cependant, ils devraient faire l'objet de futurs travaux.

Maintien du MCS : l'influence du vent d'altitude

Les MCSs-Std évoluent dans un environnement dynamique et cisailé (Figures 3.12 et 3.14) favorable au développement des systèmes linéaires (voir parties 1.1.4 et 1.1.5).

Même si la tendance est moins marquée par rapport à celle de l'instabilité, le vent d'altitude ambiant décroît tout au long du cycle de vie, notamment à 300 hPa. Coniglio *et al.* (2007) observent une tendance encore plus forte sur les États-Unis. Comme discuté dans la partie 3.4.5, cette décélération peut être liée au MCS lui-même, notamment dans les régions situées à l'avant ou directement à l'arrière du système. Pour les autres régions, notamment à droite, d'autres raisons sont possibles et énoncées ci-dessous.

- D'après la synoptique de grande échelle (partie 3.4.1) et le gradient composite de $\theta'w_{900}$ (Figure 3.11), on peut associer le flux d'altitude à la baroclinie de l'environnement. Or le gradient de $\theta'w_{900}$ se relâche sur le cycle de vie, impliquant une baroclinie moins marquée et un affaiblissement du vent thermique.
- Comme évoqué dans la partie 3.4.1, certains MCSs étudiés se développent à l'avant de gouttes froides d'altitude, en sortie gauche de jet, là où les ascendances d'origine agéostrophique favorisent le déclenchement de la convection (voir partie 1.1.2). Cette signature reste discrète sur la Figure 3.14a, avec un maximum de U_{300} à l'arrière droit du système, mais apparaît nettement sur l'environnement composite des MCSs impliqués (non montré). Selon Coniglio *et al.* (2007), les MCSs seraient ensuite advectés par le flux moyen et s'éloigneraient du jet d'altitude.

Coniglio *et al.* (2007) avancent que cette décélération du vent en haute troposphère diminue le cisaillement d'altitude et participe ainsi à l'affaiblissement des MCSs. En effet, le cisaillement renforce les ascendances en les maintenant inclinées vers l'avant du système, au-dessus du

courant de densité (Coniglio *et al.*, 2006). Même si la diminution du vent d'altitude peut avoir un impact sur les MCSs étudiés en France, leur cycle de vie reste principalement piloté par l'instabilité de l'environnement.

3.5 Zoom sur les MCSs méditerranéens quasi-stationnaires

Les MCSs-MedQS sont définis dans la partie 3.2.6. Sur la période d'étude, leur nombre est près d'un ordre de grandeur inférieur à celui des MCSs-Std. Statistiquement, les résultats sont donc moins significatifs mais introduisent une discussion sur l'environnement de ces systèmes. Après une brève description du contexte synoptique (partie 3.5.1), les résultats sont présentés dans la partie 3.5.2 et illustrés dans la partie 3.5.3. L'analyse repose sur la même méthodologie que celle employée pour les MCSs-Std (partie 3.4.2). Cependant, les environnements échantillonnés et les vecteurs de vent ne sont pas orientés dans la direction de déplacement des systèmes car les MCSs-MedQS sont supposés quasi-stationnaires. Enfin, dans la partie 3.5.4, les résultats sont comparés à la littérature très fournie des MCSs-MedQS en France.

3.5.1 Aperçu de l'environnement synoptique

Les synoptiques des 14 MCSs-MedQS sont analysées individuellement (non montrées). Dans 8 cas, un thalweg d'altitude traverse la France et s'accompagne d'une dépression en surface sur le nord du pays. On y trouve la plupart des systèmes évoluant sur les côtes françaises et catalanes (voir Figure 3.2c,e). Dans 5 autres cas, une goutte froide d'altitude circule en Méditerranée, une configuration plus propice aux trajectoires maritimes. Pour 13 des 14 MCSs, une dépression d'échelle synoptique ou de mésoéchelle est présente dans l'environnement du système, généralement sur son flanc ouest. Connu pour renforcer la convergence en basses couches, cet ingrédient se trouve fréquemment impliquée dans le développement des MCSs-MedQS (Nuissier *et al.*, 2008; Lee *et al.*, 2017).

3.5.2 Analyse statistique

Évolution de la masse d'air dans l'environnement

La Figure 3.9 compare les tendances des variables ambiantes obtenues pour les MCSs-Std et les MCSs-MedQS. L'environnement de ces derniers connaît également une baisse marquée de CAPE, bien que de moindre amplitude. Les tendances négatives de $\theta'w_{900}$ et de SH_{900} sont comparables pour les deux catégories de MCS.

Les composites de la Figure 3.21 sont bruitées mais mettent en évidence une zone d'instabilité maximale au sud du système. Si la CAPE tend à diminuer sur le cycle de vie, de fortes valeurs persistent au sud jusqu'en phase d'affaiblissement, plutôt à distance du système. La

$\theta'w_{900}$ est également maximale au sud et minimale à l'ouest. La partie nord de la composite est peu représentative (zone pointillée) car souvent concernée par les faibles précipitations de la région stratiforme, advectées vers le nord par le flux d'altitude.

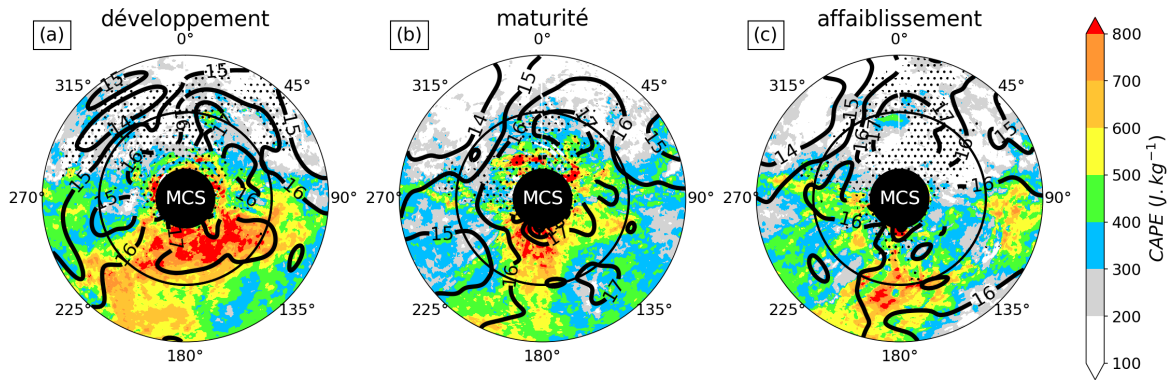


FIGURE 3.21 – Idem Figure 3.11, mais pour les MCSs-MedQS. Ici, les environnements échantillonnés ne sont pas orientés dans la direction de déplacement du système (la direction de 0° indique le nord géographique).

Aucune tendance significative n'apparaît pour les autres variables thermodynamiques, à l'exception d'une légère baisse en T_{2m} (Figure 3.9). Comme pour les MCSs-Std, la Z_{500} reste inchangée.

Évolution du flux dans l'environnement

Les vents ambiants ne montrent pas de tendance significative (Figure 3.9).

Les composites de U_{10m} sont plus informatives (Figure 3.22). Un flux de sud-est à sud-ouest converge dans la moitié sud de l'environnement, notamment pendant la phase de développement. Après analyse des situations synoptiques associées à chaque MCS (non montrées), trois origines apparaissent pour expliquer la convergence de basses couches. Le relief est impliqué dans deux tiers des cas. Les MCSs maritimes se développent à proximité de dépressions en surface. Deux systèmes évoluent à l'avant de fronts froids synoptiques progressant d'ouest en est.

Par ailleurs, le flux convergent de basses couches disparaît en phase d'affaiblissement (Figure 3.22c). Un flux d'ouest à nord-ouest se met alors en place au sud du système.

Sur les composites de U_{500} et U_{300} (non montrées), le flux de sud-ouest évolue peu et son maximum se situe au sud du système.

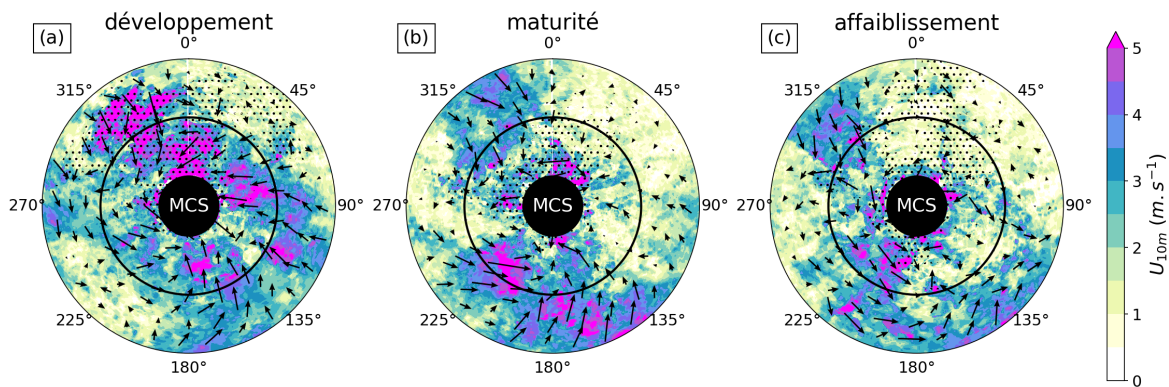


FIGURE 3.22 – Idem Figure 3.13, mais pour les MCSs-MedQS. Ici, les environnements échantillonnés et les vecteurs de vent ne sont pas orientés dans la direction de déplacement du système (la direction de 0° indique le nord géographique).

3.5.3 MCS du 20 novembre 2018 : une ligne stationnaire sur le Gard

Dans la soirée du 20 novembre 2018, une ligne convective se développe sur le Gard. Avec des cumuls dépassant 100 mm en quelques heures, le département est placé en vigilance orange « pluie-inondation ». La simulation AROME de 0600 UTC reproduit bien l'évolution du MCS. Comme pour la précédente étude de cas, les Figures 3.23, 3.24 et 3.25 décrivent le contexte synoptique ainsi que le cycle de vie de l'objet et de son environnement.

Une perturbation barocline évolue sur la France, pilotée par un creux de géopotential en altitude, centré sur le nord-ouest, et un vaste système dépressionnaire en surface (Figure 3.23). Le système est connecté à une large bande de précipitations synoptiques (Figures 3.25a) à l'interface entre l'air doux méditerranéen et l'air froid venu de l'Atlantique. En altitude, un fort flux de sud-ouest étire la ligne convective vers le nord. Le champ de Z_{500} dessine un petit thalweg sur la Catalogne qui participe au creusement d'une dépression sur le golfe du Lion (Figure 3.23). Celle-ci dirige un flux de sud instable sur le Gard et renforce la convergence sur les reliefs côtiers (Figure 3.25d,g).

Le MCS a un cycle de vie peu marqué (Figure 3.24a). La taille et l'activité convective montrent un léger pic entre 60 et 80 % du suivi.

Le vent d'altitude reste stable (Figures 3.25j-o) mais la CAPE et la $\theta'w_{900}$ ambiantes diminuent continûment (Figure 3.24b), une tendance que confirme le rétrécissement du couloir d'air instable alimentant le système par le sud (Figure 3.25e,f). L'environnement annulaire de la Figure 3.26a-c permet d'en rendre compte plus nettement. Cette évolution trouve deux origines : (1) un système convectif en mer consomme une partie de l'instabilité disponible en amont (Figure 3.25b,c,e,f), (2) comme noté sur les composites de la Figure 3.22, le flux d'alimentation tend à s'affaiblir, contré par un flux de secteur ouest (Figure 3.26d,f), peut-être en lien avec la remontée du petit thalweg d'altitude qui décale la dépression de surface vers l'ouest (Figure 3.25h,i,k,l). Les tendances de la Figure 3.24b restent modestes (CAPE

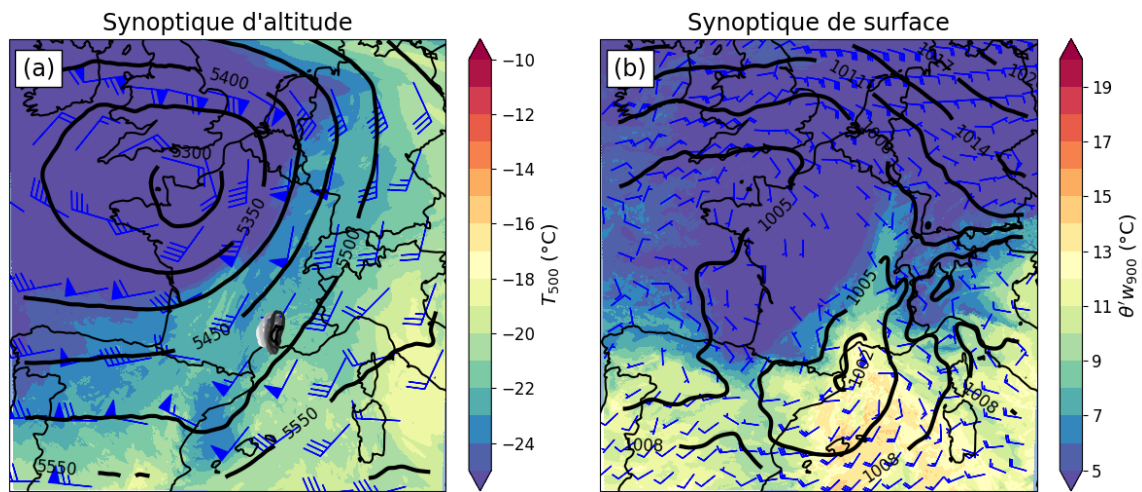


FIGURE 3.23 – Idem Figure 3.15, mais pour le MCS simulé le 20/11/2018, à la date de validité de 2045 UTC (phase de développement).




FIGURE 3.24 – Évolution temporelle de divers paramètres liés au MCS simulé le 20/11/2018. (a) Attributs de l'objet : aire avec Rflc > 46 dBZ (rose), Rflc-max (vert), TB-min (noir). (b) Variables thermodynamiques ambiantes : CAPE (rose) et $\theta'w_{900}$ (vert). La longueur de l'objet est renseignée en trait pointillé.

diminuant d'environ 200 à 50 J/kg entre le début et la fin du suivi) car la zone ambiante est trop large pour décrire avec précision l'étroit couloir d'alimentation au sud du MCS.

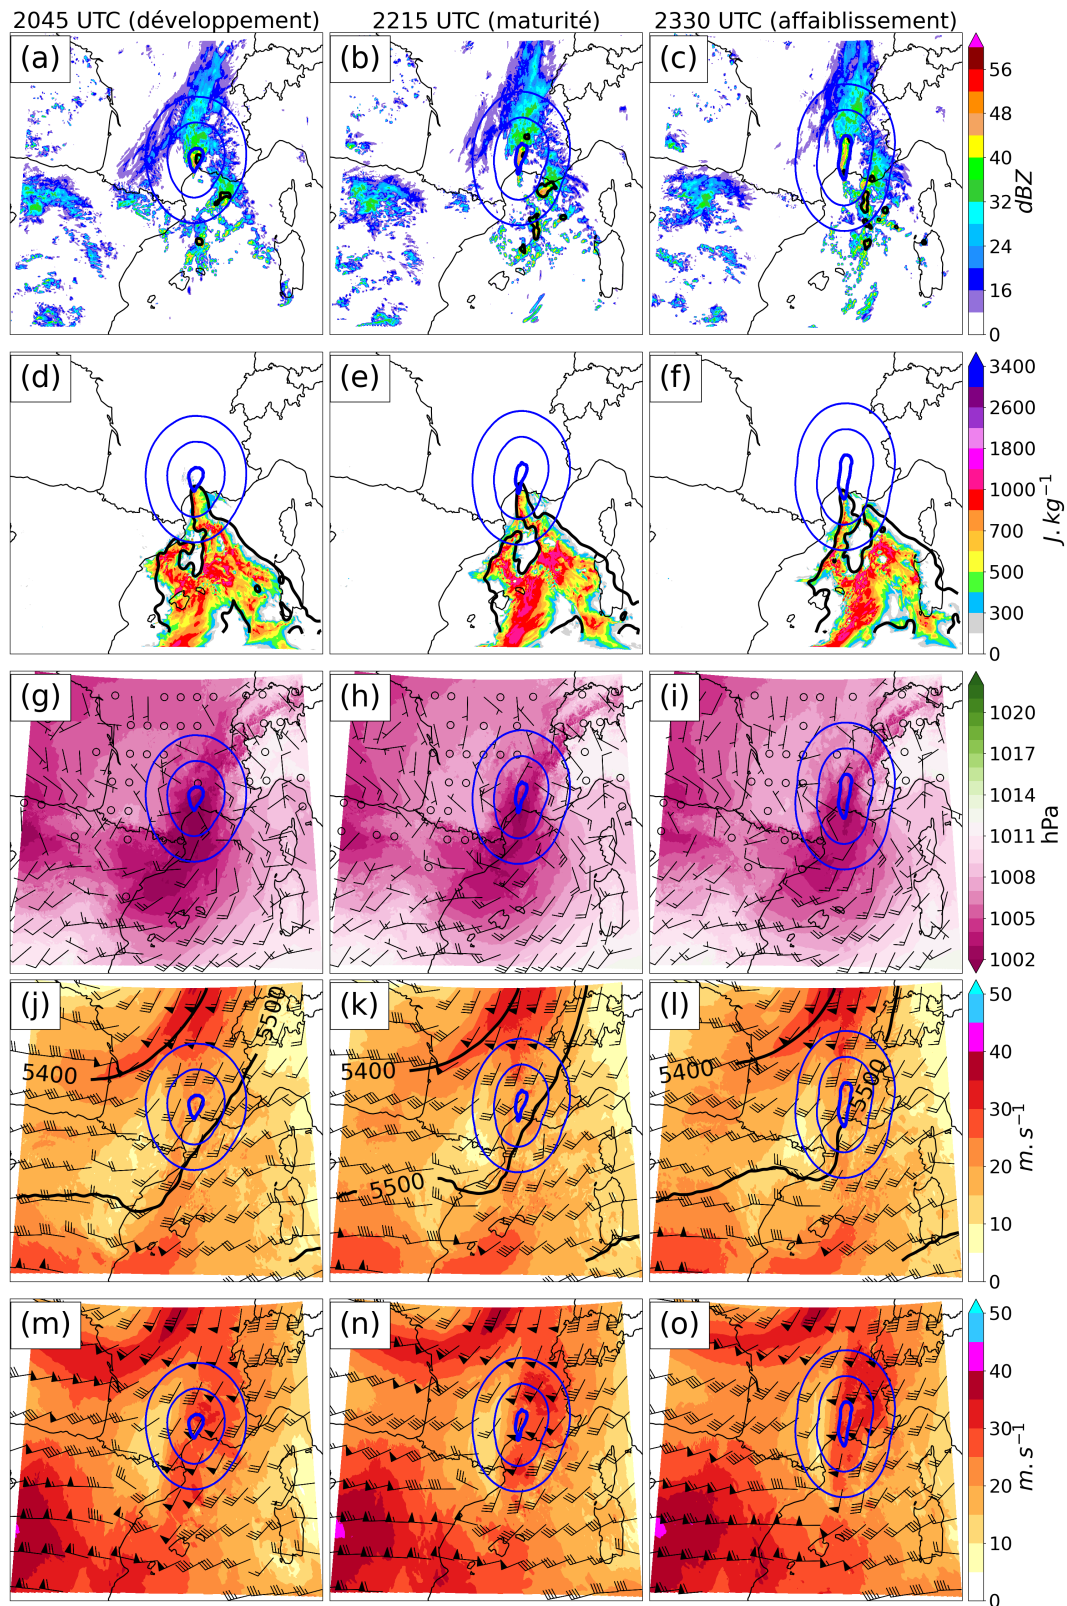


FIGURE 3.25 – Champs AROME correspondant aux phases de développement (à gauche), de maturité (au centre) et d’affaiblissement (à droite) du MCS simulé le 20/11/2018. (a)-(c) Rfic (en dBZ, couleurs) et TB (contours noirs à $-50^{\circ}C$); (d)-(f) CAPE (en J/kg , couleurs) et $\theta'w_{900}$ (contours noirs à $12^{\circ}C$); (g)-(i) pression réduite au niveau de la mer (en hPa, couleurs) et U_{10m} (en nœuds); (j)-(l) U_{500} (couleurs en m/s et barbules en nœuds) et Z_{500} (en m, contours noirs); (m)-(o) U_{300} (couleurs en m/s et barbules en nœuds). Les cercles bleus indiquent, de l’intérieur vers l’extérieur, le contour de l’objet, la zone ambiante de largeur 100 km et la zone ambiante de largeur 200 km.

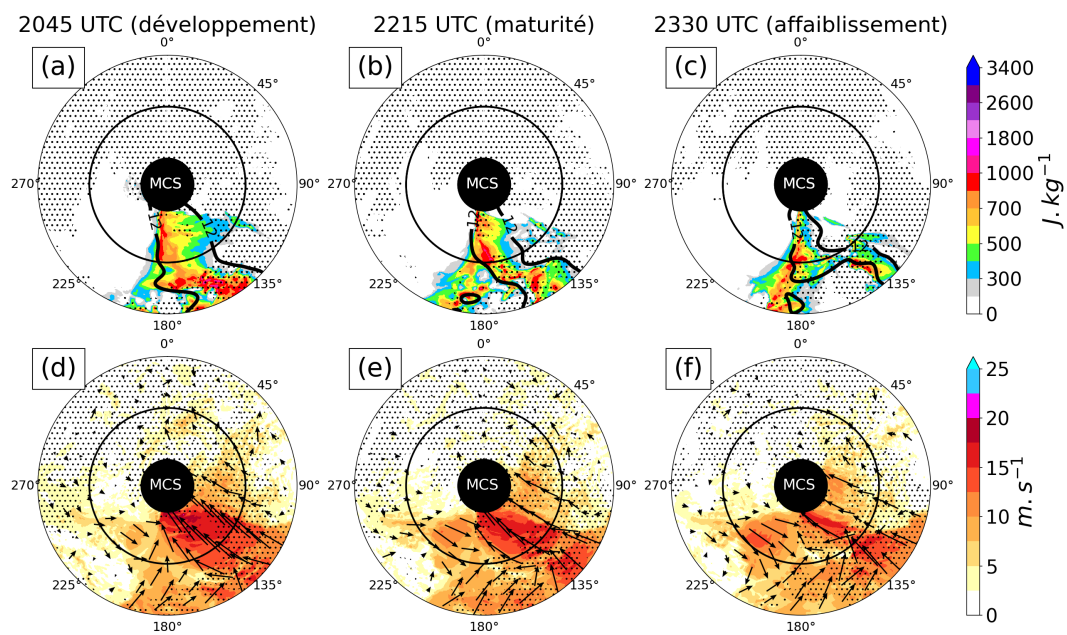


FIGURE 3.26 – Environnement annulaire de largeur 200 km correspondant au MCS du 20/11/2018 en phases de développement (à gauche), de maturité (au centre) et d'affaiblissement (à droite). (a)-(c) CAPE (en J/kg, couleurs) et $\theta'w_{900}$ (contours noirs à 12°C); (d)-(f) U_{10m} , module (en m/s, couleurs) et direction (flèches). Les pointillés correspondent aux zones de Rflc positives.

3.5.4 Conclusions

Comme pour les MCSs-Std, le cycle de vie des MCSs-MedQS dépend principalement de la disponibilité d'une masse d'air chaud et humide en basses couches, dans une atmosphère conditionnellement instable. Que ce soit au travers des cartes composites ou de l'étude du MCS de novembre 2018, l'analyse spatiale est ici préférable aux variables ambiantes pour retranscrire l'environnement des systèmes. Elle met en évidence des ingrédients d'échelle synoptique et de mésoéchelle, connus pour favoriser le développement des MCSs quasi-stationnaires en Méditerranée :

- un thalweg ou une goutte froide peu mobiles en altitude (Nuissier *et al.*, 2008; Ricard *et al.*, 2012), participant au creusement d'une dépression en surface (Khodayar *et al.*, 2021);
- un flux de sud-est à sud-ouest en basses couches, piloté par la dépression et alimentant le système en air maritime chaud et humide (Ducrocq *et al.*, 2008; Ricard *et al.*, 2012; Khodayar *et al.*, 2021);
- la convergence du flux de basses couches pour forcer le développement de la convection. La convergence est souvent de nature orographique mais aussi liée à des lignes de convergence en mer, près des dépressions, ou bien à l'arrivée d'un front froid par l'ouest. Ces trois ingrédients sont également mis en avant dans la littérature des MCSs-MedQS (Ducrocq *et al.*, 2008; Lee *et al.*, 2016; Khodayar *et al.*, 2021).

Le flux d'alimentation de basses couches est moins marqué en phase d'affaiblissement, une évolution également documentée par Ricard *et al.* (2012). D'après la situation du 20 novembre 2018, elle peut être liée au déplacement des zones de basse pression en surface et en altitude. L'impact sur l'affaiblissement des MCSs est probable mais devra être détaillé à partir d'un plus grand nombre de trajectoires.

3.6 Conclusions et perspectives

Plus de 150 MCSs ont été analysés sur une centaine de journées en France, à la fois dans des images observées et au travers de simulations AROME. Pour la plupart, il s'agit de systèmes linéaires et continentaux se développant de mai à octobre, dans l'après-midi et en soirée. Les réponses apportées à chacun des trois sous-objectifs fixés en début de chapitre sont résumées ci-dessous, accompagnées de futures pistes de recherche.

Sous-objectif n°1 : caractériser le cycle de vie

La taille des MCSs évolue de façon parabolique. Il en va de même pour les attributs liés à l'activité convective, comme les extrêmes de réflectivités ou de température de brillance. En cohérence avec des climatologies de MCSs menées ailleurs dans le monde, l'intensité convective plafonne plus tôt que la taille, respectivement vers 30 à 40 % et 50 à 60 % du cycle de vie

en moyenne. Ces deux instants divisent la vie d'un MCS en trois phases : développement, maturité et affaiblissement.

Sous-objectif n°2 : évaluer AROME pour la simulation du cycle de vie

Ce chapitre est aussi une première occasion d'évaluer de manière statistique les capacités d'AROME à reproduire le comportement des MCSs en France. Le cycle de vie des MCSs simulés est proche de celui des MCSs observés. Quelques biais apparaissent néanmoins : la vitesse des MCSs simulés est plus importante que celle des MCSs observés, leur taille maximale est atteinte plus tôt, leur Rflc maximales sont inférieures de près de 10 dBZ. Si des hypothèses ont été formulées pour les expliquer, ces biais doivent être détaillés par une étude plus exhaustive, sous forme de climatologie comparative, afin d'aiguiller les chercheurs œuvrant à l'amélioration du modèle. Les mosaïques de réflectivités du programme européen OPERA (*Operational Program for Exchange of Weather Radar Information*, Saltikoff *et al.* 2019) seraient alors utiles pour élargir le domaine de détection des MCSs observés, notamment sur le nord-est de la France. Quand le satellite MTG sera opérationnel, les données de l'imageur FCI permettront aussi de décrire plus précisément l'évolution de la TB sur le cycle de vie.

Sous-objectif n°3 : étudier l'influence de l'environnement sur le cycle de vie

Le rôle joué par l'environnement convectif dans le maintien des MCSs a été peu étudié alors que des ingrédients utiles pourraient être exploités pour anticiper l'évolution du phénomène à très courte échéance. Sur ce sujet, l'apport de la thèse est double : (1) étendre à l'Europe de l'ouest les rares études menées aux États-Unis ; (2) proposer une nouvelle méthode basée sur des *cartes composites annulaires* afin de décrire spatialement et statistiquement l'environnement d'un ensemble d'objets simulés aux géométries variables. Cette méthode complète l'approche des *variables ambiantes* qui consiste ici à moyenniser des champs AROME dans un rayon de 100 km autour de l'objet simulé. En général, les variables ambiantes évoluent de façon monotone sur le cycle de vie. La CAPE décroît et connaît l'évolution la plus marquée. Les cartes composites annulaires montrent que les MCSs « standards » (non méditerranéens quasi-stationnaires) tendent à se former au cœur d'une vaste zone instable avec de la convergence en basses couches. Les systèmes sont ensuite transportés par le flux d'altitude, leur vitesse étant à peu près égale à celle du vent ambiant à 650 hPa. La baisse de l'instabilité en amont, corrélée au refroidissement et à l'assèchement des basses couches, est principalement responsable de l'affaiblissement des MCSs. De manière plus incertaine, la diminution du cisaillement d'altitude peut aussi être impliquée. De plus, la formation d'un jet d'altitude de mésoéchelle sur le flanc gauche des systèmes a été mise en évidence. Enfin, les cartes composites annulaires confirment les connaissances recueillies au sujet des MCSs méditerranéens quasi-stationnaires, bien plus étudiés que les autres MCSs en Europe de l'ouest. Ils se développent à la convergence d'un flux maritime de basses couches qui alimente continûment le MCS en air chaud et humide. Le flux tend ensuite à s'affaiblir, avec une implication probable sur le déclin du système.

Trois axes de recherche devront compléter ces résultats :

1. La tendance de certaines variables ambiantes montre un écart-type important sur les distributions des MCSs. En travaillant sur un plus grand nombre de trajectoires, la suite de ce travail consistera à étudier séparément plusieurs catégories de MCSs discriminés selon leur environnement synoptique (comme dans [Lewis et Gray 2010](#)), leur localisation (comme dans [Ricard et al. 2012](#)), leur organisation (comme dans [Cui et al. 2021](#)) ou leur violence convective (MCS sans épiphénomènes violents, fortement précipitant ou produisant de fortes rafales de vent).
2. Il conviendra d'éclaircir le rôle joué par la dynamique de basses couches dans le cycle de vie en introduisant de nouvelles variables, notamment le vent relatif au système, les flux de chaleur et d'humidité ou un indice quantifiant l'interaction entre la plage froide et l'environnement (comme dans [Weisman 1992](#)).
3. Étudier l'environnement des MCSs observés permettra de vérifier ou de préciser les résultats issus des simulations AROME. À défaut d'observations exhaustives dans la troposphère, l'environnement pourra être caractérisé par des champs réanalysés à l'aide des données ERA5 ([Hersbach et al., 2023](#)), comme dans [Cui et al. \(2021\)](#).

Par ailleurs, la méthodologie mise en place pour suivre les objets MCS et leur environnement permet d'envisager plusieurs approches de prévision immédiate :

- à partir d'une simple équation d'évolution de la taille ou de l'activité convective, paramétrée par la tendance observée des attributs de l'objet (comme dans [Kolios et Feidas 2012a](#); [Wilhelm et al. 2023](#));
- à partir des variables ambiantes et des attributs de l'objet utilisés comme prédicteurs d'un modèle d'apprentissage machine (comme dans [Hamann et al. 2019](#));
- en exploitant l'information spatiale des environnements échantillonnés, projetés sur une carte annulaire, grâce à un réseau de neurones convolutifs.

Ces perspectives seront développées à la fin du mémoire (voir section 5.4).

Apport du modèle AROME-PI pour la prévision immédiate des MCSs

Sommaire

4.1	Introduction	162
4.2	Méthode d'évaluation	162
4.2.1	Données observées	162
4.2.2	Prévisions par extrapolation	163
4.2.3	Prévisions numériques AROME et AROME-PI	163
4.2.4	Intérêts d'une approche objet	164
4.2.5	Appariement des MCSs observés et prévus	165
4.3	Apport d'AROME-PI sur l'extrapolation	167
4.3.1	Panorama des scores	167
4.3.2	Sensibilité des scores au cycle de vie	169
4.4	Apport d'AROME-PI sur AROME-PROD	170
4.4.1	Panorama des scores	170
4.4.2	Raisonnement par trajectoire	171
4.5	Apport des réseaux AROME-PI consécutifs	173
4.5.1	Le dernier réseau est-il toujours le meilleur?	173
4.5.2	Conception d'une carte synthétique pour le prévisionniste	177
4.6	Conclusions et perspectives	178

4.1 Introduction

Le chapitre précédent a montré que le modèle AROME simulait le cycle de vie d'un MCS de façon réaliste. Désormais, on évalue ses capacités à prévoir un système au bon moment et bon endroit.

Comme décrit au chapitre 1, AROME-PI est mis à jour toutes les heures par assimilation des observations les plus récentes. Ses prévisions à 6 h sont ici évaluées pour l'anticipation des MCSs à très courte échéance. Comme au chapitre 3, l'étude concerne la France métropolitaine et les situations de vigilance orange et rouge entre mai 2018 et décembre 2022. Une approche objet est adoptée pour faciliter la comparaison des systèmes prévus et observés. Les bénéfices d'AROME-PI sont évalués par rapport à deux autres méthodes de prévision : (1) le modèle AROME de la chaîne de production, mis à jour toutes les 3 h et d'où proviennent les ébauches d'AROME-PI, (2) une méthode à moindre coût basée sur l'extrapolation lagrangienne des objets observés. Enfin, les performances relatives des réseaux AROME-PI successifs sont mesurées pour discuter de la pertinence d'une prévision ensembliste par décalage temporel.

Concrètement, les résultats de ce dernier chapitre doivent répondre aux questions suivantes :

1. Par rapport à une simple extrapolation des observations, le modèle AROME-PI est-il utile pour prévoir les MCSs sur les prochaines heures ? Si oui, pour quelles échéances ?
2. Par rapport à la chaîne de production, la mise à jour d'AROME effectuée par le 3D-Var d'AROME-PI est elle utile pour l'anticipation des MCSs ?
3. Est-ce pertinent d'étudier tous les réseaux AROME-PI consécutifs et disponibles au même instant pour une prévision immédiate ensembliste des MCSs ? En d'autres termes, n'est-il pas préférable d'utiliser systématiquement la prévision déterministe du dernier réseau disponible ?

Les sections 4.3, 4.4 et 4.5 abordent dans l'ordre les trois questions formulées ci-dessus. Avant cela, les données utilisées et la méthode d'évaluation sont détaillées dans la prochaine section.

4.2 Méthode d'évaluation

4.2.1 Données observées

Les objets de référence correspondent aux MCSs observés des 157 trajectoires introduites au chapitre 3. Les objets sont détectés dans les observations de Rflc et de TB à l'aide du **U-Net OBS** décrit dans la section 2.5. Les trajectoires sélectionnées comprennent des objets de longueur supérieure à 100 km pendant au moins 3 h et leur cycle de vie est entièrement compris dans le domaine et la période d'étude. La section 3.2 propose une description complète des trajectoires observées.

Les caractéristiques et le cycle de vie des trajectoires ont été analysés au chapitre précédent (section 3.3). Les MCSs concernent toute la France mais évoluent préférentiellement du sud-ouest au nord-est. La plupart se développent de mai à octobre, particulièrement sur les trois mois d'été, dans l'après-midi et en soirée.

Les objets observés trop petits ou mal identifiés sont exclus afin de ne pas pénaliser les prévisions à cause de la méthode de détection. Il s'agit des objets de longueur inférieure à 100 km, en phase de développement notamment, et des objets en phase de dissipation (âge relatif supérieur à 85 %) pour lesquels le U-Net est moins performant (voir partie 3.3.4). Finalement, près de 3600 objets composent la base de référence.

4.2.2 Prévisions par extrapolation

Les MCSs observés à t_0 sont extrapolés jusqu'à 6 h d'échéance à partir de leur vitesse à t_0 , calculée par l'algorithme *OSIRIS* décrit dans la partie 3.2.4. L'extrapolation est simplement linéaire : les coordonnées du contour évoluent mais la forme et la taille de l'objet prévu restent constantes. Ces prévisions sont uniquement lancées aux heures rondes afin d'être comparées à celles des réseaux horaires AROME-PI. L'extrapolation vise ici une échéance lointaine par rapport aux prévisions opérationnelles, par exemple celles du produit ASPOC (partie 1.4), où l'advection est limitée à 1 h.

4.2.3 Prévisions numériques AROME et AROME-PI

Les prévisions numériques évaluées proviennent des réseaux AROME-PI et des réseaux du cycle de production d'AROME utilisé comme ébauches dans le 3D-Var d'AROME-PI, comme décrit dans la partie 1.5.6. La chaîne de production, plus connue sous les noms d'*AROME* ou d'*AROME-France*, sera ici désignée par le terme **AROME-PROD** qui permettra d'éviter toute ambiguïté avec la configuration **AROME-PI**.

Comme schématisé sur la Figure 4.1, il y a un espacement de 3 h entre les réseaux d'AROME-PROD. Certaines des assimilations successives d'AROME-PI auront donc pour ébauches la même prévision AROME-PROD mais à différentes échéances. Puisque le délai de mise à disposition des réseaux AROME-PROD varie au cours de la journée, le nombre d'analyses AROME-PI basées sur le même réseau AROME-PROD évolue par construction. Ce nombre est au maximum de 5 pour les runs de 0500 à 0900 UTC.

Les prévisions AROME-PI et AROME-PROD proviennent des données archivées correspondant à la période d'étude. Sur cette période AROME a connu trois changements de version (appelée cycle) : le cycle 42 jusqu'en juillet 2019, le cycle 43 jusqu'en juin 2022 et le cycle 46 par la suite. Les modifications concernent principalement l'étape d'analyse, par l'ajout de nouvelles observations, l'amélioration de leur pré-traitement et de la manière dont elles sont assimilées. Le comportement d'AROME n'est donc pas strictement homogène sur la période d'évaluation mais on le considérera comme tel. D'ailleurs, ses performances pour la prévision

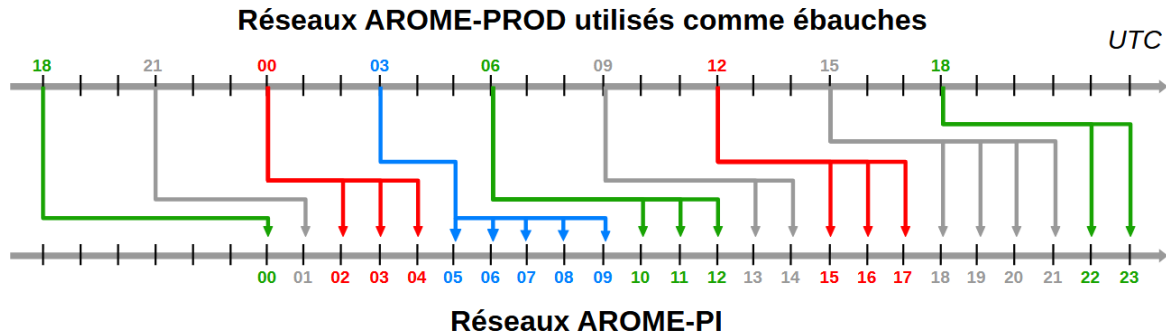


FIGURE 4.1 – Réseaux AROME-PROD utilisés comme ébauches pour les 24 réseaux quotidiens d'AROME-PI. Les réseaux grisés ne sont pas considérés dans la section 4.4 car certaines des échéances AROME-PROD associées ne sont pas archivées sur la période d'étude.

des MCSs n'indiquent pas de tendance marquée sur les cinq années étudiées (non montré).

Les prévisions AROME-PI et AROME-PROD sont archivées à cadence 15 min et 1 h respectivement. Elles sont donc uniquement comparées sur les échéances horaires dans la section 4.4. Par ailleurs, les prévisions des réseaux 0900, 1500 et 2100 UTC d'AROME-PROD étaient limitées à 7 h d'échéance jusqu'à l'arrivée du cycle 46. Elles ne peuvent donc être entièrement comparées aux prévisions AROME-PI qui les utilisent comme ébauches. D'après la Figure 4.1, il s'agit des réseaux de 0100, 1300, 1400, 1800, 1900, 2000 et 2100 UTC. Pour garantir l'homogénéité de la base de données, ces réseaux sont exclus de l'évaluation dans la section 4.4.

4.2.4 Intérêts d'une approche objet

La méthode « objet » est de plus en plus utilisée pour évaluer les capacités d'un modèle numérique à représenter un phénomène météorologique. Selon l'approche traditionnelle, le phénomène est décrit indirectement par les variables du modèle qui le caractérisent et dont on calcule, point de grille par point de grille, la différence avec des mesures ponctuelles ou des observations spatialisées. À l'inverse, comparer les phénomènes prévus et observés par leurs contours permet d'imiter une évaluation humaine (Davis *et al.*, 2009). L'approche objet a trois autres avantages (Duda et Turner, 2023) : (1) réduire la quantité d'informations à traiter, ici de quelques milliards de points de grille à quelques milliers d'objets ; (2) éviter la double peine, quand de légers décalages de prévision engendrent à la fois des non-détections et des fausses alarmes ; (3) évaluer les performances du modèle en fonction des attributs de l'objet comme sa taille ou son âge.

L'évaluation « objet » peut être statistique ou spatio-temporelle. L'évaluation statistique consiste à comparer les distributions d'attributs, comme ce fut le cas dans la section 3.6 entre les MCSs observés et simulés. Dans l'évaluation spatio-temporelle, on vérifie qu'un objet prévu est détecté à l'endroit et à la date de chaque objet observé. C'est de cette approche dont il

est ici question.

L'évaluation « objet » a été popularisée par [Davis et al. \(2006a,b\)](#) pour les systèmes de précipitations prévus par le modèle américain WRF. [Davis et al. \(2009\)](#) ont ensuite formalisé cette approche sous le nom *MODE*, pour *Method for Object-based Diagnostic Evaluation*. Dans la méthode *MODE*, tous les objets observés et prévus valides à une même date sont appariés. La pertinence de chaque appariement est quantifiée par une grandeur scalaire appelée *intérêt total*. Elle repose sur la somme pondérée de plusieurs paramètres comparatifs dont le choix revient à l'utilisateur, typiquement : le taux de recouvrement entre les objets appariés, la distance entre leur centre de gravité, la différence entre certains attributs, etc. Des *fonctions d'intérêt*, souvent basées sur de la logique floue, ramènent les paramètres comparatifs entre 0 et 1, si bien que l'*intérêt total* peut s'interpréter comme une probabilité d'appariement. Les *intérêts totaux* de toutes les paires d'objets permettent de calculer des scores « objet » adaptés, décrits dans [Davis et al. \(2009\)](#), ou bien les scores classiques dérivés des tables de contingence (p. ex. [Skinner et al. 2018](#); [Guerra et al. 2022](#)) en définissant un seuil d'intérêt minimal pour valider les appariements et dénombrer les vrais positifs (objets prévus et observés appariés), faux négatifs (objets observés sans objet prévu apparié) et faux positifs (objets prévus sans objet observé apparié). La méthode *MODE* a été reprise par de nombreux auteurs pour l'évaluation des précipitations et des systèmes convectifs, par exemple [Duda et Turner \(2021, 2023\)](#) sur le modèle HRRR, [Skinner et al. \(2018\)](#) et [Guerra et al. \(2022\)](#) sur des prototypes *Warn-on-Forecast* aux États-Unis, [Raynaud et al. \(2019\)](#) sur les modèles AROME et PE-AROME.

4.2.5 Appariement des MCSs observés et prévus




FIGURE 4.2 – Calcul de l'aire de recouvrement A_r hachurée entre un MCS observé et un MCS prévu.

Dans cette étude, l'appariement est basé uniquement sur le taux de recouvrement des MCSs observés et prévus. Cette simplification de la méthode *MODE* réduit le nombre de paramètres comparatifs à ajuster. Elle est aussi pertinente pour des objets de grande taille

comme les MCSs, moins sensibles à la double peine que les petits objets. Une légère tolérance spatiale est néanmoins appliquée en dilatant les objets de 10 km, valeur configurée sur des études de cas. Ainsi, des objets disjoints mais distants de moins de 20 km peuvent être appariés.

Pour chaque paire de MCSs observé/prévu, l'*intérêt total* est donc un taux de recouvrement r défini comme suit :

$$r = \frac{2A_r}{A_{obs} + A_{prév}}$$

où A_{obs} désigne l'aire du MCS observé, $A_{prév}$ l'aire du MCS prévu et A_r l'aire de l'intersection des deux MCSs dilatés, ainsi que le montre la Figure 4.2. En définissant A_{obs} et $A_{prév}$ par l'aire des objets initiaux, et non l'aire des objets dilatés, on s'assure que la tolérance spatiale ne pénalise pas l'appariement par une augmentation du dénominateur. Pinto *et al.* (2015) ont recours à une stratégie similaire pour l'évaluation des MCSs dans le modèle HRRR.

Un appariement est validé si le taux de recouvrement est supérieur à un certain seuil r_{min} dont plusieurs valeurs seront testées dans les prochaines sections. Si un MCS observé est apparié avec plusieurs objets prévus, on garde celui dont le taux de recouvrement est maximal. Le nombre N_{VP} d'objets observés appariés (vrais positifs) et le nombre N_{FN} d'objets observés non appariés (faux négatifs) permettent de définir un taux de bonnes détections (POD) égal à $\frac{N_{VP}}{N_{VP}+N_{FN}}$. À la différence des objets observés, aucun filtre n'est appliqué à la taille des objets prévus pour ne pas exclure des candidats potentiels, même inférieurs à 100 km.

Les MCSs prévus à tort ne sont pas considérés, et ce pour deux raisons. D'abord, on veut caractériser les scores en fonction des attributs des MCSs observés (comme dans Guerra *et al.* 2022). Ensuite, les prévisions à 6 h sont trop courtes pour embrasser le cycle de vie des objets prévus. Il est donc impossible de définir des durées ou des tailles maximales qui permettraient d'éliminer les trajectoires non-MCS, comme cela est fait pour les observations. Les fausses détections du U-Net, encore nombreuses d'après la section 2.4, dégraderaient donc le taux de fausses alarmes.

Aucune tolérance temporelle n'est considérée dans le calcul des appariements, à la différence de certains auteurs (p. ex. Skinner *et al.* 2018) qui pondèrent l'*intérêt total* selon la différence entre les heures de validité des objets. La raison est surtout technique : la tolérance temporelle ne pourrait dépasser 15 à 30 min car les prévisions évaluées concernent la très courte échéance, pour laquelle une certaine précision est exigée (Sun *et al.*, 2014). Or les données AROME-PROD ne sont disponibles qu'aux échéances horaires. On ne peut donc pas leur appliquer de tolérance temporelle. Par souci de cohérence entre les données manipulées, on ne l'applique pas non plus aux MCSs extrapolés ou prévus par AROME-PI.

4.3 Apport d'AROME-PI sur l'extrapolation

4.3.1 Panorama des scores

Le POD de l'extrapolation et d'AROME-PI est affiché sur la Figure 4.3 en fonction de l'échéance et du seuil d'appariement r_{min} . Pour une comparaison équitable des deux méthodes, on exclut les réseaux AROME-PI qui ne peuvent être comparés à une extrapolation sur les mêmes échéances, c'est-à-dire les réseaux pour lesquels le MCS observé n'existe pas encore à l'heure d'analyse. De plus, l'échéance AROME-PI 15 min n'est pas considérée. En effet, elle n'est jamais exploitable pour l'anticipation à cause des 30 minutes nécessaires au calcul de l'analyse et des 6 heures de prévision.

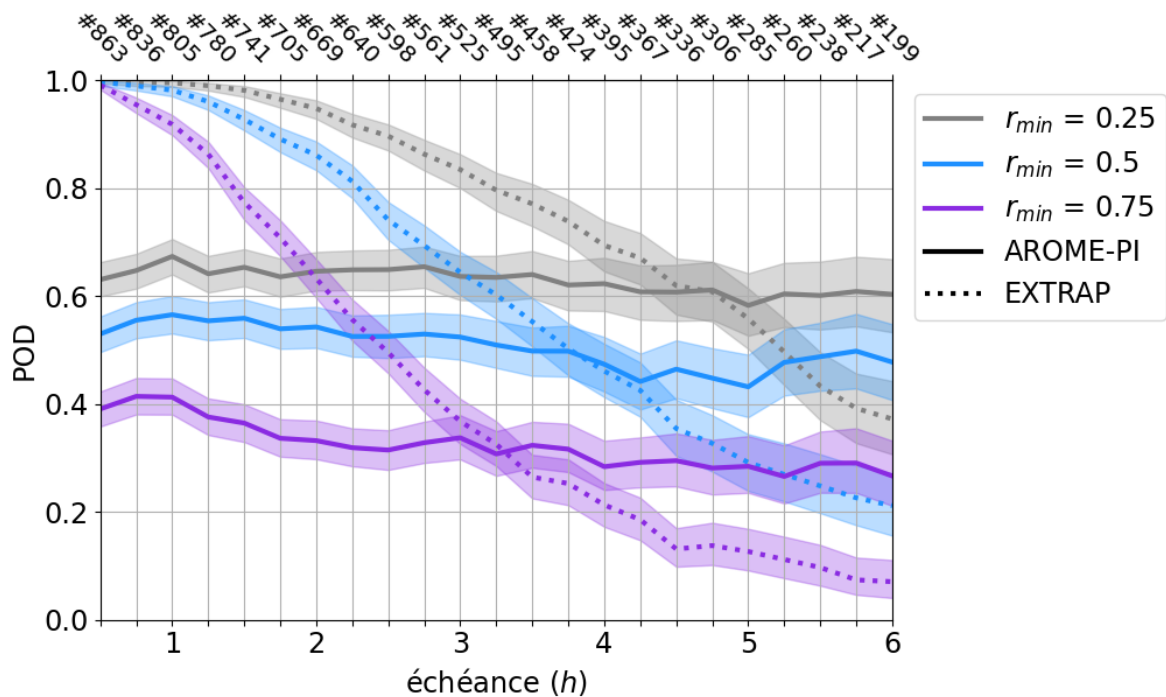


FIGURE 4.3 – POD des prévisions issues de l'extrapolation (pointillés) et d'AROME-PI (traits pleins) en fonction de l'échéance et du seuil d'appariement r_{min} . Un intervalle de confiance à 95 % est estimé par un test *bootstrap* avec 10^4 rééchantillonnages (Wilks, 1995). Seuls les MCSs observés existant à l'heure d'analyse sont considérés. Le symbole # précise le nombre de MCSs à chaque échéance.

Les performances de l'extrapolation sont supérieures ou égales à celles d'AROME-PI sur les premières échéances, jusqu'à 3 h si l'on considère un seuil r_{min} exigeant (0,75), jusqu'à 4 h avec un seuil plus tolérant (0,5) et jusqu'à 5 h pour le seuil plus souple de 0,25. Comme attendu, l'apport de l'extrapolation est particulièrement marqué sur la première heure de prévision : même au seuil de 0,75, l'extrapolation à 1 h détecte près de 90 % des MCSs observés alors qu'AROME-PI en détecte 40 %. La qualité de l'extrapolation est ici bien supérieure à celles des produits opérationnels de Météo-France qui emploient la même méthode avec des

objets seuillés à 32 dBZ dans l'image radar, comme les produits ASPOC et SRO (voir sections 1.2.1 et 1.4). Leur POD est plutôt de l'ordre de 50 % à 1 h (communication interne). Or ces produits gèrent un nombre important de petits objets, à l'échelle de la cellule convective. De part leur taille, il est plus difficile de les suivre dans les images successives et d'en estimer une vitesse fiable. De plus, l'évolution de l'objet est naturellement moins prévisible à cette échelle. Ce raisonnement est appuyé par les travaux de [Germann *et al.* \(2006\)](#) sur les précipitations convectives en Amérique du Nord. Les auteurs introduisent la notion de *durée de vie (lifetime)* qui peut s'interpréter comme l'échéance au-delà de laquelle la corrélation entre des images de Rflc observées et prévues par extrapolation lagrangienne tombe en-dessous d'un certain seuil. La durée de vie augmente avec l'échelle spatiale des précipitations. Elle est de l'ordre de 5 h pour des échelles de 100 à 300 km. Elle atteint même une dizaine d'heures entre les Rocheuses et les Grands Lacs, région fréquemment impactée par des MCSs.

Sur le Figure 4.3, la décroissance du POD selon les échéances est plus ou moins linéaire, voire exponentielle au seuil de 0,75 pour l'extrapolation. En comparaison, les scores d'AROME-PI diminuent moins fortement. La tendance est même quasiment nulle pour un seuil de 0,25. On notera la légère augmentation du POD jusqu'à 1 h d'échéance, sans doute attribuable à l'atténuation du spin-up.

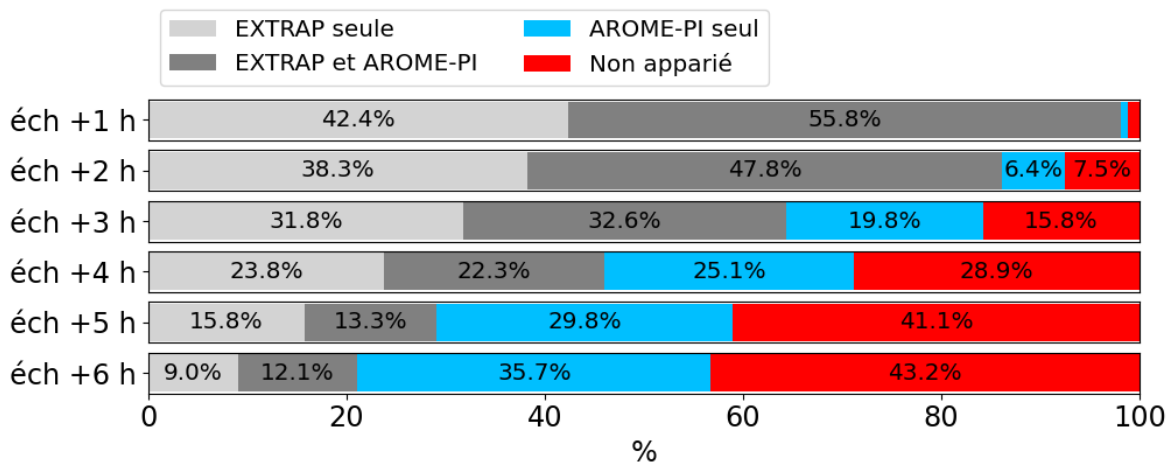


FIGURE 4.4 – Proportion d'objets observés appariés à des MCSs prévus par l'extrapolation seule (en gris clair), par AROME-PI et l'extrapolation (en gris foncé), par AROME-PI seul (en bleu) ou non appariés (en rouge), pour 6 échéances et pour $r_{min} = 0,5$.

La Figure 4.4 reflète les résultats de la Figure 4.3. L'apport d'AROME-PI sur l'extrapolation est presque nul à échéance 1 h car 98,2 % des MCSs observés sont déjà appariés à un MCS extrapolé au seuil de 0,5 (voir barres grises sur la première ligne). Cette proportion décroît au fil des échéances et n'est plus que de 21,1 % à 6 h. La proportion de MCSs non appariés augmente aussi avec le temps mais AROME-PI limite les non-détections : près de 60 % des MCSs observés sont appariés à des objets prévus à 6 h d'échéance, dont plus de la moitié à des objets simulés uniquement.

4.3.2 Sensibilité des scores au cycle de vie

La Figure 4.5 montre le comportement des prévisions sur le cycle de vie des MCSs. Au seuil r_{min} de 0,5, l'apport de l'extrapolation sur AROME-PI se vérifie jusqu'à 3 h d'échéance si le MCS analysé est en phase de développement (0 à 30 % du cycle de vie) et jusqu'à 4 ou 5 h s'il est en phase de maturité (30 à 60 %). En effet, l'extrapolation prévoit mal la croissance d'un MCS observé en phase de développement. Ses performances se dégradent donc plus rapidement. Le POD d'AROME-PI augmente également si le MCSs est mature à l'heure d'analyse car la dynamique d'un système bien développé devient certainement plus prévisible. Les performances à 2 h des deux méthodes se maintiennent entre 60 et 85 % du cycle de vie, avec un net apport de l'extrapolation sur AROME-PI. Des tendances similaires sont obtenues aux seuils r_{min} de 0,25 et de 0,75 (non montrées).

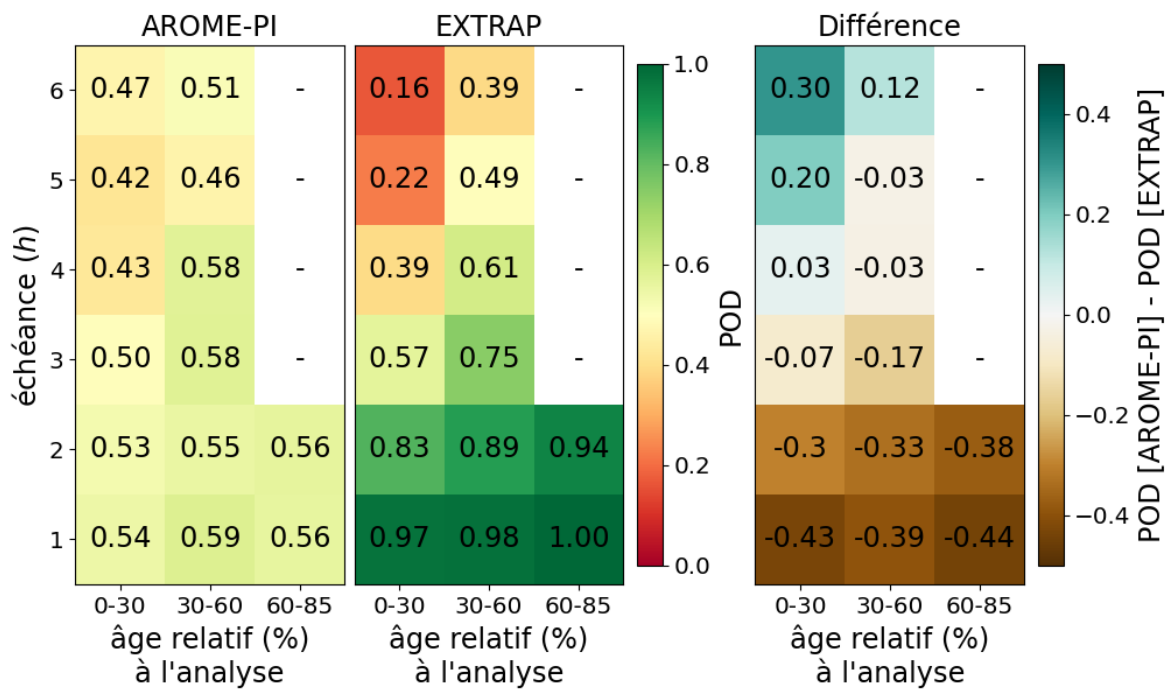


FIGURE 4.5 – POD des prévisions issues de l'extrapolation et d'AROME-PI en fonction de l'échéance et de l'âge relatif des MCSs observés à l'heure d'analyse (au seuil r_{min} de 0,5). La différence des scores entre les deux méthodes est affichée à droite. Aucun score n'est calculé pour les classes comportant moins de 30 objets (cases vides).

4.4 Apport d'AROME-PI sur AROME-PROD

4.4.1 Panorama des scores

Sur la Figure 4.6, les prévisions à 6 h d'AROME-PI sont comparées aux prévisions du réseau AROME-PROD utilisé comme ébauches, valides à la même date. La sous-figure (b) correspond aux réseaux AROME-PI pour lesquels le MCS n'est pas encore détecté à l'heure d'analyse. Comme dans [Guerra *et al.* \(2022\)](#), elle renseigne sur les performances du modèle à simuler des systèmes convectifs dont quasiment aucune observation n'a été assimilée.

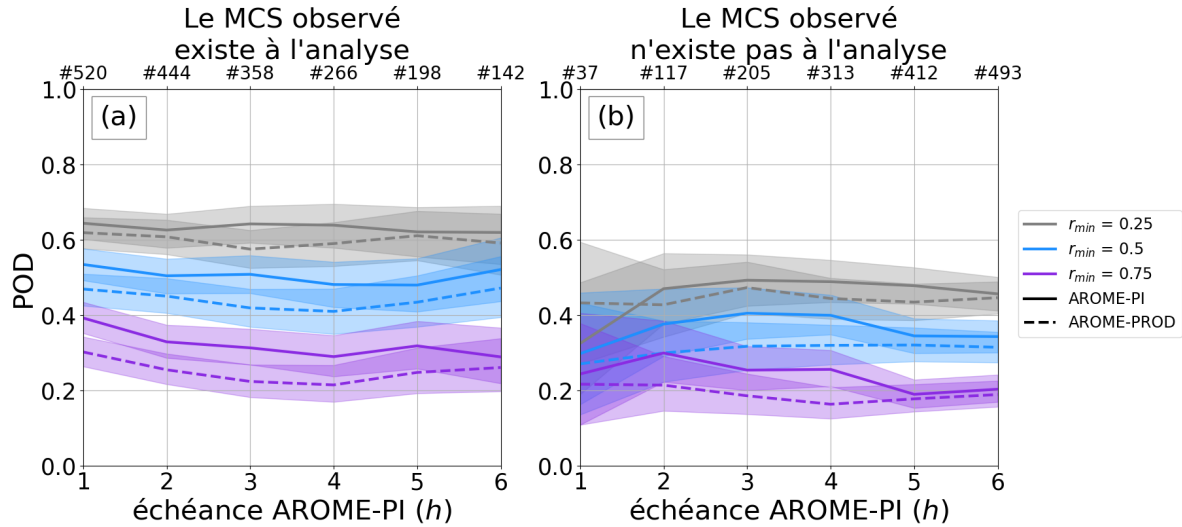


FIGURE 4.6 – POD des prévisions AROME-PI (trait plein) et AROME-PROD (tirets) en fonction de l'échéance AROME-PI et du seuil d'appariement r_{min} : (a) le MCS observé est déjà détecté dans l'analyse AROME-PI; (b) le MCS observé n'est pas encore détecté dans l'analyse AROME-PI. Un intervalle de confiance à 95 % est estimé par un test *bootstrap* avec 10^4 rééchantillonnages. Le symbole # précise le nombre de MCSs à chaque échéance. Sur la sous-figure (b), l'augmentation brutale des scores entre 1 et 2 h d'échéance est certainement un artefact lié au faible nombre de MCSs considérés à échéance 1 h.

Le POD d'AROME-PI est supérieur à celui d'AROME-PROD pour tous les seuils d'appariement testés et sur toutes les échéances, notamment entre 3 et 4 h. Cette amélioration se vérifie aussi quand le MCS n'existe pas encore à l'analyse (Figure 4.6b). L'apport d'AROME-PI sur AROME-PROD n'est donc pas restreint au suivi des MCSs mais concerne également l'initiation et le développement des systèmes. Lorsque le MCS existe déjà dans l'analyse AROME-PI, la Figure 4.7 montre que les scores et l'apport d'AROME-PI dépendent faiblement de l'âge relatif des objets analysés si ce dernier est inférieur à 60 %. Par ailleurs, l'apport d'AROME-PI demeure modeste, généralement inférieur à 0,10, avec des courbes d'incertitude qui se recouvrent partiellement sur la Figure 4.6.

La Figure 4.8 confirme ces résultats pour les appariements au seuil r_{min} de 0,5. Sur 100 MCSs observés, plus de 12 sont appariés à des MCSs détectés dans AROME-PI et non dans

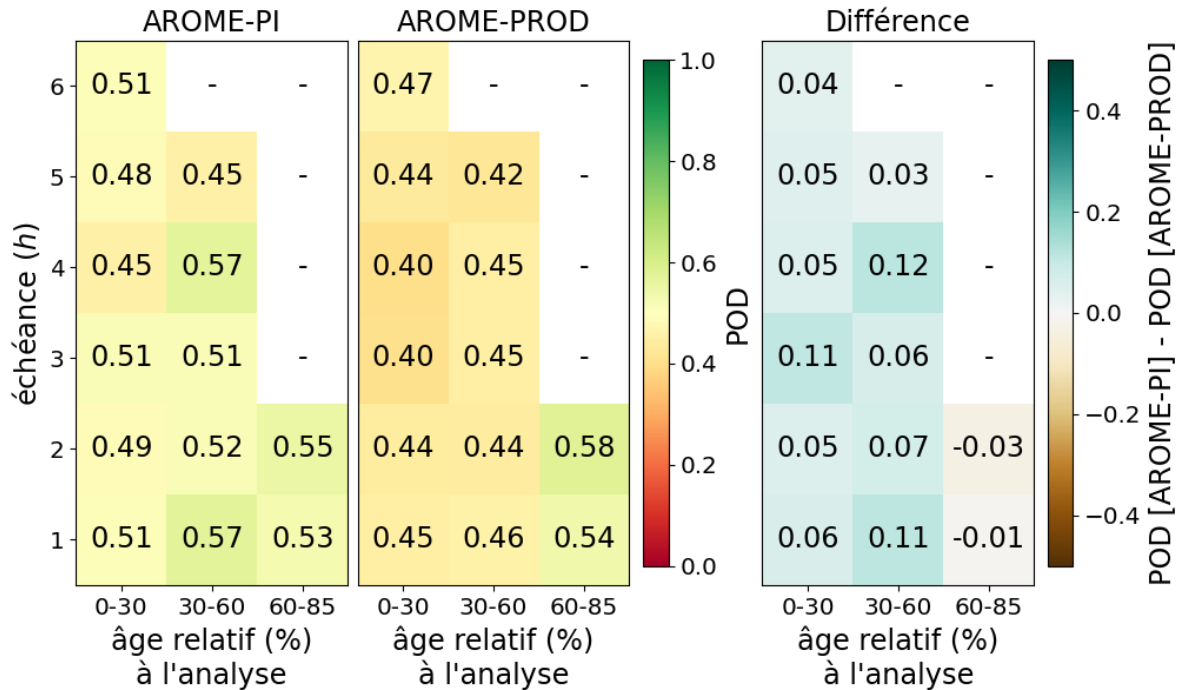


FIGURE 4.7 – Idem Figure 4.6, mais en comparant les prévisions AROME-PI et AROME-PROD. Ne sont considérées ici que les prévisions pour lesquelles le MCS observé existe déjà dans l'analyse AROME-PI.

AROME-PROD. Cette proportion est maximale aux échéances 3 et 4 h (16,2 %). Elle doit cependant être nuancée par la proportion moindre mais non négligeable d'appariements impliquant uniquement un MCS prévu par AROME-PROD (6 à 9 % pour toutes les échéances).

4.4.2 Raisonnement par trajectoire

Cette partie s'intéresse aux trajectoires pour lesquelles l'apport d'AROME-PI sur AROME-PROD est le plus important. On sélectionne d'abord les 267 réseaux AROME-PI dont les quatre premières heures d'échéance couvrent le cycle de vie d'un MCS observé. La Figure 4.9a montre le taux de recouvrement des MCSs appariés, prévus par AROME-PI à 1 h (en abscisses) et par le réseau AROME-PROD associé (en ordonnées). Une majorité de points correspondent à un apport positif d'AROME-PI sur AROME-PROD mais les valeurs en abscisses sont généralement proches des valeurs en ordonnées, avec des concentrations maximales autour de 1 et 0. Seuls 7 % des réseaux AROME-PI sélectionnés améliorent nettement les prévisions AROME-PROD (les 18 points bleus sur la Figure 4.9), avec un écart supérieur à 0,5 entre les taux de recouvrement des deux modèles. Ils concernent 16 trajectoires différentes.

La Figure 4.9b présente la distribution du même nuage de points après 4 h d'échéance. Sur les 18 réseaux AROME-PI sélectionnés, 11 conservent de bonnes performances (taux >

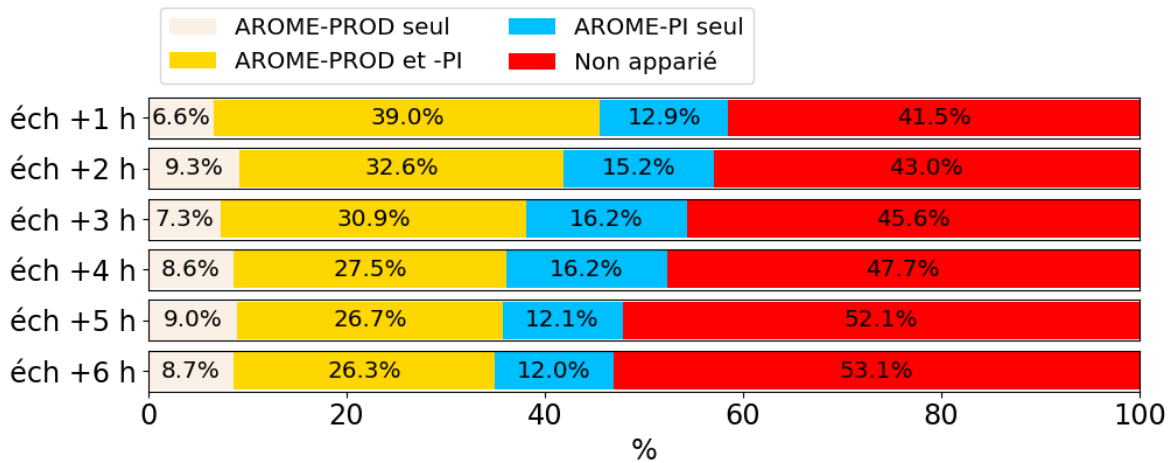


FIGURE 4.8 – Proportion d’objets observés appariés à des MCSs prévus par AROME-PROD seul (en beige), par AROME-PROD et AROME-PI (en jaune), par AROME-PI seul (en bleu) ou non appariés (en rouge), pour 6 échéances et pour $r_{min} = 0,5$.

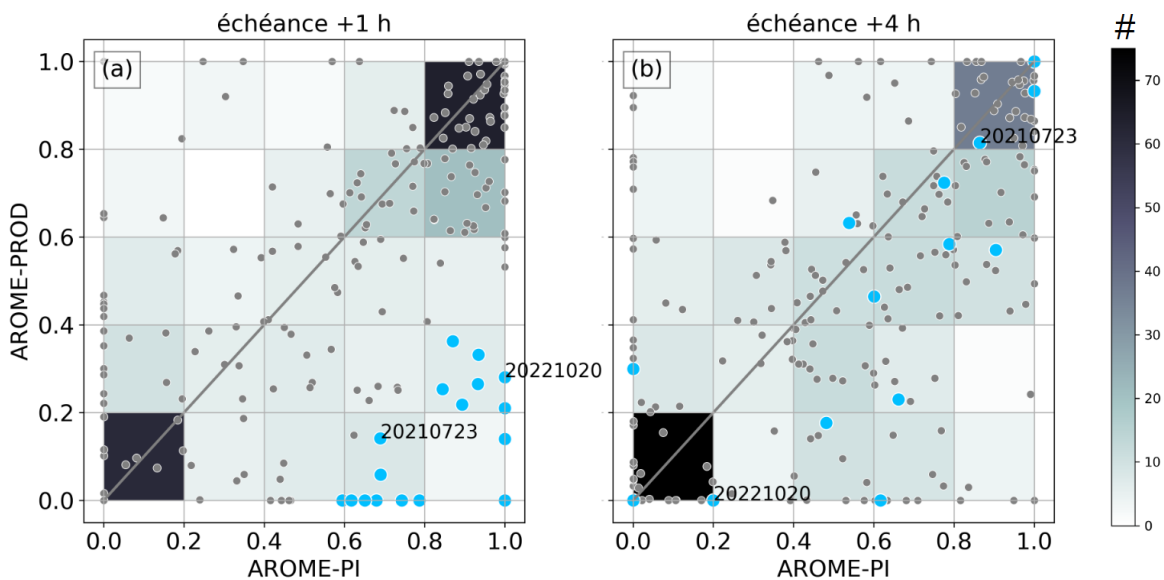


FIGURE 4.9 – Taux de recouvrement entre MCSs observés et MCSs prévus par une sélection de 267 réseaux AROME-PI (en abscisses) et leurs réseaux AROME-PROD utilisés comme ébauches (en ordonnées) sur les échéances (a) 1 h et (b) 4 h d’AROME-PI. Les points bleus représentent les réseaux AROME-PI dont le taux de recouvrement est au moins supérieur de 0,5 à celui d’AROME-PROD. Les cas étudiés dans le texte sont annotés. L’échelle de couleur indique le nombre de points dans chaque case.

0,5) comme le réseau de 2300 UTC du 23 juillet 2021 (Figure 4.10). Cette nuit-là, un MCS en amas se développe sur la Bourgogne. Grâce à l’assimilation des données radar, du moins en partie, la prévision AROME-PI à 1 h corrige l’erreur de localisation du réseau AROME-

PROD utilisé comme ébauche. AROME-PI conserve ses qualités sur les échéances suivantes et reproduit correctement l'évolution du MCS observé, tandis que la prévision AROME-PROD maintient son retard. Cependant, le groupe de supercellules au sud du MCS est mal anticipé par chacun des deux modèles.

À l'inverse, les performances se dégradent nettement pour 6 des 18 réseaux AROME-PI sélectionnés, avec un taux de recouvrement descendant en-dessous de 0,2 à 4 h d'échéance. C'est le cas du réseau de 1600 UTC sur la situation du 20 octobre 2022. Une vigilance orange concerne l'Ardèche mais pas les départements de la région Centre où un MCS produit pourtant des chutes de grêle et de fortes rafales de vent. La Figure 4.11 illustre le système linéaire mature qui se dirige vers le Grand Est. AROME-PROD modélise des systèmes convectifs mais ceux-ci sont de petite taille et situés trop à l'est. Sur sa première heure de prévision, AROME-PI semble corriger l'erreur de son ébauche, avec un MCS presque superposé sur l'objet observé. Cependant, sa prévision converge rapidement vers le scénario d'AROME-PROD. À 4 h d'échéance, le MCS simulé s'est presque totalement dissipé alors qu'il est encore bien développé dans l'observation. Si l'assimilation des données radar a permis de relocaliser les précipitations d'AROME-PROD, l'environnement convectif analysé est probablement moins instable que l'environnement réel, plus favorable au maintien d'un MCS. Cependant, si l'on compare les champs de Rflc, AROME-PI reste plus réaliste qu'AROME-PROD, notamment sur l'étendue des précipitations à la frontière allemande.

4.5 Apport des réseaux AROME-PI consécutifs

4.5.1 Le dernier réseau est-il toujours le meilleur ?

À une date de validité donnée, les prévisions de 6 réseaux AROME-PI sont disponibles à des échéances différentes : de 30 min à 1 h 15 pour le dernier réseau disponible (réseau « n°6 »), 1 h 30 à 2 h 15 pour le précédent (n°5), 2 h 30 à 3 h 15 pour le n°4, 3 h 30 à 4 h 15 pour le n°3, 4 h 30 à 5 h 15 pour le n°2, et 5 h 30 à 6 h pour le dernier réseau disponible (n°6). Le réseau n°1 profite des dernières mises à jour mais ses prévisions sont-elles pour autant les meilleures ?

D'après la Figure 4.12, 53,5 % des MCSs observés sont appariés à des systèmes prévus par le dernier réseau AROME-PI disponible (réseau « n°6 ») au seuil r_{min} de 0,5. Parmi les objets observés restants, près de la moitié sont appariés aux systèmes prévus par l'un des cinq réseaux passés. Dans 1,4 % des cas, le réseau le plus ancien (n°1) est même le seul à prévoir correctement le MCS observé. On tire des conclusions similaires aux seuils r_{min} de 0,25 et 0,75. En somme, le dernier réseau AROME-PI n'est pas forcément le meilleur. Cela est peut-être lié à l'utilisation d'un nouveau réseau AROME-PROD comme ébauche, éventuellement moins réaliste que le précédent. Pour vérifier cette hypothèse, on estime la probabilité des événements ci-dessous à partir des proportions calculées sur la base de données :

- Évènement A : le réseau n° $n - 1$ est meilleur que le réseau n° n .
- Évènement B : les réseaux n° n et $n - 1$ partent d'un réseau AROME-PROD différent.

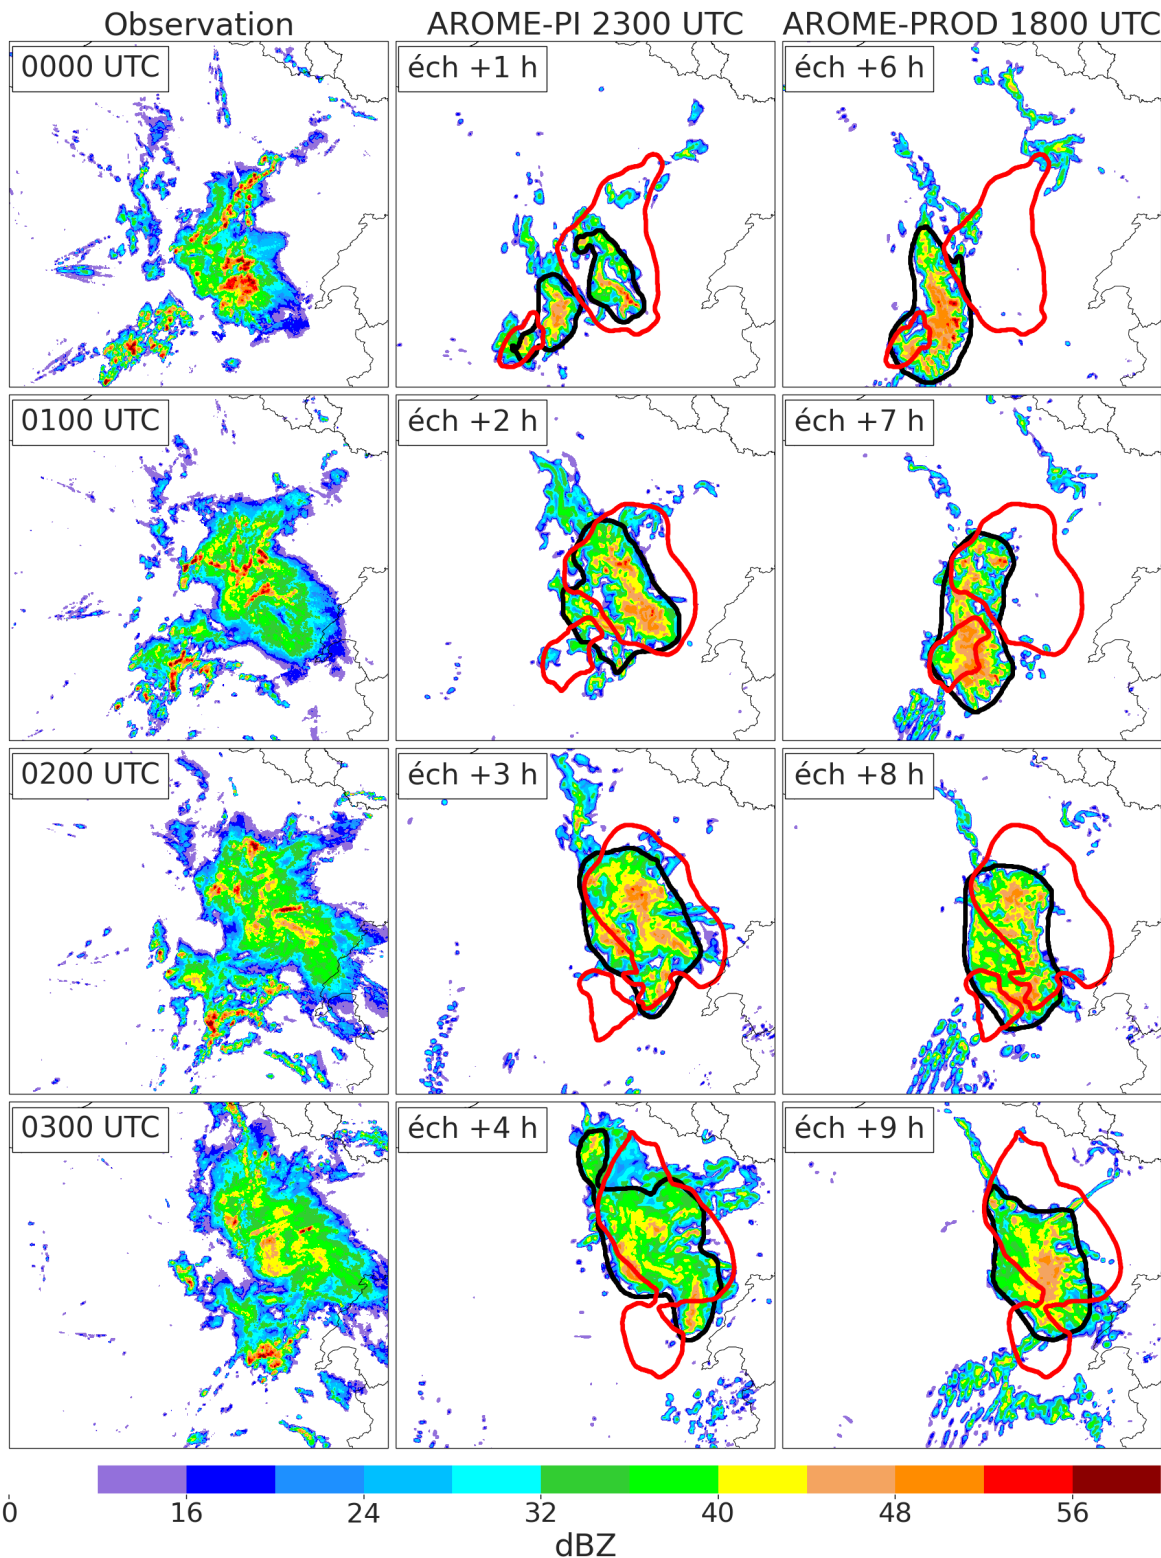


FIGURE 4.10 – Observations radar d’un MCS entre 0000 et 0300 UTC, le 24/07/2021 (à gauche) et champs de Rfc prévus par le réseau AROME-PI de la veille à 2300 UTC (au centre) et le réseau AROME-PROD utilisé comme ébauche (à droite), aux mêmes heures de validité. Sur les colonnes du centre et de droite, le contour des objets observés (en rouge) est superposé à celui des objets prévus (en noir).

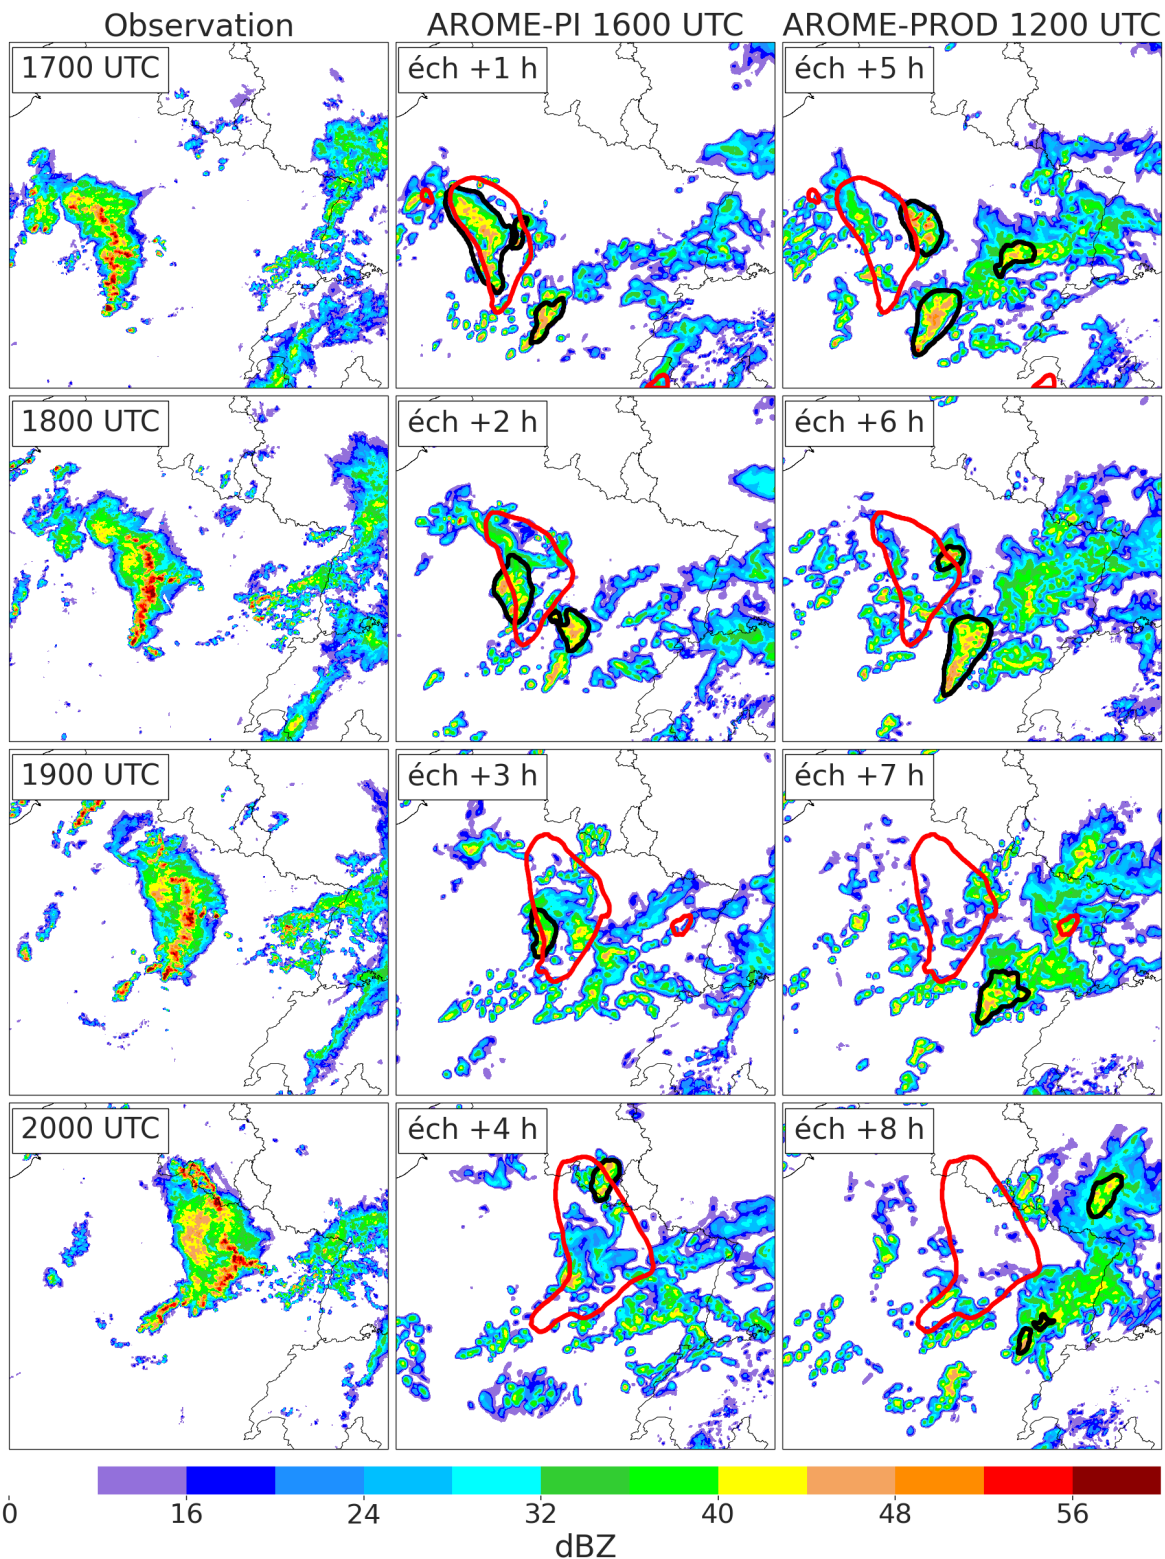


FIGURE 4.11 – Idem Figure 4.10, mais pour le MCS observé entre 1700 et 2000 UTC, le 20/10/2022, et les prévisions associées du réseau AROME-PI de 1600 UTC.




FIGURE 4.12 – Apport des réseaux AROME-PI les plus anciens sur les réseaux les plus récents. En nuances de bleu, de gauche à droite : proportion de MCSs observés appariés à un objet prévu par le dernier réseau disponible (n°6), par l'avant-dernier réseau disponible (n°5) mais pas par le dernier, par le réseau n°4 mais pas par les deux suivants, et ainsi de suite jusqu'au réseau le plus ancien (n°1). En rouge : proportion de MCSs n'étant appariés à aucun objet prévu.




FIGURE 4.13 – Apport des réseaux AROME-PI les plus récents sur les réseaux les plus anciens. En nuances de bleu, de gauche à droite : proportion de MCSs observés appariés à un objet prévu par le réseau le plus ancien (n°1), par le deuxième réseau le plus ancien (n°2) mais pas par le plus ancien, par le troisième réseau le plus ancien (n°3) mais pas par les deux précédents, et ainsi de suite jusqu'au réseau le plus récent (n°6). En rouge : proportion de MCSs n'étant appariés à aucun objet prévu.

— Évènement $A|B$: l'évènement A sachant l'évènement B .

On trouve que les probabilités des évènements A et $A|B$ sont comparables à 2 % près pour tous $n \in \llbracket 2 : 6 \rrbracket$ (non montré). L'hypothèse précédente est donc infirmée. Le fait qu'un réseau plus ancien puisse être meilleur rejoint plutôt la vision ensembliste selon laquelle une nouvelle analyse est en partie une amélioration de la précédente et en partie une perturbation de celle-ci. Cela vaut pour des analyses rapprochées (une heure dans le cas présent) mais perd en pertinence pour des analyses éloignées, où la part des nouvelles observations devient prépondérante.

Alors que la Figure 4.12 a montré l'apport des réseaux AROME-PI les plus anciens sur les plus récents, la Figure 4.13 suit le raisonnement inverse en quantifiant l'apport des réseaux les plus récents sur les plus anciens. Plus de la moitié des MCSs observés peuvent être prévus au moins trois heures à l'avance par les premiers réseaux disponibles (n°1 à 3). 35,1 % des appariements concernent même le réseau n°1. Par ailleurs, seuls 4,6 % des MCSs sont uniquement appariés à un objet prévu par le réseau le plus récent. En somme, tous les réseaux AROME-PI peuvent être utiles à l'anticipation des MCSs.

4.5.2 Conception d'une carte synthétique pour le prévisionniste

Les résultats précédents ont montré que l'utilisation des réseaux AROME-PI était pertinente pour la prévision immédiate des MCSs. Étudier chaque nouveau réseau par rapport aux plus anciens et aux réseaux AROME-PROD est néanmoins une tâche fastidieuse pour un prévisionniste en service.

Une visualisation « vignettes-confettis » est alors conçue pour faciliter l'expertise humaine des prévisions AROME-PI. Un exemple est proposé sur la Figure 4.14 pour la situation du 23 juillet 2021 introduite précédemment. La représentation s'inspire du graphique « monopoly® » imaginé par [Warren et al. \(2023\)](#) pour synthétiser l'information « objet » extraite d'un ensemble de prévisions. Elle combine la vision « confettis » (p. ex. [Mounier et al. 2022](#)), où le contour des objets détectés dans les différents membres sont superposés sur une seule carte, et la vision « vignette », appréciée des prévisionnistes pour examiner chaque membre séparément. Toutes les données de la Figure 4.14 correspondent à la même heure de validité (ici 2300 UTC). On trouve :

- les observations radar et satellite, en haut sur les deux vignettes centrales ;
- les champs de Rflc prévus par les six réseaux AROME-PI disponibles, à différentes échéances (de +1 à +6 h), à gauche et en bas, avec les MCSs qui y sont détectés en contours noirs ;
- les champs de Rflc prévus par les réseaux AROME-PROD fournissant l'ébauche des réseaux AROME-PI disponibles, à droite, avec les MCSs qui y sont détectés en contours noirs ;
- les MCSs détectés dans les six réseaux AROME-PI affichés sous forme de confettis colorés sur la carte centrale. Pour faciliter le calage des modèles par rapport à la situation réelle en cours, le contour des MCSs observés est superposé en rouge.

À chaque réseau AROME-PI est associé une couleur (bordure de la vignette) qui permet d'identifier les confettis de la carte centrale. Les réseaux AROME-PI utilisant l'ébauche d'un même réseau AROME-PROD partagent les mêmes nuances de couleur. Sur la Figure 4.14, le réseau AROME-PI de 2200 UTC est ainsi associé au réseau AROME-PROD de 1800 UTC (en vert), les réseaux de 2100, 2000, 1900 et 1800 UTC correspondent au réseau AROME-PROD de 1500 UTC (en bleu) et le réseau de 1700 UTC utilise le réseau AROME-PROD de 1200 UTC (en rouge). Pour clarifier la lecture, les MCSs détectés dans AROME-PROD ne sont pas affichés sur la carte centrale.

Sur la Figure 4.14, on voit facilement que le réseau AROME-PI le plus récent n'est pas le plus performant sur le centre de la France, peut-être à cause du décalage que l'on remarque

23/07/2021 2300 UTC

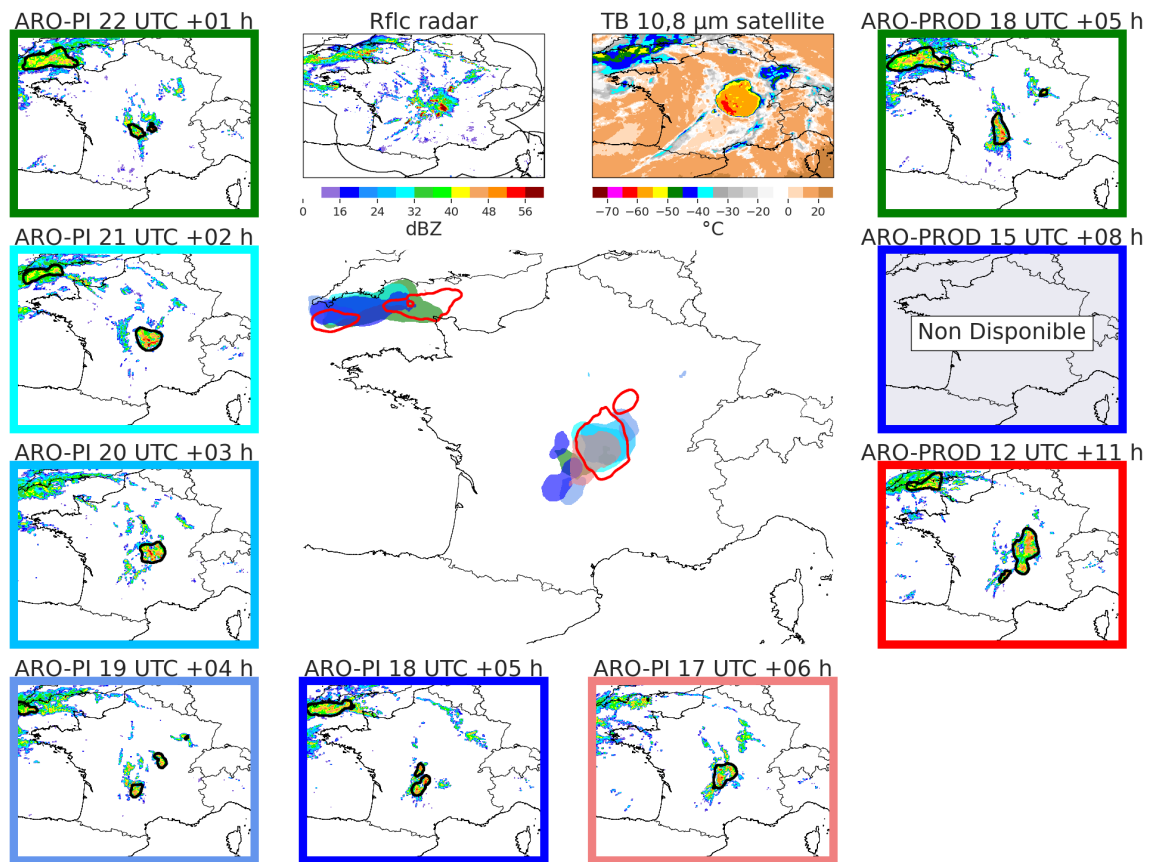


FIGURE 4.14 – Visualisation synthétique des MCSs observés et prévus par les réseaux AROM-PI et AROME-PROD, à une date de validité donnée. Les détails sont fournis dans le texte.

sur le dernier réseau AROME-PROD. Le réseau de 2100 UTC est beaucoup plus réaliste. On peut donc l'étudier plus en détail pour anticiper l'évolution du système sur les prochaines heures, en écartant les autres modèles.

4.6 Conclusions et perspectives

Les objets MCS observés en France sur les situations de vigilance entre 2018 et 2022 ont été comparés aux prévisions horaires du modèle AROME-PI. Un taux de bonnes détections a permis de quantifier la proportion d'objets bien prévus de 30 min à 6 h d'échéance. Le même score a été calculé sur une prévision par extrapolation et sur les sorties du réseau AROME utilisé comme ébauche (AROME-PROD) afin de mesurer l'apport d'AROME-PI sur les autres méthodes disponibles en opérationnel. L'objectif du chapitre était de répondre aux trois questions formulées dans la section 4.1. Les réponses apportées sont résumées puis

discutées ci-après.

Par rapport à une simple extrapolation, AROME-PI est-il utile pour prévoir les MCSs sur les prochaines heures ?

Jusqu'à près de 4 h d'échéance, l'extrapolation lagrangienne des contours est meilleure que la prévision numérique. Pour une tolérance moyenne d'appariement ($r_{min} = 0,5$), elle détecte plus de 85 % des systèmes sur les deux premières heures et près de 50 % à 4 h. Ces performances sont remarquables pour une simple extrapolation d'objets convectifs, généralement limitée à 1 h. Elle s'explique par l'échelle spatiale du phénomène, de l'ordre de 100 km, qui augmente sa prévisibilité. Dans ce chapitre, les performances de l'extrapolation doivent cependant être nuancées de trois façons :

- Sans MCS observé, aucune prévision n'est possible. L'apport de l'extrapolation sur AROME-PI est donc nul pour anticiper l'initiation des MCSs. Les performances de l'extrapolation diminuent aussi pour les MCSs en phase de développement car la méthode est incapable de retranscrire la dynamique du système.
- Le taux de fausses alarmes n'a pas été évalué mais devrait contrebalancer l'excellent POD de l'extrapolation, notamment pour les MCSs en phase de déclin.
- Seule la localisation des MCSs a été évaluée dans ce chapitre, non leur intensité. Sur ce point, AROME-PI reste plus efficace pour indiquer les tendances de l'activité convective.

L'extrapolation offre néanmoins des perspectives prometteuses pour anticiper l'évolution des MCSs à 4 h, notamment si elle est couplée à un algorithme de prévision statistique des attributs avec, en entrée, des données sur l'objet observé et son environnement (voir section 5.4).

Quelle est la plus-value d'AROME-PI sur la chaîne de production AROME ?

Les scores calculés pour des objets MCS soulignent la plus-value modeste d'AROME-PI sur le réseau AROME qui lui a servi d'ébauche, également documentée par des scores plus classiques calculés aux points de grille (voir partie 1.5.6). En moyenne, sur l'ensemble des situations étudiées, AROME-PI améliore la détection du phénomène jusqu'à 4 ou 5 h d'échéance. Les deux prévisions convergent par la suite, les effets de l'assimilation s'estompant. Cet apport concerne le suivi des MCSs déjà développés à l'heure d'analyse mais aussi l'initiation de la convection à mésoéchelle. En raisonnant par trajectoire, peu de réseaux montrent une amélioration notable des prévisions sur la première heure d'échéance. Parmi ceux-là, certains corrigent des erreurs de localisation dans les sorties AROME-PROD mais d'autres ne parviennent pas à prévoir le maintien des MCSs assimilés. La raison tient sans doute à un manque d'instabilité conditionnelle dans l'environnement analysé.

Plusieurs perspectives se présentent pour étayer et compléter les résultats obtenus :

- Si les situations les plus violentes sont couvertes par des vigilances oranges, les situations avec un enjeu moindre ne font l'objet que de vigilance jaune. Elles ne sont donc pas représentées dans le jeu de données étudié. Une évaluation menée sur une période continue donnerait ainsi une idée plus complète du potentiel d'AROME-PI.
- Pour comprendre pourquoi le modèle AROME-PI ne parvient pas à reproduire l'évolution de certains MCSs, il faudrait comparer l'environnement de l'objet prévu à celui de l'objet observé, caractérisé par des données de surface ou des réanalyses. Cette étude pourrait alors s'appuyer sur la méthode des cartes annulaires exposée dans la partie 3.4.2.
- Si l'apport d'AROME-PI sur AROME-PROD est modeste pour prévoir la localisation des MCSs, qu'en est-il de l'intensité? Pour répondre à cette question, il faudra comparer les deux modèles sur la prévision de certains attributs introduits dans la section 3.3, comme la TB minimale dans l'objet ou l'aire des Rflc supérieures à 46 dBZ.

Quelle est la pertinence d'une prévision ensembliste des MCSs à partir des réseaux AROME-PI successifs ?

Même si, pour une date de validité donnée, le dernier réseau AROME-PI disponible prévoit la majorité des MCSs observés, près de 20 % sont uniquement détectés dans les réseaux précédents. En effet, dans un environnement convectif chaotique, les erreurs d'assimilation perturbent les analyses successives. L'ensemble des réseaux est ainsi pertinent pour couvrir l'incertitude de la prévision, même à très courte échéance. Dès lors, comment valoriser l'information ensembliste d'AROME-PI ? Les objets détectés dans les réseaux successifs peuvent être convertis en masques binaires qui, additionnés et divisés par le nombre de réseaux, donnent un champ de probabilité (Raynaud *et al.*, 2019). Pour allier les lectures « objet » et probabiliste, Johnson *et al.* (2020) proposent de regrouper les objets prévus par les différents membres selon des métriques d'appariements mutuels. Pour chaque groupe n'est retenu que l'objet le plus représentatif, celui qui maximise les appariements avec les autres objets du groupe. Un attribut de probabilité est ensuite affecté à cet objet, calculé à partir du nombre de membres impliqués dans le groupe. Que le produit prenne la forme d'un champ ou d'un ensemble d'objets, la contribution de chaque membre peut aussi être pondérée par les performances récentes des réseaux. Raynaud *et al.* (2019) ont montré la plus-value de cette approche pour la PE-AROME en mesurant les performances de chaque membre avec des scores « objet ».

À ces méthodes sophistiquées s'oppose une approche beaucoup plus simple et peut-être plus adaptée aux besoins d'un prévisionniste. Celle-ci doit offrir une vision synthétique de l'ensemble des prévisions mais préserver au mieux l'information initiale rencontrée dans le modèle, afin de faciliter l'interprétation du produit. La visualisation « vignettes-confettis » décrite dans la partie 4.5.2 s'inscrit dans cette démarche. Actuellement, la visualisation permet seulement de réaliser un calage des prévisions AROME-PI avec l'observation. En collaboration avec des prévisionnistes, des travaux de développement devront être menés pour améliorer son ergonomie et son utilité. Par exemple, un affichage dynamique permettrait de cliquer sur un objet prévu de la carte centrale pour faire apparaître ses prévisions.

Enfin, la prévision ensembliste par décalage temporel des réseaux reste limitée par l'échéance

des prévisions AROME-PI. À l'instant t_0 , 5 à 6 réseaux sont disponibles jusqu'à t_0+1 h mais un seul fournit une prévision jusqu'à t_0+6 h. Allonger les échéances d'AROME-PI augmenterait le nombre de membres valides au même moment, le coût numérique, mais aussi et surtout la dispersion de l'ensemble qui pourrait devenir trop importante aux échéances de la PI. Cette sur-dispersion risquerait de diminuer les probabilités d'occurrence du phénomène et d'augmenter les fausses alarmes dans les premières échéances. Préférentiellement, plusieurs réalisations pourraient être calculées à chaque réseau grâce à des perturbations stochastiques appliquées à la physique du modèle ou aux conditions initiales. Là aussi, le coût numérique d'un tel ensemble et le temps nécessaire au post-traitement des diagnostics probabilistes peuvent s'avérer prohibitifs au vu des délais impartis en PI. De tels choix impliquent des moyens de calcul et de R&D importants. Ils ne doivent se justifier qu'au terme d'études supplémentaires basées sur de nouvelles configurations test d'AROME-PI.

Conclusions et perspectives pour la prévision immédiate des MCSs en France

Parmi les phénomènes orageux rencontrés aux moyennes latitudes, les MCSs occupent l'échelle spatio-temporelle la plus importante. Organisés en ligne, en panache ou en amas quasi-circulaire, ils peuvent s'étendre sur plusieurs centaines de kilomètres et durer une dizaine d'heures. Les MCSs sont fréquents en France métropolitaine, particulièrement de mai à octobre. Leur anticipation est nécessaire pour assurer la sécurité des personnes et des biens car les MCSs sont connus pour produire de violentes rafales de vent et des inondations. Les prévisionnistes disposent alors de deux outils principaux :

- des observations spatialisées renseignant sur l'état de l'atmosphère, notamment les précipitations détectées par les réflectivités radar (Rfc) ou l'extension verticale des nuages convectifs mesurée sous forme de température de brillance (TB) par un radiomètre embarqué dans un satellite ;
- des modèles numériques non-hydrostatiques comme AROME, développé et opéré à Météo-France, résolvant explicitement les équations d'évolution de l'atmosphère à l'échelle convective.

Plusieurs facteurs limitent toutefois la qualité des prévisions numériques : les erreurs de modélisation, liées à l'imprévisibilité intrinsèque de l'atmosphère, une connaissance imparfaite de l'état initial et des conditions aux limites du domaine. Ces erreurs croissent avec l'échéance si bien qu'une prévision réaliste des MCSs est impossible au-delà de quelques heures. L'occurrence même du phénomène peut échapper au modèle, notamment si la convection n'est pas pilotée par un forçage synoptique. La caractérisation, le suivi et l'anticipation des MCSs à quelques heures d'échéance relèvent donc souvent de la prévision immédiate. Cette stratégie mobilise les données issues de l'observation et/ou de la prévision numérique pour générer des produits fréquemment mis à jour, informant de l'état en cours ou imminent d'une situation convective.

La thèse explore plusieurs pistes d'amélioration pour la prévision immédiate des MCSs en France. Celles-ci reposent sur une approche « objet » qui consiste à étudier le phénomène à partir de son emprise spatiale, définie par les coordonnées géographiques de son contour, et par des attributs liés au système lui-même – comme sa taille, ses Rfc maximales, etc –, à sa

tendance ou à son environnement. Les problématiques de la thèse sont les suivantes :

- peut-on améliorer la détection, la caractérisation et le suivi des objets MCS en France ?
- comment la tendance observée du système et de son environnement convectif informe-t-elle sur l'évolution à venir de son intensité ?
- quelle est la pertinence de la prévision numérique AROME pour anticiper l'évolution des MCSs à 6 h d'échéance ?

Les réponses apportées à chacune de ces problématiques sont résumées dans les sections 5.1, 5.2 et 5.3 ci-dessous. Elles s'ouvrent sur des stratégies concrètes de prévision immédiate des MCSs en France, détaillées dans la dernière section 5.4.

5.1 Un réseau de neurones convolutifs pour détecter les MCSs

Pour bien identifier les MCSs et limiter les fausses détections, des auteurs ont développé des algorithmes sophistiqués basés généralement sur un seuillage des images de Rflc ou de TB. Configurer ces algorithmes de manière optimale est cependant une tâche complexe, faisant appel à des méthodes empiriques, et l'utilisation de plusieurs données d'entrée reste limitée. Dans le chapitre 2, ces deux défis sont abordés sous l'angle de l'apprentissage profond. Un réseau de neurones convolutifs est entraîné pour identifier des MCSs à partir de deux images d'entrée : les Rflc et la TB du canal infrarouge 10,8 μm . Le réseau s'appuie sur l'architecture U-Net, réputée pour ses performances en segmentation d'images. Les caractéristiques pertinentes sur les champs de Rflc et de TB sont extraites par une succession de couches de convolution et d'échantillonnage. Les filtres de convolution sont adaptés à la détection de MCS : leur nombre est plus faible afin de simplifier l'architecture originale et de limiter le surapprentissage ; leur taille augmente pour extraire de l'information à mésoéchelle. Les coefficients des filtres sont fixés statistiquement après un processus d'entraînement. Celui-ci repose sur une base de référence construite à la main, en identifiant près de 2000 MCSs sur une quarantaine de situations archivées.

Deux U-Nets sont alors développés pour répondre aux objectifs de la thèse. Le premier détecte des MCSs simulés dans les champs diagnostics de Rflc et de TB, en sortie d'AROME. Le second identifie les systèmes observés à partir de la mosaïque du réseau radar français et des images de TB issues du radiomètre SEVIRI sur le satellite MSG. Évalué sur un jeu de données indépendant, le premier U-Net présente des taux de bonnes détections et de fausses alarmes satisfaisants (0,89 et 0,40 respectivement). Ces scores sont bien supérieurs à ceux de trois autres méthodes non statistiques, inspirées de la littérature et développées en parallèle. En particulier, le U-Net limite les fausses détections au niveau des perturbations synoptiques actives et les objets identifiés présentent en moyenne des propriétés comparables à celles des MCSs de référence. On comprend davantage les performances du U-Net en examinant les filtres de la première couche. En effet, ces derniers sont sensibles aux caractéristiques connues des MCSs : fortes Rflc, faible TB et gradients périphériques de TB. Cependant, le U-Net donne plus d'importance aux images de Rflc. Les performances du second U-Net, entraîné sur des images observées, sont semblables à celles du premier. Son taux de fausses alarmes

est légèrement plus élevé mais peut être réduit en ajustant le seuil de définition des objets en sortie du U-Net, sans trop dégrader le taux de bonnes détections.

Des études de cas confirment le potentiel du U-Net pour la détection et le suivi des MCSs. Les objets détectés englobent correctement les régions convectives et stratiformes des systèmes matures. Leur contour lisse facilite l'analyse des images. Le U-Net apparaît donc utile à plusieurs applications, notamment pour étudier les MCSs en mode recherche, suivre les systèmes observés en prévision immédiate et faciliter l'analyse des prévisions AROME opérationnelles. D'ailleurs, le U-Net entraîné sur les images simulées peut être appliqué à toutes les configurations du modèle AROME : AROME-PI, bien sûr, mais aussi la prévision d'ensemble AROME pour l'anticipation du phénomène jusqu'à 51 h d'échéance.

Cependant, les trois principaux défauts du U-Net concernent (1) un taux de fausses alarmes encore trop important, (2) une tendance à définir deux MCSs proches comme un seul objet, (3) une mauvaise détection des systèmes en phase de déclin, ceux-ci étant certainement sous-représentés dans la base d'entraînement. Des solutions sont énoncées à la fin du chapitre 2 pour corriger ces défauts et améliorer les performances générales du U-Net. Les plus prometteuses reposent sur l'enrichissement de la base de référence, une pondération de certains pixels d'intérêt lors de l'entraînement, le choix d'une architecture « demi-U-Net » simplifiée pour limiter le surapprentissage.

5.2 Comprendre le cycle de vie des MCSs en France pour aiguiller des stratégies de prévision immédiate

En dehors de la zone méditerranéenne, l'évolution des MCSs a été peu étudiée sur l'Europe de l'ouest. Le chapitre 3 décrit leur cycle de vie de façon statistique, en se concentrant sur les situations de vigilance émise par Météo-France entre 2018 et 2022. Les objets MCS sont identifiés par le U-Net dans les images observées successives puis appariés temporellement par un algorithme de suivi. Plus de 150 trajectoires sont ainsi définies. Des simulations AROME de 24 h sont également lancées sur les situations sélectionnées et donnent un nombre comparable de trajectoires modélisées. Elles permettent d'analyser l'impact de l'environnement tridimensionnel sur le cycle de vie des MCSs dans un cadre de recherche.

En accord avec les climatologies existantes, la plupart des MCSs étudiés évoluent en saison chaude, entre mai et octobre, sur un axe continental orienté du sud-ouest au nord-est du pays. Ils se développent généralement dans l'après-midi et en soirée. Leur vitesse et leur aspect changent peu sur la trajectoire. En revanche, l'évolution de leur taille et de leur activité convective suit en moyenne une courbe parabolique. On peut alors partager le cycle de vie en trois phases : une phase de développement sur le premier tiers du cycle de vie, au bout duquel les extrêmes de Rfic et de TB sont atteints ; une phase de maturité sur le second tiers, quand le MCS cesse de croître ; enfin, une phase d'affaiblissement. Cette évolution est commune aux phénomènes convectifs. Elle constitue un modèle très simple pour estimer la phase future d'un MCS en fonction de la série temporelle observée de ses attributs.

Les simulations AROME reproduisent correctement le cycle de vie statistique des MCSs observés. Elles sont ainsi exploitées pour quantifier l'influence de l'environnement convectif sur le cycle de vie des objets modélisés. Deux approches ont donc été développées. La première consiste à moyenniser des champs AROME dans un rayon de 100 km autour de l'objet. On calcule alors des *variables ambiantes*, synthétisant l'environnement de mésoéchelle. La seconde approche repose sur un échantillonnage radial et angulaire des champs afin d'élaborer une visualisation originale, dite *annulaire*. Celle-ci permet de représenter l'environnement convectif sur une grille standard de $360^\circ \times 200$ km autour de l'objet, peu importe la forme et la taille de celui-ci. Des cartes composites sont finalement construites pour décrire l'environnement moyen des MCSs sur les trois phases de leur cycle de vie. Les résultats font apparaître les quatre ingrédients propices à la formation d'un MCS : (1) l'approche d'une onde barocline et d'un thalweg d'altitude, (2) un environnement dynamique et cisailé, (3) une vaste zone d'instabilité conditionnelle, (4) de la convergence en basses couches. À la différence de l'activité convective de l'objet, les variables ambiantes évoluent de façon monotone sur le cycle de vie. La CAPE affiche la tendance la plus marquée. Elle diminue continûment, notamment à l'avant du système, pilotée par le refroidissement et l'assèchement des basses couches. La décroissance de l'instabilité apparaît comme le principal élément responsable de l'affaiblissement des MCSs. On remarque aussi une diminution du vent d'altitude, notamment à 300 hPa, liée en partie à l'impact du système sur son environnement. Cet impact se traduit également par la déviation du flux autour de l'objet et par l'apparition d'un jet de mésoéchelle sur son flanc gauche. Par ailleurs, le vent de moyenne troposphère donne une bonne approximation de la vitesse de déplacement des MCSs. La plupart des résultats obtenus sont cohérents avec la littérature nord-américaine. Ils devront néanmoins être complétés par une analyse du vent relatif au déplacement de l'objet et un suivi de la plage froide sur son cycle de vie.

Les MCSs méditerranéens quasi-stationnaires ont fait l'objet d'une analyse séparée mais limitée par le faible nombre de cas sélectionnés. Or ces systèmes sont déjà largement documentés en raison de leur propension à générer des inondations destructrices. Les cartes composites sont en accord avec la littérature. Un flux de sud convergent alimente le système en air chaud et humide mais tend à s'affaiblir à la fin du cycle de vie.

Des études de cas illustrent les résultats statistiques. Elles confirment l'importance de suivre l'environnement des MCSs pour anticiper leur formation, leur maintien et leur affaiblissement. Caractériser l'instabilité ambiante est d'un intérêt premier. Des applications à la prévision immédiate sont discutées dans la section 5.4.

5.3 L'apport du modèle AROME pour la prévision immédiate des MCSs

Le chapitre 3 a confirmé la capacité d'AROME à modéliser de manière réaliste des MCSs tout au long de leur cycle de vie. Le chapitre 4 étudie sa capacité à prévoir le phénomène au bon endroit jusqu'à 6 h d'échéance. Deux configurations d'AROME sont ainsi évaluées sur les situations de vigilance introduites au chapitre précédent, entre 2018 et 2022.

- La chaîne de production AROME (AROME-PROD) fournit des prévisions jusqu'à 51 h d'échéance qui (1) sont mises à jour toutes les 3 h à partir des analyses fournies par le cycle horaire d'assimilation AROME et (2) sont disponibles au bout d'un délai qui peut atteindre 4 h par rapport au temps réel. Ce délai permet d'assimiler le plus d'observations possibles.
- AROME-PI est une mise à jour de la dernière prévision AROME-PROD par assimilation des dernières observations disponibles, principalement des données conventionnelles de surface, des réflectivités et des vitesses radiales Doppler issues des radars. AROME-PI fournit à chaque heure ronde des prévisions jusqu'à 6 h d'échéance, après 30 min de calcul environ. En contrepartie, le nombre d'observations assimilées est bien plus faible que dans la chaîne d'assimilation AROME et les réseaux ne sont pas cyclés : les ébauches d'AROME-PI proviennent des prévisions AROME-PROD.

L'évaluation se base sur une logique « objet ». Les MCSs observés sont appariés ou non avec des MCSs prévus et le nombre d'appariements permet de calculer un taux de bonnes détections.

Les prévisions à 6 h d'AROME-PI sont légèrement meilleures que les prévisions d'AROME-PROD disponibles aux mêmes dates, notamment jusqu'à 4 h d'échéance. AROME-PI améliore l'anticipation des MCSs, à la fois pour le suivi des systèmes en cours et pour l'initiation de la convection. AROME-PI peut corriger des erreurs de localisation et de temporalité mais cet apport est souvent limité si le MCS est très mal prévu par AROME-PROD. Par ailleurs, le dernier réseau AROME-PI disponible n'est pas toujours le plus performant. Dans un environnement convectif chaotique, les réseaux horaires successifs échantillonnent un état initial incertain et peuvent être vus comme les membres d'une prévision ensembliste. Une visualisation synthétique « vignettes-confettis » a donc été développée pour comparer facilement les objets MCS observés aux objets prévus et choisir le réseau le plus adapté à la situation. Ce produit sera mis à disposition des prévisionnistes prochainement.

Près de 50 % des objets observés ne sont pas prévus ou sont mal prévus par les chaînes AROME-PI et AROME-PROD. Certes, AROME-PI est l'outil le plus adapté pour anticiper l'initiation des MCSs. Cependant, lorsque le système est déjà formé, l'extrapolation linéaire des contours est en moyenne meilleure sur les quatre premières heures, une performance remarquable qui s'explique par les grandes dimensions du phénomène. Améliorer la détection des objets et considérer le taux de fausses alarmes dans le calcul des scores permettront de quantifier plus précisément l'apport d'AROME-PI sur l'extrapolation. Cette dernière apparaît toutefois comme la stratégie la plus pertinente pour estimer la tendance des MCSs sur les premières échéances, d'autant plus si elle est complétée par des données de prévision numérique. La section 5.4 propose quelques solutions.

5.4 Perspectives pour l'anticipation des MCSs à 6 h d'échéance

Les méthodes et résultats de la thèse ouvrent quatre perspectives pour anticiper les MCSs à très courte échéance via une approche « objet ». Elles sont résumées sur la Figure 5.1

et présentées ci-après. Ces perspectives sont illustrées dans le cadre de Météo-France mais peuvent aussi intéresser d'autres services météorologiques nationaux. Des échanges avec les prévisionnistes seront nécessaires pour identifier les paramètres à prévoir les plus pertinents. En attendant, cette section se concentre sur la localisation des MCSs et la caractérisation de leur activité convective.

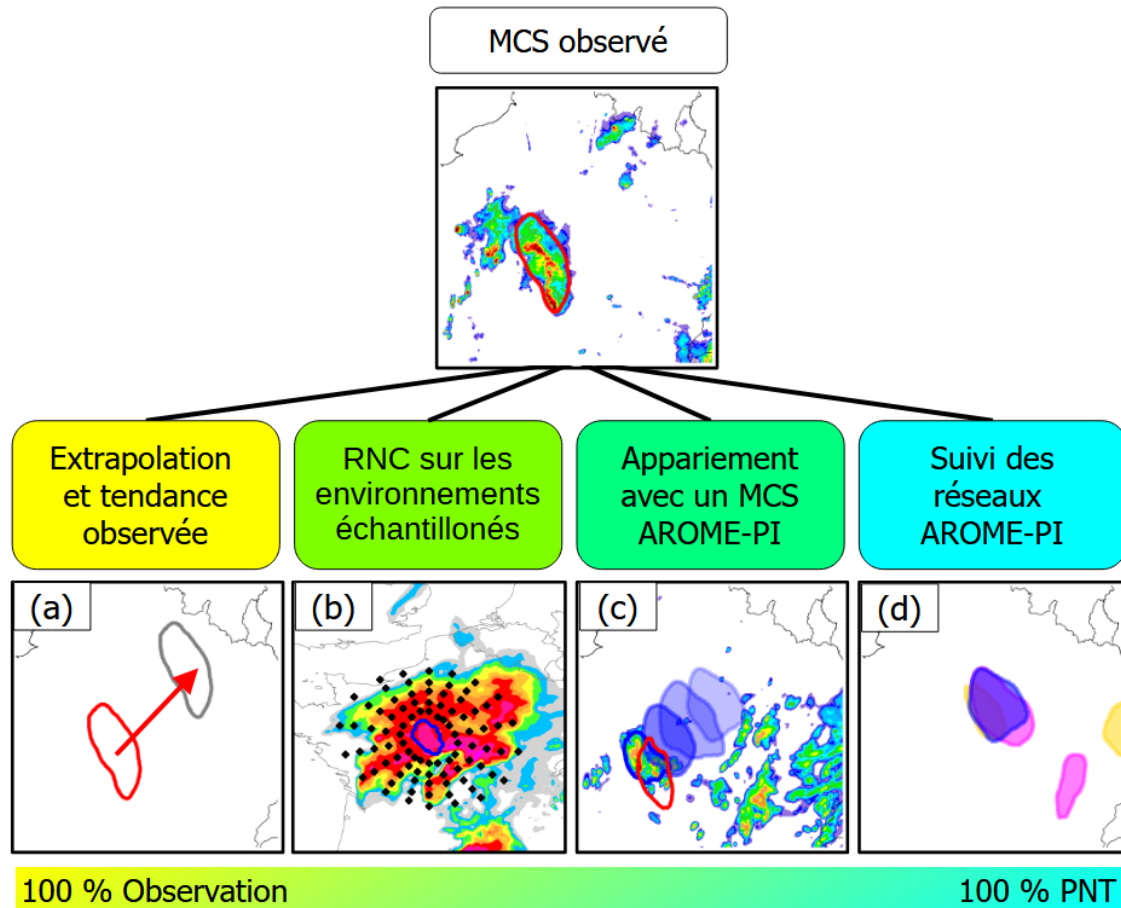


FIGURE 5.1 – Quatre méthodes pour la prévision immédiate d'un objet MCS observé (contour rouge), illustrées sur le cas du 20/10/2022, 1500 UTC. (a) Extrapolation du contour à 3 h. (b) Échantillonnage de la CAPE prévue dans l'environnement par le réseau ARPEGE de 1200 UTC. (c) Un MCS détecté dans le champ de Rfc AROME-PI valide à 1500 UTC (contour bleu), apparié à l'observation et suivi sur les 3 prochaines heures (contours bleus en transparence). (d) Objets MCS détectés par tous les réseaux AROME-PI disponibles et valides à 1800 UTC.

Méthode (a) : extrapolation et tendance observée

Extrapoler le contour à partir des vitesses observées est efficace pour prévoir la localisation d'un MCS sur les prochaines heures (Figure 5.1a). D'après le chapitre 4, plus de 60 % des




FIGURE 5.2 – Deux méthodes de prévision immédiate à 3 h de l'intensité convective pour le MCS observé le 20/10/2022, à 1500 UTC (étoile noire), la première à partir de la tendance moyenne observée entre 1400 et 1500 UTC (en gris), la seconde à partir de l'évolution du même attribut dans le MCS AROME-PI apparié (en bleu clair), débiaisée en fonction de l'intensité convective observée à 1500 UTC (en bleu foncé). L'observation est tracée en rouge, en trait plein jusqu'à 1500 UTC puis, pour vérification, en trait pointillé sur le reste du cycle de vie.

systèmes sont correctement advectés à 3 h. Cette prévision peut être complétée par une tendance de l'activité convective. La Figure 5.2 en montre la prévision à 3 h (en gris) pour le MCS du 20/10/2022 observé à 1500 UTC. Elle repose simplement sur la tendance moyenne observée dans l'heure précédente, entre 1400 et 1500 UTC. La croissance du MCS est bien reproduite mais surestimée car la tendance est calculée au tout début du cycle de vie, quand l'activité convective augmente très rapidement. Une équation d'évolution comportant une phase de croissance puis de décroissance serait plus conforme au cycle de vie moyen décrit dans le chapitre 3. Plusieurs formulations sont alors possibles :

- implémenter une **équation triangulaire** dont les pentes sont estimées à partir d'une régression linéaire sur les attributs observés, comme dans [Kolios et Feidas \(2012a\)](#). Cette formulation nécessite de connaître la durée de vie prévue t_d et l'instant de transition $\alpha.t_d$ ($\alpha \in [0, 1]$) entre les phases de croissance et de décroissance. α peut être déduit du cycle de vie statistique (comme indiqué sur la Figure 3.5) et t_d estimée à partir de la tendance de certains attributs observés au début du cycle de vie (p. ex. l'aire de l'objet dans [Kolios et Feidas 2012a](#)).
- implémenter une **équation d'évolution parabolique** pour les attributs qui atteignent leur valeur maximale vers 50 % du cycle de vie, comme la longueur, l'aire et l'extension des Rflic > 46 dBZ. [Wilhelm et al. \(2023\)](#) proposent ce type de formulation pour modéliser l'évolution temporelle de l'aire A des cellules convectives, en s'appuyant sur une

climatologie réalisée en Allemagne par [Wapler \(2021\)](#) :

$$A(t) = A_{max} - \frac{A_{max}}{\left(\frac{t_d}{2}\right)^2} \left(t - \frac{t_d}{2}\right)^2 \quad (5.1)$$

avec A_{max} l'aire maximale sur le cycle de vie. En écrivant A_{max} comme une fonction linéaire de t_d , les deux paramètres inconnus de l'équation 5.1 se réduisent à un seul ([Wilhelm et al., 2023](#)), lequel est fixé à partir des données $A_{obs}(t_{obs})$ fournies par le suivi de l'objet observé.

- **considérer l'environnement convectif** pour affiner l'équation 5.1, en paramétrant A_{max} comme une fonction linéaire de $U.t_d$, U étant une variable ambiante définie au début du cycle de vie ([Wilhelm et al., 2023](#)).

Une analyse approfondie des objets observés sera nécessaire en vue de tester la pertinence de ces méthodes pour la prévision immédiate des MCSs en France. Il s'agira notamment d'étudier les corrélations entre la durée des MCSs et (1) la croissance de certains attributs au début du cycle de vie (idée de [Kolios et Feidas 2012a](#)), (2) la valeur maximale des attributs sur le cycle de vie et (3) des variables ambiantes (idées de [Wilhelm et al. 2023](#)). Par ailleurs, la performance de ces approches essentiellement basées sur l'extrapolation linéaire des observations se limitera sans doute aux deux premières heures d'échéance.

Méthode (b) : prévision par apprentissage automatique

Plusieurs prédicteurs doivent être pris en compte pour améliorer la prévision de l'activité convective, qu'ils soient liés à l'objet ou à son environnement. En effet, d'après le chapitre 3, certains paramètres de l'environnement évoluent fortement durant le cycle de vie. Leur tendance est généralement monotone. Ils peuvent donc renseigner sur la durée du système. Par exemple, si la CAPE descend en-dessous d'un certain seuil, la probabilité que le MCS s'affaiblisse augmente.

D'après l'état de l'art réalisé au chapitre 1, un modèle statistique est une méthode efficace pour extraire l'information contenue au sein de nombreux prédicteurs. La méthode (b) propose de construire un réseau de neurones convolutifs (RNC) qui, en sortie, produirait une grandeur scalaire (par exemple, l'aire des Rfbc supérieures à 46 dBZ à 3 h ou un indice de violence à définir) et, en entrée, considérerait des données 2D sur l'environnement de l'objet observé. La méthode d'échantillonnage décrite au chapitre 3 projetterait ces données sur une carte annulaire adaptée à la morphologie et au déplacement de chaque objet, permettant de produire des images d'entrée homogènes (Figure 5.1b). L'architecture du réseau serait donc celle d'un simple encodeur, tel que représenté sur la Figure 2.1c. Pour compléter les prédicteurs spatiaux de l'environnement, des données scalaires sur les attributs de l'objet pourraient être intégrées en entrée des couches denses, comme dans [Lagerquist et al. \(2020\)](#). Une approche plus simple (p. ex. [Hamann et al. 2019](#)) reviendrait à décrire l'environnement grâce aux variables ambiantes définies au chapitre 3. Tous les prédicteurs seraient donc des scalaires et un modèle d'apprentissage automatique moins complexe pourrait être employé. Or cette solution

ne tient pas compte de la variabilité spatiale de l'environnement. Comme montré au chapitre 3, celle-ci est pourtant riche d'informations, notamment pour les phénomènes méditerranéens où le flux d'alimentation est cantonné à la région sud du système.

Une question se pose par ailleurs : quelles données utiliser pour caractériser l'environnement d'un MCS observé ? Idéalement, il faudrait des observations, notamment des mesures de surface spatialisées (par exemple avec krigeage) ou bien des produits dérivés des données radar ou satellite comme le produit iSHAI du NWC SAF (voir partie 1.3.1). Or les observations sont encore limitées par leur couverture spatiale et le nombre de paramètres disponibles. À l'inverse, les champs des dernières prévisions numériques fournissent des informations exhaustives à tous les niveaux. Mais quel modèle choisir ? À Météo-France, deux solutions existent :

- **AROME-PI** a l'avantage d'être mis à jour toutes les heures. Or les MCSs simulés modifient les champs du modèle, comme cela a été constaté au chapitre 3. L'environnement d'AROME-PI peut donc être incohérent avec le MCS observé si la prévision est décalée par rapport à la réalité. C'est notamment problématique pour le champ de CAPE. En effet, avec la résolution explicite de la convection, la CAPE est consommée dans les zones de précipitations simulées.
- Le modèle hydrostatique **ARPEGE** ne présente pas cet inconvénient. De plus, sa maille concentrée sur la France métropolitaine (environ 5 km) décrit l'environnement avec une bonne résolution. Cependant, les mises à jour sont effectuées toutes les 6 h et un délai important sépare l'heure d'analyse de l'heure de disponibilité. L'environnement prévu peut donc s'écarter davantage de l'environnement réel.

La Figure 5.3 montre l'environnement annulaire du MCS observé le 20/10/2022, caractérisé par la CAPE du dernier réseau ARPEGE disponible cet après-midi-là. On retrouve l'évolution documentée au chapitre 3. Sur la Figure 5.3f, on voit que le système se dirige vers une région moins instable qui sera certainement responsable de son affaiblissement. Dans ce cas précis, les données ARPEGE sont pertinentes pour suivre le cycle de vie du système.

Dans la littérature, les modèles hydrostatiques sont souvent employés pour décrire l'environnement des objets convectifs observés (Coniglio *et al.*, 2010; Leinonen *et al.*, 2022; Wilhelm *et al.*, 2023). Hors du cadre opérationnel, les auteurs utilisent des analyses ou des réanalyses de meilleure qualité. En prévision immédiate, il faudrait disposer d'un modèle hydrostatique à mise à jour fréquente, comme le modèle américain RUC (*Rapid Update Cycle*, Benjamin *et al.* 2004) aujourd'hui remplacé par le modèle RAP (*Rapid Refresh*, Benjamin *et al.* 2016). Ce type de modèle n'existe pas à Météo-France. Tester la méthode (b) sur des données ARPEGE et AROME-PI permettra de choisir empiriquement le modèle le plus pertinent.

Méthode (c) : appariement avec un MCS simulé par AROME-PI

La prévision numérique peut être directement exploitée si le modèle est bien calé sur l'observation. Dans la méthode (c), on cherche à appairer le MCS observé avec un objet simulé par le meilleur des derniers réseaux AROME-PI, en raisonnant par exemple sur le taux de recouvrement décrit au chapitre 4. Sur la Figure 5.1c, le MCS étudié (en rouge) est

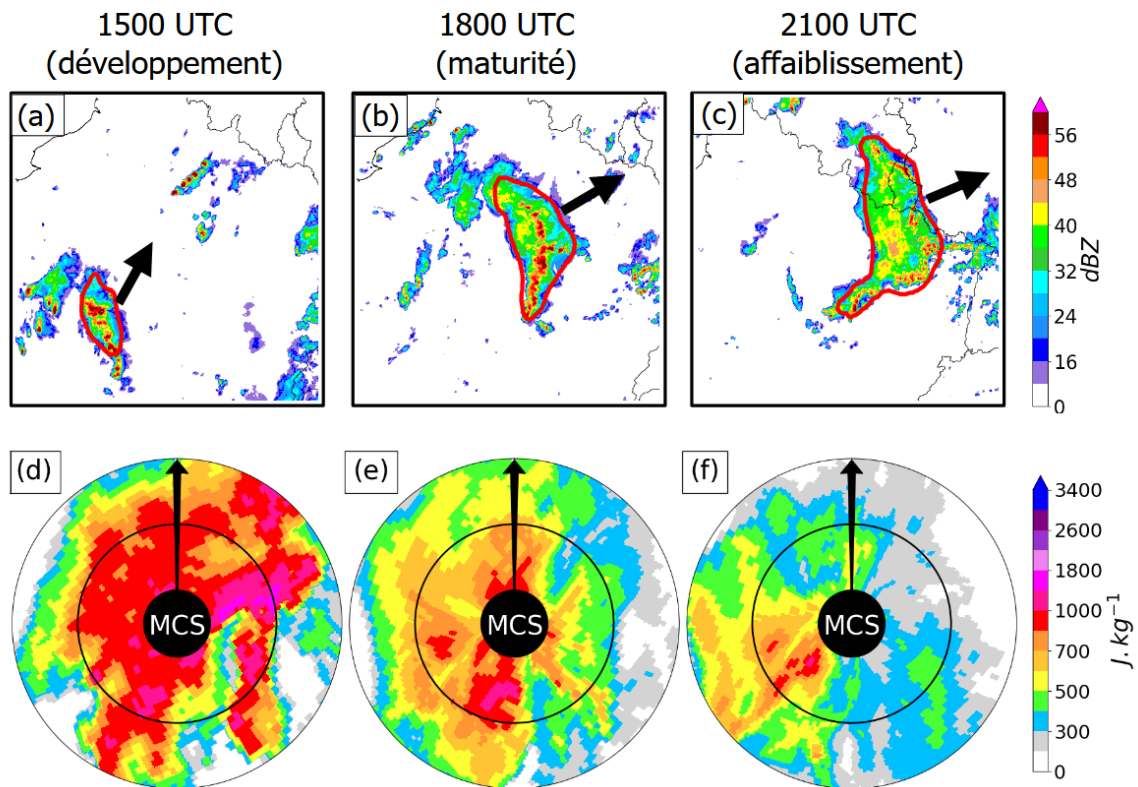


FIGURE 5.3 – Le MCS du 20/10/2022 en phase (a,d) de développement, (b,e) de maturité et (c,f) d'affaiblissement. (a-c) Rfic observées et contour de l'objet détecté (en rouge). (d-f) CAPE prévue par le réseau ARPEGE de 1200 UTC aux heures de validité affichées, projetée sur la carte annulaire orientée dans le sens de déplacement du système (flèche noire).

ainsi apparié avec un objet prévu par l'avant-dernier réseau disponible (en bleu). La tendance future de l'objet observé est alors calculée sur celle de l'objet simulé, et ce pour deux usages :

- prévoir la trajectoire (Figure 5.1c), même si l'extrapolation est souvent préférable ;
- prévoir l'activité convective grâce à la tendance de l'objet simulé, corrigée par l'écart entre l'observation et le modèle. Sur la Figure 5.2, cette tendance corrigée est meilleure que la tendance linéaire observée pour reproduire l'évolution de l'activité convective à 3 h. Cette approche reste néanmoins sensible à la qualité des réseaux AROME-PI dont certains, ce jour-là, ne parvenaient pas à simuler le maintien du MCS (voir chapitre 4).

Méthode (d) : le « 100 % numérique-ensembliste »

Pour anticiper les MCSs, l'utilisation exclusive de la prévision numérique est pertinente au-delà de 4 h d'échéance. En mode déterministe, elle repose sur le suivi d'un réseau AROME-PI sélectionné pour ses performances récentes. La visualisation synthétique développée durant la thèse permet de faciliter cette analyse. Le mode ensembliste, plus approprié à la dynamique chaotique de la convection, estime l'incertitude en étudiant les prévisions de plusieurs réseaux

(Figure 5.1d). Des perspectives ont été décrites en conclusion du chapitre 4 pour valoriser cette lecture ensembliste : pondération des membres, objets « probabilistes », etc.

La prévision immédiate « 100 % numérique-ensembliste » est encore limitée par le faible nombre de réseaux AROME-PI disponibles ainsi que les erreurs de modélisation et d'assimilation. À Météo-France, cette dernière problématique est un intense sujet de recherches dont l'objectif est principalement d'améliorer les chaînes déterministes AROME :

- En mode *Rapid Scan*, le radiomètre SEVIRI fournit des données toutes les 5 min qui seront assimilées dans la version d'AROME-PI opérationnelle fin 2024. Elles permettront une meilleure analyse de l'environnement convectif, notamment de l'humidité en moyenne troposphère (T. Montmerle, communication personnelle).
- Depuis une dizaine d'années, des travaux sont menés pour améliorer l'estimation des covariances des erreurs de l'ébauche, les coefficients de la matrice \mathbf{B} décrite dans la partie 1.5.5. Il repose sur l'assimilation variationnelle ensembliste (3DEnVar). Le lecteur pourra se référer à la revue de [Bannister \(2008\)](#) sur cette méthode ou à [Montmerle et al. \(2018\)](#) et [Michel et Brousseau \(2021\)](#) pour son implémentation dans AROME. Désormais, les covariances des erreurs de l'ébauche ne sont plus fixées « climatologiquement » mais échantillonnées à partir de perturbations d'ébauche, les écarts entre la moyenne d'un ensemble et chacune de ses 50 prévisions : celles de l'Assimilation d'Ensemble AROME (AEARO). Les erreurs d'ébauche sont donc plus réalistes car elles dépendent de la situation météorologique. Dans sa prochaine version (cycle 48), la chaîne d'assimilation AROME sera basée sur ce 3DEnVar. D'après les tests amont, la prévision du modèle est nettement améliorée. Ce changement profitera à AROME-PI par l'intermédiaire d'ébauches de meilleure qualité.
- Avec l'AEARO, des covariances peuvent être calculées pour n'importe quelle variable pronostique. Par les covariances croisées (entre différentes variables), les incréments des variables de contrôle classiques, obtenus grâce à l'assimilation des observations actuelles, se projettent sur les incréments des variables qui jusqu'alors n'étaient pas considérées. Par conséquent, celles-ci peuvent désormais être analysées, notamment les quantités spécifiques en hydrométéores. [Destouches et al. \(2023\)](#) ont montré que l'ajout des hydrométéores dans la variable de contrôle réduisait significativement le *spin-up* du modèle et améliorerait ainsi la prévision immédiate des précipitations et de la couverture nuageuse.
- Les données du radiomètre FCI et du sondeur infrarouge IRS à bord des satellites MTG permettront d'accroître la qualité des analyses. En parallèle, des études sont en cours pour assimiler des observations plus nombreuses et plus variées, par exemple des variables radar polarimétriques ([Thomas et al., 2020](#)), les données de l'imagerie d'éclairs LI à bord de MTG ([Combarnous et al., 2024](#)), les mesures opportunes de pression issues de plusieurs dizaines de milliers de capteurs grand public ([Demortier et al., 2024](#)).

Par ailleurs, des services météorologiques nationaux annoncent un changement de paradigme pour les prochaines années : les prévisions numériques seraient directement utilisées par les prévisionnistes pour alerter d'un phénomène convectif imminent. Aux États-Unis, le système *Warn-on-Forecast* est encore en phase de test ([Stensrud et al., 2009](#); [Heinselman et al., 2024](#)). Il incarne une nouvelle conception de la prévision numérique à très courte échéance : un modèle non-hydrostatique à 3 km de résolution, lancé à la demande sur un domaine variable,

adapté à la situation du jour. Le système comporte une chaîne d'assimilation ensembliste avec un réseau toutes les 15 min, des prévisions à 18 membres réalisées toutes les 30 min, jusqu'à 3 ou 6 h d'échéance, et des champs disponibles au pas de temps 5 min, éventuellement post-traités par des algorithmes d'apprentissage automatique. La masse considérable de données impose des visualisations synthétiques dont certaines sont basées sur des objets.

* * *

Pour anticiper l'évolution de la convection à très courte échéance, il faut une méthode performante, rapide, capable d'exploiter un grand nombre d'informations issues de plusieurs sources de données. La problématique est donc à la croisée des disciplines. Elle profite d'observations plus nombreuses et plus diversifiées, des progrès de la prévision numérique et de l'apprentissage profond. Des approches sophistiquées voient le jour : des prévisions ensemblistes actualisées à fréquence horaire, bientôt infra-horaire, complétées, parfois concurrencées par des réseaux de neurones. Dans le cadre opérationnel, la lecture objet, lecture du phénomène, veut faire bénéficier l'expertise humaine de ces nouvelles opportunités. Les quatre perspectives décrites plus haut s'inscrivent dans cette logique pour améliorer la prévision immédiate des MCSs à Météo-France.

Acronymes

2PIR	Prévision Immédiate des Précipitations par Imagerie Radar
AEARO	Assimilation d'Ensemble AROME
AIREP	Air Report
ALADIN	Aire Limitée Adaptation dynamique Développement InterNational
AMDAR	Aircraft Meteorological Data Relay
ARAMIS	Application radar à la météorologie infra-synoptique
AROME	Applications de la Recherche à l'Opérationnel à MÉSocéchelle
AROME-PI	AROME-Prévision Immédiate
AROME-PROD	Chaîne de production AROME
ARPEGE	Action de Recherche Petite Échelle Grande Échelle
CAPE	Convective Available Potential Energy ou Énergie Potentielle Convective Utilisable
CI	Convection Initiation
COALITION	Context and Scale Oriented Thunderstorm Satellite Predictors Development
COSMO	Consortium for Small-scale Modeling
DWD	Deutscher Wetterdienst
EUMETSAT	European Organisation for the Exploitation of Meteorological Satellites
FCI	Flexible Combined Imager
GATE	Global Atmospheric Research Program Atlantic Tropical Experiment
HRRR	High Resolution Rapid Refresh
HyMeX	HYdrological cycle in the Mediterranean EXperiment
IA	Intelligence Artificielle
IAU	Incremental Analysis Update
ICON	ICOsahedral Non-hydrostatic
IMERG	Integrated Multi-satellitE Retrievals for Global Precipitation Measurement
IRS	Infrared Sounding
iSHAI	imaging Satellite Humidity And Instability
ISIS	Instrument de Suivi dans l'Imagerie Satellitaire
KONRAD3D	KONvektive Entwicklung in RADArprodukten 3D
MCS	Système convectif de mésoéchelle
MODE	Method for Object-based Diagnostic Evaluation
MSG	Météosat Seconde Génération
MTG	Météosat Troisième Génération
PI	Prévision Immédiate
PIAF	Prévision Immédiate Agrégée Fusionnée

PE-AROME	Prévision d'Ensemble AROME
PNT	Prévision Numérique du Temps
PRE-STORM	Preliminary Regional Experiment for STORM-Central
Radar	RAdio Detection And Ranging
RAP	Rapid Refresh
RCN	Réseau de neurones convolutifs
RDT	Rapidly Developing Thunderstorm
RUC	Rapid Update Cycle
SERVAL	Système d'Élaboration des produits Radar et de Visualisation centrALisé
SEVIRI	Spinning Enhanced Visible and Infrared Imager
SRO	Suivi du Risque Orageux
TITAN	Thunderstorm Identification, Tracking, Analysis, and Nowcasting
tobac	Tracking and Object-Based Analysis of Clouds
TOGA	Tropical Ocean–Global Atmosphere Coupled Ocean–Atmosphere Response Experiment
TOOCAN	Tracking Of Organized Convection Algorithm through a 3-D segmentatioN
TRT	Thunderstorms Radar Tracking
UKV	United Kingdom Variable-resolution
UTC	temps universel coordonné
VET	variational echo tracking

Table des figures

1	À gauche : front de rafale d'un MCS en approche d'Ajaccio, le 18/08/2022 vers 0600 UTC (photo de Jérémy Gaudin). À droite : structures nuageuses observées à la même heure par le canal visible (texture) et le canal infrarouge (couleurs en transparence) du radiomètre SEVIRI, depuis le satellite MSG. Ajaccio est indiquée par le point rouge.	14
2	La thèse en un schéma : objectifs généraux (en vert) et objectifs de chaque chapitre (en bleu).	15
1.1	Phénomènes météorologiques (a) d'échelle synoptique, (b) de mésoéchelle et (c) d'échelle aérologique. Images satellite infrarouge extraites des archives Infoclimat . 19	19
1.2	Trajectoire d'une particule sur un émagramme (ligne pointillée rouge), depuis le sol jusqu'au sommet de la troposphère. Sur l'axe des ordonnées, l'altitude est donnée en km (à droite) ou en hPa (à gauche). La courbe d'état figure en noir. La surface rouge (bleue) est proportionnelle à la CAPE (CIN). Le nuage est schématisé en gris à droite de la figure, ainsi que la particule et son bilan des forces sur la verticale à trois instants de son ascendance.	22
1.3	Représentation très schématique d'une situation synoptique propice à la formation des orages en France, avec trois origines possibles de forçage.	24
1.4	Trois évolutions possibles d'une cellule convective. Le profil de vent sur les sous-figures (c) et (d) correspond au flux relatif au mouvement de la cellule. .	26
1.5	Organisation ou non de la convection à mésoéchelle. Schéma inspiré de Markowski et Richardson (2010)	27
1.6	Schéma conceptuel du MCS. Les éléments annotés sont décrits dans le texte.	29
1.7	Bestiaire des MCSs. Les contours gris, bleus et rouges symbolisent respectivement l'étendue de la couverture nuageuse, des précipitations stratiformes et des précipitations convectives. Pour certaines organisations, les flèches roses et vertes donnent une idée approximative du CABC et du flux d'altitude, tous deux relatifs au déplacement du système (flèches noires).	32

- 1.8 Exemples de MCSs observés en France : (a) SCQL parallèle-stratiforme, le 18/06/2023 ; (b) SCQL rétro-stratiforme avec écho ondulant, le 03/01/2014 ; (c) MCC en amas, le 11/07/2023 ; (d) SCQL rétro-stratiforme avec écho arqué, le 26/05/2018 ; (e) deux SCQL, le 28/08/2018 ; (f) SCQL frontal de Type 1, le 27/04/2024 ; (g) MCS quasi-stationnaire à régénération focalisée, en « V », le 19/09/2020 ; (h) SCQL parallèle-stratiforme avec écho arqué, le 18/08/2022. L'échelle de couleurs indique les précipitations convectives (réflectivités radar $\gtrsim 40$ dBZ) et stratiformes ($\lesssim 40$ dBZ). La zone blanche estime le contour du nuage (TB inférieure à -30 °C sur l'image satellite). Les flèches noires donnent le sens de déplacement du système. 36
- 1.9 Distribution spatiale des MCSs en Europe sur cinq saisons convectives (avril à septembre) de 1993 à 1997 (en nombre de MCSs observés par pixel). Les MCSs ont été détectés dans les images satellite de température de brillance du canal infrarouge. Figure extraite de [Morel et Senesi \(2002b\)](#). 37
- 1.10 La chaîne de la prévision immédiate. 39
- 1.11 Évolution schématique de la qualité de la PI en fonction de l'échéance (d'après [Germann et al. 2006](#) et [Bojinski et al. 2023](#)) avec quelques exemples de production : (a) un MCS observé sur l'image radar, (b) extrapolation du système « pixel par pixel » à 1 h par l'algorithme *2PIR* de Météo-France, (c) identification du système sous forme d'un objet que l'on extrapole à 1 h à partir de sa vitesse observée (produit SRO de Météo-France), (d) réflectivités prévues à 3 h par le modèle AROME-PI. Non montrés ici, d'autres facteurs influencent la qualité de la PI en plus de l'échéance, notamment la densité des observations et la résolution spatiale et temporelle de la prévision. 41
- 1.12 Trois observations d'un même MCS sur le sud-ouest de la France (le 27/04/2024 à 1600 UTC) et leurs instruments de mesure respectifs : (a) température de brillance du canal $10,8 \mu\text{m}$ mesurée par le radiomètre SEVIRI (en °C) et (d) satellite MSG hébergeant SEVIRI (source : *European Space Agency*) ; (b) mosaïque de réflectivités SERVAL mesurées par le réseau ARAMIS (en dBZ) et (e) radar de Toulouse protégé par son radome sphérique blanc ; (c, marqueurs colorés) position des éclairs détectés par le réseau Météorage et (g) un capteur du réseau (source : [Royet 2023](#)). Sur la sous-figure (c) sont également affichées les barbules du vent à 10 mètres mesuré par les stations de surface du réseau RADOME. 43
- 1.13 Radars du réseau français ARAMIS et de réseaux étrangers pris en compte dans la mosaïque de réflectivités SERVAL en 2023. Source : Météo-France/DSO/CMR. 45
- 1.14 (a) Coupe verticale réalisée dans le sens de déplacement d'un MCS (du sud vers le nord) à partir de la mosaïque de réflectivités 3D IRMA. (b) Le même MCS visualisé sur la mosaïque 2D IRMA, avec l'axe de la coupe en trait noir. Observation du 14/08/2024, à 0000 UTC. 46

1.15	Domaine du modèle AROME-France (à droite) et représentation schématique de sa grille (à gauche).	55
1.16	Évolution du nombre mensuel d'observations utilisées pour l'assimilation dans AROME depuis sa mise en opérationnel (à gauche) et proportion des observations utilisées en avril 2024 (à droite). Adapté de Météo-France/DirOP/COMPAS.	59
1.17	Schéma décrivant la restitution d'un profil d'humidité pseudo-observé au point <i>A</i> par combinaison des profils d'humidité d'AROME alentour (face droite des cubes), pondérés par la différence entre les réflectivités simulées et observées (face gauche des cubes). Adapté de Mahfouf <i>et al.</i> (2013).	61
1.18	Chaînes opérationnelles du modèle AROME en 2022. Schéma adapté de Thibaut Montmerle.	62
1.19	Performances des prévisions AROME-PI (traits pleins) et des prévisions AROME utilisées comme ébauches (traits pointillés) en 2022 : (a) taux de bonnes détections et (b) taux de fausses alarmes pour les cumuls horaires de précipitations supérieurs à 2 mm. La référence est la lame d'eau ANTILOPE de Météo-France (Laurantin, 2008). Scores calculés par l'équipe DirOP/COMPAS de Météo-France.	63
2.1	Vocabulaire et architectures de l' <i>apprentissage profond</i> . Les schémas ont été créés à partir du site http://alexlenail.me/NN-SVG/LeNet.html	72
2.2	Architecture du réseau de neurones convolutifs, type U-Net, élaboré pour l'identification de MCSs dans des images de Rflc et de TB simulées par AROME. Les données sont schématisées par des rectangles. Leur longueur indique la dimension des images, également précisée en bleu à droite de la figure. Leur largeur indique le nombre d'images dans chaque couche, également précisé en noir en bas des rectangles. Les zooms n°1 et 2 font référence aux figures 2.3 et 2.5 respectivement. Les couches affectées par le <i>dropout</i> sont suivies de la lettre « d » (voir section 2.3.3).	76
2.3	Zoom n°1 sur le 1 ^{er} bloc de convolution du U-Net de la figure 2.2. Les notations sont expliquées dans le texte.	77
2.4	Zoom sur l'opération de convolution appliquée aux images de la 1 ^{ère} couche par le 2 ^e filtre de la 2 ^e couche, suivie de l'opération de <i>maxpooling</i> associée.	78
2.5	Zoom n°2 sur le dernier bloc de convolution du U-Net de la figure 2.2, la production des images de sortie et la comparaison aux masques de référence. Les notations sont expliquées dans le texte.	80
2.6	Nombre de paramètres entraînaables pour chaque couche de convolution du U-Net étudié.	81

2.7	Principe de la mise à jour d'un paramètre θ_n du réseau de neurones par l'algorithme de <i>descente du gradient</i> (schéma adapté de Goodfellow et al. 2016).	82
2.8	Domaine des images d'entraînement centrées sur la France. Pour le U-Net dédié aux données simulées, le domaine (en bleu foncé) est au cœur de la grille de calcul du modèle AROME (limites en bleu clair). Pour le U-Net dédié aux données observées, le domaine (en rouge foncé) est limité par la portée maximale du réseau radar ARAMIS (en rouge clair).	85
2.9	Disposition type de l'écran de travail pour l'annotation d'objets MCS à partir du logiciel <i>Synopsis</i> . Le champ de Rflc est affiché à droite, celui de TB à gauche. Le cadre bleu indique les limites du domaine d'entraînement. Les polygones rouges (identiques à gauche et à droite) représentent les contours de MCSs tracés à la main.	87
2.10	Visualisation sous forme de boîtes à moustaches (a,c) et d'histogrammes de densité (b,d) des distributions de Rflc simulées dans les bases d'entraînement (en bleu), de validation (en gris) et de test (en orange) : (a,b) pour tous les pixels ; (c,d) pour les pixels à l'intérieur des contours de MCS annotés. Sur les boîtes, le rond blanc indique la moyenne et les moustaches correspondent aux quantiles 0,01% et 99,9% des distributions. Les pixels sans précipitations (Rflc < 7 dBZ soit environ 0.1 mm/h) ont été écartés.	89
2.11	Idem Figure 2.10, mais pour les valeurs de TB. Ici, les pixels sans précipitations ont été pris en compte.	90
2.12	Champs récepteurs (carrés colorés vides) associés à des pixels (carrés colorés pleins) des quatre premières couches d'un U-Net aux filtres 5×5 . Du plus petit au plus grand, les champs récepteurs sur l'image d'entrée correspondent au pixel coloré de la 1 ^{ère} couche de convolution (5×5 pixels), de la 2 ^e (9×9), de la 1 ^{ère} couche de <i>maxpooling</i> (10×10) et de la 3 ^e couche de convolution (18×18).	91
2.13	Taille du champ récepteur à l'issue de chaque couche d'un U-Net constitué de 4 blocs et de filtres 5×5 . Les couches de convolution (Conv) sont en bleu, celles de <i>pooling</i> (Maxpool) en rose et celles de suréchantillonnage (SurÉch) en vert.	93
2.14	Diagrammes de performance synthétisant les scores obtenus par différentes configurations de U-Net évaluées sur le jeu de validation. Le score CSI apparaît en isolignes. La configuration retenue est marquée d'une étoile (POD=0.88, FAR=0.32, CSI=0.62).	97
2.15	Attributs des objets annotés (a-c) et des objets détectés par le U-Net (d-f) sur les Images du jeu de validation. Les objets bien détectés, non détectés et détectés à tort sont affichés en vert, en noir et en rose respectivement. Les attributs renseignés sont la longueur ainsi que les quantiles 1 (99) % des pixels de TB (Rflc) à l'intérieur de chaque objet. Analyse inspirée de Mounier et al. (2022)	99

2.16	Impact des images d'entrée sur la sortie du U-Net dans une zone d'intérêt centrée sur la région convective d'un MCS (carré noir) : (a) champ de probabilité pour la classe « MCS » générée en sortie du U-Net, (b) images de Rflc et (c) de TB, (d) pavage des images d'entrée en super-pixels, (e) contribution des super-pixels de Rflc et (f) de TB à la sortie moyenne dans la zone d'intérêt. Les isolignes 40 dBZ et -45°C sont ajoutées en pointillés sur les sous-figures (e) et (f) respectivement. Situation du 20/06/2021, réseau AROME-PI de 0900 UTC, échéance 270 min.	101
2.17	Idem Figure 2.16, mais pour une zone d'intérêt centrée sur la région stratiforme du MCS.	102
2.18	Quatre méthodes de segmentation des MCSs : (a) représentation schématique 1D d'un champ de Rflc et de TB avec (a1) un MCS « classique », (a2) des cellules isolées, (a3) deux MCSs adjacents, (a4) un système convectif noyé dans une perturbation synoptique ; (b) méthode <i>simple</i> ; (c) méthode <i>watershed</i> ; (d) méthodes à <i>2 rayons</i> ; (e) U-Net. Les objets détectés figurent en gris et sont numérotés. Les méthodes (b,d) se basent uniquement sur les images de Rflc, (c,e) sur celles de Rflc et de TB. Les notations sont détaillées dans le texte.	104
2.19	Performances obtenues sur le jeu de test par les quatre méthodes de détection des MCSs simulés, (a) évaluées à l'échelle du pixel et (b) évaluées en quantifiant les appariements entre objets détectés et objets de référence. La sous-figure (a) montre aussi les scores du U-Net calculés pour plusieurs niveaux de probabilité $Prob_{min}$ entre 10 et 90 %, comme indiqué à-côté du marqueur correspondant en forme d'étoile. Le score CSI apparaît en isolignes.	106
2.20	Distributions des attributs associés aux objets annotés et aux objets détectés par les quatre méthodes sur le jeu de test : (a) longueur, (b) quantile 99 % des pixels de Rflc et (c) quantile 1 % des pixels de TB à l'intérieur de chaque objet. Sur les boîtes, le rond blanc indique la moyenne et les moustaches correspondent aux quantiles 10% et 90% des distributions. Le symbole # précise le nombre d'objets dans chaque classe.	107
2.21	Objets MCS détectés (contours noirs) par chacune des quatre méthodes testées sur la situation du 12/08/2020 (réseau AROME-PI de 1200 UTC, échéance 300 min). Seuls les objets de longueur supérieure à 100 km sont considérés. La sous-figure (f) indique aussi le champ de probabilité pour la classe « MCS » généré par le U-Net. Les objets de référence, annotés à la main, sont superposés aux champs de Rflc et de TB sur les sous-figures (a) et (d).	108
2.22	Idem Figure 2.21, mais pour la situation du 03/10/2021 (réseau AROME-PI de 0200 UTC, échéance 180 min).	109
2.23	Idem Figure 2.21, mais pour la situation du 03/10/2021 (réseau AROME-PI de 1500 UTC, échéance 60 min).	109

2.24	Idem Figure 2.10, mais pour les jeux d'entraînement des images AROME (en bleu) et des images observées (en rose).	111
2.25	Idem Figure 2.11, mais pour les jeux d'entraînement des images AROME (en bleu) et des images observées (en rose).	112
2.26	Scores obtenus par le U-Net OBS sur le jeu de test des données observées, pour plusieurs seuils de probabilité testés (points) et le seuil de 60 % retenu au final (croix). Le symbole étoile rappelle les scores obtenus par le U-Net AROME sur le jeu de test des données simulées. Le score CSI apparaît en isolignes.	113
2.27	Comportement du U-Net OBS sur la situation du 12/08/2020, 1700 UTC. Les MCSs annotés figurent en contours noirs sur les observations de Rflc (a) et de TB (b). La sous-figure (c) indique le champ de probabilité pour la classe « MCS » avec les objets détectés au seuil de 60 % en contours noirs.	114
2.28	Idem Figure 2.27, mais pour la situation du 03/10/2021, 0500 UTC.	114
2.29	Idem Figure 2.27, mais pour la situation du 03/10/2021, 1600 UTC.	114
3.1	Schématisation de l'algorithme de suivi <i>OSIRIS</i> employé pour apparier deux objets aux pas de temps successifs.	123
3.2	Trajectoires complètes de MCSs identifiés dans des simulations AROME (à gauche) et des images observées (à droite) sur les journées de vigilance entre mai 2018 et décembre 2022 : (a,b) de mars à mai, (c,d) de juin à août, (e,f) de septembre à février. Les points noirs indiquent le premier MCS détecté sur chaque trajectoire. Les MCSs-MedQS sont colorés en nuances de rouge, les MCSs-Std en nuances de bleu. Les nuances aident seulement à distinguer les différentes trajectoires. Le trait pointillé délimite le domaine d'étude. Le relief supérieur à 1000 m apparaît en gris. Certaines trajectoires simulées sont coupées sur la figure mais restent comprises dans le domaine de calcul AROME.	126
3.3	Distributions des heures (a) d'initiation et (b) de fin de trajectoire pour les MCSs simulés (en violet) et observés (en vert).	127
3.4	Évolution des principaux attributs des objets MCS simulés (en violet) et observés (en vert) sur leur cycle de vie normalisé : (a) module de la vitesse, (b) déviation du vecteur vitesse par rapport à la droite passant par les centres de gravité du premier et du dernier objet détectés, (c) probabilité moyenne de la classe « MCS » générée par le U-Net, (d) rapport d'aspect de l'ellipse approchant l'objet, (e) longueur (c.-à-d. la distance entre les deux points les plus éloignés sur le contour de l'objet), (f) aire, (g) aire de la région avec des Rflc supérieures à 46 dBZ, (h) Rflc maximale, (i) TB minimale. La courbe en trait plein (pointillé) correspond à la moyenne (médiane) de la distribution. Les plages de couleurs délimitent les quantiles 10 et 90 %.	129

3.5	Distributions des âges relatifs associés aux statistiques extrêmes que certains attributs atteignent sur le cycle de vie des MCSs étudiés : la valeur maximale pour la longueur, l'aire, l'aire > 46 dBZ et les Rflc-max ; la valeur minimale pour la TB-min. Les moustaches correspondent aux quantiles 10 % et 90 % de chaque distribution et le rond blanc affiche la moyenne.	130
3.6	Environnement synoptique composite des 153 MCSs-Std en phase de développement : (a) T_{500} (en °C, couleurs), Z_{500} (en m, contours) et U_{300} (en nœuds, barbules) ; (b) $\theta'w_{900}$ (en °C, couleurs), P_{mer} (en hPa, contours) et U_{10m} (en nœuds, barbules seuillées à 2,5 nœuds).	133
3.7	Deux méthodes pour analyser l'environnement convectif de mésoéchelle des MCSs simulés (ici sur l'exemple de la CAPE). Les détails sont donnés dans le texte.	134
3.8	Proportion de l'environnement associé à des Rflc positives sur le cycle de vie des MCSs étudiés. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.	135
3.9	Tendances des variables ambiantes calculées entre les phases de développement et d'affaiblissement pour chacun des 153 MCSs standards (MCSs-Std, en bleu) et chacun des 14 MCSs méditerranéens quasi-stationnaires (MCSs-MedQS, en rouge). Les tendances sont mesurées en unité d'écart-type de chaque variable ambiante. Les hachures signalent les évolutions non significatives (p -value > 0.05) selon le test non paramétrique des rangs signés de Wilcoxon (Wilks, 1995) adapté aux données appariées (ici, une variable ambiante calculée à deux phases distinctes du cycle de vie). Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.	137
3.10	Évolution de quelques variables ambiantes sur le cycle de vie normalisé des MCSs-Std. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.	138
3.11	Cartes composites annulaires pour les variables CAPE (en J/kg, couleurs) et $\theta'w_{900}$ (en °C, contours), orientées selon le déplacement des MCSs-Std : en phases (a) de développement, (b) de maturité et (c) d'affaiblissement. L'objet MCS est symbolisé par un rond noir au centre de la carte, la flèche indiquant sa direction de déplacement fixée à 0°. Les distances radiales à l'objet sont repérées par le premier cercle (100 km) et le bord extérieur des composites (200 km). Les pointillés représentent les régions qui traduisent mal l'environnement moyen des MCSs car des Rflc positives y sont présentes sur plus de la moitié des échantillons.	139
3.12	Distributions des vents ambiants à différents niveaux durant les phases de développement (en bleu) et d'affaiblissement (en gris) des MCSs-Std. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.	140

3.13	Idem Figure 3.11, mais pour le module (en m/s, couleurs) et la direction (flèches) de la variable U_{10m} . La longueur des flèches est proportionnelle au module.	140
3.14	Idem Figure 3.13, mais (a)-(c) pour les variables U_{300} et (d)-(f) pour les variables U_{500} et Z_{500} (en m, contours). Le lecteur notera que les intervalles de valeurs diffèrent entre les deux échelles de couleurs.	141
3.15	Environnement synoptique du MCS simulé le 04/06/2022, à la date de validité de 1600 UTC (phase de développement) : (a) T_{500} (en °C, couleurs), Z_{500} (en m, contours) et U_{300} (en nœuds, barbules); (b) $\theta'w_{900}$ (en °C, couleurs), P_{mer} (en hPa, contours) et U_{10m} (en nœuds, barbules seuillées à 2,5 nœuds). La trajectoire du MCS est représentée sur la sous-figure (a), du premier objet détecté (en blanc) au dernier (en noir).	142
3.16	Évolution temporelle de divers paramètres liés au MCS simulé le 04/06/2022. (a) Attributs de l'objet : aire avec Rflc > 46 dBZ (rose), Rflc-max (vert), TB-min (noir). (b) Variables thermodynamiques ambiantes : CAPE (rose) et $\theta'w_{900}$ (vert). (c) Variables dynamiques ambiantes : U_{10m} (rose), U_{500} (vert) et U_{300} (noir). La longueur de l'objet est renseignée en trait pointillé.	143
3.17	Champs AROME correspondant aux phases de développement (à gauche), de maturité (au centre) et d'affaiblissement (à droite) du MCS simulé le 04/06/2022. (a)-(c) Rflc (en dBZ, couleurs) et TB (contours noirs à -50°C); (d)-(f) CAPE (en J/kg, couleurs) et $\theta'w_{900}$ (contours noirs à 20°C); (g)-(i) pression réduite au niveau de la mer (en hPa, couleurs) et U_{10m} (en nœuds); (j)-(l) U_{500} (couleurs en m/s et barbules en nœuds) et Z_{500} (en m, contours noirs); (m)-(o) U_{300} (couleurs en m/s et barbules en nœuds). Les cercles bleus indiquent, de l'intérieur vers l'extérieur, le contour de l'objet, la zone ambiante de largeur 100 km et la zone ambiante de largeur 200 km.	145
3.18	Corrélations (en %) entre les tendances de chaque variable ambiante normalisée sur le cycle de vie. Un coefficient de 1 (-1) correspond à une corrélation (anti-corrélation) parfaite, un coefficient de 0 indique une absence de corrélation. Les valeurs en % sont précisées pour les coefficients supérieurs (inférieurs) à 0,30 (-0,30).	146
3.19	Idem Figure 3.11, mais pour la composante verticale du tourbillon relatif à 300 hPa (en $10^{-5}s^{-1}$).	148
3.20	Distributions des écarts de modules entre le vent ambiant à différents niveaux et la vitesse des MCSs-Std, de 10 à 80 % du cycle de vie. Les propriétés des boîtes à moustaches sont décrites en légende de la Figure 3.5.	149
3.21	Idem Figure 3.11, mais pour les MCSs-MedQS. Ici, les environnements échantillonnés ne sont pas orientés dans la direction de déplacement du système (la direction de 0° indique le nord géographique).	152

3.22	Idem Figure 3.13, mais pour les MCSs-MedQS. Ici, les environnements échantillonnés et les vecteurs de vent ne sont pas orientés dans la direction de déplacement du système (la direction de 0° indique le nord géographique). . . .	153
3.23	Idem Figure 3.15, mais pour le MCS simulé le 20/11/2018, à la date de validité de 2045 UTC (phase de développement).	154
3.24	Évolution temporelle de divers paramètres liés au MCS simulé le 20/11/2018. (a) Attributs de l'objet : aire avec Rflc > 46 dBZ (rose), Rflc-max (vert), TB-min (noir). (b) Variables thermodynamiques ambiantes : CAPE (rose) et $\theta'w_{900}$ (vert). La longueur de l'objet est renseignée en trait pointillé.	154
3.25	Champs AROME correspondant aux phases de développement (à gauche), de maturité (au centre) et d'affaiblissement (à droite) du MCS simulé le 20/11/2018. (a)-(c) Rflc (en dBZ, couleurs) et TB (contours noirs à -50°C); (d)-(f) CAPE (en J/kg, couleurs) et $\theta'w_{900}$ (contours noirs à 12°C); (g)-(i) pression réduite au niveau de la mer (en hPa, couleurs) et U_{10m} (en nœuds); (j)-(l) U_{500} (couleurs en m/s et barbules en nœuds) et Z_{500} (en m, contours noirs); (m)-(o) U_{300} (couleurs en m/s et barbules en nœuds). Les cercles bleus indiquent, de l'intérieur vers l'extérieur, le contour de l'objet, la zone ambiante de largeur 100 km et la zone ambiante de largeur 200 km.	155
3.26	Environnement annulaire de largeur 200 km correspondant au MCS du 20/11/2018 en phases de développement (à gauche), de maturité (au centre) et d'affaiblissement (à droite). (a)-(c) CAPE (en J/kg, couleurs) et $\theta'w_{900}$ (contours noirs à 12°C); (d)-(f) U_{10m} , module (en m/s, couleurs) et direction (flèches). Les pointillés correspondent aux zones de Rflc positives.	156
4.1	Réseaux AROME-PROD utilisés comme ébauches pour les 24 réseaux quotidiens d'AROME-PI. Les réseaux grisés ne sont pas considérés dans la section 4.4 car certaines des échéances AROME-PROD associées ne sont pas archivées sur la période d'étude.	164
4.2	Calcul de l'aire de recouvrement A_r hachurée entre un MCS observé et un MCS prévu.	165
4.3	POD des prévisions issues de l'extrapolation (pointillés) et d'AROME-PI (traits pleins) en fonction de l'échéance et du seuil d'appariement r_{min} . Un intervalle de confiance à 95 % est estimé par un test <i>bootstrap</i> avec 10^4 rééchantillonnages (Wilks, 1995). Seuls les MCSs observés existant à l'heure d'analyse sont considérés. Le symbole # précise le nombre de MCSs à chaque échéance. . . .	167
4.4	Proportion d'objets observés appariés à des MCSs prévus par l'extrapolation seule (en gris clair), par AROME-PI et l'extrapolation (en gris foncé), par AROME-PI seul (en bleu) ou non appariés (en rouge), pour 6 échéances et pour $r_{min} = 0,5$	168

- 4.5 POD des prévisions issues de l'extrapolation et d'AROME-PI en fonction de l'échéance et de l'âge relatif des MCSs observés à l'heure d'analyse (au seuil r_{min} de 0,5). La différence des scores entre les deux méthodes est affichée à droite. Aucun score n'est calculé pour les classes comportant moins de 30 objets (cases vides). 169
- 4.6 POD des prévisions AROME-PI (trait plein) et AROME-PROD (tirets) en fonction de l'échéance AROME-PI et du seuil d'appariement r_{min} : (a) le MCS observé est déjà détecté dans l'analyse AROME-PI ; (b) le MCS observé n'est pas encore détecté dans l'analyse AROME-PI. Un intervalle de confiance à 95 % est estimé par un test *bootstrap* avec 10^4 rééchantillonnages. Le symbole # précise le nombre de MCSs à chaque échéance. Sur la sous-figure (b), l'augmentation brutale des scores entre 1 et 2 h d'échéance est certainement un artefact lié au faible nombre de MCSs considérés à échéance 1 h. 170
- 4.7 Idem Figure 4.6, mais en comparant les prévisions AROME-PI et AROME-PROD. Ne sont considérées ici que les prévisions pour lesquelles le MCS observé existe déjà dans l'analyse AROME-PI. 171
- 4.8 Proportion d'objets observés appariés à des MCSs prévus par AROME-PROD seul (en beige), par AROME-PROD et AROME-PI (en jaune), par AROME-PI seul (en bleu) ou non appariés (en rouge), pour 6 échéances et pour $r_{min} = 0,5$. 172
- 4.9 Taux de recouvrement entre MCSs observés et MCSs prévus par une sélection de 267 réseaux AROME-PI (en abscisses) et leurs réseaux AROME-PROD utilisés comme ébauches (en ordonnées) sur les échéances (a) 1 h et (b) 4 h d'AROME-PI. Les points bleus représentent les réseaux AROME-PI dont le taux de recouvrement est au moins supérieur de 0,5 à celui d'AROME-PROD. Les cas étudiés dans le texte sont annotés. L'échelle de couleur indique le nombre de points dans chaque case. 172
- 4.10 Observations radar d'un MCS entre 0000 et 0300 UTC, le 24/07/2021 (à gauche) et champs de Rflc prévus par le réseau AROME-PI de la veille à 2300 UTC (au centre) et le réseau AROME-PROD utilisé comme ébauche (à droite), aux mêmes heures de validité. Sur les colonnes du centre et de droite, le contour des objets observés (en rouge) est superposé à celui des objets prévus (en noir). 174
- 4.11 Idem Figure 4.10, mais pour le MCS observé entre 1700 et 2000 UTC, le 20/10/2022, et les prévisions associées du réseau AROME-PI de 1600 UTC. 175

4.12	Apport des réseaux AROME-PI les plus anciens sur les réseaux les plus récents. En nuances de bleu, de gauche à droite : proportion de MCSs observés appariés à un objet prévu par le dernier réseau disponible (n°6), par l'avant-dernier réseau disponible (n°5) mais pas par le dernier, par le réseau n°4 mais pas par les deux suivants, et ainsi de suite jusqu'au réseau le plus ancien (n°1). En rouge : proportion de MCSs n'étant appariés à aucun objet prévu.	176
4.13	Apport des réseaux AROME-PI les plus récents sur les réseaux les plus anciens. En nuances de bleu, de gauche à droite : proportion de MCSs observés appariés à un objet prévu par le réseau le plus ancien (n°1), par le deuxième réseau le plus ancien (n°2) mais pas par le plus ancien, par le troisième réseau le plus ancien (n°3) mais pas par les deux précédents, et ainsi de suite jusqu'au réseau le plus récent (n°6). En rouge : proportion de MCSs n'étant appariés à aucun objet prévu.	176
4.14	Visualisation synthétique des MCSs observés et prévus par les réseaux AROME-PI et AROME-PROD, à une date de validité donnée. Les détails sont fournis dans le texte.	178
5.1	Quatre méthodes pour la prévision immédiate d'un objet MCS observé (contour rouge), illustrées sur le cas du 20/10/2022, 1500 UTC. (a) Extrapolation du contour à 3 h. (b) Échantillonnage de la CAPE prévue dans l'environnement par le réseau ARPEGE de 1200 UTC. (c) Un MCS détecté dans le champ de Rflc AROME-PI valide à 1500 UTC (contour bleu), apparié à l'observation et suivi sur les 3 prochaines heures (contours bleus en transparence). (d) Objets MCS détectés par tous les réseaux AROME-PI disponibles et valides à 1800 UTC.	188
5.2	Deux méthodes de prévision immédiate à 3 h de l'intensité convective pour le MCS observé le 20/10/2022, à 1500 UTC (étoile noire), la première à partir de la tendance moyenne observée entre 1400 et 1500 UTC (en gris), la seconde à partir de l'évolution du même attribut dans le MCS AROME-PI apparié (en bleu clair), débiaisée en fonction de l'intensité convective observée à 1500 UTC (en bleu foncé). L'observation est tracée en rouge, en trait plein jusqu'à 1500 UTC puis, pour vérification, en trait pointillé sur le reste du cycle de vie.	189
5.3	Le MCS du 20/10/2022 en phase (a,d) de développement, (b,e) de maturité et (c,f) d'affaiblissement. (a-c) Rflc observées et contour de l'objet détecté (en rouge). (d-f) CAPE prévue par le réseau ARPEGE de 1200 UTC aux heures de validité affichées, projetée sur la carte annulaire orientée dans le sens de déplacement du système (flèche noire).	192

Liste des tableaux

1.1	Quelques approches « objet » développées pour l'étude des MCSs. Abréviations de la colonne Filtres éventuels : A (aire du MCS), L (longueur du MCS), D (durée de la trajectoire), $Rflc_x$ (Rflc maximales dans l'objet), TB_n (TB minimale dans l'objet).	53
1.2	Caractéristiques du modèles AROME en 2022.	56
2.1	Composition des jeux de données utilisés pour mettre au point une méthode de détection des MCSs dans les simulations AROME d'une part (section 2.3) et les observations d'autre part (section 2.5).	88
2.2	Hyperparamètres du U-Net entraîné pour détecter des MCSs dans les images simulées par AROME. Les lignes grises correspondent aux hyperparamètres testés sur le jeu de validation.	91
2.3	Table de contingence pour l'évaluation d'une méthode de détection des MCSs.	96
3.1	Abréviation et description des principales variables AROME considérées. La CAPE et la $\theta'w_{900}$ sont définies dans la partie 1.1.1.	121
3.2	Distributions saisonnières des trajectoires de MCSs simulés et observés (en nombre de trajectoires).	125
5.1	Hyperparamètres testés pour les trois méthodes non statistiques de détection des MCSs dans les images simulées par AROME. Les valeurs retenues sont écrites en gras.	211

Annexe

Méthode	Hyperparamètre	Valeurs testées
<i>simple</i>	ν	1, 5 ou 10
<i>simple</i>	$Rflc_{min}$	20, 25, 30 ou 35 dBZ
<i>simple</i>	$Rflc_h$	0, 35, 40 ou 45 dBZ
<i>watershed</i>	ν_{Rflc}	1, 5 ou 10
<i>watershed</i>	ν_{TB}	1, 5 ou 10
<i>watershed</i>	l_{min}	50 ou 100 km
<i>watershed</i>	TB_{max}	-40, -45 ou -50 °C
<i>watershed</i>	$Rflc_{min}$	20, 25, 30 ou 35 dBZ
<i>2 rayons</i>	ν_{Rflc}	1, 5 ou 10
<i>2 rayons</i>	$Rflc_{min}$	20, 25, 30 ou 35 dBZ
<i>2 rayons</i>	R_1	6, 12, 24 ou 48 km
<i>2 rayons</i>	R_2	48 , 96 ou 192 km

Hyperparamètres testés pour les trois méthodes non statistiques de détection des MCSs dans les images simulées par AROME. Les valeurs retenues sont écrites en gras.

Bibliographie

- ABADI, M., AGARWAL, A., BARHAM, P., BREVDO, E., CHEN, Z., CITRO, C., CORRADO, G. S., DAVIS, A., DEAN, J., DEVIN, M., GHEMAWAT, S., GOODFELLOW, I., HARP, A., IRVING, G., ISARD, M., JIA, Y., JOZEFOWICZ, R., KAISER, L., KUDLUR, M., LEVENBERG, J., MANE, D., MONGA, R., MOORE, S., MURRAY, D., OLAH, C., SCHUSTER, M., SHLENS, J., STEINER, B., SUTSKEVER, I., TALWAR, K., TUCKER, P., VANHOUCHE, V., VASUDEVAN, V., VIEGAS, F., VINYALS, O., WARDEN, P., WATTENBERG, M., WICKE, M., YU, Y. et ZHENG, X. (2016). TensorFlow : Large-Scale Machine Learning on Heterogeneous Distributed Systems.
- ABRAMIAN, S., MULLER, C. et RISI, C. (2022). Shear-Convection Interactions and Orientation of Tropical Squall Lines. *Geophysical Research Letters*, 49(1):e2021GL095184. e2021GL095184 2021GL095184.
- ALEXIUK, M., PIZZI, N., LI, P. C. et PEDRYCZ, W. (2000). Classification of Volumetric Storm Cell Patterns. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 4(3):206–211.
- ANDRYCHOWICZ, M., ESPEHOLT, L., LI, D., MERCHANT, S., MEROSE, A., ZYDA, F., AGRAWAL, S. et KALCHBRENNER, N. (2023). Deep Learning for Day Forecasts from Sparse Observations.
- ARBOGAST, P., PANNEKOUCKE, O., RAYNAUD, L., LALANNE, R. et MÉMIN, E. (2016). Object-oriented processing of CRM precipitation forecasts by stochastic filtering. *Quarterly Journal of the Royal Meteorological Society*, 142(700):2827–2838.
- ARNOULD, G., MONTMERLE, T., ROTTNER, L. et MOISSELIN, J.-M. (2024). An object-based method to study the life cycle of mesoscale convective systems and their environment from cloud-resolving arome-france simulations (en préparation). *Quarterly Journal of the Royal Meteorological Society*.
- AUGER, L., DUPONT, O., HAGELIN, S., BROUSSEAU, P. et BROVELLI, P. (2014). AROME–NWC : a new nowcasting tool based on an operational mesoscale forecasting system. *Quarterly Journal of the Royal Meteorological Society*, 141(690).
- AUTONÈS, F. et CLAUDON, M. (2022). User Manual for the Convection Product Processors of the NWC/GEO. Rapport technique.
- BANNISTER, R. N. (2008). A review of forecast error covariance statistics in atmospheric variational data assimilation. I : Characteristics and measurements of forecast error covariances. *Quarterly Journal of the Royal Meteorological Society*, 134(637):1951–1970.
- BAUER, P., THORPE, A. et BRUNET, G. (2015). The quiet revolution of numerical weather prediction. 525(7567):47–55.

- BECK, J. et BOUSQUET, O. (2013). Using Gap-Filling Radars in Mountainous Regions to Complement a National Radar Network : Improvements in Multiple-Doppler Wind Syntheses. *Journal of Applied Meteorology and Climatology*, 52(8):1836 – 1850.
- BEDKA, K., BRUNNER, J., DWORAK, R., FELTZ, W., OTKIN, J. et GREENWALD, T. (2010). Objective Satellite-Based Detection of Overshooting Tops Using Infrared Window Channel Brightness Temperature Gradients. *Journal of Applied Meteorology and Climatology*, 49(2): 181 – 202.
- BENJAMIN, S. G., BROWN, J. M., BRUNET, G., LYNCH, P., SAITO, K. et SCHLATTER, T. W. (2018). 100 Years of Progress in Forecasting and NWP Applications. *Meteorological Monographs*, 59:13.1 – 13.67.
- BENJAMIN, S. G., DÉVÉNYI, D., WEYGANDT, S. S., BRUNDAGE, K. J., BROWN, J. M., GRELL, G. A., KIM, D., SCHWARTZ, B. E., SMIRNOVA, T. G., SMITH, T. L. et MANIKIN, G. S. (2004). An Hourly Assimilation–Forecast Cycle : The RUC. *Monthly Weather Review*, 132(2):495 – 518.
- BENJAMIN, S. G., WEYGANDT, S. S., BROWN, J. M., HU, M., ALEXANDER, C. R., SMIRNOVA, T. G., OLSON, J. B., JAMES, E. P., DOWELL, D. C., GRELL, G. A., LIN, H., PECKHAM, S. E., SMITH, T. L., MONINGER, W. R., KENYON, J. S. et MANIKIN, G. S. (2016). A North American Hourly Assimilation and Model Forecast Cycle : The Rapid Refresh. *Monthly Weather Review*, 144(4):1669 – 1694.
- BERRE, L. (2000). Estimation of Synoptic and Mesoscale Forecast Error Covariances in a Limited-Area Model. *Monthly Weather Review*, 128(3):644 – 667.
- BERTHOMIER, L. et PERIER, L. (2023). Espresso : A Global Deep Learning Model to Estimate Precipitation from Satellite Observations. *Meteorology*, 2(4):421–444.
- BIARD, J. C. et KUNKEL, K. E. (2019). Automated detection of weather fronts using a deep learning neural network. *Advances in Statistical Climatology, Meteorology and Oceanography*, 5(2).
- BOJINSKI, S., BLAAUBOER, D., CALBET, X., de CONING, E., DEBIE, F., MONTMERLE, T., NIETOSVAARA, V., NORMAN, K., BAÑÓN PEREGRÍN, L., SCHMID, F., STRELEC MAHOVIĆ, N. et WAPLER, K. (2023). Towards nowcasting in Europe in 2030. *Meteorological Applications*, 30(4).
- BOLTON, D. (1980). The Computation of Equivalent Potential Temperature. *Monthly Weather Review*, 108(7):1046 – 1053.
- BOUSQUET, O., TABARY, P. et Parent du CHÂTELET, J. (2008). Observation opérationnelle du vent 3D dans les nuages à partir des radars du réseau Aramis. *La Météorologie*, (61):41–51.
- BOUTTIER, F., RAYNAUD, L., NUISSIER, O. et MÉNÉTRIER, B. (2016). Sensitivity of the AROME ensemble to initial and surface perturbations during HyMeX. *Quarterly Journal of the Royal Meteorological Society*, 142(S1):390–403.

- BROOKS, H. E., III, C. A. D., ZHANG, X., CHERNOKULSKY, A. M. A., TOCHIMOTO, E., HANSTRUM, B., de LIMA NASCIMENTO, E., SILLS, D. M. L., ANTONESCU, B. et BARRETT, B. (2019). A Century of Progress in Severe Convective Storm Research and Forecasting. *Meteorological Monographs*, 59:18.1 – 18.41.
- BROUSSEAU, P., BERRE, L., BOUTTIER, F. et DESROZIERS, G. (2011). Background-error covariances for a convective-scale data-assimilation system : AROME–France 3D-Var. *Quarterly Journal of the Royal Meteorological Society*, 137(655):409–422.
- BROUSSEAU, P., SEITY, Y., RICARD, D. et LÉGER, J. (2016). Improvement of the forecast of convective activity from the AROME-France system. *Quarterly Journal of the Royal Meteorological Society*, 142(699).
- BUBNOVÁ, R., HELLO, G., BÉNARD, P. et GELEYN, J.-F. (1995). Integration of the Fully Elastic Equations Cast in the Hydrostatic Pressure Terrain-Following Coordinate in the Framework of the ARPEGE/Aladin NWP System. *Monthly Weather Review*, 123(2):515 – 535.
- BÉNARD, P., VIVODA, J., MAŠEK, J., SMOLÍKOVÁ, P., YESSAD, K., SMITH, C., BROŽKOVÁ, R. et GELEYN, J.-F. (2010). Dynamical kernel of the Aladin–NH spectral limited-area model : Revised formulation and sensitivity experiments. *Quarterly Journal of the Royal Meteorological Society*, 136(646):155–169.
- CAILLAUD, C., SOMOT, S., ALIAS, A., BERNARD-BOUSSIÈRES, I., FUMIÈRE, Q., LAURANTIN, O., SEITY, Y. et DUCROCQ, V. (2021). Modelling Mediterranean heavy precipitation events at climate scale : an object-oriented evaluation of the CNRM-AROME convection-permitting regional climate model. *Climate Dynamics*, 56(5–6).
- CALAS, C. (2013). *Concepts et méthodes pour le météorologiste - Tome 1, Les savoirs : modèles conceptuels et données disponibles*. Météo-France, Cours et manuels.
- CALAS, C., DUCROCQ, V. et SÉNÉSI, S. (2000). Mesoscale analyses and diagnostic parameters for deep convection nowcasting. *Meteorological Applications*, 7(2).
- CALMET, C. (2018). La vigilance météorologique, une innovation pour le grand public. *La Météorologie*, (100, Numéro Spécial Anniversaire 25 ans):56 – 65.
- CAUMONT, O., DUCROCQ, V., DELRIEU, G., GOSSET, M., PINTY, J.-P., Parent du CHÂTELET, J., ANDRIEU, H., LEMAÎTRE, Y. et SCIALOM, G. (2006). A Radar Simulator for High-Resolution Nonhydrostatic Models. *Journal of Atmospheric and Oceanic Technology*, 23(8).
- CAUMONT, O., DUCROCQ, V., WATTRELOT, , JAUBERT, G. et PRADIER-VABRE, S. (2010). 1D+3DVar assimilation of radar reflectivity data : a proof of concept. *Tellus A : Dynamic Meteorology and Oceanography*.
- CHEEKS, S. M., FUEGLISTALER, S. et GARNER, S. T. (2020). A Satellite-Based Climatology of Central and Southeastern U.S. Mesoscale Convective Systems. *Monthly Weather Review*, 148(6).

- CHEN, D., GUO, J., YAO, D., FENG, Z. et LIN, Y. (2020). Elucidating the Life Cycle of Warm-Season Mesoscale Convective Systems in Eastern China from the Himawari-8 Geostationary Satellite. *Remote Sensing*, 12(14).
- CHEN, L.-C., PAPANDREOU, G., KOKKINOS, I., MURPHY, K. et YUILLE, A. L. (2017a). Deeplab : Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs.
- CHEN, L.-C., PAPANDREOU, G., SCHROFF, F. et ADAM, H. (2017b). Rethinking atrous convolution for semantic image segmentation.
- CINTINEO, J. L., PAVOLONIS, M. J., SIEGLAFF, J. M., CRONCE, L. et BRUNNER, J. (2020a). NOAA ProbSevere v2.0—ProbHail, ProbWind, and ProbTor. *Weather and Forecasting*, 35(4).
- CINTINEO, J. L., PAVOLONIS, M. J., SIEGLAFF, J. M., WIMMERS, A., BRUNNER, J. et BELLON, W. (2020b). A Deep-Learning Model for Automated Detection of Intense Midlatitude Convection Using Geostationary Satellite Images. *Weather and Forecasting*, 35(6):2567 – 2588.
- COHEN, A. E., CONIGLIO, M. C., CORFIDI, S. F. et CORFIDI, S. J. (2007). Discrimination of Mesoscale Convective System Environments Using Sounding Observations. *Weather and Forecasting*, 22(5).
- COIFFIER, J. (2009). *Les bases de la prévision numérique du temps*. Météo-France.
- COMBARNOUS, P., MARTET, M., CAUMONT, O. et ÉRIC DEFER (2024). Assimilation of Satellite Lightning Data in a Storm-Scale Numerical Weather Prediction System Using a 3D-EnVar Data Assimilation Scheme. *Monthly Weather Review*, 152(2):553 – 570.
- CONIGLIO, M. C., BROOKS, H. E., WEISS, S. J. et CORFIDI, S. F. (2007). Forecasting the Maintenance of Quasi-Linear Mesoscale Convective Systems. *Weather and Forecasting*, 22(3).
- CONIGLIO, M. C., HWANG, J. Y. et STENSRUD, D. J. (2010). Environmental Factors in the Upscale Growth and Longevity of MCSs Derived from Rapid Update Cycle Analyses. *Monthly Weather Review*, 138(9).
- CONIGLIO, M. C., STENSRUD, D. J. et WICKER, L. J. (2006). Effects of Upper-Level Shear on the Structure and Maintenance of Strong Quasi-Linear Mesoscale Convective Systems. *Journal of the Atmospheric Sciences*, 63(4).
- CORFIDI, S. F. (2003). Cold Pools and MCS Propagation : Forecasting the Motion of Downwind-Developing MCSs. *Weather and Forecasting*, 18(6).
- CORFIDI, S. F., MERITT, J. H. et FRITSCH, J. M. (1996). Predicting the Movement of Mesoscale Convective Complexes. *Weather and Forecasting*, 11(1).
- COURBOT, J.-B., DUVAL, V. et LEGRAS, B. (2020). Sparse analysis for mesoscale convective systems tracking. *Signal Processing : Image Communication*, 85:115854.

- COURTIER, P., FREYDIER, C., GELEYN, J., RABIER, F. et ROCHAS, M. (1991). The ARPEGE project at Météo-France. *In Proceeding of Seminar on Numerical Methods on Atmospheric Models 2 : 193–231. ECMWF : Reading, UK.*
- CUI, W., DONG, X., XI, B. et FENG, Z. (2021). Climatology of Linear Mesoscale Convective System Morphology in the United States based on Random Forests Method. *Journal of Climate.*
- CUI, X., CHEN, M., SONG, L., LI, C. et HAN, L. (2023). Statistical analysis of quasi-linear convective systems over the Beijing-Tianjin-Hebei region during the warm season. *Atmospheric Research*, 289:106777.
- DA SILVA, N. A. et HAERTER, J. O. (2023). The Precipitation Characteristics of Mesoscale Convective Systems Over Europe. *Journal of Geophysical Research : Atmospheres*, 128(23).
- DAHL, J. M. L. et FISCHER, J. (2016). The Origin of Western European Warm-Season Prefrontal Convergence Lines. *Weather and Forecasting*, 31(5):1417 – 1431.
- DARDOUILLET, P., BENOIT, A., AMRI, E., BOLON, P., DUBUCQ, D. et CRÉDOZ, A. (2022). Explainability of Image Semantic Segmentation Through SHAP Values. *In ICPR-XAIE -26TH International Conference on Pattern Recognition 2-nd Workshop on Explainable and Ethical AI*, Montreal, Canada.
- DAVIS, C., ATKINS, N., BARTELS, D., BOSART, L., CONIGLIO, M., BRYAN, G., COTTON, W., DOWELL, D., JEWETT, B., JOHNS, R., JORGENSEN, D., KNIEVEL, J., KNUPP, K., LEE, W.-C., MCFARQUHAR, G., MOORE, J., PRZYBYLINSKI, R., RAUBER, R., SMULL, B., TRAPP, R., TRIER, S., WAKIMOTO, R., WEISMAN, M. et ZIEGLER, C. (2004). The Bow Echo and MCV Experiment : Observations and Opportunities : Observations and Opportunities. *Bulletin of the American Meteorological Society*, 85(8):1075 – 1094.
- DAVIS, C., BROWN, B. et BULLOCK, R. (2006a). Object-Based Verification of Precipitation Forecasts. Part I : Methodology and Application to Mesoscale Rain Areas. *Monthly Weather Review*, 134(7):1772 – 1784.
- DAVIS, C., BROWN, B. et BULLOCK, R. (2006b). Object-Based Verification of Precipitation Forecasts. Part II : Application to Convective Rain Systems. *Monthly Weather Review*, 134(7):1785 – 1795.
- DAVIS, C. A., BROWN, B. G., BULLOCK, R. et HALLEY-GOTWAY, J. (2009). The Method for Object-Based Diagnostic Evaluation (MODE) Applied to Numerical Forecasts from the 2005 NSSL/SPC Spring Program. *Weather and Forecasting*, 24(5):1252 – 1267.
- DEMORTIER, A., MANDEMENT, M., POURRET, V. et CAUMONT, O. (2024). Assimilation of surface pressure observations from personal weather stations in AROME-France. *Natural Hazards and Earth System Sciences*, 24(3):907–927.
- DESTOUCHES, M., MONTMERLE, T., MICHEL, Y. et CARON, J.-F. (2023). Impact of hydro-meteor control variables in a convective-scale 3DEnVar data assimilation scheme. *Quarterly Journal of the Royal Meteorological Society*, 149(752):757–780.

- DIXON, M. et ROMATSCHKE, U. (2022). Three-dimensional convective–stratiform echo-type classification and convectivity retrieval from radar reflectivity. *Journal of Atmospheric and Oceanic Technology*, 39(11):1685 – 1704.
- DIXON, M. et WIENER, G. (1993). Titan : Thunderstorm identification, tracking, analysis, and nowcasting—a radar-based methodology. *Journal of Atmospheric and Oceanic Technology*, 10(6):785 – 797.
- DOSWELL, C. A. (2001). *Severe Convective Storms—An Overview*, pages 1–26. American Meteorological Society, Boston, MA.
- DOVIK, R. J. et ZRNIC, D. S. (1993). Doppler Radar and Weather Observations (Second Edition). Academic Press, San Diego, second edition édition.
- DOWELL, D. C., ALEXANDER, C. R., JAMES, E. P., WEYGANDT, S. S., BENJAMIN, S. G., MANIKIN, G. S., BLAKE, B. T., BROWN, J. M., OLSON, J. B., HU, M., SMIRNOVA, T. G., LADWIG, T., KENYON, J. S., AHMADOV, R., TURNER, D. D., DUDA, J. D. et ALCOTT, T. I. (2022). The High-Resolution Rapid Refresh (HRRR) : An Hourly Updating Convection-Allowing Forecast Model. Part I : Motivation and System Description. *Weather and Forecasting*, 37(8):1371 – 1395.
- DROBINSKI, P., DUCROCQ, V., ALPERT, P., ANAGNOSTOU, E., BÉRANGER, K., BORGA, M., BRAUD, I., CHANZY, A., DAVOLIO, S., DELRIEU, G., ESTOURNEL, C., BOUBRAHMI, N. F., FONT, J., GRUBIŠIĆ, V., GUALDI, S., HOMAR, V., IVANČAN-PICEK, B., KOTTMEIER, C., KOTRONI, V., LAGOUVARDOS, K., LIONELLO, P., LLASAT, M. C., LUDWIG, W., LUTOFF, C., MARIOTTI, A., RICHARD, E., ROMERO, R., ROTUNNO, R., ROUSSOT, O., RUIN, I., SOMOT, S., TAUPIER-LETAGE, I., TINTORE, J., UIJLENHOET, R. et WERNLI, H. (2014). HyMeX : A 10-Year Multidisciplinary Program on the Mediterranean Water Cycle. *Bulletin of the American Meteorological Society*, 95(7).
- DUCROCQ, V., BRAUD, I., DAVOLIO, S., FERRETTI, R., FLAMANT, C., JANSÁ, A., KALTHOFF, N., RICHARD, E., TAUPIER-LETAGE, I., AYRAL, P.-A., BELAMARI, S., BERNE, A., BORGA, M., BODEVILLAIN, B., BOCK, O., BOICHARD, J.-L., BOUIN, M.-N., BOUSQUET, O., BOUVIER, C., CHIGGIATO, J., CIMINI, D., CORSMEIER, U., COPPOLA, L., COCQUE-REZ, P., DEFER, E., DELANOË, J., DI GIROLAMO, P., DOERENBECHER, A., DROBINSKI, P., DUFOURNET, Y., FOURRIÉ, N., GOURLEY, J. J., LABATUT, L., LAMBERT, D., LE COZ, J., MARZANO, F. S., MOLINIÉ, G., MONTANI, A., NORD, G., NURET, M., RAMAGE, K., RISON, W., ROUSSOT, O., SAID, F., SCHWARZENBOECK, A., TESTOR, P., VAN BAELEN, J., VINCENDON, B., ARAN, M. et TAMAYO, J. (2014). HyMeX-SOP1 : The Field Campaign Dedicated to Heavy Precipitation and Flash Flooding in the Northwestern Mediterranean. *Bulletin of the American Meteorological Society*, 95(7).
- DUCROCQ, V., NUISSIER, O., RICARD, D., LEBEAUPIN, C. et THOUVENIN, T. (2008). A numerical study of three catastrophic precipitating events over southern France. II : Mesoscale triggering and stationarity factors. *Quarterly Journal of the Royal Meteorological Society*, 134(630).

- DUDA, J. D. et TURNER, D. D. (2021). Large-Sample Application of Radar Reflectivity Object-Based Verification to Evaluate HRRR Warm-Season Forecasts. *Weather and Forecasting*, 36(3):805 – 821.
- DUDA, J. D. et TURNER, D. D. (2023). Using Object-Based Verification to Assess Improvements in Forecasts of Convective Storms between Operational HRRR Versions 3 and 4. *Weather and Forecasting*, 38(10):1971 – 1994.
- EBERT-UPHOFF, I. et HILBURN, K. (2020). Evaluation, Tuning, and Interpretation of Neural Networks for Working with Images in Meteorological Applications. *Bulletin of the American Meteorological Society*, 101(12):E2149 – E2170.
- ESPEHOLT, L., AGRAWAL, S., SØNDERBY, C., KUMAR, M., HECK, J., BROMBERG, C., GAZEN, C., CARVER, R., ANDRYCHOWICZ, M., HICKEY, J., BELL, A. et KALCHBRENNER, N. (2022). Deep learning for twelve hour precipitation forecasts. *Nature Communications*, 13.
- FENG, Z., LEUNG, L. R., LIU, N., WANG, J., HOUZE, R. A., LI, J., HARDIN, J. C., CHEN, D. et GUO, J. (2021). A Global High-Resolution Mesoscale Convective System Database Using Satellite-Derived Cloud Tops, Surface Precipitation, and Tracking. *Journal of Geophysical Research : Atmospheres*, 126(8).
- FERY, L. et FARANDA, D. (2024). Analysing 23 years of warm-season derechos in France : a climatology and investigation of synoptic and environmental changes. *Weather and Climate Dynamics*, 5(1):439–461.
- Figueras i VENTURA, J., BOUMAHMOUD, A.-A., FRADON, B., DUPUY, P. et TABARY, P. (2012). Long-term monitoring of french polarimetric radar data quality and evaluation of several polarimetric quantitative precipitation estimators in ideal conditions for operational implementation at c-band. *Quarterly Journal of the Royal Meteorological Society*, 138(669): 2212–2228.
- Figueras i VENTURA, J. et TABARY, P. (2013). The New French Operational Polarimetric Radar Rainfall Rate Product. *Journal of Applied Meteorology and Climatology*, 52(8).
- FIOLLEAU, T. et ROCA, R. (2013). An Algorithm for the Detection and Tracking of Tropical Mesoscale Convective Systems Using Infrared Images From Geostationary Satellite. *IEEE Transactions on Geoscience and Remote Sensing*, 51(7).
- FISCHER, C., MONTMERLE, T., BERRE, L., AUGER, L. et ȘTEFĂNESCU, S. E. (2005). An overview of the variational assimilation in the ALADIN/France numerical weather-prediction system. *Quarterly Journal of the Royal Meteorological Society*, 131(613):3477–3492.
- FOURRIÉ, N., BRESSON, E., NURET, M., JANY, C., BROUSSEAU, P., DOERENBECHER, A., KREITZ, M., NUISSIER, O., SEVAULT, E., BÉNICHOU, H., AMODEI, M. et POUPONNEAU, F. (2015). AROME-WMED, a real-time mesoscale model designed for the HyMeX special observation periods. *Geoscientific Model Development*, 8(7):1919–1941.

- FRANCH, G., TOMASI, E., WANJARI, R., POLI, V., CARDINALI, C., ALBERONI, P. P. et CRISTOFORETTI, M. (2024). Gptcast : a weather language model for precipitation nowcasting.
- FRITSCH, J. M., et FORBES, G. S. (2001). Mesoscale Convective Systems. *Meteorological Monographs*, 28(50):323 – 358.
- GAGNE, D. J., MCGOVERN, A., HAUPT, S. E., SOBASH, R. A., WILLIAMS, J. K. et XUE, M. (2017). Storm-Based Probabilistic Hail Forecasting with Machine Learning Applied to Convection-Allowing Ensembles. *Weather and Forecasting*, 32(5):1819 – 1840.
- GAGNEII, D. J., HAUPT, S. E., NYCHKA, D. W. et THOMPSON, G. (2019). Interpretable Deep Learning for Spatial Analysis of Severe Hailstorms. *Monthly Weather Review*, 147(8):2827 – 2845.
- GALE, J. J., GALLUS, W. A. et JUNGBLUTH, K. A. (2002). Toward Improved Prediction of Mesoscale Convective System Dissipation. *Weather and Forecasting*, 17(4).
- GALLUS, W. A., SNOOK, N. A. et JOHNSON, E. V. (2008). Spring and Summer Severe Weather Reports over the Midwest as a Function of Convective Mode : A Preliminary Study. *Weather and Forecasting*, 23(1):101 – 113.
- GERMANN, U. et ZAWADZKI, I. (2002). Scale-dependence of the predictability of precipitation from continental radar images. part i : Description of the methodology. *Monthly Weather Review*, 130(12):2859 – 2873.
- GERMANN, U., ZAWADZKI, I. et TURNER, B. (2006). Predictability of Precipitation from Continental Radar Images. Part IV : Limits to Prediction. *Journal of the Atmospheric Sciences*, 63(8):2092 – 2108.
- GOODFELLOW, I., BENGIO, Y. et COURVILLE, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- GOULET, L. (2015). La prévision des systèmes orageux stationnaires dans le sud-est de la France. *La Météorologie*, 90:27 – 39.
- GROENEMEIJER, P., PÚČIK, T., TSONEVSKY, I. et BECHTOLD, P. (2019). An overview of CAPE and CIN provided by NWP models for operational forecasting. Rapport technique, European Centre for Medium-Range Weather Forecasts.
- GUERRA, J. E., SKINNER, P. S., CLARK, A., FLORA, M., MATILLA, B., KNOPFMEIER, K. et REINHART, A. E. (2022). Quantification of NSSL Warn-on-Forecast System Accuracy by Storm Age Using Object-Based Verification. *Weather and Forecasting*, 37(11):1973 – 1983.
- GUILLOU, Y. (2018). L’automatisation des observations météorologiques de surface à Météo-France. Une r-évolution. *La Météorologie*, (100):96–99.
- GUO, M.-H., XU, T.-X., LIU, J.-J., LIU, Z.-N., JIANG, P.-T., MU, T.-J., ZHANG, S.-H., MARTIN, R. R., CHENG, M.-M. et HU, S.-M. (2022). Attention mechanisms in computer vision : A survey. *Computational Visual Media*, 8:331–368.

- GUSTAFSSON, N., JANJIĆ, T., SCHRAFF, C., LEUENBERGER, D., WEISSMANN, M., REICH, H., BROUSSEAU, P., MONTMERLE, T., WATTRELOT, E., BUČÁNEK, A., MILE, M., HAMDI, R., LINDSKOG, M., BARKMEIJER, J., DAHLBOM, M., MACPHERSON, B., BALLARD, S., INVERARITY, G., CARLEY, J., ALEXANDER, C., DOWELL, D., LIU, S., IKUTA, Y. et FUJITA, T. (2018). Survey of data assimilation methods for convective-scale numerical weather prediction at operational centres. *Quarterly Journal of the Royal Meteorological Society*, 144(713).
- HABERLIE, A. M. et ASHLEY, W. S. (2018a). A Method for Identifying Midlatitude Mesoscale Convective Systems in Radar Mosaics. Part I : Segmentation and Classification. *Journal of Applied Meteorology and Climatology*, 57(7).
- HABERLIE, A. M. et ASHLEY, W. S. (2018b). A Method for Identifying Midlatitude Mesoscale Convective Systems in Radar Mosaics. Part II : Tracking. *Journal of Applied Meteorology and Climatology*, 57(7):1599 – 1621.
- HABERLIE, A. M. et ASHLEY, W. S. (2019). A Radar-Based Climatology of Mesoscale Convective Systems in the United States. *Journal of Climate*, 32(5):1591 – 1606.
- HAGEN, M., BARTENSCHLAGER, B. et FINKE, U. (1999). Motion characteristics of thunderstorms in southern Germany. *Meteorological Applications*, 6(3).
- HAMANN, U., ZEDER, J., BEUSCH, L., CLEMENTI, L., FORESTI, L., HERING, A., NERINI, D., NISI, L., SASSI, M. et GERMANN, U. (2019). Nowcasting of thunderstorm severity with machine learning in the Alpine region. In *In : 3rd European Nowcasting Conference. Madrid : Agencia Estatal de Meteorología. <https://repositorio.aemet.es/handle/20.500.11765/10617>*.
- HEIKENFELD, M., MARINESCU, P. J., CHRISTENSEN, M., WATSON-PARRIS, D., SENF, F., van den HEEVER, S. C. et STIER, P. (2019). tobac 1.2 : towards a flexible framework for tracking and analysis of clouds in diverse datasets. *Geoscientific Model Development*, 12(11):4551–4570.
- HEINSELMAN, P. L., BURKE, P. C., WICKER, L. J., CLARK, A. J., KAIN, J. S., GAO, J., YUSSOUF, N., JONES, T. A., SKINNER, P. S., POTVIN, C. K., WILSON, K. A., GALLO, B. T., FLORA, M. L., MARTIN, J., CREAGER, G., KNOPFMEIER, K. H., WANG, Y., MATILLA, B. C., DOWELL, D. C., MANSSELL, E. R., ROBERTS, B., HOOGWIND, K. A., STRATMAN, D. R., GUERRA, J., REINHART, A. E., KERR, C. A. et MILLER, W. (2024). Warn-on-Forecast System : From Vision to Reality. *Weather and Forecasting*, 39(1):75 – 95.
- HERING, A., MOREL, C., GALLI, G., SÉNÉSI, S., AMBROSETTI, P. et BOSCACCI, M. (2004). Nowcasting thunderstorms in the Alpine region using a radar based adaptive thresholding scheme. In *In Proceedings of the 3th European Conference on Radar in Meteorology and Hydrology, Gotland, Sweden, 6–10 September 2004 ; Copernicus : Gottingen, Germany, 2004 ; pp. 206–211*.
- HERING, A., NISI, L., BRUNA, G., GAIA, M., NERINI, D., AMBROSETTI, P., HAMANN, U., TREFALT, S. et GERMANN, U. (2015). Fully automated thunderstorm warnings and operational nowcasting at MeteoSwiss.

- HERSBACH, H., BELL, B., BERRISFORD, P., BIAVATI, G., HORÁNYI, A., MUÑOZ SABATER, J., NICOLAS, J., PEUBEY, C., RADU, R., ROZUM, I., SCHEPERS, D., SIMMONS, A., SOCI, C., DEE, D. et THÉPAUT, J.-N. (2023). ERA5 hourly data on single levels from 1940 to present. *Copernicus Climate Change Service (C3S) Climate Data Store (CDS)*. Dernier accès : 11-06-2024.
- HINTZ, K. S., O'BOYLE, K., DANCE, S. L., AL-ALI, S., ANSPER, I., BLAAUBOER, D., CLARK, M., CRESS, A., DAHOUI, M., DARCY, R., HYRKKANEN, J., ISAKSEN, L., KAAS, E., KORSHOLM, U. S., LAVANANT, M., LE BLOA, G., MALLET, E., MCNICHOLAS, C., ONVLEE-HOOIMEIJER, J., SASS, B., SIIRAND, V., VEDEL, H., WALLER, J. A. et YANG, X. (2019). Collecting and utilising crowdsourced data for numerical weather prediction : Propositions from the meeting held in Copenhagen, 4–5 December 2018. *Atmospheric Science Letters*, 20(7):e921.
- HOHENEGGER, C. et SCHAR, C. (2007). Atmospheric Predictability at Synoptic Versus Cloud-Resolving Scales. *Bulletin of the American Meteorological Society*, 88(11):1783 – 1794.
- HOLMLUND, K., GRANDELL, J., SCHMETZ, J., STUHLMANN, R., BOJKOV, B., MUNRO, R., LEKOUARA, M., COPPENS, D., VITICCHIE, B., AUGUST, T., THEODORE, B., WATTS, P., DOBBER, M., FOWLER, G., BOJINSKI, S., SCHMID, A., SALONEN, K., TJEMKES, S., AMINOU, D. et BLYTHE, P. (2021). Meteosat Third Generation (MTG) : Continuation and Innovation of Observations from Geostationary Orbit. *Bulletin of the American Meteorological Society*, 102(5):E990 – E1015.
- HOUZE, R. A. (1997). Stratiform Precipitation in Regions of Convection : A Meteorological Paradox? *Bulletin of the American Meteorological Society*, 78(10):2179 – 2196.
- HOUZE, R. A. (2004). Mesoscale convective systems. *Reviews of Geophysics*, 42(4).
- HOUZE, R. A. (2018). 100 Years of Research on Mesoscale Convective Systems. *Meteorological Monographs*, 59.
- HU, J., SHEN, L., ALBANIE, S., SUN, G. et WU, E. (2019). Squeeze-and-excitation networks.
- IMBERT, Jean ; Touze, B. (2021). Automatic Detection of Severe Thunderstorms to Improve Weather Warnings. *The European Forecaster, Newsletter of the WGCEF*, 26.
- JIRAK, I. L. et COTTON, W. R. (2007). Observational Analysis of the Predictability of Mesoscale Convective Systems. *Weather and Forecasting*, 22(4).
- JOHNS, R. H. et HIRT, W. D. (1987). Derechos : Widespread Convectively Induced Windstorms. *Weather and Forecasting*, 2(1):32 – 49.
- JOHNSON, A., WANG, X., WANG, Y., REINHART, A., CLARK, A. J. et JIRAK, I. L. (2020). Neighborhood- and Object-Based Probabilistic Verification of the OU MAP Ensemble Forecasts during 2017 and 2018 Hazardous Weather Testbeds. *Weather and Forecasting*, 35(1):169 – 191.

- KHODAYAR, S., DAVOLIO, S., DI GIROLAMO, P., LEBEAUPIN BROSSIER, C., FLAOUNAS, E., FOURRIE, N., LEE, K.-O., RICARD, D., VIE, B., BOUTTIER, F., CALDAS-ALVAREZ, A. et DUCROCQ, V. (2021). Overview towards improved understanding of the mechanisms leading to heavy precipitation in the western Mediterranean : lessons learned from HyMeX. *Atmospheric Chemistry and Physics*, 21(22).
- KINGMA, D. et BA, J. (2014). Adam : A Method for Stochastic Optimization. Accessed on Sun, November 19, 2023.
- KINGSMILL, D. E. et HOUZE JR., R. A. (1999). Kinematic characteristics of air flowing into and out of precipitating convection over the west Pacific warm pool : An airborne Doppler radar survey. *Quarterly Journal of the Royal Meteorological Society*, 125(556):1165–1207.
- KIRSHBAUM, D. J., ADLER, B., KALTHOFF, N., BARTHLOTT, C. et SERAFIN, S. (2018). Moist Orographic Convection : Physical Mechanisms and Links to Surface-Exchange Processes. *Atmosphere*, 9(3).
- KOLIOS, S. et FEIDAS, H. (2009). A warm season climatology of mesoscale convective systems in the Mediterranean basin using satellite data. *Theoretical and Applied Climatology*, 102(1–2).
- KOLIOS, S. et FEIDAS, H. (2012a). An automated nowcasting system of mesoscale convective systems for the Mediterranean basin using Meteosat imagery. Part I : System description : Automated nowcasting system of MCSs for the Mediterranean basin. *Meteorological Applications*, 20(3).
- KOLIOS, S. et FEIDAS, H. (2012b). An automated nowcasting system of mesoscale convective systems for the Mediterranean basin using Meteosat imagery. Part II : Verification statistics : Automated nowcasting system of MCSs based on MSG. *Meteorological Applications*, 20(3).
- KOLONKO, M., SZCZĘCH-GAJEWSKA, M., BOCHENEK, B., STACHURA, G. et SEKUŁA, P. (2022). Using ALARO and AROME numerical weather prediction models for the derecho case on 11 August 2017. *Meteorology Hydrology and Water Management*, 10(2):88–105.
- KREITZ, M. (2021). Trois phénomènes météorologiques exceptionnels durant l’automne 2020. *La Météorologie*, (112):115 – 124.
- KREITZ, M. (2023). Les rafales orageuses exceptionnelles du 18 août 2022 en Corse. *La Météorologie*, (122):74 – 80.
- KREITZ, M. (2024). Les rafales orageuses exceptionnelles du 18 août 2022 en Corse. Analyse de la situation météorologique. *La Météorologie*, (125):52 – 59.
- KRINITSKIY, M., SPRYGIN, A., ELIZAROV, S., NARIZHNAYA, A., SHIKHOV, A. et CHERNO-KULSKY, A. (2023). Towards the Accurate Automatic Detection of Mesoscale Convective Systems in Remote Sensing Data : From Data Mining to Deep Learning Models and Their Applications. *Remote Sensing*, 15(14).

- KRIZHEVSKY, A., SUTSKEVER, I. et HINTON, G. E. (2012). Imagenet classification with deep convolutional neural networks. *In* PEREIRA, F., BURGESS, C., BOTTOU, L. et WEINBERGER, K., éditeurs : *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc.
- KUMJIAN, M. R. (2013a). Principles and Applications of Dual-Polarization Weather Radar. Part I : Description of the Polarimetric Radar Variables. *Journal of Operational Meteorology*, 1.
- KUMJIAN, M. R. (2013b). Principles and Applications of Dual-Polarization Weather Radar. Part II : Warm-and Cold-Season Applications. *Journal of Operational Meteorology*, 1.
- KUMLER-BONFANTI, C., STEWART, J., HALL, D. et GOVETT, M. (2020). Tropical and Extratropical Cyclone Detection Using Deep Learning. *Journal of Applied Meteorology and Climatology*, 59(12).
- LAC, C., CHABOUREAU, J.-P., MASSON, V., PINTY, J.-P., TULET, P., ESCOBAR, J., LERICHE, M., BARTHE, C., AOUIZERATS, B., AUGROS, C., AUMOND, P., AUGUSTE, F., BECHTOLD, P., BERTHET, S., BIELLI, S., BOSSEUR, F., CAUMONT, O., COHARD, J.-M., COLIN, J., COUVREUX, F., CUXART, J., DELAUTIER, G., DAUHUT, T., DUCROCQ, V., FILIPPI, J.-B., GAZEN, D., GEOFFROY, O., GHEUSI, F., HONNERT, R., LAFORE, J.-P., LEBEAUPIN BROSSIER, C., LIBOIS, Q., LUNET, T., MARI, C., MARIC, T., MASCART, P., MOGÉ, M., MOLINIÉ, G., NUISSIER, O., PANTILLON, F., PEYRILLÉ, P., PERGAUD, J., PERRAUD, E., PIANEZZE, J., REDELSPERGER, J.-L., RICARD, D., RICHARD, E., RIETTE, S., RODIER, Q., SCHOETTER, R., SEYFRIED, L., STEIN, J., SUHRE, K., TAUFOR, M., THOURON, O., TURNER, S., VERRELLE, A., VIÉ, B., VISENTIN, F., VIONNET, V. et WAUTELET, P. (2018). Overview of the Meso-NH model version 5.4 and its applications. *Geoscientific Model Development*, 11(5):1929–1969.
- LACKMANN, G. (2015). *Midlatitude Synoptic Meteorology. Dynamics, Analysis & Forecasting*. Boston : American Meteorological Society.
- LAGERQUIST, R., MCGOVERN, A. et GAGNE II, D. J. (2019). Deep Learning for Spatially Explicit Prediction of Synoptic-Scale Fronts. *Weather and Forecasting*, 34(4).
- LAGERQUIST, R., MCGOVERN, A., HOMEYER, C. R., GAGNE II, D. J. et SMITH, T. (2020). Deep Learning on Three-Dimensional Multiscale Data for Next-Hour Tornado Prediction. *Monthly Weather Review*, 148(7).
- LAGERQUIST, R., MCGOVERN, A. et SMITH, T. (2017). Machine Learning for Real-Time Prediction of Damaging Straight-Line Convective Wind. *Weather and Forecasting*, 32(6).
- LAKSHMANAN, V., HONDL, K. et RABIN, R. (2009). An Efficient, General-Purpose Technique for Identifying Storm Cells in Geospatial Images. *Journal of Atmospheric and Oceanic Technology*, 26(3):523 – 537.
- LAKSHMANAN, V. et SMITH, T. (2009). Data Mining Storm Attributes from Spatial Grids. *Journal of Atmospheric and Oceanic Technology*, 26(11):2353 – 2365.

- LAKSHMANAN, V. et SMITH, T. (2010). An Objective Method of Evaluating and Devising Storm-Tracking Algorithms. *Weather and Forecasting*, 25(2):701 – 709.
- LAROCHE, S. et ZAWADZKI, I. (1994). A variational analysis method for retrieval of three-dimensional wind field from single-doppler radar data. *Journal of Atmospheric Sciences*, 51(18):2664 – 2682.
- LASSERRE-BIGORRY, A. (2014). Météo-France rénove les outils des prévisionnistes. *La Météorologie*, (87):5 – 6.
- LAURANTIN, O. (2008). ANTILOPE : Hourly rainfall analysis merging radar and rain gauge data. In *Proceedings of the International Symposium on Weather Radar and Hydrology*.
- LECUN, Y., BOSER, B., DENKER, J. S., HENDERSON, D., HOWARD, R. E., HUBBARD, W. et JACKEL, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1(4):541–551.
- LECUN, Y., BOTTOU, L., BENGIO, Y. et HAFFNER, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- LEE, K., FLAMANT, C., DUCROCQ, V., DUFFOURG, F., FOURRIÉ, N., DELANOË, J. et BECH, J. (2017). Initiation and development of a mesoscale convective system in the Ebro River Valley and related heavy precipitation over northeastern Spain during HyMeX IOP 15a. *Quarterly Journal of the Royal Meteorological Society*, 143(703).
- LEE, K.-O., FLAMANT, C., DUCROCQ, V., DUFFOURG, F., FOURRIÉ, N. et DAVOLIO, S. (2016). Convective initiation and maintenance processes of two back-building mesoscale convective systems leading to heavy precipitation events in Southern Italy during HyMeX IOP 13. *Quarterly Journal of the Royal Meteorological Society*, 142(700):2623–2635.
- LEE, Y., KUMMEROW, C. D. et EBERT-UPHOFF, I. (2021). Applying machine learning methods to detect convection using Geostationary Operational Environmental Satellite-16 (GOES-16) advanced baseline imager (ABI) data. *Atmospheric Measurement Techniques*, 14(4):2699–2716.
- LEGG, S. et HUTTER, M. (2007). A collection of definitions of intelligence. *CoRR*, abs/0706.3639.
- LEINONEN, J. (2021). Spatiotemporal Weather Data Predictions with Shortcut Recurrent-Convolutional Networks : A Solution for the Weather4cast challenge.
- LEINONEN, J., HAMANN, U., GERMANN, U. et MECIKALSKI, J. R. (2022). Nowcasting thunderstorm hazards using machine learning : the impact of data sources on performance. *Natural Hazards and Earth System Sciences*, 22(2).
- LEINONEN, J., HAMANN, U., NERINI, D., GERMANN, U. et FRANCH, G. (2023a). Latent diffusion models for generative precipitation nowcasting with accurate uncertainty quantification.

- LEINONEN, J., HAMANN, U., SIDERIS, I. V. et GERMANN, U. (2023b). Thunderstorm Nowcasting With Deep Learning : A Multi-Hazard Data Fusion Model. *Geophysical Research Letters*, 50(8).
- LEWIS, M. W. et GRAY, S. L. (2010). Categorisation of synoptic environments associated with mesoscale convective systems over the UK. *Atmospheric Research*, 97(1–2).
- LI, T., WU, D., WANG, L. et YU, X. (2022). Recognition algorithm for deep convective clouds based on fy4a. *Neural Computing and Applications*, 34.
- LIN, T., GOYAL, P., GIRSHICK, R. B., HE, K. et DOLLÁR, P. (2017). Focal loss for dense object detection. *CoRR*, abs/1708.02002.
- LIU, Y., RACAH, E., PRABHAT, CORREA, J., KHOSROWSHAHI, A., LAVERS, D., KUNKEL, K., WEHNER, M. et COLLINS, W. (2016). Application of Deep Convolutional Neural Networks for Detecting Extreme Weather in Climate Datasets.
- LOMBARDO, K. A. et COLLE, B. A. (2012). Ambient Conditions Associated with the Maintenance and Decay of Quasi-Linear Convective Systems Crossing the Northeastern U.S. Coast. *Monthly Weather Review*, 140(12):3805 – 3819.
- LONG, J., SHELHAMER, E. et DARRELL, T. (2014). Fully convolutional networks for semantic segmentation. *CoRR*, abs/1411.4038.
- LOVAT, A. (2019). *Prévision à très courte échéance des crues rapides méditerranéennes*. Phd thesis, Institut National Polytechnique de Toulouse, Toulouse.
- LU, C., YUAN, H., SCHWARTZ, B. E. et BENJAMIN, S. G. (2007). Short-Range Numerical Weather Prediction Using Time-Lagged Ensembles. *Weather and Forecasting*, 22(3):580 – 595.
- LU, H., SHE, Y., TIE, J. et XU, S. (2022). Half-UNet : A Simplified U-Net Architecture for Medical Image Segmentation. *Frontiers in Neuroinformatics*, 16.
- LUNDBERG, S. et LEE, S.-I. (2017). A unified approach to interpreting model predictions.
- MACHADO, L. A. T., ROSSOW, W. B., GUEDES, R. L. et WALKER, A. W. (1998). Life Cycle Variations of Mesoscale Convective Systems over the Americas. *Monthly Weather Review*, 126(6).
- MADDOX, R. A. (1980). Mesoscale Convective Complexes. *Bulletin of the American Meteorological Society*, 61(11):1374–1387.
- MAHFOUF, J.-F., CAUMONT, O., MONTMERLE, T., WATTRELOT, et DUCROCQ, V. (2013). Assimilation des données radar dans le modèle Arome. *La Météorologie*, (83):42 – 49.
- MALARDEL, S. (2009). *Fondamentaux de Météorologie*. - (2ème Édition). Toulouse : Cépaduès-Éditions.
- MANACH, J. (2002). Les besoins en observations des prévisionnistes. *La Météorologie*, (39):22 – 28.

- MANDEMENT, M. et CAUMONT, O. (2020). Contribution of personal weather stations to the observation of deep-convection features near the ground. *Natural Hazards and Earth System Sciences*, 20(1).
- MARKOWSKI, P. et RICHARDSON, Y. (2010). *Mesoscale Meteorology in Midlatitudes*. John Wiley Sons, Ltd.
- MARTET, M., BROUSSEAU, P., WATTRELOT, E., GUILLAUME, F. et MAHFOUF, J.-F. (2022). *Operational Assimilation of Radar Data from the European EUMETNET Programme OPERA in the Météo-France Convective-Scale Model AROME*, pages 629–644. Springer International Publishing, Cham.
- MASSON, V., LE MOIGNE, P., MARTIN, E., FAROUX, S., ALIAS, A., ALKAMA, R., BELAMARI, S., BARBU, A., BOONE, A., BOUYSSSEL, F., BROUSSEAU, P., BRUN, E., CALVET, J.-C., CARRER, D., DECHARME, B., DELIRE, C., DONIER, S., ESSAOUINI, K., GIBELIN, A.-L., GIORDANI, H., HABETS, F., JIDANE, M., KERDRAON, G., KOURZENEVA, E., LAFAYSSSE, M., LAFONT, S., LEBEAUPIN BROSSIER, C., LEMONSU, A., MAHFOUF, J.-F., MARGUINAUD, P., MOKHTARI, M., MORIN, S., PIGEON, G., SALGADO, R., SEITY, Y., TAILLEFER, F., TANGUY, G., TULET, P., VINCENDON, B., VIONNET, V. et VOLDOIRE, A. (2013). The SURFEXv7.2 land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geoscientific Model Development*, 6(4).
- MATHIAS, L., LUDWIG, P. et PINTO, J. G. (2019). Synoptic-scale conditions and convection-resolving hindcast experiments of a cold-season derecho on 3 January 2014 in western Europe. *Natural Hazards and Earth System Sciences*, 19(5).
- MCANELLY, R. L. et COTTON, W. R. (1989). The Precipitation Life Cycle of Mesoscale Convective Complexes over the Central United States. *Monthly Weather Review*, 117(4).
- MCCANN, D. W. (1983). The Enhanced-V : A Satellite Observable Severe Storm Signature. *Monthly Weather Review*, 111(4):887 – 894.
- MCGOVERN, A., CHASE, R. J., FLORA, M., GAGNE, D. J., LAGERQUIST, R., POTVIN, C. K., SNOOK, N. et LOKEN, E. (2023). A Review of Machine Learning for Convective Weather. *Artificial Intelligence for the Earth Systems*, 2(3).
- MCGOVERN, A., ELMORE, K. L., GAGNE, D. J., HAUPT, S. E., KARSTENS, C. D., LAGERQUIST, R., SMITH, T. et WILLIAMS, J. K. (2017). Using Artificial Intelligence to Improve Real-Time Decision-Making for High-Impact Weather", journal = "Bulletin of the American Meteorological Society. 98(10):2073 – 2090.
- MECIKALSKI, J. R., SANDMÆL, T. N., MURILLO, E. M., HOMEYER, C. R., BEDKA, K. M., APKE, J. M. et JEWETT, C. P. (2021). A Random-Forest Model to Assess Predictor Importance and Nowcast Severe Storms Using High-Resolution Radar–GOES Satellite–Lightning Observations. *Monthly Weather Review*, 149(6):1725 – 1746.
- MICHEL, Y. et BROUSSEAU, P. (2021). A Square-Root, Dual-Resolution 3DEnVar for the AROME Model : Formulation and Evaluation on a Summertime Convective Period. *Monthly Weather Review*, 149(9):3135 – 3153.

- MIGLIETTA, M. M. et DAVOLIO, S. (2022). Dynamical forcings in heavy precipitation events over Italy : lessons from the HyMeX SOP1 campaign. *Hydrology and Earth System Sciences*, 26(3):627–646.
- MIGLIETTA, M. M. et ROTUNNO, R. (2014). Numerical Simulations of Sheared Conditionally Unstable Flows over a Mountain Ridge. *Journal of the Atmospheric Sciences*, 71(5):1747 – 1762.
- MILAN, M., MACPHERSON, B., TUBBS, R., DOW, G., INVERARITY, G., MITTERMAIER, M., HALLORAN, G., KELLY, G., LI, D., MAYCOCK, A., PAYNE, T., PICCOLO, C., STEWART, L. et WLASAK, M. (2020). Hourly 4D-Var in the Met Office UKV operational forecast model. *Quarterly Journal of the Royal Meteorological Society*, 146(728):1281–1301.
- MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR, DE LA RECHERCHE ET DE L'INNOVATION (2019). Bulletin officiel n°6 du 7 février 2019. https://www.enseignementsup-recherche.gouv.fr/fr/pid20536/bulletin_officiel.html?cbo=1&pid_bo=38531. Dernier accès : 23-03-2024.
- MONCRIEFF, M. W. et GREEN, J. S. A. (1972). The propagation and transfer properties of steady convective overturning in shear. *Quarterly Journal of the Royal Meteorological Society*, 98(416):336–352.
- MONTMERLE, T. et FACCANI, C. (2009). Mesoscale Assimilation of Radial Velocities from Doppler Radars in a Preoperational Framework. *Monthly Weather Review*, 137(6).
- MONTMERLE, T., LAFORE, J.-P. et REDELSPERGER, J.-L. (2000). A Tropical Squall Line Observed during TOGA COARE : Extended Comparisons between Simulations and Doppler Radar Data and the Role of Midlevel Wind Shear. *Monthly Weather Review*, 128(11):3709 – 3730.
- MONTMERLE, T., MICHEL, Y., ARBOGAST, E., MÉNÉTRIER, B. et BROUSSEAU, P. (2018). A 3D ensemble variational data assimilation scheme for the limited-area AROME model : Formulation and preliminary results. *Quarterly Journal of the Royal Meteorological Society*, 144(716):2196–2215.
- MOREL, C. (2001). *Caractérisation objective des systèmes convectifs européens à partir de leur suivi dans l'imagerie satellitaire*. Thèse de doctorat. Thèse de doctorat dirigée par Sénési, Stéphane Physique de l'atmosphère Toulouse 3 2001.
- MOREL, C. et SENESI, S. (2002a). A climatology of mesoscale convective systems over Europe using satellite infrared imagery. I : Methodology. *Quarterly Journal of the Royal Meteorological Society*, 128(584).
- MOREL, C. et SENESI, S. (2002b). A climatology of mesoscale convective systems over Europe using satellite infrared imagery. II : Characteristics of European mesoscale convective systems. *Quarterly Journal of the Royal Meteorological Society*, 128(584).
- MOUNIER, A., RAYNAUD, L., ROTTNER, L., PLU, M., ARBOGAST, P., KREITZ, M., MIGNAN, L. et TOUZÉ, B. (2022). Detection of Bow Echoes in Kilometer-Scale Forecasts Using a Convolutional Neural Network. *Artificial Intelligence for the Earth Systems*, 1(2).

- MULLER, C. et ABRAMIAN, S. (2023). The cloud dynamics of convective storm systems. *Physics Today*, 76(5):28–28.
- MUNICH RE (2024). Hail, tornadoes, flash floods : Losses from thunderstorms on the rise. <https://www.munichre.com/en/risks/natural-disasters/thunderstorms-hail-tornados.html>. Dernier accès : 17-05-2024.
- MUNKRES, J. (1957). Algorithms for the assignment and transportation problems. *Journal of the Society for Industrial and Applied Mathematics*, 5(1):32–38.
- MÉTÉO-FRANCE (2021). Documentation utilisateur belenos taranis - version 2 - 24/03/2021. Rapport technique.
- MÉTÉO-FRANCE (2023). Les bilans vigilance. <https://meteofrance.fr/actualite/publications/documents-institutionnels/les-bilans-vigilance>. Dernier accès : 17-05-2024.
- MÉTÉO-FRANCE/DSO/CMR (2018). Fiche synthétique produit de données spatialisées « mosaïque radar de réflectivité france métropole 1km ». Rapport technique.
- NIELSEN, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press.
- NISI, L., AMBROSETTI, P. et CLEMENTI, L. (2014). Nowcasting severe convection in the Alpine region : the COALITION approach. *Quarterly Journal of the Royal Meteorological Society*, 140(682):1684–1699.
- NUISSIER, O., DUCROCQ, V., RICARD, D., LEBEAUPIN, C. et ANQUETIN, S. (2008). A numerical study of three catastrophic precipitating events over southern France. I : Numerical framework and synoptic ingredients. *Quarterly Journal of the Royal Meteorological Society*, 134(630).
- OERTEL, A. et SCHEMM, S. (2021). Quantifying the circulation induced by convective clouds in kilometer-scale simulations. *Quarterly Journal of the Royal Meteorological Society*, 147(736).
- OLIVIER PIOTTE, Thibaut Montmerle, C. F. A. B. L. G. B. J. C. J. J. D. et ORGANDE, D. (2020). Les évolutions du service d'avertissement sur les pluies intenses et les crues soudaines en France. *La Houille Blanche*, 106(6):75–84.
- OSINSKI, R. et BOUTTIER, F. (2018). Short-range probabilistic forecasting of convective risks for aviation based on a lagged-average-forecast ensemble approach. *Meteorological Applications*, 25(1):105–118.
- PAILLEUX, J., GELEYN, J.-F., EL KHATIB, R., FISCHER, C., HAMRUD, M., THÉPAUT, J.-N., RABIER, F., ANDERSSON, E., SALMOND, D., BURRIDGE, D., SIMMONS, A. et COURTIER, P. (2015). Les 25 ans du système de prévision numérique du temps IFS/Arpège. *La Météorologie*, (89):18 – 27.
- Parent du CHÂTELET, J. (2003). Aramis, le réseau français de radars pour la surveillance des précipitations. *La Météorologie*, (40):44–52.

- PARKER, M. D. et JOHNSON, R. H. (2000). Organizational Modes of Midlatitude Mesoscale Convective Systems. *Monthly Weather Review*, 128(10).
- PARKER, M. D. et JOHNSON, R. H. (2004). Structures and Dynamics of Quasi-2D Mesoscale Convective Systems. *Journal of the Atmospheric Sciences*, 61(5):545 – 567.
- PINTO, J. O., GRIM, J. A. et STEINER, M. (2015). Assessment of the High-Resolution Rapid Refresh Model’s Ability to Predict Mesoscale Convective Systems Using Object-Based Evaluation. *Weather and Forecasting*, 30(4):892 – 913.
- PINTY, J.-P. et JABOUILLE, P. (1998). A mixed-phase cloud parameterization for use in a mesoscale non-hydrostatic model : Simulations of a squall line of orographic precipitation. *In Conference on Cloud Physics*, Everett. American Meteorological Society.
- PUNKKA, A.-J. et BISTER, M. (2015). Mesoscale Convective Systems and Their Synoptic-Scale Environment in Finland. *Weather and Forecasting*, 30(1).
- RAVURI, S., LENC, K., WILLSON, M., KANGIN, D., LAM, R., MIROWSKI, P., FITZSIMONS, M., ATHANASSIADOU, M., KASHEM, S., MADGE, S., PRUDDEN, R., MANDHANE, A., CLARK, A., BROCK, A., SIMONYAN, K., HADSELL, R., ROBINSON, N., CLANCY, E., ARRIBAS, A. et MOHAMED, S. (2021). Skilful precipitation nowcasting using deep generative models of radar. *Nature*.
- RAYMOND, D. J. et JIANG, H. (1990). A Theory for Long-Lived Mesoscale Convective Systems. *Journal of Atmospheric Sciences*, 47(24):3067 – 3077.
- RAYNAUD, L., PANNEKOUCKE, O., ARBOGAST, P. et BOUTTIER, F. (2015). Application of a Bayesian weighting for short-range lagged ensemble forecasting at the convective scale. *Quarterly Journal of the Royal Meteorological Society*, 141(687):459–468.
- RAYNAUD, L., PECHIN, I., ARBOGAST, P., ROTTNER, L. et DESTOUCHES, M. (2019). Object-based verification metrics applied to the evaluation and weighting of convective-scale precipitation forecasts. *Quarterly Journal of the Royal Meteorological Society*, 145(722):1992–2008.
- REYNOLDS, D. W. (1980). Observations of Damaging Hailstorms from Geosynchronous Satellite Digital Data. *Monthly Weather Review*, 108(3):337 – 348.
- RICARD, D., DUCROCQ, V. et AUGER, L. (2012). A Climatology of the Mesoscale Environment Associated with Heavily Precipitating Events over a Northwestern Mediterranean Area. *Journal of Applied Meteorology and Climatology*, 51(3).
- RIGO, T., BERENQUER, M. et LLASAT, M. d. C. (2019). An improved analysis of mesoscale convective systems in the western Mediterranean using weather radar. *Atmospheric Research*, 227.
- ROBE, F. R. et EMANUEL, K. A. (2001). The Effect of Vertical Wind Shear on Radiative–Convective Equilibrium States. *Journal of the Atmospheric Sciences*, 58(11):1427 – 1445.

- ROEBBER, P. J. (2009). Visualizing Multiple Measures of Forecast Quality. *Weather and Forecasting*, 24(2):601 – 608.
- RONNEBERGER, O., FISCHER, P. et BROX, T. (2015). U-Net : Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention, MICCAI 2015, N. Navab et al., Eds., Lecture Notes in Computer Science*, Vol. 9351, Springer, 234–241. Accessed on Sun, November 19, 2023.
- ROSENBLATT, F. (1958). The perceptron : a probabilistic model for information storage and organization in the brain. *Psychological review*, 65 6:386–408.
- ROTUNNO, R., KLEMP, J. B. et WEISMAN, M. L. (1988). A Theory for Strong, Long-Lived Squall Lines. *Journal of the Atmospheric Sciences*, 45(3).
- ROYET, J. (2023). Bilan orageux de l’année 2022. *La Météorologie*, (121):63–66.
- RUDER, S. (2017). An overview of gradient descent optimization algorithms.
- SALTIKOFF, E., HAASE, G., DELOBBE, L., GAUSSIAT, N., MARTET, M., IDZIOREK, D., LEIJNSE, H., NOVÁK, P., LUKACH, M. et STEPHAN, K. (2019). OPERA the Radar Project. *Atmosphere*, 10(6).
- SAUNDERS, R., HOCKING, J., TURNER, E., RAYER, P., RUNDLE, D., BRUNEL, P., VIDOT, J., ROQUET, P., MATRICARDI, M., GEER, A., BORMANN, N. et LUPU, C. (2018). An update on the RTTOV fast radiative transfer model (currently at version 12). *Geoscientific Model Development*, 11(7).
- SAÏX, F. et ROULET, B. (2014). Un exemple de prévision réussie de fortes précipitations orageuses sur le Languedoc. *La Météorologie*, (86):49–56.
- SCHLEMPER, J., OKTAY, O., SCHAAP, M., HEINRICH, M., KAINZ, B., GLOCKER, B. et RUECKERT, D. (2019). Attention gated networks : Learning to leverage salient regions in medical images. *Medical Image Analysis*, 53:197–207.
- SCHMID, J. (2000). The SEVIRI instrument. In *Proceedings of the 2000 EUMETSAT meteorological satellite data users’ conference*.
- SCHMITT, S. et KREITZ, M. (2022). Analyse de 10 ans d’accidentologie humaine par la foudre en France et en Europe. *La Météorologie*, (122):27 – 36.
- SCHULTZ, C. J., PETERSEN, W. A. et CAREY, L. D. (2009). Preliminary Development and Evaluation of Lightning Jump Algorithms for the Real-Time Detection of Severe Weather. *Journal of Applied Meteorology and Climatology*, 48(12):2543 – 2563.
- SCHULZ, W., DIENDORFER, G., PEDEBOY, S. et POELMAN, D. R. (2016). The European lightning location system EUCLID – Part 1 : Performance analysis and validation. *Natural Hazards and Earth System Sciences*, 16(2).
- SCHUMACHER, R. et RASMUSSEN, K. (2020). The formation, character and changing nature of mesoscale convective systems. *Nature Reviews Earth Environment*, 1(6):300 – 314.

- SCHUMACHER, R. S. et JOHNSON, R. H. (2005). Organization and Environmental Properties of Extreme-Rain-Producing Mesoscale Convective Systems. *Monthly Weather Review*, 133(4).
- SCIALOM, G. et LEMAÎTRE, Y. (1990). A New Analysis for the Retrieval of Three-Dimensional Mesoscale Wind Fields from Multiple Doppler Radar. *Journal of Atmospheric and Oceanic Technology*, 7(5):640 – 665.
- SCOVELL, R. et al SAKKA, H. (2016). A point cloud method for retrieval of high-resolution 3d gridded reflectivity from weather radar networks for air traffic management. *Journal of Atmospheric and Oceanic Technology*, 33(3):461 – 479.
- SEITY, Y., BROUSSEAU, P., MALARDEL, S., HELLO, G., BÉNARD, P., BOUTTIER, F., LAC, C. et MASSON, V. (2011). The AROME-France Convective-Scale Operational Model. *Monthly Weather Review*, 139(3).
- SHEHU, B. et HABERLANDT, U. (2021). Improving object-oriented radar based nowcast by a nearest neighbour approach 2. *Hydrology and Earth System Sciences Discussions*, 2021:1–25.
- SHORTEN, C. et KHOSHGOFTAAR, T. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(60).
- SIDERIS, I. V., FORESTI, L., NERINI, D. et GERMANN, U. (2020). NowPrecip : localized precipitation nowcasting in the complex terrain of Switzerland. *Quarterly Journal of the Royal Meteorological Society*, 146(729):1768–1800.
- SIDERIS, I. V., GABELLA, M., ERDIN, R. et GERMANN, U. (2014). Real-time radar-rain-gauge merging using spatio-temporal co-kriging with external drift in the alpine terrain of Switzerland. *Quarterly Journal of the Royal Meteorological Society*, 140(680):1097–1111.
- SKINNER, P. S., WHEATLEY, D. M., KNOPFMEIER, K. H., REINHART, A. E., CHOATE, J. J., JONES, T. A., CREAGER, G. J., DOWELL, D. C., ALEXANDER, C. R., LADWIG, T. T., WICKER, L. J., HEINSELMAN, P. L., MINNIS, P. et PALIKONDA, R. (2018). Object-Based Verification of a Prototype Warn-on-Forecast System. *Weather and Forecasting*, 33(5):1225 – 1250.
- SRIVASTAVA, N., HINTON, G., KRIZHEVSKY, A., SUTSKEVER, I. et SALAKHUTDINOV, R. (2014). Dropout : A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(56):1929–1958.
- STARZEC, M., HOMEYER, C. R. et MULLENDORE, G. L. (2017). Storm labeling in three dimensions (sl3d) : A volumetric radar echo and dual-polarization updraft classification algorithm. *Monthly Weather Review*, 145(3):1127 – 1145.
- STENSRUD, D. J., CONIGLIO, M. C., DAVIES-JONES, R. P. et EVANS, J. S. (2005). Comments on “‘A Theory for Strong Long-Lived Squall Lines’ Revisited”. *Journal of the Atmospheric Sciences*, 62(8):2989 – 2996.

- STENSRUD, D. J., XUE, M., WICKER, L. J., KELLEHER, K. E., FOSTER, M. P., SCHAEFER, J. T., SCHNEIDER, R. S., BENJAMIN, S. G., WEYGANDT, S. S., FERREE, J. T. et TUELL, J. P. (2009). Convective-Scale Warn-on-Forecast System : A Vision for 2020. *Bulletin of the American Meteorological Society*, 90(10):1487 – 1500.
- SUDRE, C. H., LI, W., VERCAUTEREN, T., OURSELIN, S. et JORGE CARDOSO, M. (2017). Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In CARDOSO, M. J., ARBEL, T., CARNEIRO, G., SYEDA-MAHMOOD, T., TAVARES, J. M. R., MORADI, M., BRADLEY, A., GREENSPAN, H., PAPA, J. P., MADABHUSHI, A., NASCIMENTO, J. C., CARDOSO, J. S., BELAGIANNIS, V. et LU, Z., éditeurs : *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, pages 240–248, Cham. Springer International Publishing.
- SUN, J., XUE, M., WILSON, J. W., ZAWADZKI, I., BALLARD, S. P., ONVLEE-HOOIMEYER, J., JOE, P., BARKER, D. M., LI, P.-W., GOLDING, B., XU, M. et PINTO, J. (2014). Use of NWP for Nowcasting Convective Precipitation : Recent Progress and Challenges. *Bulletin of the American Meteorological Society*, 95(3).
- SUROWIECKI, A. et TASZAREK, M. (2020). A 10-Year Radar-Based Climatology of Mesoscale Convective System Archetypes and Derechos in Poland. *Monthly Weather Review*, 148(8): 3471 – 3488.
- SÉNÉSI, S. et THEPENIER, R.-M. (1997). Indices d’instabilité et occurrence d’orage : le cas de l’Île-de-France. *La Météorologie*, 19:18 – 33.
- TABARY, P., AUGROS, C., CHAMPEAUX, J.-L., CHÈZE, J.-L., FAURE, D., IDZIOREK, D., LORANDEL, R., URBAN, B. et VOGT, V. (2013). Le réseau et les produits radars de Météo-France. *La Météorologie*, (83):15–27.
- TASZAREK, M., ALLEN, J. T., PÚČIK, T., HOOGWIND, K. A. et BROOKS, H. E. (2020). Severe Convective Storms across Europe and the United States. Part II : ERA5 Environments Associated with Lightning, Large Hail, Severe Wind, and Tornadoes. *Journal of Climate*, 33(23).
- THOMAS, G., MAHFOUF, J.-F. et MONTMERLE, T. (2020). Toward a variational assimilation of polarimetric radar observations in a convective-scale numerical weather prediction (NWP) model. *Atmospheric Measurement Techniques*, 13(5):2279–2298.
- TRAPP, R. J. (2013). *Mesoscale-Convective Processes in the Atmosphere*. Cambridge University Press.
- TREBING, K., STANCZYK, T. et MEHRKANOON, S. (2021). Smaat-unet : Precipitation nowcasting using a small attention-unet architecture.
- UCCELLINI, L. W. et JOHNSON, D. R. (1979). The Coupling of Upper and Lower Tropospheric Jet Streaks and Implications for the Development of Severe Convective Storms. *Monthly Weather Review*, 107(6).

- WANG, P. K., SU, S.-H., SETVAK, M., LIN, H. et RABIN, R. M. (2010). Ship wave signature at the cloud top of deep convective storms. *Atmospheric Research*, 97(3):294–302.
- WANG, Y., CONING, E., HAROU, A., JACOBS, W., JOE, P., NITINA, L., ROBERTS, R., WANG, J., WISON, J., ATENICA, A., BICA, B., BROWN, B., GOODMAN, S., KANN, A., LI, P.W., M. I., PARRISH, P., SCHMID, F., SEED, A. et SUN, J. (2017). Guidelines for Nowcasting Techniques. Rapport technique, World Meteorological Organization.
- WAPLER, K. (2021). Mesocyclonic and non-mesocyclonic convective storms in germany : Storm characteristics and life-cycle. *Atmospheric Research*, 248:105186.
- WARREN, R., RICHTER, H., BLOCKLEY, I. et SGARBOSSA, D. (2023). New convective guidance at the Australian Bureau of Meteorology. In *Proceedings of the 11th European Conference on Severe Storms, Bucharest, Romania, 8–12 May 2023, ECSS2023-178*.
- WATTRELOT, E., CAUMONT, O. et MAHFOUF, J.-F. (2014). Operational Implementation of the 1D+3D-Var Assimilation Method of Radar Reflectivity Data in the AROME Model. *Monthly Weather Review*, 142(5).
- WEISMAN, M. L. (1992). The Role of Convectively Generated Rear-Inflow Jets in the Evolution of Long-Lived Mesoconvective Systems. *Journal of Atmospheric Sciences*, 49(19):1826 – 1847.
- WEISMAN, M. L. et KLEMP, J. B. (1982). The Dependence of Numerically Simulated Convective Storms on Vertical Wind Shear and Buoyancy. *Monthly Weather Review*, 110(6):504 – 520.
- WERNER, M., FEGER, R., JOSIPOVIC, L., et BÖHME, T. (2023). Operational usage of KONRAD3D, DWD’s scheme for detection, tracking, and nowcasting of convective cells. In *Proceedings of the 11th European Conference on Severe Storms, Bucharest, Romania, 8–12 May 2023*.
- WILHELM, J., WAPLER, K., BLAHAK, U., POTTHAST, R. et KUNZ, M. (2023). Statistical relevance of meteorological ambient conditions and cell attributes for nowcasting the life cycle of convective storms. *Quarterly Journal of the Royal Meteorological Society*, 149(755).
- WILKS, D. S. (1995). *Statistical Methods in the Atmospheric Sciences*. Academic Press.
- WOO, S., PARK, J., LEE, J.-Y. et KWEON, I. S. (2018). Cbam : Convolutional block attention module.
- YANG, Q., HOUZE, R. A., LEUNG, L. R. et FENG, Z. (2017). Environments of Long-Lived Mesoscale Convective Systems Over the Central United States in Convection Permitting Climate Simulations. *Journal of Geophysical Research : Atmospheres*, 122(24).
- YOU, Z. et DENG, Y. (2023). A Hierarchical Dissection of Multiscale Forcing on the Springtime Mesoscale Convective Systems in the United States. *Journal of Climate*, 36(1):39 – 54.
- YUAN, X., SHI, J. et GU, L. (2021). A review of deep learning methods for semantic segmentation of remote sensing imagery. *Expert Systems with Applications*, 169:114417.

- ZHANG, Y., LONG, M., CHEN, K., XING, L., JIN, R., JORDAN, M. I. et WANG, J. (2023). Skilful nowcasting of extreme precipitation with nowcastnet. *Nature*, 619:526–532.
- ZHANG, Z. (2016). Derivation of backpropagation in convolutional neural network (CNN). *University of Tennessee, Knoxville, TN*, 22(23).
- ZHENG, L., SUN, J., ZHANG, X. et LIU, C. (2013). Organizational Modes of Mesoscale Convective Systems over Central East China. *Weather and Forecasting*, 28(5).
- ZÄNGL, G., REINERT, D., RÍPODAS, P. et BALDAUF, M. (2015). The ICON (ICOsahedral Non-hydrostatic) modelling framework of DWD and MPI-M : Description of the non-hydrostatic dynamical core. *Quarterly Journal of the Royal Meteorological Society*, 141(687):563–579.
- ZÖBISCH, I., FORSTER, C., ZINNER, T., BUGLIARO, L., TAFFERNER, A. et WAPLER, K. (2020). Characteristics of deep moist convection over Germany in multi-source data. *Meteorologische Zeitschrift*, 29(5).

Titre : Approche objet pour la détection, le suivi et la prévision à très courte échéance des systèmes convectifs de mésoéchelle

Mots clés : Système convectif de mésoéchelle, Orage, Objet, Prévision immédiate, Prévision numérique du temps, Réseau de neurones convolutifs

Résumé : Les systèmes convectifs de mésoéchelle (MCSs) peuvent produire des inondations et de violentes rafales de vent. Bien que leur taille dépasse 100 km, leur prévisibilité est limitée par l'instabilité convective. La thèse fournit des clés pour améliorer le suivi et l'anticipation à 6 h des MCSs en France et pour progresser dans la compréhension des processus physiques impliqués. Deux types de données sont utilisées : des observations, radar et satellite, ainsi que les prévisions numériques du modèle AROME à résolution kilométrique. Les MCSs sont identifiés comme des « objets » auxquels sont attachés des attributs sur l'activité convective, la tendance et l'environnement en interaction avec le système.

Un réseau de neurones convolutifs U-Net est d'abord mis au point pour identifier les MCSs dans les images exploitées, qu'elles soient observées ou simulées à partir des variables pronostiques d'AROME. Il s'agit des réflectivités radar et de la température de brillance infrarouge mesurée par satellite. Le U-Net est entraîné sur plus de 1200 images annotées à la main. Évaluée sur des scores objectifs et des études de cas, la méthode s'avère plus robuste que des algorithmes moins complexes basés sur un seuillage.

Comprendre le cycle de vie des MCSs en France est nécessaire à leur anticipation. Plus de 150 MCSs sont ainsi étudiés sur des situations à enjeu entre 2018 et 2022. La plupart évoluent de mai à octobre, dans une large bande du sud-ouest au nord-est du pays. En moyenne, leur taille suit une évolution parabolique et culmine sur le second tiers du cycle de vie. Il en va de même pour l'activité convective dont le pic est atteint plus tôt. Des simulations AROME, lancées sur les mêmes situations, reproduisent de manière réaliste le cycle de vie des objets observés. Les champs 3D d'AROME sont alors exploités pour comprendre l'influence de l'environnement sur l'évolution des MCSs. Deux méthodes sont employées : (1) calculer les valeurs moyennes ambiantes dans un voisinage de 100 km, (2) tracer des cartes composites annulaires permettant de visualiser des champs moyennés, projetés sur une grille adaptée à la géométrie de chaque objet. Les MCSs se forment généralement dans un environnement dynamique, instable, avec de la convergence en basses couches. Leur déplacement est bien approché par le vent de moyenne troposphère. L'assèchement et le refroidissement des basses couches en amont du système sont principalement responsables de son affaiblissement. Étudiés séparément, les MCSs méditerranéens quasi-stationnaires sont pilotés par le flux chaud et humide de basses couches qui tend à s'affaiblir à la fin du cycle de vie.

La dernière partie de la thèse mesure l'apport des modèles numériques. À Météo-France, la configuration AROME-PI met à jour toutes les heures les prévisions de la chaîne de production AROME par assimilation des dernières observations, principalement issues du radar. Les scores « objet » calculés par rapport aux MCSs observés montrent que, lorsqu'un MCS est effectivement présent dans l'ébauche AROME, AROME-PI en corrige efficacement les erreurs de localisation. Par ailleurs, le dernier réseau AROME-PI disponible n'est pas toujours le plus performant. Cependant, l'extrapolation linéaire des objets observés reste meilleure que la prévision numérique jusqu'à près de 4 h d'échéance. Sur cette période, la stratégie d'anticipation la plus pertinente repose donc sur l'extrapolation et la tendance des attributs de l'objet, éventuellement complétée par des données de prévision numérique pour décrire l'environnement et anticiper l'activité convective. Au-delà de 4 h, la prévision numérique devient indispensable et les ensembles constitués des prévisions de réseaux successifs AROME-PI valides aux mêmes instants permettent d'estimer la probabilité d'occurrence du phénomène. Des méthodes concrètes basées sur une synergie observation-prévision numérique sont détaillées à la fin du mémoire.

Title: An object-based method for the detection, tracking and very short-term forecasting of mesoscale convective systems

Key words: Mesoscale convective system, Thunderstorm, Object, Nowcasting, Numerical weather prediction, Convolutional neural network

Abstract: Mesoscale convective systems (MCSs) can produce floods and severe wind gusts. Although their size exceeds 100 km, their predictability is limited by convective instability. This thesis provides keys to improving the monitoring and 6-hour forecasting of MCSs in France and to making progress in our understanding of the physical processes involved. Two types of data are used: radar and satellite observations, and numerical forecasts from the AROME model at kilometre resolution. The MCSs are identified as "objects" to which attributes are attached concerning convective activity, the trend and the environment interacting with the system.

A U-Net convolutional neural network was first developed to identify the MCSs in meteorological images, whether observed or simulated from the AROME prognostic variables. These are radar reflectivity and infrared brightness temperature measured by satellite. The U-Net is trained on more than 1,200 hand-annotated images. Evaluated on objective scores and case studies, the method proves to be more robust than less complex algorithms based on thresholding.

Understanding the life cycle of MCSs in France is essential to anticipating them. More than 150 MCSs are being studied in severe convective situations between 2018 and 2022. Most of them evolve from May to October, in a wide band from the south-west to the north-east of the country. On average, their size follows a parabolic trend, peaking in the second third of their life cycle. The same applies to convective activity, which peaks earlier. AROME simulations, run on the same situations, realistically reproduce the life cycle of the objects observed. The AROME 3D fields are then used to understand the influence of the environment on the evolution of MCSs. Two methods are used: (1) calculating average ambient values within a 100 km radius, (2) creating composite annular maps to display averaged fields, projected onto a grid adapted to the geometry of each object. MCSs generally form in a dynamic, unstable environment, with low-level convergence. Their displacement is well approximated by the mid-level wind. The drying and cooling at low-level ahead of the system are mainly responsible for its weakening. Studied separately, the quasi-stationary Mediterranean MCSs are driven by the warm, moist low-level flow, which tends to weaken at the end of their life cycle.

The last part of the thesis measures the contribution of numerical weather prediction. At Météo-France, the AROME-NWC configuration updates the forecasts of the AROME production chain every hour by assimilating the latest observations, mainly from radar. The "object" scores calculated with observed MCSs as ground truth show that, when an MCS is present in the AROME background, AROME-NWC corrects its location errors. Moreover, the latest available AROME-NWC run is not always the best performing. However, the Lagrangian extrapolation of observed objects remains better than the numerical forecast up to almost 4 hours ahead. Over this period, the most relevant forecasting strategy is therefore based on the extrapolation and trend of object attributes, possibly supplemented by numerical forecast data to describe the environment and anticipate convective activity. Beyond 4 h, numerical forecasting becomes essential, and the sets of forecasts from successive AROME-NWC runs valid at the same times can be used to estimate the probability of occurrence of the phenomenon. Practical methods based on a synergy between observation and numerical forecasting are introduced at the end of the thesis.