

Faculté des sciences

# Les prévisions saisonnières sont-elles fiables en Europe ?

Auteur-es : Cécile Osy de Zegwaart-Favart

Promoteur-rices : Pr. François Massonnet

Lecteur-rices : Pr. Hugues Gosse et Pr. Eric Lambin

Année académique 2020-2021

# Remerciements

Au terme de ce mémoire, je tiens à remercier mon promoteur, François Massonnet, pour sa disponibilité, son suivi continu et ses encouragements, qui m'ont permis de finir ce travail.

Je remercie également mes proches pour leur présence, leur soutien, leurs conseils et leurs corrections de dernière minute.

Enfin, je souhaite remercier particulièrement Constance Vandendorpe et Emile Neimry, qui par leur présence lors des longues journées d'écriture m'ont permis de rester motivée et saine d'esprit.

## Résumé

Les prévisions saisonnières sont des intermédiaires entre les prévisions météorologiques et les projections climatiques. Elles peuvent apporter une grande plus-value dans la prise de décisions pour de nombreux domaines, tels que ceux de la santé, de l'économie ou encore de l'agriculture. Il est donc important de savoir à quel point on peut leur faire confiance. Ce mémoire a pour but d'évaluer la fiabilité d'un de ces modèles de prévisions, le SEAS5 développé par l'ECMWF, dans une région d'Europe centrale en hiver. Pour ce faire, des scores pour différents indicateurs (corrélation de Pearson, biais et erreurs quadratiques moyennes) sont calculés en comparant les données de vérifications ERA5 aux prévisions du modèle de l'ECMWF réduit à sa forme déterministe ainsi qu'à deux prévisions de contrôle. Si le modèle de prévision de l'ECMWF montre de meilleurs résultats que les prévisions de contrôle pour la corrélation de Pearson et l'ECMWF, ce n'est pas le cas pour le biais. Une méthode de correction de biais linéaire est donc proposée, afin de ne pas influencer les résultats des corrélations de Pearson. Les résultats montrent que la prévision de l'ECMWF n'est pas toujours plus performante que les prévisions de contrôle. La variance du modèle est également étudiée, avec des histogrammes de rang et des diagrammes de fiabilité qui indiquent une sous-dispersion du modèle. Enfin, un cas particulier est examiné, l'hiver 2009-2010. Le modèle a bien prédit les températures extrêmes de cet hiver, mais montre de moins bonnes performances dans la prévision du mécanisme menant à ces températures (phase négative de l'Oscillation Nord-Atlantique).

## Abstract

Seasonal predictions are intermediaries between meteorological predictions and climate projections. They can bring to the table a great improvement in decision making in a lot of sectors, such as the health, economic or agricultural sectors. Knowing how much trust we can put in them is thus important. The goal of this thesis is to evaluate the reliability of one seasonal prediction model, the SEAS5 developed by the ECMWF, in mid-Europe for the winter months. To that end, different scores (Pearson's correlation, bias and mean squared errors) are calculated by comparing the reanalysis ERA5 to the predictions of the ECMWF's model reduced to its deterministic form, as well as to two benchmark predictions. If the ECMWF's model shows better results than the two benchmark predictions for the Pearson's correlation and the mean squared error, it is not the case for the bias. A linear bias correction method is proposed, to not interfere with the Pearson's correlation score. Results show that the ECMWF's model is not always more skilled than the two benchmark predictions. The variance of the model is studied as well with reliability diagrams and rank histograms, which show an under-dispersion of the model. Finally, the case study of the 2009-2010 winter is evaluated. The model performed well in predicting the extreme temperatures of that winter, but showed less performance in the prediction of the mechanism that lead to those temperatures, the NAO-.

# Table des matières

<b>1</b>	<b>Introduction</b>	<b>1</b>
1.1	Mécanismes de prévisibilité . . . . .	2
1.1.1	Sources de prévisibilité en Europe . . . . .	3
1.2	Pourquoi étudier la fiabilité des prévisions saisonnières ? . . . . .	4
<b>2</b>	<b>Revue de littérature</b>	<b>5</b>
2.1	Prévisions . . . . .	5
2.1.1	Prévisions d'ensemble . . . . .	5
2.1.2	Dépendance de la prévisibilité aux conditions initiales . . . . .	5
2.1.3	Incertitudes . . . . .	6
2.2	Prévisions saisonnières . . . . .	9
2.2.1	<i>Seamless predictions</i> . . . . .	9
2.2.2	Fiabilité des prévisions . . . . .	9
<b>3</b>	<b>Matériel et méthodes</b>	<b>11</b>
3.1	Matériel . . . . .	11
3.1.1	Modèles . . . . .	11
3.1.2	Ré-analyse ERA5 . . . . .	12
3.2	Méthodes . . . . .	12
3.2.1	Zone d'étude . . . . .	12
3.2.2	Indicateurs . . . . .	13
3.2.3	Correction du biais . . . . .	14
3.2.4	Calibration du modèle . . . . .	15
<b>4</b>	<b>Résultats</b>	<b>18</b>
4.1	Indicateurs de fiabilité du modèle . . . . .	18
4.1.1	Moyenne sur la zone d'étude . . . . .	18
4.1.2	Moyenne temporelle par cellule du modèle . . . . .	23
4.2	Évènements extrêmes . . . . .	26
4.2.1	Diagrammes de fiabilité . . . . .	26
4.2.2	Cas particulier : l'hiver 2009-2010 . . . . .	27
<b>5</b>	<b>Discussion</b>	<b>30</b>
5.1	Evaluation du modèle . . . . .	30
5.1.1	Indicateurs . . . . .	30
5.1.2	Fiabilité . . . . .	33
5.2	Progrès futurs . . . . .	37
5.2.1	<i>Modifiable Areal Unit Problem (MAUP)</i> . . . . .	37
5.2.2	Progrès constants . . . . .	37
5.3	Limites . . . . .	38
5.3.1	Limites du modèle SEAS5 de l'ECMWF . . . . .	38

5.3.2	Limite de l'étude . . . . .	40
5.4	Pour la suite . . . . .	41
<b>6</b>	<b>Conclusion</b>	<b>42</b>
<b>7</b>	<b>Bibliographie</b>	<b>44</b>
	<b>Table des figures</b>	<b>51</b>
	<b>Liste des tableaux</b>	<b>54</b>

# Chapitre 1

## Introduction

Les prévisions saisonnières sont des intermédiaires entre les prévisions météorologiques et les projections climatiques (Doblas-Reyes et al., 2013). Elles désignent donc les prévisions effectuées pour un horizon s'étalant entre plus de deux semaines et un peu plus d'un an (Doblas-Reyes et al., 2013). Elles diffèrent des prévisions météorologiques : elles permettent de donner des valeurs moyennes attendues pour le mois étudié, et non des prévisions au jour le jour. Les prévisions saisonnières servent donc à dégager les grandes tendances pour les prochains mois (MétéoFrance, 2021). La figure 1.1 donne un exemple de prévision saisonnière réalisée par MétéoFrance pour le printemps 2021, qui donne une indication de température en terme de probabilité par rapport à la normale établie sur les années précédentes.

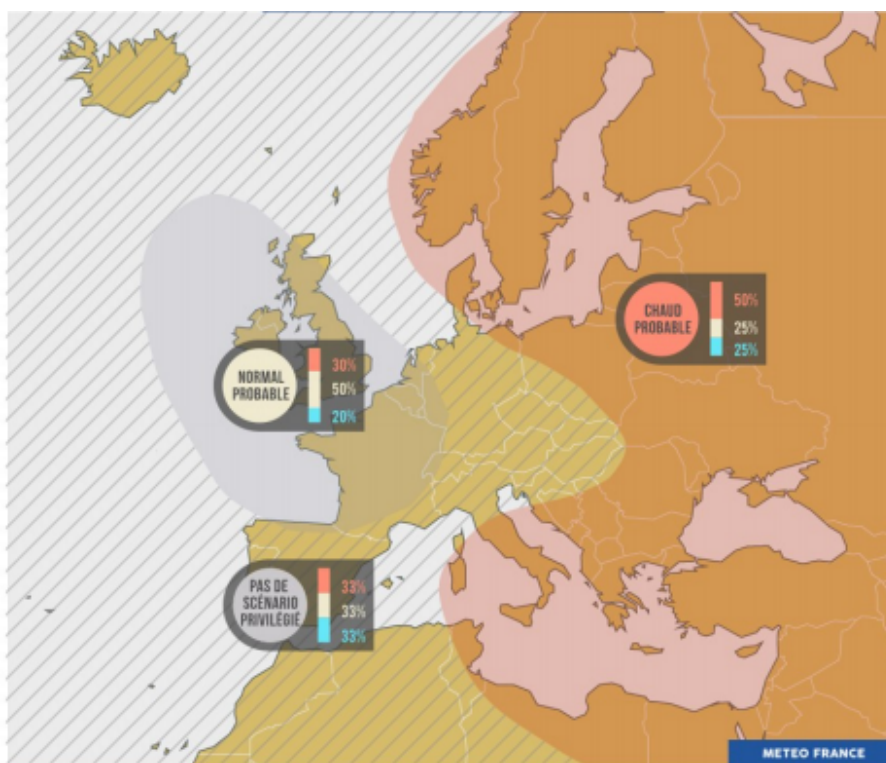


FIGURE 1.1 – Prévisions saisonnières probabilistes de la température de surface de l'air pour les mois de mars à mai 2021. La couleur bleue indique la probabilité d'un scénario plus froid que la normale, la rouge la probabilité d'un scénario plus chaud que la normale et la beige la probabilité d'un scénario proche de la normale. (MétéoFrance, 2021)

Les prévisions saisonnières peuvent se montrer utiles pour la prise de décision dans de nombreux domaines socio-économiques, les milieux de la santé, de l'agriculture ou encore de

l'énergie (Doblas-Reyes, 2010). En effet, les prévisions saisonnières permettent de quantifier les risques que des événements extrêmes se produisent, ou encore de fournir des données pour les décisions concernant la gestion des ressources (Vitart et al., 2017). Ces prévisions sont d'autant plus utiles que les catastrophes naturelles liées au temps, telles que les sécheresses ou les longues périodes de froid ou de chaleur, sont responsables pour une grande partie des pertes liées aux désastres (Vitart et al., 2017).

Ainsi, les prévisions saisonnières sont par exemple primordiales pour les décisions concernant les énergies renouvelables. En effet, avec les politiques de mitigation visant à contenir le réchauffement climatique global à un maximum de 1.5°C, une augmentation de la production d'énergie verte est indispensable (Orlov et al., 2020). Or, l'offre et la demande pour les énergies renouvelables dépendent de la météo : des températures hautes ou basses entraînent une plus grande consommation d'énergie (à cause de l'utilisation accrue de l'air conditionné ou du chauffage) (Orlov et al., 2020). Les prévisions saisonnières pourraient informer sur les risques d'événements extrêmes, afin d'aider dans la planification, l'investissement et les décisions financières (Orlov et al., 2020). De meilleures prévisions permettraient une meilleure planification de la production d'énergie renouvelable et de son importation, entraînant une augmentation de la compétitivité de ces entreprises, attirant plus d'investisseurs et donc aidant la transition vers une économie moins productrice de carbone (Orlov et al., 2020). Un autre exemple de cette plus-value des prévisions saisonnières pour les énergies renouvelables est pour l'utilisation d'énergie provenant du photovoltaïque ou de l'éolien : en période froide, où la consommation d'énergie est importante, lorsqu'il y a peu de vent et une grosse couverture nuageuse, ni les panneaux solaires ni les éoliennes ne pourront répondre à la demande. Avoir la possibilité de prévoir cette situation et donc de s'y préparer constitue un plus pour les entreprises d'énergie.

## 1.1 Mécanismes de prévisibilité

Afin de pouvoir profiter de ces avantages liés aux prévisions saisonnières, il faut tout d'abord être capable de les réaliser. Et pour cela, une question fondamentale apparaît : le climat est-il prévisible à l'échelle de temps saisonnière ? Les prévisions saisonnières s'appuient sur des changements lents et prévisibles de différents éléments, tels que l'humidité du sol, la glace de mer, ainsi que l'interaction et l'impact de l'atmosphère avec/sur ces conditions aux frontières. (Doblas-Reyes, 2010 ; Doblas-Reyes et al., 2013, Shukla & Kinter, 2006). Les anomalies de température de surface de l'océan, en particulier celles liées aux événements El Niño Southern Oscillation (ENSO), sont les sources principales de prévisibilité à l'échelle saisonnière (van Oldenborgh et al., 2005). Ces différentes composantes présentent des temps caractéristiques significativement plus longs que celui de l'atmosphère, lui apportant ainsi de la prévisibilité malgré son caractère intrinsèquement chaotique (Doblas-Reyes et al., 2013 ; EFFIS, s. d.). Le système tire également de la prévisibilité de forçages dits naturels, tels que les variations d'activité solaire (insolation) et les aérosols d'origine volcanique (Doblas-Reyes et al., 2013). En plus de ceci, les forçages externes non-naturels, tels que les changements anthropiques des concentrations en gaz à effet de serre et des aérosols d'origine industrielle et les changements d'utilisation de sol sont également à prendre en compte (Doblas-Reyes et al., 2013 ; Smith et al., 2007). Tous ces éléments font que, pour les prévisions saisonnières, il convient de prendre en compte à la fois les conditions initiales, y compris les composantes non-atmosphériques, tout en prescrivant les conditions aux frontières de l'atmosphère (Doblas-Reyes et al., 2013).

### 1.1.1 Sources de prévisibilité en Europe

Ce mémoire se concentre plus particulièrement sur l'Europe, où la prévisibilité est moindre que pour les zones tropicales (Scaife et al., 2014). La température de surface en Europe présente une variabilité prononcée à l'échelle interannuelle à multidécennale (Årthun et al., 2017; Årthun et al., 2018). Les mécanismes de prévisibilité en Europe varient en outre en fonction des saisons étudiées.

Ainsi, en Europe, le facteur principal de changement de climat saisonnier en hiver est l'Oscillation Nord-Atlantique (NAO), et son analogue hémisphérique l'Oscillation Arctique (AO) (Scaife et al., 2014). C'est d'ailleurs également le cas pour le reste des régions situées de part et d'autre du bassin atlantique (Scaife et al., 2014). En effet, le jet stream atlantique, décrit par la variabilité de la NAO, induit les vents de surface, qui sont responsables par advection des températures d'hiver en Europe (Scaife et al., 2014). Durant les mois d'hiver, les températures en Europe du nord vont être plus basses que la moyenne lors d'une oscillation arctique négative et inversement (Buermann et al., 2003; Scaife et al., 2014). La relation entre la NAO et les températures d'hiver est montrée à la figure 1.2. Riddle et al. (2013) ont en outre démontré une capacité de prévision pour cette oscillation arctique, menant à de la prévisibilité en Europe durant les mois d'hiver. Cette prévisibilité a d'ailleurs été étendue à plus d'un an par Dunstone et al. (2016). L'océan semble également jouer un rôle majeur dans la prévisibilité de la température de surface (Årthun et al., 2017; Årthun et al., 2018). Il reste cependant encore des inconnues dans le lien entre la température de surface de l'océan Atlantique Nord et l'atmosphère. En effet, la causalité ainsi que les mécanismes sous-jacents ne sont toujours pas clairs pour l'ensemble des régions ou des échelles de temps (Ghosh et al., 2017; Årthun et al., 2018). Årthun et al. (2018) ont démontré que, pour l'Europe en saison froide (entre novembre et avril), l'échelle de temps dominante de la variabilité de température de surface varie géographiquement. Ainsi, l'Europe centrale et de l'est présente une variation sous-décennale, tandis que la Péninsule ibérique et le sud de la Grande-Bretagne ont une variation multi-décennale. Enfin, l'Europe du nord présente une variation inter-décennale (Årthun et al., 2018). Ces variabilités peuvent provenir de deux sources : soit elles se forment en réponse à des variations dans la dynamique du système, c'est-à-dire dans la circulation atmosphérique, ou elles proviennent d'un effet thermodynamique, initié par l'advection d'anomalies de chaleur dans l'océan Nord-Atlantique (Årthun et al., 2018). Dans le nord de l'Europe, l'origine des variations est principalement thermodynamique (Årthun et al., 2018). Elle est reliée à la variabilité des températures de surface de la mer de Norvège (Årthun et al., 2018).

Le cycle solaire a également une influence sur le climat d'hiver européen (Ineson et al., 2011). Une basse activité solaire serait responsable des hivers froids en Europe du nord et de l'est (Chen et al., 2015; Ineson et al., 2011). Ainsi, Malieniemi et al. (2014) ont démontré que des anomalies positives de températures étaient observées en Europe durant les phases ascendantes et descendantes du cycle solaire, tandis que des anomalies froides s'observent durant les phases de maximum et de minimum de ce cycle.

L'Oscillation Atlantique Multidécennale (AMO) impacte quant à elle le climat estival européen : une anomalie positive de la température de surface de l'AMO dans les zones extratropicales s'accompagne d'une augmentation des températures en Europe de l'Ouest et inversement (Ghosh et al., 2017; Sutton & Hodson, 2005).

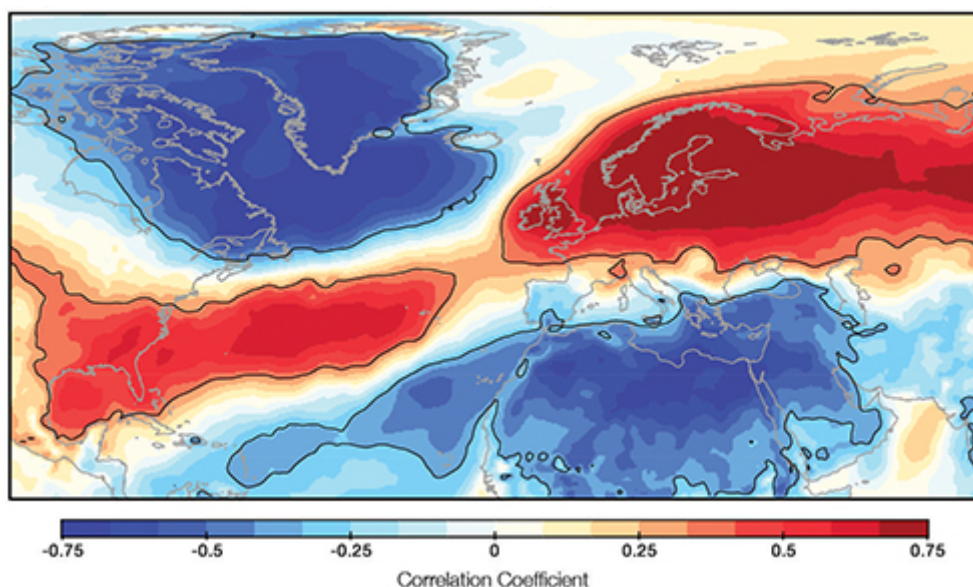


FIGURE 1.2 – Coefficient de corrélation entre la NAO et la réanalyse ERA-Interim de la température à 2 mètres pour les mois d’hiver (décembre à février) (1979-2015) (Hanna & Cropper, 2017).

## 1.2 Pourquoi étudier la fiabilité des prévisions saisonnières ?

Comme expliqué ci-dessus, les prévisions saisonnières sont importantes pour la prise de décisions dans de nombreux domaines. Il est donc important d’étudier leur fiabilité, afin d’informer au mieux leurs utilisateurs (Coelho et al., 2019).

Il existe deux grandes familles de prévisions saisonnières : les méthodes dynamiques et les méthodes statistiques (Doblas-Reyes et al., 2013). Les méthodes dynamiques se basent sur la modélisation physique du système climatique à partir des lois de conservation, alors que les méthodes statistiques se basent sur des relations observées empiriquement dans les données passées pour déduire les évolutions futures (Doblas-Reyes et al., 2013). Les meilleures prévisions sont toutefois obtenues en combinant ces deux méthodes (Doblas-Reyes et al., 2013). En raison de la nature chaotique du système climatique, les prévisions sont fournies sous forme probabiliste (Doblas-Reyes et al., 2013 ; Tippet & Barnston, 2008). Afin d’évaluer correctement une prévision, il faut donc ajouter à l’étude de la précision de celle-ci une étude sur la confiance que l’on peut attribuer à la prévision elle-même, c’est-à-dire sur la fiabilité de la prévision (Slingo & Palmer, 2011).

Les méthodes dynamiques de prévision demandent un temps de calcul conséquent. *Dès lors, valent-elles le surplus de temps et de calculs nécessaires ? Sont-elles plus fiables que des prévisions statistiques "triviales" de contrôle ?* Ce mémoire a pour but de répondre à ces questions. Pour ce faire, les résultats d’un modèle de prévision saisonnière dynamique (modèle SEAS5 de l’European Center for Medium-Range Weather Forecast (ECMWF)) pour différents scores (biais, corrélation de Pearson, erreur quadratique moyenne), sur une zone d’Europe centrale, seront comparés à ceux de deux prévisions de contrôle (moyenne climatologique et persistance en anomalies). La capacité du modèle à prévoir des événements extrêmes sera en outre étudiée. Enfin, une méthode de correction du biais du modèle sera proposée.

# Chapitre 2

## Revue de littérature

### 2.1 Prévisions

Une prévision peut s'exprimer sous forme déterministe ou sous forme probabiliste. Le but des prévisions exprimées sous forme déterministe est de fournir une estimation quantitative de la composante climatique recherchée, telle que la température en un lieu donné par exemple (Yang et al., 2018). Elles ignorent par définition les incertitudes associées (voir section ci-dessous) à la méconnaissance des conditions initiales, à la méconnaissance de la physique du système étudié, aux forçages futurs du système climatique et à la variabilité chaotique inhérente à l'atmosphère. Le système est tel qu'une incertitude subsistera toujours sur ces facteurs (Yang et al., 2018). En toute rigueur, la voie déterministe est donc trompeuse car elle ne véhiculera jamais l'idée qu'une part d'incertitude imprègne chaque prévision. En conséquence, Palmer (2002) argumente en faveur de l'utilisation de prévisions probabilistes, qui sont considérées comme plus informatives. D'ailleurs, les prévisions déterministes sont souvent obtenues en calculant la moyenne de ces prévisions probabilistes, ce qui explique cette information moindre. Les prévisions probabilistes ont une plus-value économique par rapport aux prévisions déterministes pour leurs utilisateurs, car elles s'adaptent à différents besoins : par exemple, une prévision déterministe pourrait prévoir qu'il ne gèlera pas, tandis que les prévisions probabilistes donneront 20% de risque de gel. Un agriculteur pourra, avec la prévision probabiliste, mieux analyser les risques avant de faire ses plantations, car il a accès à une information plus complète (Richardson, 2006, 2012).

#### 2.1.1 Prévisions d'ensemble

Les prévisions du modèle SEAS5 de l'ECMWF étant formulées sous forme probabiliste, cette revue de littérature se concentrera principalement sur ce type de prévisions. Afin d'effectuer des prévisions probabilistes avec des modèles dynamiques, plusieurs simulations sont effectuées en parallèle, appelées "membres", qui visent à discrétiser la distribution statistique de la prévision depuis le temps initial jusqu'à l'échéance, et ainsi représenter au mieux la distribution des états possibles du système dans le futur.

#### 2.1.2 Dépendance de la prévisibilité aux conditions initiales

Dans des systèmes non-linéaires, la prévisibilité est dépendante des conditions initiales. Ceci est montré par la figure 2.1. Cette dernière montre qu'en fonction des conditions initiales, la situation peut être prévisible et considérée comme déterministe (a), totalement imprévisible et considérée comme non déterministe (c) ou semi-prévisible et considérée comme semi-déterministe (b) (Lorenz, 1963). Cette non-linéarité du système fait qu'il est important de

développer des modèles d'ensembles non seulement pour les échelles temporelles moyennes mais aussi pour les courtes (Palmer, 2020). En effet, on voit sur la figure du bas que la prévisibilité est très courte. Il est également important d'observer les ensembles dans leur intégralité, et non pas juste leur moyenne (Palmer, 2006). Ainsi, sur la figure en haut à droite, une prévision déterministe basée sur la moyenne des ensembles donnerait une prévision dans "l'aile" gauche de la figure, alors qu'une prévision d'ensemble montre bien qu'un évènement de "l'aile" droite de la figure est possible (Palmer, 2006). Les différences de prévisibilités viennent des conditions initiales : par exemple, les situations anticycloniques sont généralement très prévisibles, alors que celles avec des NAO positives le sont moins.




FIGURE 2.1 – Représentation 3D simplifiée de la dynamique de l'atmosphère montrant sa nature chaotique selon le système Lorenz (1963), extraite de Slingo et Palmer (2011).

### 2.1.3 Incertitudes

À toute prévision est associée une incertitude. Aucune prévision n'est parfaite, il est donc important de savoir d'où viennent ces incertitudes afin de pouvoir en tenir compte. Il existe trois types d'incertitudes dans les prévisions : l'incertitude sur les conditions initiales, sur le modèle, et sur les paramètres externes (Adapté de Palmer (2006)).

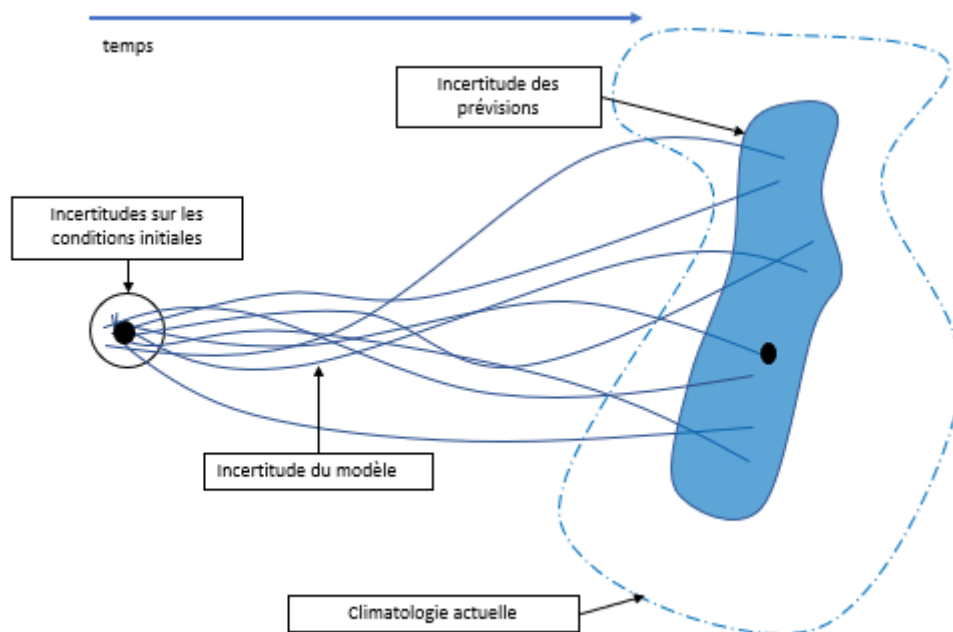


FIGURE 2.2 – Incertitudes pour les prévisions (Adapté de Slingo et Palmer (2011))

La figure 2.2 montre l'effet de ces incertitudes. Ainsi, les prévisions divergent les unes des autres en fonction des différences dans les conditions initiales et dans les modèles utilisés pour représenter les processus opérant à une échelle inférieure à la résolution nominale utilisée (Slingo & Palmer, 2011). Le contour extérieur en pointillés est l'ensemble des états possibles de l'atmosphère au moment étudié, tandis que le centre en ligne pleine est l'ensemble des états prévus par la prévision (Slingo & Palmer, 2011).

L'incertitude liée aux conditions initiales a été en premier relevée par Lorenz (1969). Il a démontré qu'une incertitude, aussi petite soit-elle, dans les conditions initiales causera des incertitudes dans les prévisions (Lorenz, 1969). Les prévisions d'ensemble permettent d'échantillonner cette incertitude : chaque membre de l'ensemble est initialisé avec des conditions initiales légèrement différentes contenues dans un domaine plausible (ECMWF, 2014).

L'incertitude provenant du modèle vient quant à elle du fait que notre représentation du système est imparfaite. Pour comprendre cette source d'incertitude, considérons un moment le cas des projections climatiques avant de nous pencher sur les prévisions saisonnières. Dans le cas des projections climatiques, la réponse en température dépend de façon sensible des paramètres de feedbacks climatiques, dont certains sont très mal contraints (Zelinka et al., 2020). La figure 2.3 montre bien que, si certains feedbacks sont bien compris et modélisés (les quatre feedbacks de gauche), les feedbacks liés aux nuages sont encore une grande source d'incertitude. À l'échelle saisonnière, les incertitudes du modèle sont principalement la représentation des interactions entre l'océan et l'atmosphère ainsi que la stratosphère et la troposphère, la représentation de la circulation atmosphérique et des téléconnexions qui lient ces composantes. De plus, la résolution des modèles étant limitée, les processus se déroulant à des échelles moindres (tels que la convection ou l'effet des montagnes), doivent être paramétrisés, menant donc à des incertitudes (Doblas-Reyes et al., 2009). Pour les prévisions saisonnières, deux méthodes sont efficaces pour réduire les problèmes liés à ces incertitudes du modèle : l'ensemble multi-modèles pour les températures de surface et l'ensemble à paramétrisation stochastique pour les précipitations (Weisheimer et al., 2011). Les ensembles multi-modèles sont un groupe de prévisions effectuées

avec des modèles structurellement différents les uns des autres (Krishnamurti et al., 2000). Ce type de modèle n'amène pas spécialement une meilleure performance de la prévision pour un seul indicateur, mais quand tous les aspects de la prévision (fiabilité, cohérence et compétence) sont étudiés l'ensemble multi-modèles a une meilleure performance (Hagedorn et al., 2005).

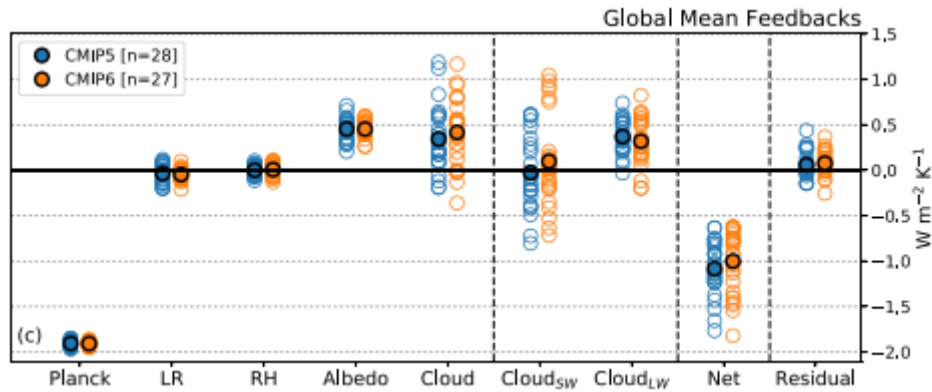


FIGURE 2.3 – Incertitudes liées aux différents feedback. Les ordonnées représentent la valeur de feedback radiatif pour un scénario avec une abrupte quadruplication de CO<sub>2</sub>(Zelinka et al., 2020).

Enfin, l'incertitude quant aux paramètres externes est liée au fait que les conditions aux frontières sont inconnues. En effet, pour les prévisions de longue durée, comme par exemple les projections climatiques, la trajectoire que prend la société (émissions de gaz à effet de serre, croissance de la population, changement d'utilisation du sol, etc.) va avoir un impact sur le climat. Toutefois, cette incertitude est négligeable pour les prévisions à l'échelle saisonnière, comme le montre la figure 2.4 (Meehl et al., 2009).

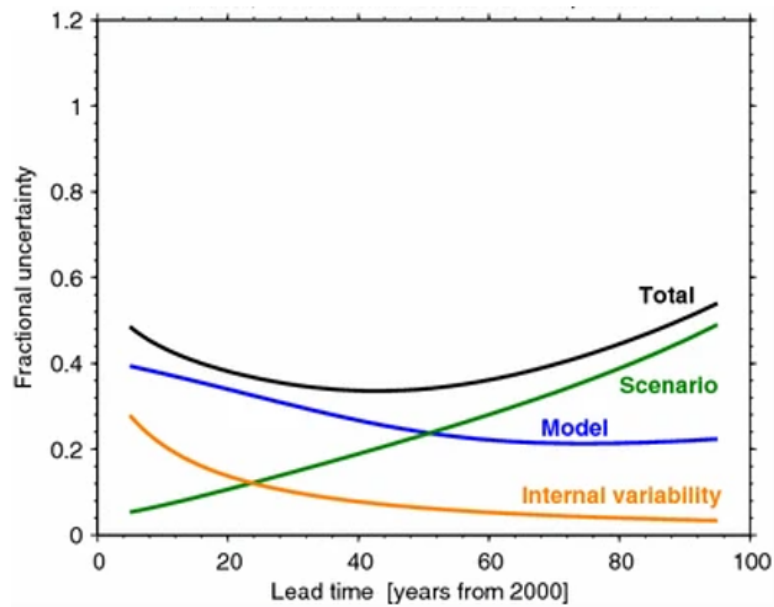


FIGURE 2.4 – Importance relative des différentes sources d'incertitudes en fonction du temps pour la moyenne de température de surface décennale (Hawkins & Sutton, 2011). La *fractional uncertainty* représente l'incertitude divisée par le changement moyen attendu de température de surface, la courbe *internal variability* représente l'incertitude sur les conditions initiales, la courbe *model* celle provenant du modèle et la courbe *scenario* celle des conditions au frontières.

## 2.2 Prévisions saisonnières

Les prévisions saisonnières, comme mentionné précédemment, sont des intermédiaires entre les prévisions météorologiques et les projections climatiques (Doblas-Reyes et al., 2013). Historiquement, les prévisions saisonnières et les projections climatiques étaient traitées séparément (Vitart & Robertson, 2019). En effet, les prévisions saisonnières prennent en compte les interactions entre l’atmosphère, la glace de mer et l’océan, mais sans prendre en compte les forçages, qui sont considérés comme n’influant pas à cette échelle de temps, contrairement aux projections climatiques pour lesquelles les forçages sont essentiels (Doblas-Reyes et al., 2013). Aujourd’hui, ces deux disciplines se rapprochent, grâce à la réalisation que, malgré cette différence, elles se déroulent sur des échelles temporelles et spatiales continues (Vitart & Robertson, 2019). Cette prise de conscience a mené au concept de *seamless predictions*, détaillé ci-après.

### 2.2.1 *Seamless predictions*

Outre les bénéfices des prévisions saisonnières déjà détaillées jusqu’ici, ces dernières apportent également une plus-value dans le domaine des projections climatiques. En effet, la vérification des projections de changements climatiques mettra encore des dizaines d’années avant de pouvoir se faire (Palmer et al., 2008). Si pour certaines régions les différents modèles de projections arrivent à un consensus, pour d’autres ce n’est pas le cas (Palmer et al., 2008). De plus, même si Giorgi et Mearns (2002) discutent du fait qu’il faudrait en principe être plus confiant pour les projections concernant des régions avec un certain consensus dans les modèles, ce critère n’est pas suffisant pour établir la confiance que l’on peut avoir dans les projections (Giorgi & Mearns, 2002 ; Shukla et al., 2006).

Le concept de *seamless predictions* s’appuie sur le fait que les prévisions saisonnières et les projections climatiques partagent des processus physiques fondamentaux (Palmer et al., 2008). Par conséquent, pour un même système de prévision d’ensemble, la validation du modèle à une échelle de temps plus courte (prévisions journalières, saisonnières ou décadales) pour laquelle des données de vérification existent amène à des améliorations dans les modèles de projections climatiques en fonction des scores de vérification (Palmer et al., 2008 ; Weisheimer & Palmer, 2014).

### 2.2.2 Fiabilité des prévisions

Une fois les prévisions réalisées, il est important de les évaluer, et ce pour trois raisons principales : administratives, scientifiques et économiques (Coelho et al., 2019 ; Jolliffe & Stephenson, 2012). Ces trois catégories ont un but commun : évaluer objectivement la prévision dans le but de pouvoir prendre des décisions informées et rationnelles, même si le but final de ces décisions diffère (Jolliffe & Stephenson, 2012). Le but administratif est de surveiller la performance de la prévision à travers le temps ou de justifier l’achat d’un nouveau superordinateur (Coelho et al., 2019). La raison économique consiste à récompenser financièrement les auteurs des prévisions en fonction de la qualité de celles-ci (Jolliffe & Stephenson, 2012). Ce travail s’articule autour de la raison scientifique, son but est de comprendre la fiabilité du modèle étudié en vue d’une amélioration de celui-ci. Étudier la fiabilité d’une prévision est donc important afin de pouvoir lui apporter des améliorations, ainsi que pour informer les utilisateurs de ces prévisions (Coelho et al., 2019).

La vérification d’une prévision passe par la comparaison entre les prévisions et des données dites de "vérification" (Coelho et al., 2019). Il existe un grand nombre d’indicateurs qui permettent d’évaluer différentes prévisions d’une même nature entre elles (Jolliffe & Stephenson,

2012). Afin de choisir quels indicateurs utiliser, il faut d'abord déterminer dans quel but la vérification est effectuée. Murphy (1993) classe la *goodness* d'une prévision en trois catégories : la cohérence, la qualité et la valeur. En d'autres termes, s'intéresse-t-on à la correspondance entre le jugement du prévisionniste et la prévision, à celle entre les prévisions et les observations ou aux bénéfices réalisés grâce aux prévisions (Murphy, 1993) ? Ce mémoire porte sur l'étude de la qualité des prévisions, la cohérence et la valeur ne seront pas abordés. Différents indicateurs seront utilisés, ceux-ci seront décrits dans la section "Matériel et méthodes".

Une bonne prévision est une prévision dont les probabilités sont différentes de la distribution climatologique pour une valeur donnée (Weisheimer & Palmer, 2014). Afin de réaliser l'évaluation d'une prévision, il est important de mesurer différents attributs de celle-ci, car une vérification est un problème multidimensionnel : différents indicateurs ne fourniront pas nécessairement un même classement entre les différentes prévisions étudiées (Jolliffe & Stephenson, 2012). Une mesure seule ne fournira donc non seulement pas une évaluation pertinente de la prévision, mais elle risque en outre de cacher des informations importantes sur la qualité de cette prévision (Coelho et al., 2019).

# Chapitre 3

## Matériel et méthodes

### 3.1 Matériel

Les données ont été traitées avec le logiciel R.

#### 3.1.1 Modèles

Le modèle de prévisions saisonnières étudié est celui de l'ECMWF. Afin de rendre compte de la fiabilité de celui-ci, il sera comparé à deux prévisions de contrôle : la moyenne climatologique et la persistance en anomalies.

#### ECMWF

La description de ce modèle se base sur le fichier "SEAS5 user guide", disponible sur le site de l'ECMWF (ECMWF, 2014).

Le modèle de prévisions saisonnières de l'ECMWF, SEAS5, a été développé en 2017. Il est le cinquième modèle de l'ECMWF. C'est un modèle d'ensemble, c'est-à-dire qu'il est composé de membres. Chaque membre correspond à une prévision avec des conditions initiales légèrement différentes mais qui restent dans un domaine plausible, et chaque prévision est perturbée par des nombres aléatoires, afin de représenter l'incertitude causée par les erreurs possibles du modèle. Un échantillonnage est donc réalisé à la fois sur les incertitudes du modèles et des conditions initiales. L'ensemble est la combinaison de chacune de ces prévisions individuelles, et il permet de fournir des prévisions probabilistes plutôt que déterministes. Les ensembles peuvent également être utilisés pour évaluer la précision de la prévision. Le modèle de prévision saisonnière de l'ECMWF comprend 25 membres pour les *hindcasts* (prévisions rétrospectives, réalisées a posteriori sans utiliser d'information ultérieure à la date étudiée) et 51 pour les *forecasts*, et présente une résolution horizontale de  $1^\circ \times 1^\circ$ .

Le modèle de l'ECMWF utilise lui-même un modèle d'océans et de glace de mer, le NEMO (Nucleus for European Modelling of the Ocean) et le LIM2 (Louvain-la-Neuve Sea-Ice Model). Le NEMO permet la représentation de la circulation océanique de grande échelle ainsi que la représentation du cycle diurne de la température de surface des mers. Le LIM2 permet de considérer l'évolution de l'atmosphère en interaction avec la banquise.

Le modèle atmosphérique utilisé est l'ECMWF IFS (Integrated Forecast System) 43r1. L'IFS possède 91 niveaux verticaux, avec son sommet à 0.01 hPa, c'est-à-dire 80km. Sa résolution horizontale est d'environ 36 km. Les données téléchargées sont celles de la moyenne mensuelle de la température à 2m pour les mois de novembre à février, avec une date d'initialisation au 1er octobre, entre 1993 et 2020. Elles proviennent du site de Copernicus (Copernicus, 2021).

## Moyenne climatologique

La moyenne climatologique est la moyenne, pour un mois donné, des valeurs antérieures de la variable étudiée pour ce même mois.

### persistance en anomalies

La persistance en anomalies consiste à évaluer l'anomalie à un moment donné (différence entre la valeur observée et la moyenne climatologique pour le même mois), et à reporter cette différence à la moyenne climatologique des mois suivants. Les données sont ici initialisées en octobre. Pour chaque année, la moyenne climatologique jusqu'à l'année précédente pour le mois d'octobre est calculée pour obtenir l'anomalie, en soustrayant cette moyenne à la valeur observée pour le mois en question. Ensuite, cette anomalie est reportée jusqu'en février.

### 3.1.2 Ré-analyse ERA5

Les données ERA5 servent en tant que données de vérification. Elles proviennent d'une ré-analyse, c'est-à-dire que les données provenant d'un modèle sont combinées avec des observations pour obtenir une base de données utilisant les lois de la physique (Copernicus, 2019). Les prévisions de l'état de l'atmosphère sont combinées avec des observations nouvellement disponibles afin d'obtenir la meilleure estimation de l'état de l'atmosphère possible (Copernicus, 2019).

Les données ERA5 entre 1979 et 2020 ont été téléchargées pour les mois d'octobre à février. Elles proviennent également du site de Copernicus (Copernicus, 2021).

## 3.2 Méthodes

### 3.2.1 Zone d'étude

La zone d'étude est située en Europe, entre les longitudes de 2° ouest et 16° est, et les latitudes de 48° et 55° nord (Figure 3.1, cadre rouge). Dans leur étude, Christensen et Christensen (2007) ont déterminé différentes sous-zones européennes qui correspondent à des régions climatiques distinctes, dans lesquelles le climat est relativement homogène.

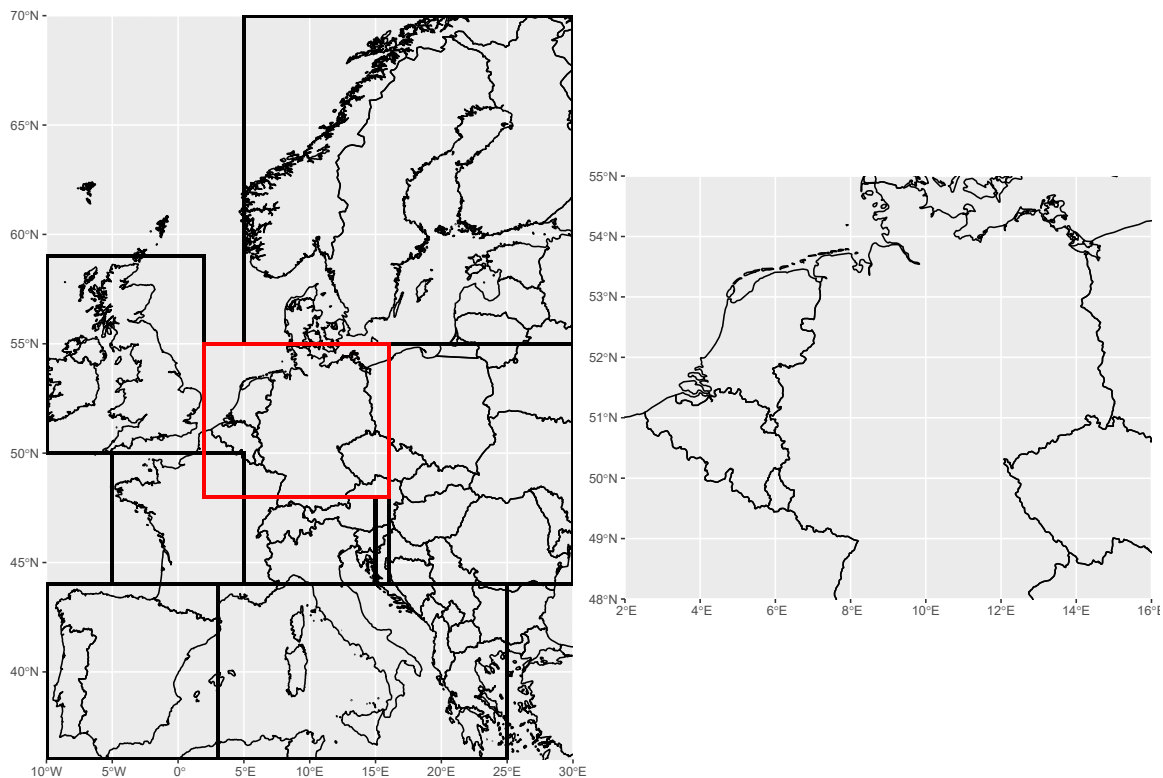


FIGURE 3.1 – Sous-zones européennes basées sur Christensen et Christensen (2007). La zone étudiée est celle entourée par le cadre et rouge, et est agrandie sur la figure de droite.

### 3.2.2 Indicateurs

Les trois indicateurs décrits ci-dessous seront calculés pour l'ensemble de la zone d'étude ainsi que pour chaque cellule du modèle (98) dans celle-ci. Ils sont calculés en prenant, pour le modèle, la valeur moyenne de l'ensemble.

#### Corrélation de Pearson

Le coefficient de corrélation de Pearson est un outil souvent utilisé en prévisions météorologiques et climatiques, parce qu'il a des propriétés invariantes : le résultat ne varie pas en fonction des conditions (une correction du biais ne changera par exemple pas le résultat du test de corrélation) (Déqué, 2012). La corrélation de Pearson permet donc de mesurer l'association entre les valeurs prédites et observées. Elle se calcule avec l'équation 3.1.

$$\rho = \frac{Cov(f, o)}{\sqrt{V(f)V(o)}} \quad (3.1)$$

où  $f$  est la valeur prédite par le modèle et  $o$  la valeur observée,  $Cov()$  est la covariance et  $V()$  la variance.

#### Biais

Le biais provient du fait que le modèle présente des erreurs systématiques qui impactent tous les membres de l'ensemble (ECMWF, 2014). L'écart entre la moyenne des prévisions et la

moyenne des données de vérification, provenant de ces erreurs systématiques, est appelée biais, et peut varier en fonction de la saison, la région et le délai de mise en oeuvre (ECMWF, 2014). Ce biais provient d'une différence entre le climat moyen observé et l'état moyen de l'atmosphère et des océans modélisés (ECMWF, 2014). Le biais s'obtient grâce à la formule suivante :

$$B = \frac{1}{n} \sum_{i=1}^n (f_i - o_i) \quad (3.2)$$

où  $n$  est le nombre d'observations,  $f$  est la valeur prédite par le modèle pour l'observation  $i$  et  $o$  la valeur de vérification pour l'observation  $i$ .

Le biais est donc une mesure de précision.

### Erreur quadratique moyenne

L'erreur quadratique moyenne est également une mesure de précision. Elle est plus sensible aux larges erreurs à cause du terme quadratique (Déqué, 2012). Il faut donc rester vigilant quant à ce score qui va être très sensible aux *outliers* plutôt que de traiter la prévision comme un tout (Déqué, 2012). Elle s'obtient grâce à l'équation 3.3

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2 \quad (3.3)$$

où  $f$  est la valeur prédite par le modèle pour l'observation  $i$  et  $o$  la valeur de vérification pour l'observation  $i$ .

### 3.2.3 Correction du biais

La correction de biais se fait en post-traitement de la prévision. Elle sert à retirer, ou tout du moins minimiser, les erreurs systématiques du modèle. La figure 3.2 montre le nuage de points de la température observée en fonction de la température prédite des moyennes de températures sur la zone entre 1993 et 2015 pour une cellule du modèle durant le mois de janvier. En rouge la droite de régression linéaire pour ce nuage de points est tracée. Si le modèle était parfaitement ajusté, cette droite serait égale à la ligne en pointillés noirs traçant  $x = y$ . L'équation de cette droite de régression permet de corriger les données prédites par la suite : en remplaçant le  $x$  dans l'équation  $y = ax + b$  de la droite de régression par la valeur prédite, on obtient une valeur  $y$  plus proche de la réalité. Lors de l'utilisation de cette méthode, il faut toutefois être attentif à ne pas utiliser les données que l'on veut modifier pour réaliser la droite de régression. En effet, ne pas exclure les données étudiées mènerait à une surestimation de la capacité du modèle (Déqué, 2012). C'est pourquoi la correction de biais se réalisera grâce aux années antérieures à 2016 et sera appliquée de façon prospective entre 2016 et 2020.




FIGURE 3.2 – Températures observées en fonction des températures prédites pour une cellule de la zone d’étude au mois de janvier. La droite en pointillés est la droite  $y = x$ , la droite rouge est la droite de régression linéaire.

### 3.2.4 Calibration du modèle

#### Histogramme de rang

L’histogramme de rang (Figure 3.3), aussi appelé diagramme de Talagrand, est un moyen d’évaluer la fiabilité d’un modèle d’ensemble (Hamill, 2001). Il se construit en ordonnant les membres du modèle par ordre croissant, puis en comptabilisant où se situe la donnée de vérification dans cette série. La position de la donnée de vérification est enregistrée pour plusieurs prévisions, et l’histogramme de toutes ces positions est alors constitué. Étant donné que le nombre de membres diffère entre les *hindcasts* et les *forecasts*, seuls les 25 premiers membres des *forecasts* sont utilisés dans la construction des histogrammes de rang, afin d’éviter un biais dans leur analyse.

Un histogramme de rang uniforme est traditionnellement considéré comme désignant un modèle fiable, mais il faut toutefois rester critique par rapport à cette hypothèse, discutée de manière plus approfondie dans la section discussion de ce travail (Hamill, 2001).

Les histogrammes de rang seront ici réalisés avec les valeurs moyennes de température sur la zone d’étude pour chaque année, mais également par cellule de la zone pour les cinq années sur lesquelles la correction de biais est appliquée.

La figure 3.3 montre cinq résultats possibles pour un histogramme de rang. Si le modèle présente un biais négatif, un histogramme ressemblant à celui en haut à gauche sera obtenu : la donnée de vérification se placera souvent après le dernier membre du modèle, car celui-ci sous-évalue la valeur réelle de la variable recherchée. Un modèle avec un biais positif, au contraire, mènera à un histogramme de rang tel que celui en haut à droite de la figure, où la majorité des événements ont une valeur inférieure à celle prédite. Les diagrammes sur- et sous-dispersifs (les deux diagrammes du bas) montrent quant à eux des problèmes dans la variance de la prévision. Si cette variance est trop faible, beaucoup d’évènements extrêmes ne seront pas prédits, et beaucoup d’observations tomberont donc avant et après les membres du modèle. Au contraire, une variance trop importante fait que les membres centraux de la prévisions sont sur-représentés par rapport aux premiers et derniers membres. Un histogramme constant provient donc d’un

modèle à partir duquel les prévisions montrent une moyenne et une variance adaptées à la réalité.

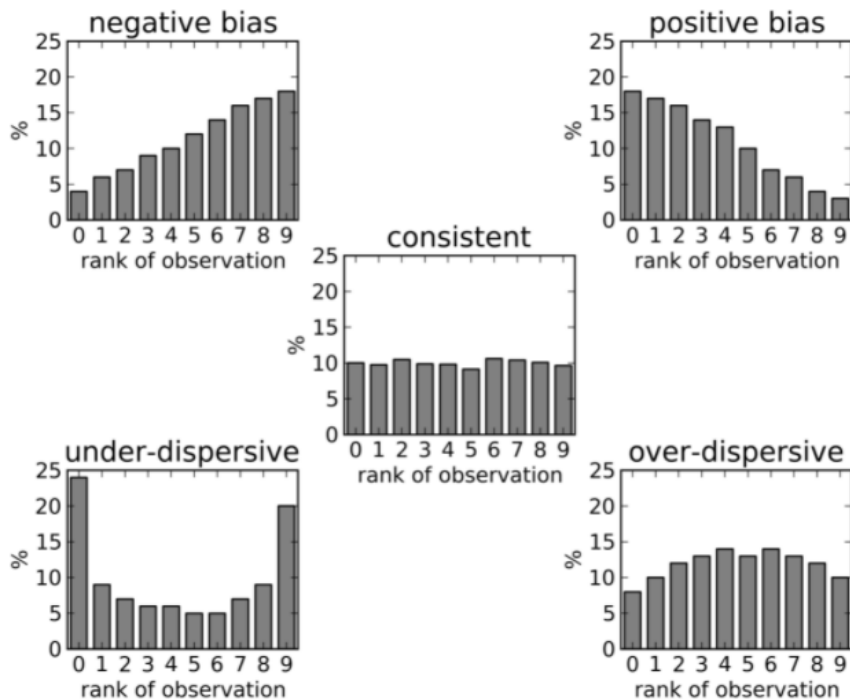


FIGURE 3.3 – Exemples d’histogrammes de rang pour un modèle à biais négatif (en-haut à gauche), à biais positif (en-haut à droite), sous-dispersif (en bas à gauche), sur-dispersif (en bas à droite) et constant (milieu) (Callado et al., 2013)

### Diagramme de fiabilité

Les diagrammes de fiabilités montrent, pour un évènement donné, si les probabilités de prévisions correspondent aux fréquences observées. Ainsi, pour un modèle parfaitement calibré, le diagramme de fiabilité suivrait la diagonale. En effet, dans un système probabiliste, prévoir un évènement à 70% signifie que celui-ci devrait se réaliser dans 70% des cas.

Le diagramme de fiabilité se construit en quatre étapes :

1. *Choix de l’évènement étudié*

Ici, les diagrammes de fiabilités (Figure 3.4) servent à étudier la fiabilité de prévisions d’évènements extrêmes par le modèle. Les évènements choisis sont une température inférieure au centile 33 ou supérieure au centile 66 des températures observées pour le mois étudié sur l’ensemble des années.

2. *Probabilité que l’évènement soit prédit*

L’axe des abscisses représente la probabilité que l’évènement soit prédit par les membres du modèle. Encore une fois, seuls les 25 premiers membres sont pris en compte. Donc pour chaque année, le nombre de membres ayant prédit l’évènement est comptabilisé.

3. *Sous-groupe de probabilité égale*

Les probabilités sont regroupées en tranches de 10% (0.1).

4. *Fréquence d’observation de l’évènement*

Pour chaque sous-groupe déterminé à l’étape 3, on observe la fréquence à laquelle l’évènement a bien été observé ces années-là.

Le biais du modèle est également à prendre en compte. En effet, si le diagramme de fiabilité est réalisé de cette manière sur les données avant que la correction de biais ne soit effectuée, les diagrammes montreront principalement ce biais : pour les mois où le biais systématique du modèle surestime les températures, les événements supérieurs au centile 66 seront sur-évalués, et inversement. Pour parer à cet inconvénient, deux solutions sont possibles. Soit réaliser le diagramme à partir des valeurs prédites corrigées, soit considérer l'événement comme prédit s'il se situe dans la partie supérieure (inférieure) à 66% (33%) de la distribution des valeurs prédites et de calculer la probabilité d'observation de ce même événement à partir de la distribution des valeurs observées. Afin d'avoir un plus grand nombre d'observations et ainsi obtenir un résultat interprétable et significatif, les diagrammes de fiabilité seront réalisés par cellule du modèle, et non sur la moyenne de la zone d'étude. Cependant, même si cette méthode permet d'augmenter la taille de l'échantillon des observations, elle ajoute également de l'autocorrélation spatiale dans les diagrammes, car les différents événements ne peuvent plus être considérés comme indépendants les uns des autres.

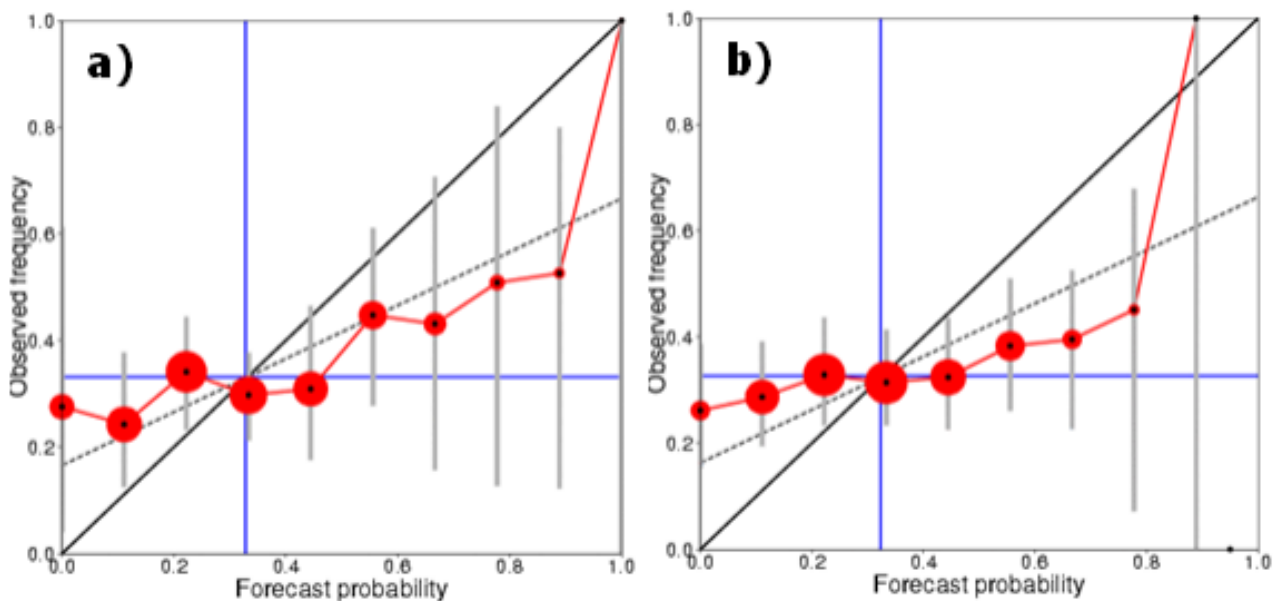


FIGURE 3.4 – Exemples de diagrammes de fiabilité de prévisions saisonnières d'été avec le système 3 de l'ECMWF, pour a) la température de surface et b) les précipitations au-dessus du deuxième tercile (1981-2005) (Doblas-Reyes, 2010). Les lignes bleues indiquent la climatologie, la taille des cercles représente la fréquence relative de chaque probabilité de prévision, les barres grises donnent l'intervalle de confiance à 95% de la fréquence d'observation relative.

# Chapitre 4

## Résultats

### 4.1 Indicateurs de fiabilité du modèle

#### 4.1.1 Moyenne sur la zone d'étude

##### Moyennes de températures

En première étape, les prévisions de l'ECMWF ainsi que les prévisions de contrôle ont été comparées aux données de vérification (ERA5) pour l'ensemble de la zone d'étude (Figure 4.1).

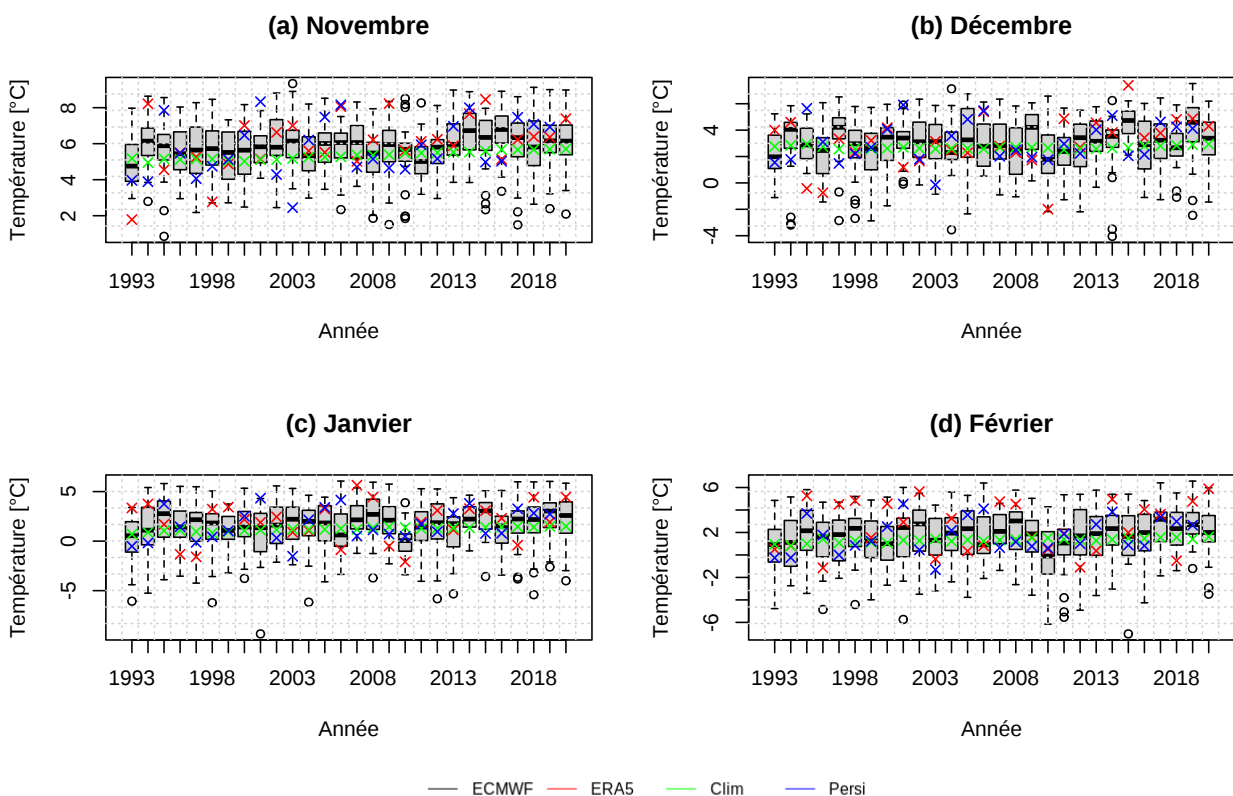


FIGURE 4.1 – Valeurs des moyennes de température prédites et observées pour (a) novembre, (b) décembre, (c) janvier et (d) février. En noir sont représentées les prévisions de l'ECMWF avec un intervalle de confiance à 95% ainsi que les outliers de ces prévisions. Les croix bleues représentent les valeurs moyennes pour la zone d'étude prédites par la persistance en anomalies, les croix vertes celles prédites par la moyenne climatologique et les croix rouges les données de vérification.

La figure 4.1 montre, pour l'ensemble de la zone d'étude, les valeurs prédites et les valeurs de vérification. On peut y remarquer qu'au fur et à mesure du temps, un biais négatif s'installe dans le modèle : si en novembre et en décembre les valeurs de vérification sont réparties de part et d'autre de la médiane de la prévision de l'ECMWF, pour les mois de janvier et surtout de février de plus en plus de valeurs de vérification se situent dans la partie supérieure de la distribution du modèle. Cette même tendance est notée dans le tableau 4.1, où le biais de la prévision devient de plus en plus négatif avec le temps. Cependant les biais de novembre et de décembre ne suivent pas cette tendance, vu que celui de décembre est le plus faible des quatre mois étudiés.

En outre, les prévisions en moyennes climatologiques et en persistance en anomalies sont également présentes sur cette figure. On peut remarquer que les valeurs pour la persistance en anomalies sont bien plus variables d'une année à l'autre que celles pour la moyenne climatologique. Cela s'explique facilement : pour la moyenne climatologique, une année, même extrême ne pourra avoir un impact très important étant donné que sa valeur sera moyennée par celles de toutes les années précédentes, contrairement à la persistance en anomalies où cette valeur extrême va impacter directement la prévision. Contrairement au modèle de l'ECMWF, ces deux prévisions de contrôle ne semblent pas présenter de biais systématique. Elles ne sont en effet pas soumises au biais systématique croissant inhérent au modèle dynamique, lié aux incertitudes de la prévision.

### Corrélations de Pearson, biais et erreurs quadratiques moyennes

Différents indicateurs ont été calculés sur l'ensemble de la zone d'étude pour chaque mois entre novembre et février : les corrélations de Pearson, le biais et l'erreur quadratique moyenne (Tableau 4.1).

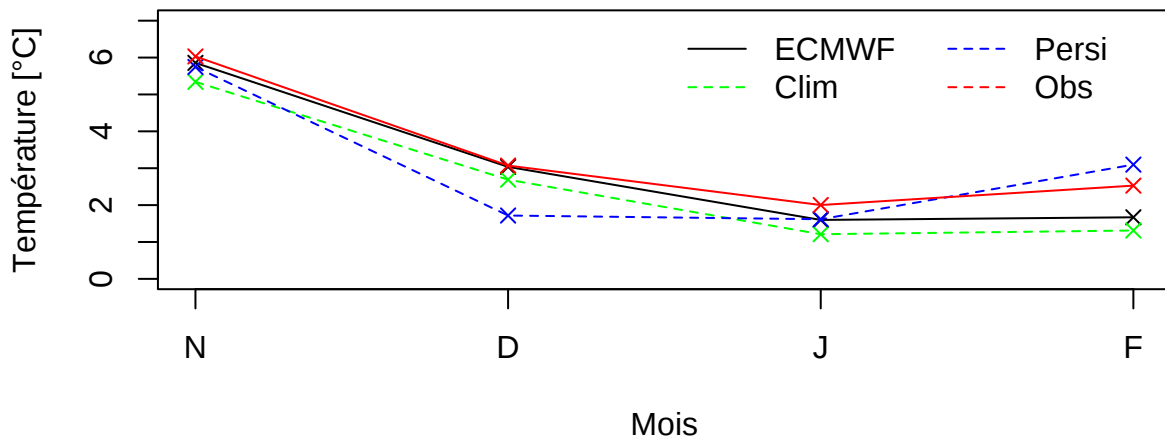


FIGURE 4.2 – Dérive du modèle de prévision saisonnière en fonction du temps. La courbe noire montre les températures moyennes prévues pour chaque mois par le modèle de l'ECMWF, la verte les températures moyennes prévues par la moyenne climatologique, la bleue les températures moyennes de la persistance en anomalies et la rouge la moyenne des données de vérifications.

Le tableau 4.1 résume donc les indicateurs étudiés pour l'ensemble de la zone et pour chacun des mois d'hiver. Si les corrélations de Pearson sont plus élevées pour le modèle de l'ECMWF, les biais de ce dernier sont plus importants que pour la persistance en anomalies pour tous les mois, excepté pour le mois de janvier. Comme mentionné précédemment, le biais du modèle pour le mois de décembre est plus faible que celui de novembre. Ceci est plutôt contre-intuitif, étant donné que le modèle a été initialisé au premier octobre de chaque année. En effet, un modèle dynamique a tendance, avec le temps et à cause de ses incertitudes, à s'éloigner de la climatologie observée. En toute logique, le biais de novembre devrait donc être plus faible que celui de décembre. D'ailleurs, la figure 4.2 montre cet éloignement entre le modèle de l'ECMWF et la climatologie. Une explication de cette incohérence pourrait venir d'une "annulation" du biais plus importante en décembre qu'en janvier : le biais est ici calculé sur l'ensemble de la zone d'étude. Au plus le nombre de cellules présentant un biais négatif sera proche du nombre de celles présentant un biais positif (avec des amplitudes de biais équivalentes), au plus le biais sera diminué, car les biais positifs compenseront les négatifs. La figure 4.7 semble en effet montrer légèrement plus de biais positifs pour le mois de décembre que celui de novembre. Un autre argument en faveur de cette hypothèse sont les valeurs d'erreurs quadratiques moyennes : celles-ci sont bien croissantes en fonction du temps (Tableau 4.1). Le tableau 4.1 est également illustré par la figure 4.3. La dérive du modèle est peu visible sur ces figures, à part pour les erreurs quadratiques moyennes.

TABLE 4.1 – Corrélations de Pearson, biais et erreurs quadratiques moyennes entre la température à deux mètres prédite par le modèle de l'ECMWF ou par les deux prévisions de contrôle et les valeurs de vérification de ERA5, pour les mois de novembre à février.

<b>Novembre</b>	<b>ECMWF</b>	<b>Moyenne climatologique</b>	<b>persistance en anomalies</b>
Corrélation de Pearson	0.41	0.25	0.10
P-valeurs	0.03199	0.2042	0.6087
Biais [°C]	-0.17	-0.65	-0.24
MSE [°C]	1.92	2.60	4.17
<b>Décembre</b>	<b>ECMWF</b>	<b>Moyenne climatologique</b>	<b>persistance en anomalies</b>
Corrélation de Pearson	0.44	-0.04	0.01
P-valeurs	0.01888	0.8227	0.9421
Biais [°C]	-0.03	-0.35	0.07
MSE [°C]	3.08	4.00	6.01
<b>Janvier</b>	<b>ECMWF</b>	<b>Moyenne climatologique</b>	<b>persistance en anomalies</b>
Corrélation de Pearson	0.36	-0.09	-0.06
P-valeurs	0.05626	0.6379	0.7821
Biais [°C]	-0.40	-0.71	-0.30
MSE [°C]	3.56	4.51	6.61
<b>Février</b>	<b>ECMWF</b>	<b>Moyenne climatologique</b>	<b>persistance en anomalies</b>
Corrélation de Pearson	0.51	-0.05	0.13
P-valeurs	0.005086	0.8068	0.5036
Biais [°C]	-0.86	-1.10	-0.69
MSE [°C]	4.65	5.98	6.45




FIGURE 4.3 – Biais, corrélation de Pearson et erreur quadratique moyenne en fonction des mois. La courbe noire représente le modèle de l’ECMWF, la verte la moyenne climatologique et la bleue la persistance en anomalies.

## Histogrammes de rang

Les histogrammes de rang montrent que si les prévisions proches de la date d’initialisation présentent une répartition plus ou moins uniforme de leur rang, c’est moins le cas pour la fin de la prévision. En effet, l’histogramme de rang de février semble montrer un biais négatif (Figures 3.3, 4.4). Toutefois, le fait que peu d’années soient étudiées complique les analyses. Ainsi, pour chaque mois, beaucoup de rangs non-représentés sont observés. De plus, dans les rangs représentés, beaucoup ne le sont que pour une année. Peut-on vraiment considérer cela représentatif lorsque le nombre d’années total n’est que de 28, alors que l’histogramme est réalisé sur 25 membres ?

Pour remédier au problème du nombre d’observations trop faible, des histogrammes de rang sont réalisés en prenant en compte chaque cellule du modèle, et non plus la température moyenne de la zone. Ceci permet un plus grand nombre d’observations, mais amène un autre problème : les observations ne peuvent plus être considérées comme indépendantes les unes par rapport aux autres. Les histogrammes de rang résultants peuvent donc se retrouver biaisés.

Pour réaliser ces nouveaux histogrammes, ce sont les données corrigées (voir section 3.2.3, *Correction du biais*) qui ont été utilisées, afin de limiter l’effet du biais systématique du modèle sur les résultats. La correction a ici été effectuée sur chaque membre du modèle séparément, et non pas sur la moyenne de ceux-ci comme pour la correction du biais (Figure 4.5).

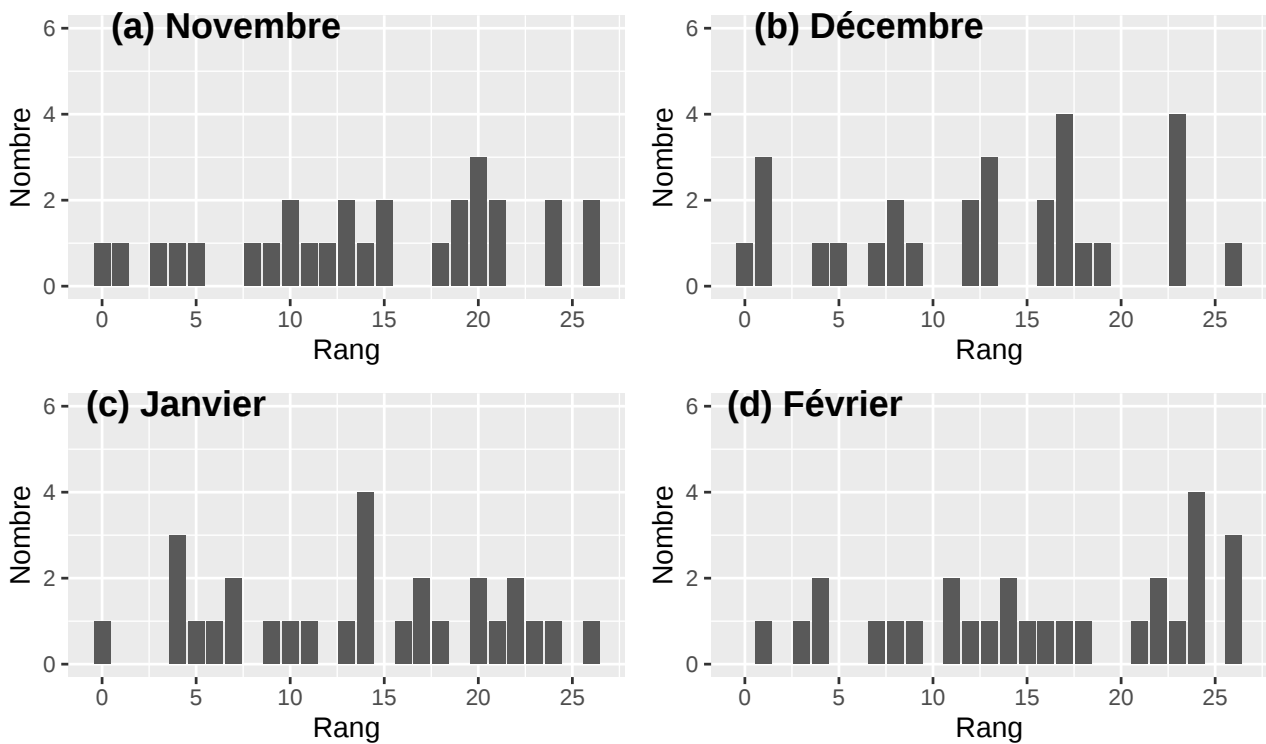


FIGURE 4.4 – Histogrammes de rang pour les mois de (a) novembre et (b) janvier.

La figure 4.5 montre clairement une sous-dispersion du modèle, et ce pour tous les mois. Cela signifie que le modèle est trop confiant, il a une variance trop faible, ce qui entraîne qu'un grand nombre d'évènements observés ont lieu en-deçà ou au-delà des évènements prédits. Les diagrammes de fiabilité réalisés plus loin pourront aider à confirmer cette sous-dispersion du modèle.

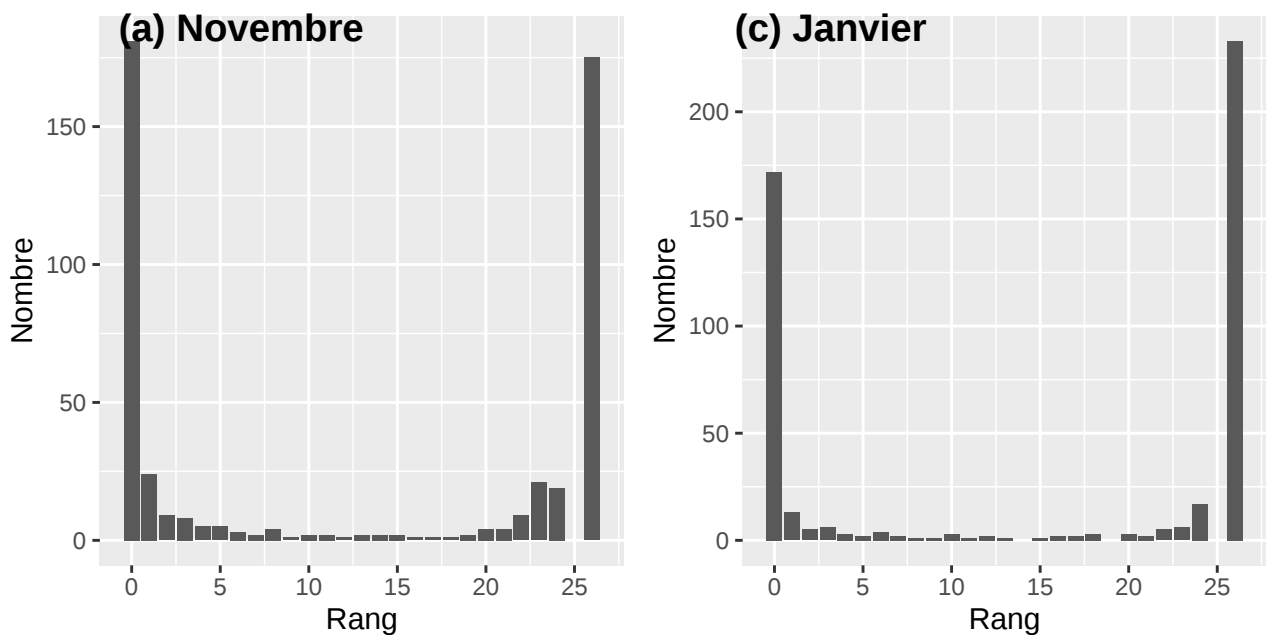


FIGURE 4.5 – Histogramme de rang des cellules corrigées du modèle de l'ECMWF entre 2016 et 2020 pour (a) novembre (b) décembre (c) janvier et (d) février.

## 4.1.2 Moyenne temporelle par cellule du modèle

### Corrélation de Pearson

Les corrélations sont significatives pour toutes les cellules du modèle, et ce pour tous les mois. Par contre, pour les prévisions de contrôle, seules quelques cellules le sont (une pour la moyenne climatologique et 16 pour la persistance en anomalies) pour le mois de novembre. Le tableau 4.1 montre d'ailleurs des corrélations de Pearson non significatives pour l'ensemble de la zone pour les deux prévisions de contrôle. Une corrélation plus élevée que sur le continent se remarque sur la mer, provenant sans doute de la plus grande inertie de l'océan, qui lui confère une plus grande prévisibilité.

La figure 4.6 montre que le modèle de l'ECMWF présente de manière générale une meilleure corrélation avec les données de vérification que les deux prévisions de contrôle.

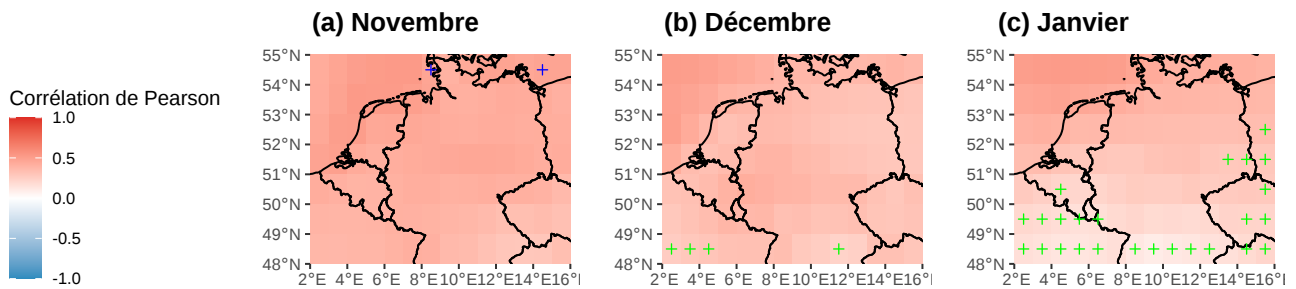


FIGURE 4.6 – Corrélation de Pearson entre les températures de surface prévues par le modèle de l'ECMWF et les données de vérification pour les mois de (a) novembre, (b) décembre et (c) janvier, de 1993 à 2020. Les croix bleues (vertes) sont placées là où la persistance en anomalies (la moyenne climatologique) présente une meilleure corrélation que le modèle de l'ECMWF.

La corrélation est une mesure de l'association linéaire entre les valeurs prédites et les valeurs observées. Une valeur faible de corrélation n'implique donc pas que les deux variables (ici la moyenne climatologique ou la persistance en anomalies et les données de vérification) sont indépendantes, elles peuvent avoir une relation non-linéaire (Déqué, 2012).

### Biais et sa correction

La figure 4.7 présente le biais par cellule du modèle, en le comparant aux deux prévisions de contrôle. Sur cette figure, on se rend compte que les prévisions de contrôle montrent un biais plus faible pour la quasi totalité de la zone d'étude, et ce dès le mois de novembre. La persistance en anomalies montre en outre une meilleure performance en ce qui concerne le biais que la moyenne climatologique.

Il est possible de lier ces cartes à la figure 4.1. En effet, la figure 4.7 montre des biais à la fois positifs et négatifs pour les mois de novembre et décembre, et des biais essentiellement négatifs pour le mois de février. Cela confirme la première impression obtenue grâce à la figure 4.1, où la même tendance se dégage.

Toutefois, la figure 4.7 montre une contradiction avec le tableau 4.1 et la figure 4.3. Ces deux derniers présentent le biais de la moyenne climatologique comme plus important que celui du modèle de l'ECMWF, or la figure 4.7 montre que ce n'est pas le cas pour de nombreuses

cellules. Cette divergence dans les résultats pourrait provenir de sources diverses : une meilleure compensation des biais pour la prévision de l'ECMWF que pour la moyenne climatologique, comme présentée précédemment pour expliquer le plus grand biais de novembre par rapport à décembre, ou bien des biais extrêmement élevés de la moyenne climatologique pour les cellules où le biais n'est pas plus faible que celui du modèle de l'ECMWF.

Le modèle de l'ECMWF montre donc une meilleure performance que les prévisions de contrôle en ce qui concerne les corrélations de Pearson, mais présente un biais plus élevé. Afin d'améliorer ces résultats, une correction du biais est proposée. Cette correction étant linéaire, elle n'affectera pas les résultats des corrélations, mais elle pourra par contre permettre une meilleure performance en ce qui concerne le biais du modèle.

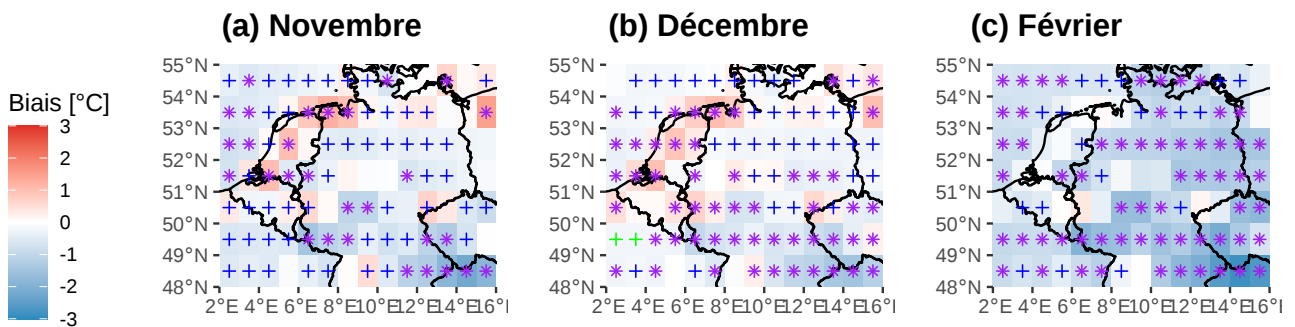


FIGURE 4.7 – Biais de température de surface du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a un biais moins élevé que le modèle. Les étoiles mauves montrent les cellules où les deux prévisions de contrôle ont un biais plus faible que celui du modèle de l'ECMWF.

La correction du biais permet effectivement de diminuer celui-ci, comme le montre la figure 4.8, où les biais sont plus faibles qu'à la figure 4.7. Toutefois, même après la correction, beaucoup de cellules du modèle de l'ECMWF présentent toujours un biais plus important que celui des prévisions de contrôle. De plus, si en février la correction permet une réduction du nombre de cellules présentant un biais inférieur pour la moyenne climatologique, l'inverse est observé en novembre. Ceci peut venir du peu d'années utilisées pour calculer le biais corrigé : les cartes de la figure 4.8 ont été réalisées sur quatre années (de 2016 à 2019) au lieu des 27 utilisées précédemment, afin de ne pas surévaluer la performance du modèle en utilisant les années qui ont servi à réaliser la régression linéaire qui a permis de corriger les données. Les valeurs de biais sont par conséquent plus dépendantes du biais de chaque année que précédemment, ce qui pourrait causer cette meilleure performance de la moyenne climatologique en novembre. En effet, la figure 4.1 montre pour le mois de novembre pour ces quatre années une valeur de moyenne climatologique plutôt proche des valeurs de vérification, ce qui n'est pas toujours le cas lorsqu'on observe l'ensemble des années étudiées. Le même constat peut-être dressé pour décembre.

Il est également visible sur la figure 4.8 que le biais corrigé devient totalement positif pour novembre et totalement négatif pour décembre, alors que le biais de la prévision brute présente pour ces deux mois des biais à la fois positifs et négatifs. Ceci pourrait également venir du fait que la correction n'a été appliquée que sur quatre années. Pour peu que ces quatre années

en comprenant une avec un biais beaucoup plus faible (conséquent) que la moyenne, ou que toutes ces quatre années présentent des biais légèrement plus faibles (élevés) que la moyenne, la correction de biais pourrait avoir cet effet.

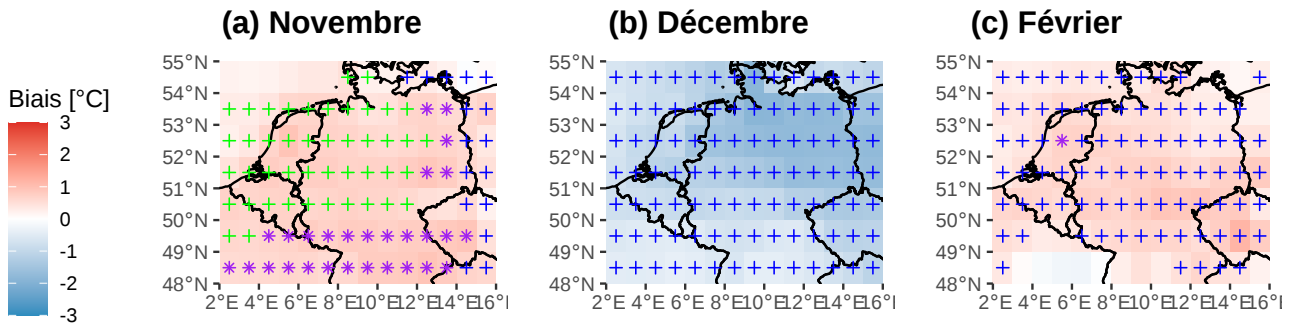


FIGURE 4.8 – Biais corrigé du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a un biais moins élevé que le modèle.

### Erreur quadratique moyenne

L'erreur quadratique moyenne est plus sensible aux *outliers*, à cause de son terme quadratique. Il faut donc rester prudent vis-à-vis de ce score : une seule année avec une erreur de prévision importante peut largement détériorer le score de prévision, en dépit d'une bonne performance pour les autres années (Déqué, 2012). Ceci pourrait expliquer la grande différence de performance des deux prévisions de contrôle pour l'erreur quadratique moyenne par rapport au biais (Figures 4.7, 4.9). En effet, si pour le biais bon nombre de cellules présentent un biais moins important pour les prévisions de contrôle que pour le modèle de l'ECMWF, c'est loin d'être le cas pour l'erreur quadratique moyenne. Cette différence de performance pourrait venir de la définition même des prévisions de contrôle utilisées ici : la moyenne climatologique, par définition, ne prévoit pas les événements extrêmes, et pour que la persistance en anomalies les détecte il faut qu'ils soient déjà présents dans les conditions initiales au mois d'octobre, le mois d'initialisation de cette prévision. Ce manque de prévisibilité des événements extrêmes pour les deux prévisions de contrôle tend donc à diminuer grandement leur performance en ce qui concerne l'erreur quadratique moyenne.

Jusqu'ici, seule la moyenne de l'ensemble a été étudiée. Ce choix a été fait afin de réduire le bruit lié au caractère chaotique de l'atmosphère. En prenant la moyenne de l'ensemble, on augmente donc la performance du modèle. Cependant, on y perd également en dispersion. C'est pourquoi la prochaine section consiste en une analyse de la prévisibilité des événements extrêmes par le modèle.

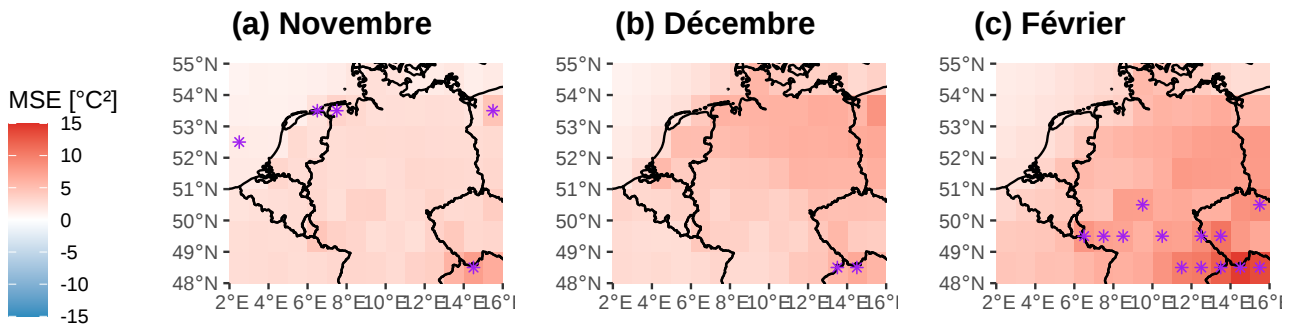


FIGURE 4.9 – Erreur quadratique moyenne du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a une erreur quadratique moyenne moins élevée que le modèle.

## 4.2 Évènements extrêmes

### 4.2.1 Diagrammes de fiabilité

Les diagrammes de fiabilité servent à établir si les probabilités prédites correspondent aux fréquences observées pour un évènement donné. La figure 4.10 montre ces diagrammes pour deux évènements de la distribution observée sur la période 1993-2020 : "la température sera inférieure au centile 33" (dans le premier tercile), en bleu ; et "la température sera supérieure au centile 66" (dans le dernier tercile), en rouge. Ces classes sont celles habituellement analysées dans les prévisions saisonnières (Figure 1.1). Un modèle bien ajusté pour la prévision d'évènements extrêmes montrera une probabilité de prévision égale à la fréquence observée. La figure 4.10 montre que le modèle est plutôt bien ajusté pour prédire les températures inférieures (supérieures) au centile 33 (66). On peut y remarquer toutefois une légère sous-dispersion du modèle, ce qui concorde avec les histogrammes de rang de la figure 4.5.

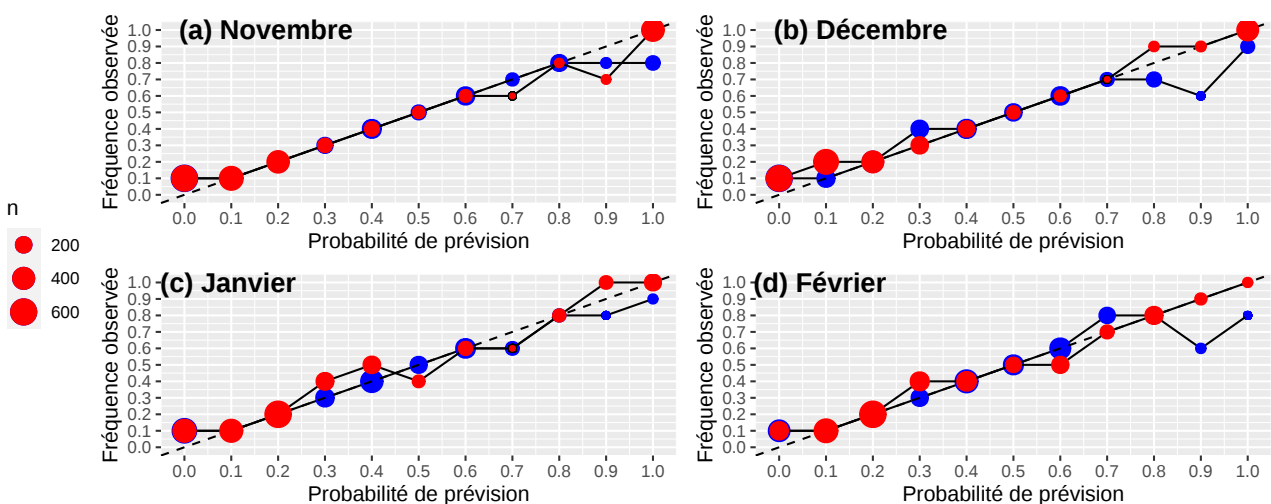


FIGURE 4.10 – Diagrammes de fiabilité par cellule du modèle de l'ECMWF pour (a) novembre, (b) décembre, (c) janvier et (d) février 1993 à 2020. Les points bleus représentent les valeurs inférieures au premier tercile, les rouges supérieurs au deuxième. La taille des cercles représente le nombre d'observations pour une probabilité donnée.

## 4.2.2 Cas particulier : l'hiver 2009-2010

L'analyse statistique globale réalisée jusqu'ici permet une vue d'ensemble des différents indicateurs, mais elle agrège également par définition toutes les années, et ne permet donc pas de comprendre ce qui se passe avec une granularité au niveau de l'année. Une année particulière va donc ici être analysée pour parer à cette problématique, l'hiver 2009-2010.

L'hiver 2009-2010 a été particulier en Europe. En effet, un automne doux a été suivi par de multiples vagues de froid. Les vagues de froids ont été causées par une oscillation Nord-Atlantique négative, autrement dit le géopotential présentait une anomalie positive au pôle Nord qui devenait plus négative vers l'équateur (Fereday et al., 2012). Cette oscillation négative est visible sur la figure 4.14b. Les valeurs négatives de la NAO causent des anomalies dans les vents de surface provenant du nord, entraînant l'advection d'air arctique (et donc froid) vers le sud (Wang et al., 2010). L'effet de cette NAO négative en hiver est représenté sur la figure 4.11.

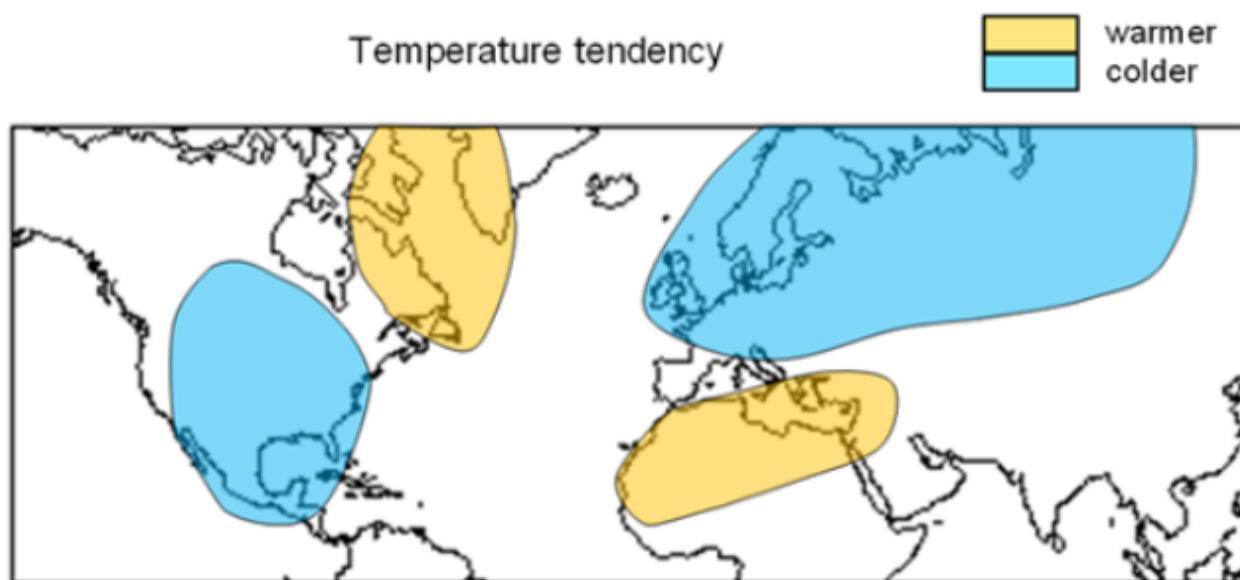


FIGURE 4.11 – Effet d'une NAO négative en hiver sur les températures (MetOffice, s. d.).

La figure 4.12 présente la distribution prédite par les membres du modèle de l'ECMWF pour les mois de janvier et février 2010. À cette distribution a été ajoutée la température observée, ainsi que la distribution des températures pour les mois équivalents entre 1993 et 2020 (en omettant 2010). La température observée en janvier 2010 est particulièrement faible, avec une moyenne sur la zone d'étude en dessous de  $-2^{\circ}\text{C}$ , alors que la température la plus basse pour ce même mois, toutes autres années confondues entre 1993 et 2020, est située aux alentours de  $-1.6^{\circ}\text{C}$  (Figure 4.12). La moyenne de température observée en février ( $0.5^{\circ}\text{C}$ ) est bien dans la distribution de la climatologie de ce mois (dont le minimum de température est aux environs de  $-1^{\circ}\text{C}$ ), mais février 2010 a tout de même connu une vague de froid mi-février (Magdelaine, 2010). La figure 4.12 montre également que la moyenne de température observée pour les mois de janvier et de février 2010 se retrouvent dans la distribution des moyennes de températures des différents membres du modèle. Le modèle a prédit avec 13% que des températures plus basses que celles observées se produiraient. La température observée en janvier n'était donc pas improbable d'après le modèle, alors qu'il l'était bien plus pour la moyenne climatologique.

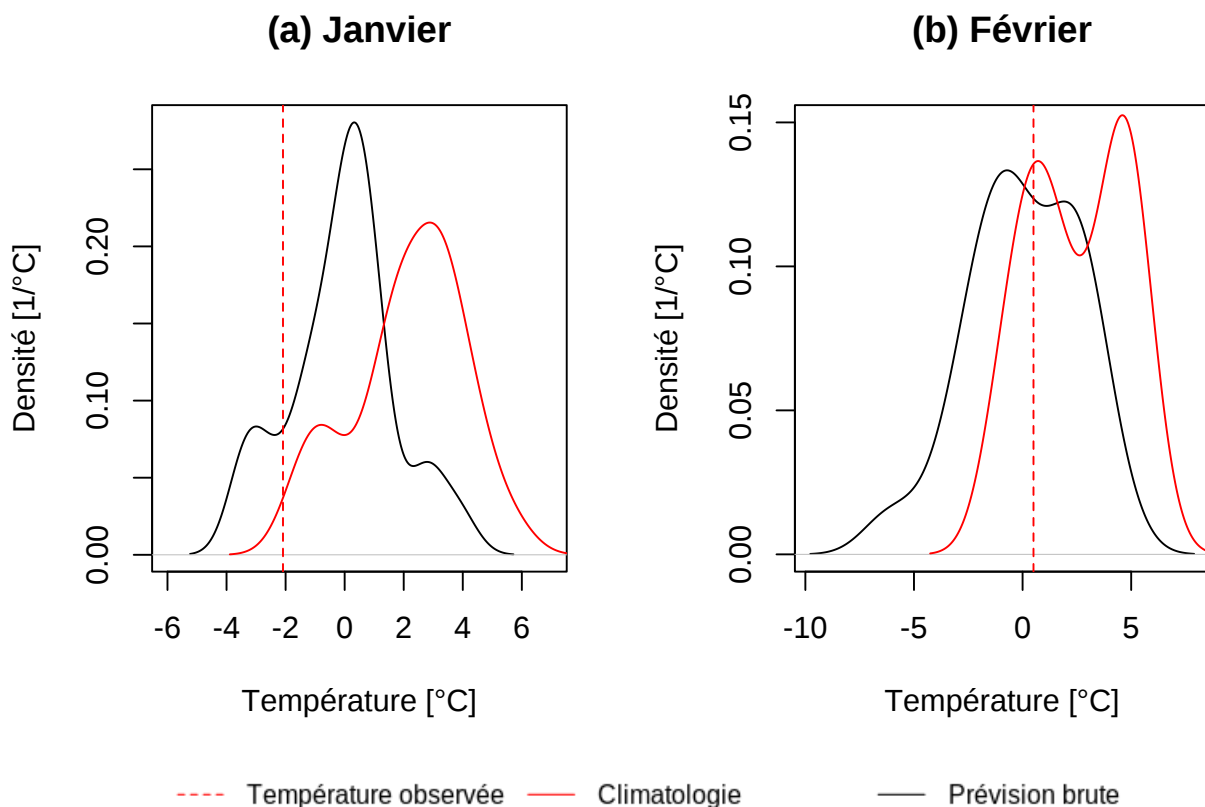


FIGURE 4.12 – Distribution prévue et température observée en (a) janvier et (b) février 2010.

Mais le modèle a-t-il effectué une prévision acceptable pour les bonnes raisons? A-t-il su prévoir la NAO négative? Pour répondre à ces questions, la figure 4.13 a été réalisée. Celle-ci présente les géopotentiels moyens observés entre 1993 et 2009 ainsi que l'anomalie de géopotentiel observée pour janvier et février 2010. La NAO négative est particulièrement visible en février.

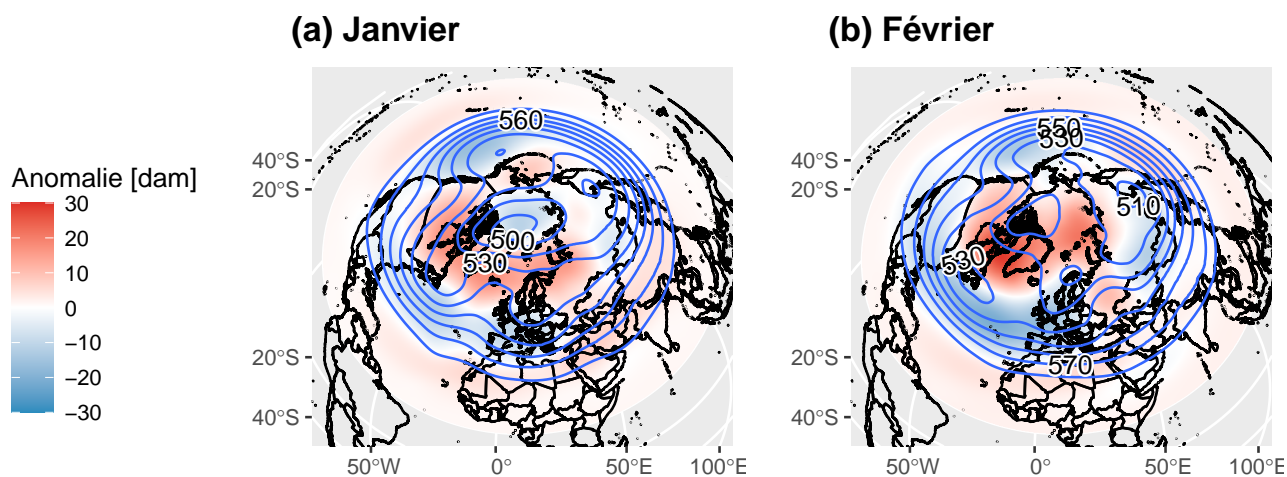


FIGURE 4.13 – Géopotentiel moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotentiel observés, en (a) janvier 2010 et (b) février 2010 (champ coloré).

Les mêmes cartes ont ensuite été réalisées avec les valeurs de géopotentiel à 500hPa prédites

par le modèle (Figure 4.14). Le dipôle visible à la figure 4.13 (anomalie positive sur l'Islande, négative sur les Açores) se retrouve à la figure 4.14. L'anomalie prédite est cependant moins importante que celle observée (aux alentours de 10 dam contre 20 dam).

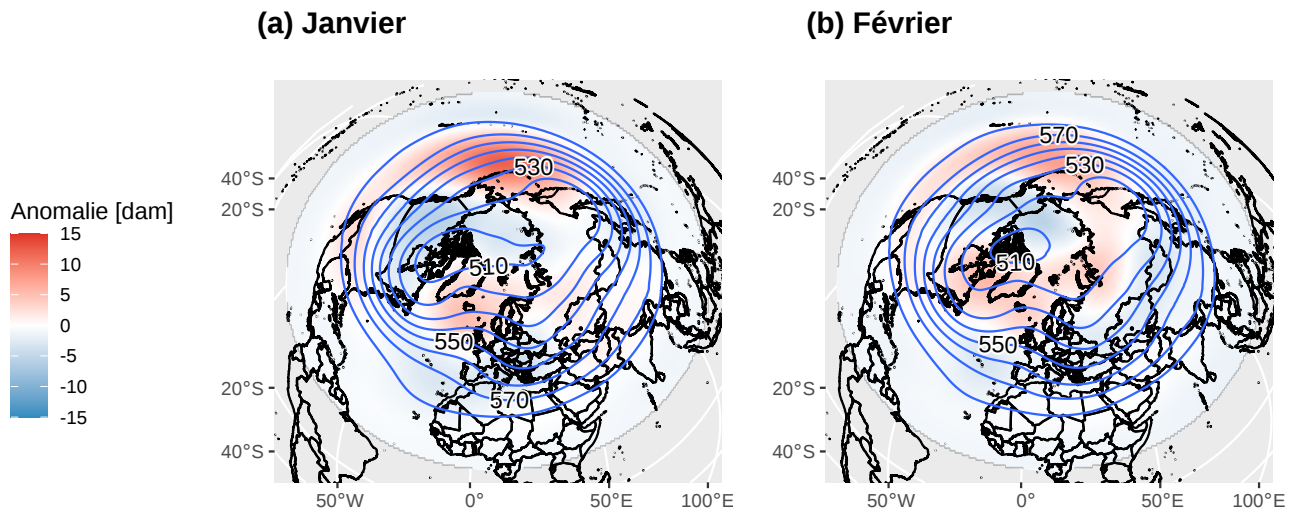


FIGURE 4.14 – Géopotential moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotential prédits, en (a) janvier 2010 et (b) février 2010 (champ coloré).

Le modèle a donc bien su prévoir les températures extrêmes de l'hiver 2009-2010, mais n'a pas prédit l'amplitude de l'anomalie de géopotential qui a mené à cet évènement, ou tout du moins pas avec une initialisation du modèle en octobre.

# Chapitre 5

## Discussion

### 5.1 Evaluation du modèle

#### 5.1.1 Indicateurs

Si le modèle obtient de meilleurs scores de corrélations de Pearson et d'erreurs quadratiques moyennes que les prévisions de contrôle pour tous les mois, ce n'est pas le cas pour le biais (Table 4.1). En effet, si le biais moyenné sur la zone d'étude est plus faible pour le modèle en novembre et en décembre, la persistance en anomalies montre un meilleur score pour janvier et février. En outre, lorsque le biais est spatialisé, de nombreuses cellules présentent un biais moins important pour au moins une des prévisions de contrôle, principalement la persistance en anomalies (Figure 4.7). Au cours du temps, on peut observer l'effet de la dérive du modèle, avec de plus en plus de cellules qui présentent un biais moins important pour les deux prévisions de contrôle en même temps. Ainsi, si en novembre seule une petite partie des cellules présente un biais moins important pour les deux prévisions de contrôle, en février c'est le cas pour la majorité d'entre-elles. La figure 4.2 montre d'ailleurs les températures moyennes prédites par le modèle de l'ECMWF s'écarter avec le temps de la température moyenne des données de vérification.

Cependant, un meilleur résultat des prévisions de contrôle par rapport au modèle n'est pas forcément imputable uniquement à celui-ci. En effet, seule la moyenne de chaque membre du modèle a été prise en compte pour effectuer ces calculs, afin de limiter le bruit lié au caractère imprévisible de l'atmosphère. Mais en utilisant uniquement cette moyenne, l'information donnée par le modèle se retrouve réduite, puisqu'il perd de sa dispersion. Ainsi, la figure 4.1 montre bien que pour la plupart des années les valeurs de vérification se situent dans l'ensemble de la prévision, elles ne sont juste pas spécialement proches de la moyenne de celui-ci, ce qui se traduit par ce biais parfois plus élevé que celui des prévisions de contrôle.

Un biais sur la moyenne du modèle est problématique : la moyenne donnée influence les décisions des utilisateurs. Si cette moyenne est biaisée, les décisions risquent de ne pas être adéquates. Prenons l'exemple d'un agriculteur qui ne peut semer ses plantations s'il fait moins de 0°C. Si la prévision présente un biais positif, il pourrait, sur base des prévisions du modèle, semer alors que des périodes de gel arrivent, ce qui entraînerait des pertes pour lui.

La correction effectuée sur le biais apporte des résultats assez satisfaisants. En effet, avec une correction a posteriori aisée à mettre en place et peu demandeuse en temps de calculs, les résultats se trouvent déjà assez bien améliorés. Le biais maximal du modèle pour les quatre mois étudiés est réduit, et le nombre de cellules où les deux prévisions de contrôle sont meilleures que

le modèle diminue fortement. Il reste cependant de nombreuses cellules où une des prévisions de contrôle reste meilleure que le modèle. Ceci peut venir de plusieurs raisons. Une première est le nombre d'années très faible (quatre ans) sur lequel ces biais ont été calculés qui, comme expliqué précédemment, fait que chaque année a un impact bien plus important sur le biais total et peut donc faire qu'un seul événement non prévu augmente fortement le résultat. Une autre raison est, comme mentionné ci-avant, l'utilisation de la moyenne de l'ensemble dans les calculs plutôt que de prendre en compte la prévision du modèle dans son entièreté. En tout cas, la correction de biais appliquée ici ne suffit évidemment pas à rendre le modèle parfait. Elle ne règle en rien les problèmes du modèle. En effet, ces résultats améliorés ne proviennent pas d'une meilleure connaissance du système, ou d'une augmentation de la compétence en modélisation, mais bien d'une correction artificielle et statistique provenant d'une connaissance des observations préalables. Toutefois, avec les changements climatiques que nous connaissons aujourd'hui, la question se pose de savoir pour combien de temps ces corrections artificielles pourront être valables. En effet, si la tendance des températures d'une région change au cours du temps, cette méthode de correction ne sera plus efficace, ou tout du moins pas avant que des observations pour un certain nombre d'années avec cette nouvelle tendance ne soient disponibles. Il paraît dès lors important de continuer à travailler sur la modélisation en tant que telle plutôt que de se concentrer sur des corrections a posteriori, même si celles-ci montrent une certaine efficacité.

Les analyses montrent également, comme mentionné précédemment, que l'éloignement de la date d'initialisation du modèle cause une erreur grandissante dans la prévision (Figure 4.2). À cause des erreurs dans le modèle, la prévision dérive du climat observé (Doblas-Reyes, 2010). La dérive est l'évolution de l'erreur systématique du modèle avec la durée de prévision (Doblas-Reyes, 2010). En effet, l'erreur systématique du modèle dépend de la région, de la saison mais également de l'échéance de prévision du modèle (ECMWF, 2014). Doblas-Reyes (2010) a étudié la dérive du troisième système du modèle de l'ECMWF. Il a établi que le modèle présente en hiver un biais chaud sur le nord de l'Europe et froid dans le sud de la Méditerranée, tandis qu'en été le sud-est de l'Europe présente un biais chaud (Figure 5.1) (Doblas-Reyes, 2010). Ceci ne concorde pas tout à fait avec les résultats obtenus ici, où le mois de novembre présente en effet un biais positif pour certaines cellules de la zone mais quand même un biais majoritairement négatif au total. Au niveau de l'amplitude du biais, il semble assez similaire entre le système 3 et le SEAS5, en tout cas avant correction, mais il est difficile de l'affirmer avec certitude sans les données exactes.

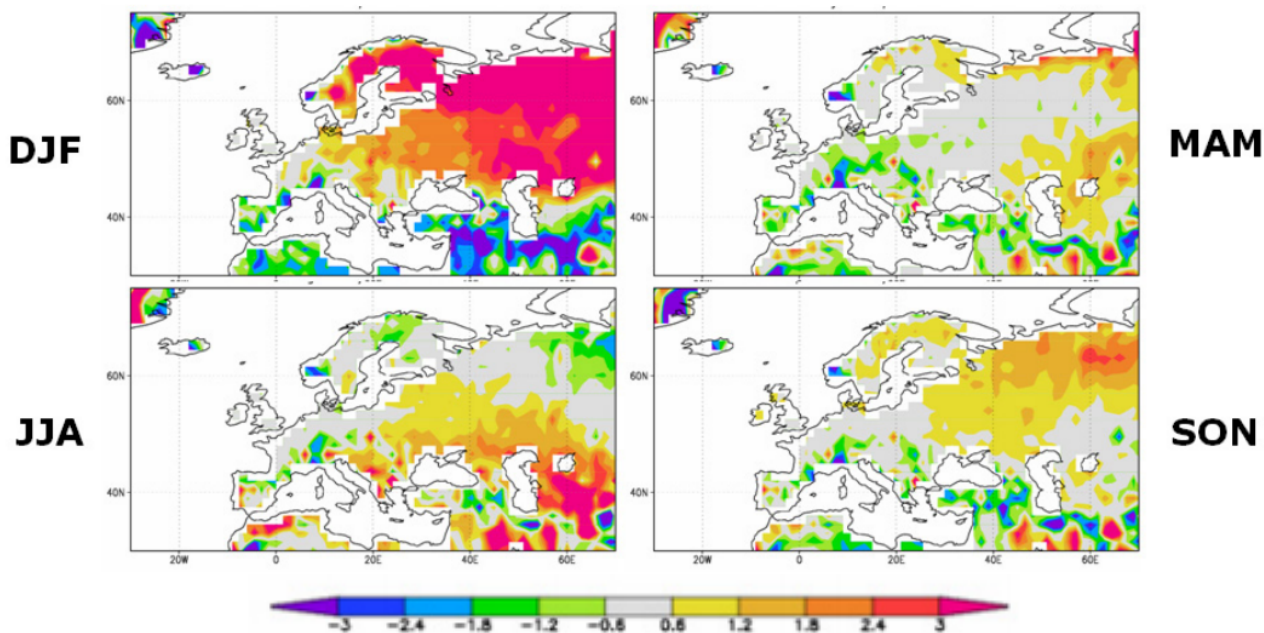


FIGURE 5.1 – Erreur systématique de la valeur moyenne de température de surface du système 3 de l’ECMWF (un mois d’échéance de prévision, de 1981 à 2005) (Doblas-Reyes, 2010).

Le biais négatif observé pour la zone d’étude concorde avec l’étude menée par Roberts et al. (2018). Ils ont établi que le modèle SEAS5 présente un biais froid, qui est accentué par le couplage avec le modèle océanique NEMO (Figure 5.2). L’amplitude du biais donné par (Roberts et al., 2018) à la figure 5.2 semble également concorder avec les résultats obtenus ici (biais maximum à  $-2.2^{\circ}\text{C}$  pour novembre).

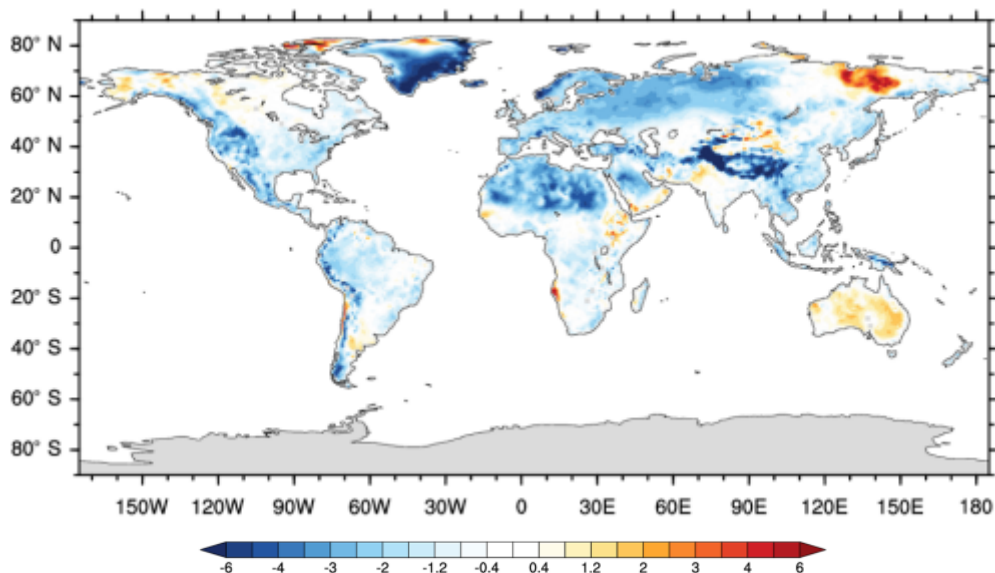


FIGURE 5.2 – Biais annuel moyen de la température continentale à deux mètres ( $^{\circ}\text{C}$ ) par rapport à la *Climate Research Unit time series 4.01 data set* pour la période 1981-2010 (Roberts et al., 2018).

### Histogrammes de rang

Si le modèle était bien ajusté (sans biais positif ou négatif, et sans problème de dispersion), les histogrammes de rang devraient être plats, c’est-à-dire que tous les rangs devraient être

représentés de manière plus ou moins équitable (Callado et al., 2013). En effet, une prévision fiable est une prévision pour laquelle les valeurs de vérification ne sont pas distinguables des prévisions (Candille & Talagrand, 2005). Les histogrammes de la figure 4.4 paraissent assez peu interprétables, de par le peu d'observations disponibles. Toutefois, ils permettent de rendre compte du biais systématique du modèle, grâce à leur forme. En effet, si en règle générale les histogrammes en forme de "U" sont pensés indiquer un manque de variabilité dans l'ensemble, ils peuvent aussi indiquer un biais du modèle (Hamill, 2001). Ainsi, un léger biais négatif peut être observé en février (Figure 3.3).

La figure 4.5 montre une sous-dispersion évidente du modèle. La méthodologie utilisée pour l'obtenir peut être critiquée : les différentes observations ne peuvent réellement être considérées comme indépendantes, amenant de l'autocorrélation spatiale, et les histogrammes, prenant en compte les observations des années 2016 à 2020, n'ont été réalisés que sur 25 membres alors que le modèle en comporte 51 pour les années entre 2017 et 2020. Ces 25 membres ont toutefois été choisis aléatoirement, et les 26 restants ne devraient donc pas influencer énormément le résultat. Ces histogrammes de rang confirment donc la sous-dispersion du modèle également visible sur les diagrammes de fiabilité et établie ci-après par (Johnson et al., 2019) (Figure 4.10).

### 5.1.2 Fiabilité

L'avantage principal du modèle de prévisions saisonnières de l'ECMWF par rapport aux prévisions de contrôle devrait être la prévision des événements extrêmes. En effet, la moyenne climatologique n'a par définition aucune fiabilité concernant ceux-ci, tandis que la persistance en anomalies ne peut les prévoir que si ces événements ont une durée de vie plutôt longue, vu qu'ils doivent déjà être présents en octobre afin que les anomalies soient reportées sur les mois suivants.

#### Diagrammes de fiabilité

Les diagrammes de fiabilité réalisés montrent un modèle plutôt fiable, quoique avec quelques problèmes de dispersion : ce sont les probabilités très faibles et très fortes qui ne sont pas observées à fréquence égale (Figure 4.10). Attention toutefois, ces diagrammes ont été réalisés, à cause du peu d'années disponibles, non pas sur la température moyenne de la zone d'étude mais bien avec une valeur par cellule du modèle. Si cette méthode permet un plus grand nombre d'observations, elle amène aussi de l'autocorrélation spatiale, car chaque événement ne peut être considéré comme indépendant des autres. Les diagrammes de fiabilité résultant peuvent donc être de ce fait biaisés.

Toutefois, Johnson et al. (2019) ont également réalisé un diagramme de fiabilité pour les températures à 2m supérieures au deuxième tercile de la distribution des mois de décembre à février (couleur rouge dans la figure 4.10) (Figure 5.3). Cette figure se rapproche de la figure 4.10, en ce sens qu'elle montre également un modèle sous-dispersif, même si cette sur-confiance est plus visible ici qu'à la figure 4.10. Ceci tendrait à montrer que la sous-dispersion visible dans la figure 4.10 ne vient pas d'un problème d'autocorrélation spatiale mais bien d'un problème dans la dispersion du modèle. Une raison pour laquelle la sous-dispersion est plus visible sur la figure 5.3 que sur la figure 4.10 pourrait être la taille des sous-groupes de probabilité égale. Alors que pour la figure 4.10 ces sous-groupes rassemblent des tranches de 10%, ils sont bien plus petits à la figure 5.3 (4%). La plus grande taille des sous-groupes peut entraîner dans la figure 4.10 une sur-confiance en la fiabilité du modèle. Ainsi, si on agrégeait la figure 5.3 en des sous-groupes de 10%, bien plus d'observations présenteraient des probabilités de prévisions égales à leurs fréquences observées.




FIGURE 5.3 – Diagramme de fiabilité des mois de décembre à février pour les températures à 2m supérieures au deuxième tercile de la distribution observée, pour la région européenne (35 à 75°N, 12.5°O à 42.5°E), de 1981 à 2016 (Johnson et al., 2019).

Plusieurs éléments peuvent expliquer les différences entre la figure 4.10, et la figure 5.3, qui ont pourtant toutes les deux été réalisées à partir du modèle SEAS5 de l’ECMWF. Tout d’abord les années de prévisions du modèle ne sont pas tout à fait les mêmes : Johnson et al. (2019) utilisent les années de 1981 à 2016 alors qu’ici les années de 1993 à 2020 sont utilisées. Ensuite, Johnson et al. (2019) se servent de ERA-Interim comme données de vérifications et non pas de ERA5. La zone d’étude de Johnson et al. (2019) est plus grande (35 à 75°N, 12.5°O à 42.5°E contre 48 à 55°N, 2°O à 16°E), ce qui peut mener à de plus grandes disparités spatiales dans la fiabilité du modèle. Les mois de décembre à janvier sont combinés dans Johnson et al. (2019), alors que les mois de novembre à février sont ici traités séparément. Enfin, la taille des sous-groupes de probabilité égale, discutée plus haut, joue probablement un rôle majeur dans ces disparités.

Le fait que le modèle présente une sous-variabilité peut poser problème : avec une dispersion trop faible, des événements extrêmes ne seront pas prédits, et la fiabilité du modèle diminue donc.

Les histogrammes de rang et les diagrammes de fiabilité réalisés ici mettent en lumière, outre la sous-dispersion du modèle de l’ECMWF, un problème commun aux prévisions saisonnières et décennales : le peu d’observations disponibles pour vérifier les modèles. La même difficulté a d’ailleurs été soulevée lors de la correction du biais : il faut y faire un compromis entre la régression linéaire la plus robuste possible et avoir suffisamment d’années restantes pour pouvoir effectuer une vérification significative sur les données corrigées.

### Hiver 2009-2010

Les résultats montrent que le modèle n’a pas été capable de prévoir l’amplitude de la NAO négative observée en février 2010. Cependant, la figure 4.14b a été réalisée à partir des données du modèle pour une échéance de prévision de 5 mois. Le fait que le modèle n’ait pas prédit

l'évènement ne remet donc pas en cause entièrement la capacité de prévision du modèle de cette NAO négative. Ainsi, en analysant le géopotential du mois de février 2010 prédit pour différentes échéances de prévisions, on remarque tout de même comme mentionné dans les résultats une structure spatiale commune entre le modèle et les valeurs observées (Figure 5.4). Il faut néanmoins attendre une échéance de prévision d'un mois pour que l'amplitude de l'anomalie de la prévision augmente, même si elle n'atteint toujours pas les valeurs observées.

Jung et al. (2011) ont montré que la plupart des systèmes avaient eu des difficultés à prévoir la phase négative de la NAO pour l'hiver 2009-2010. Ils ont testé différents forçages possibles, tels que les anomalies de température de surface des océans, El Niño ou encore une réduction de l'insolation solaire, mais aucun n'a permis de reproduire l'amplitude de la NAO négative. Jung et al. (2011) ont donc conclu que cette phase négative de la NAO était due à des processus atmosphériques dynamiques internes. Ceci concorde avec la figure 5.4, où l'on remarque la même difficulté à atteindre l'amplitude de cette phase négative de la NAO, même avec un mois d'échéance de prévision.

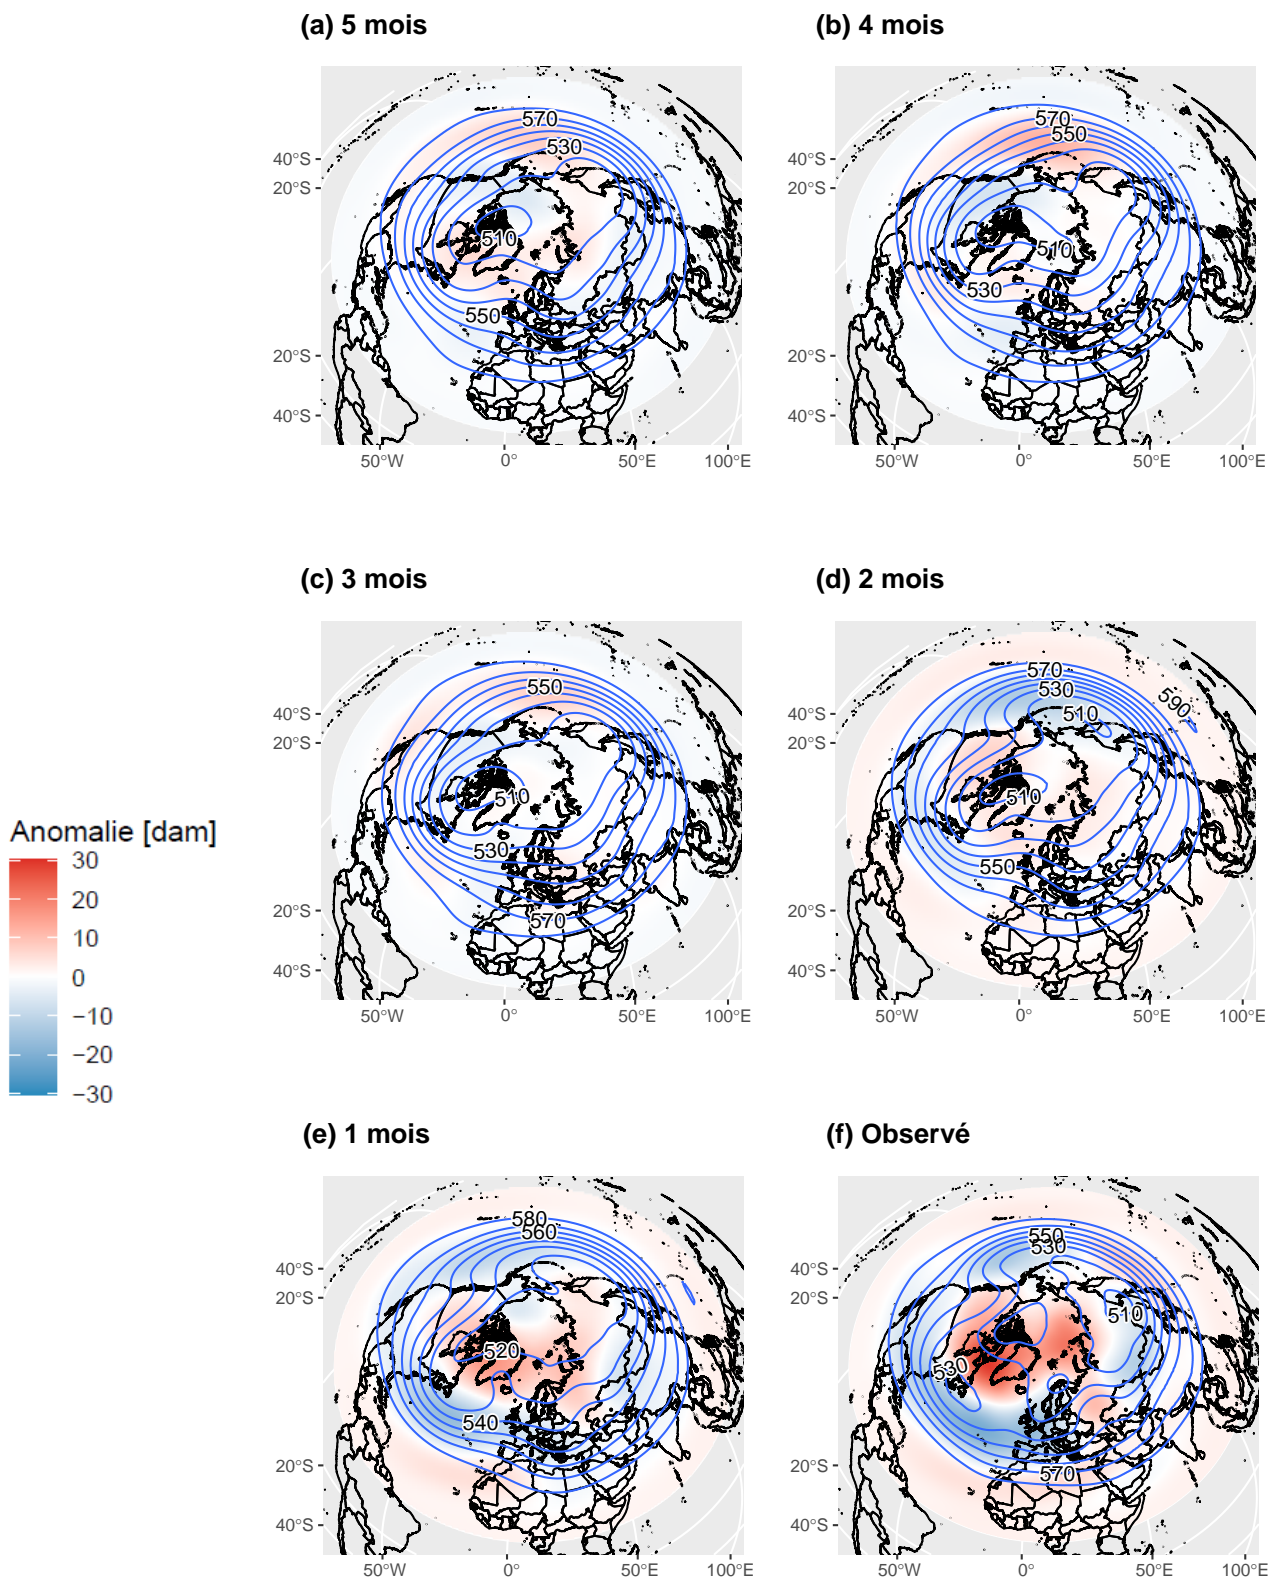


FIGURE 5.4 – Géopotential moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotential (champ coloré) prédits pour le mois de février 2010 avec (a) cinq mois (b) quatre mois (c) trois mois (d) deux mois et (e) un mois d'échéance de prévision. La figure (f) montre le géopotential moyen et l'anomalie de géopotential observés pour la même période (données de vérification ERA5).

## 5.2 Progrès futurs

### 5.2.1 *Modifiable Areal Unit Problem (MAUP)*

Le MAUP exprime que la division que l'on opère sur une zone d'étude pour l'analyser va influencer les résultats de cette analyse (Johnston et al., 2019). Les prévisions saisonnières effectuées par l'ECMWF reposent sur la modélisation du système atmosphère-océan. Or, certains processus se déroulent à des échelles très petites, parfois inférieures à la taille d'une cellule du modèle (Doblas-Reyes et al., 2009). De plus, tous les processus ne peuvent pas être pris en compte dans la modélisation, et certains ne sont pas encore assez bien compris pour pouvoir y être inclus sans une grande incertitude. Tout ceci cause des erreurs dans les prévisions. La taille des cellules joue donc un rôle sur la performance du modèle. De plus petites cellules peuvent amener à de meilleures prévisions. En revanche, le temps de calcul augmente avec le nombre de cellules, ce qui a un coût (Doblas-Reyes et al., 2009 ; Stockdale et al., 2018). Il est donc important d'arriver à un équilibre entre temps de calcul et résolution.

### 5.2.2 Progrès constants

Les différents scores ont montré ici que les prévisions saisonnières ne sont pas toujours spécialement plus précises que les deux prévisions de contrôle. Dès lors, pourquoi continuer à les étudier ? Ne serait-il pas plus rentable d'uniquement se fier aux moyennes climatologiques et à la persistance en anomalies, beaucoup moins coûteuses en temps de calculs ? Bauer et al. (2015) ont discuté "la révolution silencieuse de la prévision météorologique numérique". Ainsi, les révolutions dans le domaine des prévisions se font rarement avec des avancées majeures soudaines, mais plutôt lentement, avec des progrès continus (Bauer et al., 2015). Donc même si aujourd'hui les prévisions de contrôles ont un meilleur rapport temps de calcul/résultats, il est tout à fait possible que dans le futur ce ne soit plus le cas, il est donc intéressant de continuer à étudier et à progresser dans les prévisions saisonnières.

La figure 5.5 montre ces progrès. En effet, si dans les années 80 les prévisions à 7 jours montraient très peu de performance (aux alentours de 40% de performance de prévision), 20 ans plus tard les prévisions à 7 jours sont aussi bonnes que les prévisions à 5 jours au début de l'étude (Bauer et al., 2015). Les prévisions météorologiques ont donc gagné 1 jour de prévisibilité tous les dix ans (Bauer et al., 2015).

Le même concept s'applique aux prévisions saisonnières, et c'est pourquoi il est important de continuer à les étudier. En effet, Johnson et al. (2019) étudient les améliorations entre le système 4 de l'ECMWF et son système 5 (évalué ici). Johnson et al. (2019) ont ainsi établi que le nouveau modèle présente de nombreuses améliorations, telles que le biais dans la température de surface du Pacifique ou encore dans la capacité de prévision d'ENSO. Il reste néanmoins encore des améliorations à apporter, qui seront discutées ci-après.

De plus, de meilleures prévisions saisonnières permettraient, selon le concept de *seamless predictions*, d'améliorer les projections climatiques. Comme les prévisions saisonnières et les projections climatiques s'appuient sur des processus physiques fondamentaux communs, la validation d'un modèle à l'échelle saisonnière peut permettre une meilleure idée de la performance de projections climatique provenant de modèles définis de manière similaire (Palmer et al., 2008 ; Weisheimer & Palmer, 2014).




FIGURE 5.5 – Performance de prévisions à 3, 5, 7 et 10 jours, pour les zones extra-tropicales (Bauer et al., 2015). La performance de prévision est la corrélation entre la prévision et l’analyse de vérification à la hauteur du niveau de 500hPa. Les valeurs supérieures à 60% indiquent des prévisions utiles, tandis que celles supérieures à 80% indique un grand degré de précision.

## 5.3 Limites

### 5.3.1 Limites du modèle SEAS5 de l’ECMWF

La performance du modèle dépend de la zone d’étude et de la saison choisie. Les figures 5.7 (a) et (b) présentent les *Continuous Ranked Probability Skill Score* (CRPSS) des températures à deux mètres pour les mois d’hiver et d’été respectivement (Equation 5.1). Le CRPSS est un dérivé du *Continuous Ranked Probability Score* CRPS, qui est une mesure quadratique de la différence entre la fonction de la distribution cumulative de la prévision et la fonction cumulative de la climatologie (Figure 5.6) (Zamo & Naveau, 2018)




FIGURE 5.6 – Illustration du CRPS Hudson (2017). PDF est la fonction de distribution de probabilité de la prévision et CDF la fonction de distribution cumulative de la prédiction.

Le CRPSS est ensuite obtenu grâce à l’équation 5.1.

$$CRPSS = 1 - \frac{CRPS}{CRPS_{clim}} \quad (5.1)$$

Ce score s’interprète par rapport à la moyenne climatologique : un résultat de 1 indique une prévision parfaite, 0 pas d’amélioration par rapport à la climatologie et les résultats négatifs représentent des prévisions moins bonnes que la climatologie (Johnson et al., 2019). Sur ces

figures, il est visible que si la prévisibilité est bonne pour les zones tropicales en été comme en hiver, pour les zones extra-tropicales, en particulier dans l'hémisphère nord, l'été montre une plus grande prévisibilité que l'hiver (Figure 5.7). La figure 5.7 montre également que très peu de régions montrent un score négatif de CPRSS. En outre, ces zones se situent souvent aux endroits où le modèle présente des problèmes connus, comme par exemple l'Atlantique Nord en hiver ou l'Océan Indien Equatorial Est en été (Johnson et al., 2019). Les figures 5.7 (c) et (d) montrent quant à elles les changements de prévisibilité entre les modèles SEAS4 et SEAS5. On remarque sur ces figures de nombreuses zones d'amélioration de la prévisibilité, mais également des détériorations.

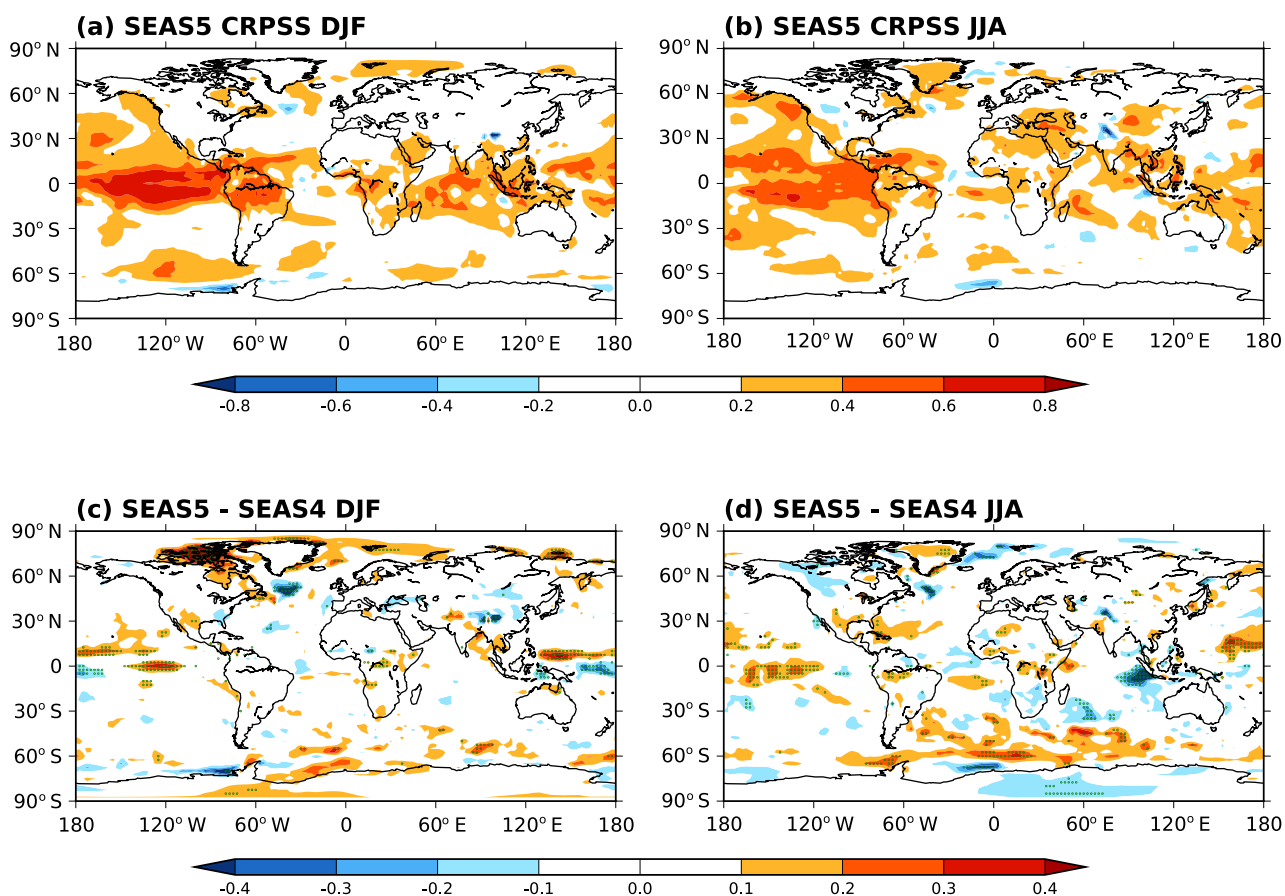


FIGURE 5.7 – Carte de CPRSS des températures à 2m pour SEAS5 (a) décembre à février et (b) juin à août et changements de score CPRSS entre SEAS4 et SEAS5 pour (c) décembre à février et (d) juin à août (Johnson et al., 2019).

Ainsi, la performance des modèles de prévisions saisonnières en dehors des tropiques est assez pauvre (Kim et al., 2012 ; Scaife et al., 2014).

La figure 5.8 montre la corrélation d'anomalie en Europe pour la température à deux mètres. La corrélation d'anomalie est une corrélation entre la moyenne des anomalies de l'ensemble de la prévision et des anomalies observées (Johnson et al., 2019). La figure 5.8 montre bien la différence de performance du modèle en fonction des régions et des saisons. Cette figure montre que la zone et la saison choisies pour cette étude ne sont pas spécialement celles où le modèle a le plus de performance. Il est dès lors important de se rendre compte que ce n'est pas parce que les résultats présentés ici ne sont pas toujours très favorables au modèle que celui-ci n'a pas de plus grandes capacités de prévisions dans d'autres zones ou à d'autres périodes de l'année.

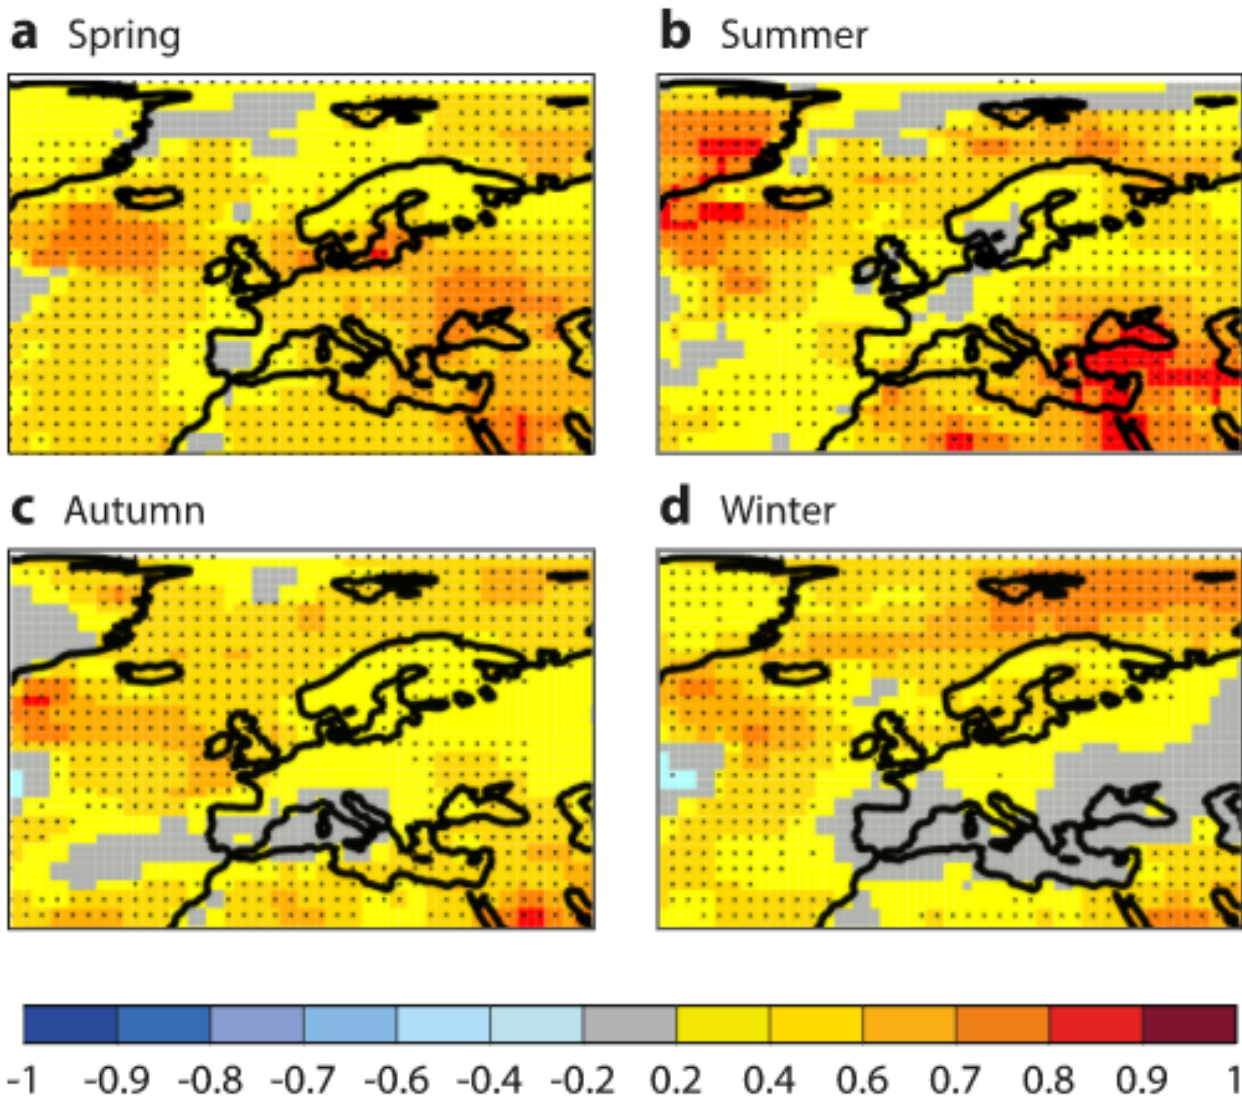


FIGURE 5.8 – Performance de corrélation d’anomalie de SEAS5 en Europe pour la température à 2 mètres, basée sur les hindcasts de 1981 à 2016 pour (a) mars à mai, (b) juin à août, (c) septembre à novembre et (d) décembre à février. Les points montrent les corrélations significatives à 95% (Stockdale et al., 2018).

### 5.3.2 Limite de l’étude

En ce qui concerne les indicateurs de fiabilité du modèle (corrélations, biais et erreurs quadratiques moyennes), les calculs ont été réalisés en utilisant la moyenne des membres. Or, les modèles de prévisions d’ensembles ont pour but de fournir des prévisions probabilistes, et non déterministes. En ne prenant que la moyenne des ensembles, la fiabilité du modèle est réduite, et des événements extrêmes éventuellement prévus dans certains membres du modèle ne seront pas pris en compte. Cependant, comme expliqué précédemment, cette méthodologie présente également l’avantage de réduire le bruit lié à la nature chaotique de l’atmosphère.

Une grande limite de l’étude, et des prévisions saisonnières et décennales de manière générale, est le peu d’observations disponible, ce qui rend les analyses compliquées, comme nous l’avons vu ici. Ainsi, si plus d’années d’observations étaient disponibles, les histogrammes de rang et les diagrammes de fiabilité auraient pu être réalisés sur la moyenne de température de la zone, et non par cellule du modèle, ce qui mènerait à une indépendance des observations et donc à un résultat moins biaisé par la méthodologie employée. Le même constat peut-être

fait pour la correction du biais, étant donné que les années utilisées pour obtenir la régression linéaire ne peuvent être corrigées sans sur-évaluer la performance du modèle.

## 5.4 Pour la suite

Il serait intéressant, pour faire suite à cette étude, de réaliser des prévisions combinant le modèle de l'ECMWF et la moyenne climatologique ou la persistance en anomalies en fonction de quelle prévision se montre la meilleure pour la cellule considérée. Ceci permettrait d'améliorer le modèle sans augmenter énormément les temps de calculs, et sans devoir attendre une compétence accrue dans la modélisation du climat.

En outre, des tests de vérification sur l'ensemble des membres plutôt que sur la dégénération déterministe du modèle pourraient apporter des informations complémentaires quant à la performance effective de celui-ci. En effet, en effectuant la plupart des tests sur la moyenne des ensembles, l'information réellement donnée par le modèle se trouve réduite.

Une comparaison entre les différents modèles de prévisions saisonnières apporterait en outre des informations intéressante pour évaluer les forces et les faiblesses de chaque modèle et ainsi permettre une amélioration de ceux-ci.

Une évaluation des problèmes dans la modélisation du système serait également la bienvenue, afin de pouvoir mettre en place une étude de projection climatique, selon le modèle de prévisions continues.

# Chapitre 6

## Conclusion

Les prévisions saisonnières sont des prévisions à quelques mois, rendues possibles grâce à des composantes présentant des changements lents et prévisibles, tels que les anomalies de températures de surface des océans (associées en particulier au phénomène ENSO), l'humidité du sol, la glace de mer, etc. qui permettent des prévisions sur le long terme malgré la nature chaotique de l'atmosphère. Ces prévisions sont utiles dans de nombreux domaines, comme par exemple les milieux de la santé, de l'agriculture ou de l'énergie, pour lesquels elles peuvent mener à des prises de décisions informées pour le futur.

Les incertitudes liées aux prévisions font que la manière la plus précise de formuler ces prévisions saisonnières est sous la forme probabiliste, en utilisant des membres pour lesquels les conditions initiales sont légèrement variées les unes par rapport aux autres tout en restant dans le domaine du plausible. Mais ces prévisions sont-elles pour autant fiables, ou tout du moins plus que des prévisions de contrôle établies grâce aux données passées ?

Pour répondre à cette question pour le modèle SEAS5 de l'ECMWF, différents indicateurs ont été étudiés (corrélation de Pearson, biais et erreur quadratique moyenne). Ces résultats ont été comparés à ceux pour la moyenne climatologique et la persistance en anomalies, et il a été montré que si le modèle présente de meilleurs résultats pour la corrélation de Pearson et l'erreur quadratique moyenne pour chaque mois, ce n'est pas le cas pour le biais, pour lequel dès le mois de novembre de nombreuses cellules montrent un biais plus élevé que pour la persistance en anomalies voire que pour les deux prévisions de contrôle. Au plus on avance dans le temps, au plus les deux prévisions de contrôle montrent un meilleur biais. La moindre performance du modèle de l'ECMWF pourrait s'expliquer par l'utilisation de la forme déterministe de la prévision. Si cette méthode permet de réduire le bruit lié au caractère chaotique de l'atmosphère, elle réduit également la dispersion du modèle, pouvant le rendre biaisé alors que la valeur de vérification se situe dans la distribution des membres du modèle dans son entièreté. Ce score dépend fortement des *outliers*, ce qui pourrait expliquer la meilleure performance du modèle : la moyenne climatologique ne prédit pas les événements extrêmes, et la persistance en anomalies est dépendante de leur durée.

Les histogrammes de rang ont ensuite été étudiés pour les quatre mois de prévisions et semblent confirmer le biais grandissant du modèle avec le temps. Les histogrammes de rang réalisés par cellule du modèle sur les années corrigées montrent une sous-dispersion dans le modèle.

Enfin, la fiabilité à proprement parler est étudiée. Pour ce faire, des diagrammes de fiabilité sont d'abord réalisés. Ceux-ci montrent que la prévision est relativement fiable, bien qu'ils

confirment la sous-dispersion observée avec les histogrammes de rang. Un cas particulier, l'hiver 2009-2010 qui a connu plusieurs vagues de froids, est également étudié. Les températures des mois de janvier et février 2010 sont bien situées dans la distribution prédite par le modèle. Mais comme ces vagues de froids ont été causées majoritairement par une phase négative de la NAO, l'anomalie de géopotentiel prédite pour le mois de février a également été étudiée. Les résultats montrent que la répartition spatiale de l'évènement est prédite déjà à 5 mois d'échéance de prévision, même si l'amplitude de l'anomalie prédite est bien plus faible que celle observée. Ceci indique que le modèle présente tout de même une certaine capacité de prévision pour cet évènement, même si son amplitude n'est pas respectée.

Différentes pistes pourraient être explorées pour faire suite à ce travail, comme par exemple combiner les prévisions du modèle avec les prévisions de contrôles ou encore mener plus de tests sur les ensembles dans leur entièreté plutôt que sur leur forme déterministe.

En conclusion, les prévisions saisonnières de l'ECMWF ne sont pas toujours spécialement plus précises que les prévisions de contrôle. Il est important de continuer à les améliorer, car dans ce domaine les progrès se font petit à petit et non d'un seul coup. Il faut cependant également noter que la performance des prévisions saisonnières dépend fortement de la région et de la saison étudiées. Les résultats présentés ici ne signifient pas que le modèle dans son ensemble présente les mêmes problèmes. Ce mémoire illustre également un problème présent lors de l'étude de prévisions saisonnières ou décennales : l'échantillon d'observations limité complique les vérifications.

# Chapitre 7

## Bibliographie

- Bauer, P., Thorpe, A., & Brunet, G. (2015, septembre). The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47–55. Consulté le 2021-03-17, sur <https://www.nature.com/articles/nature14956> (Number : 7567 Publisher : Nature Publishing Group) doi: 10.1038/nature14956
- Buermann, W., Anderson, B., Tucker, C. J., Dickinson, R. E., Lucht, W., Potter, C. S., & Myneni, R. B. (2003). Interannual covariability in Northern Hemisphere air temperatures and greenness associated with El Niño-Southern Oscillation and the Arctic Oscillation. *Journal of Geophysical Research : Atmospheres*, 108(D13). Consulté le 2021-05-06, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2002JD002630> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2002JD002630>) doi: <https://doi.org/10.1029/2002JD002630>
- Callado, A., Escribà, P., García-Moya, J. A., Montero, J., Santos, C., Santos-Muñoz, D., & Simarro, J. (2013). *Ensemble Forecasting*. IntechOpen. Consulté le 2021-05-07, sur <https://www.intechopen.com/books/climate-change-and-regional-local-responses/ensemble-forecasting> (Publication Title : Climate Change and Regional/Local Responses) doi: 10.5772/55699
- Candille, G., & Talagrand, O. (2005). Evaluation of probabilistic prediction systems for a scalar variable. *Quarterly Journal of the Royal Meteorological Society*, 131(609), 2131–2150. Consulté le 2021-05-10, sur <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1256/qj.04.71> (\_eprint : <https://rmets.onlinelibrary.wiley.com/doi/pdf/10.1256/qj.04.71>) doi: <https://doi.org/10.1256/qj.04.71>
- Chen, H., Ma, H., Li, X., & Sun, S. (2015). Solar influences on spatial patterns of Eurasian winter temperature and atmospheric general circulation anomalies. *Journal of Geophysical Research : Atmospheres*, 120(17), 8642–8657. Consulté le 2021-03-31, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2015JD023415> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1002/2015JD023415>) doi: <https://doi.org/10.1002/2015JD023415>
- Christensen, J. H., & Christensen, O. B. (2007, mai). A summary of the PRUDENCE model projections of changes in European climate by the end of this century. *Climatic Change*, 81(S1), 7–30. Consulté le 2020-11-07, sur <http://link.springer.com/10.1007/s10584-006-9210-7> doi: 10.1007/s10584-006-9210-7
- Coelho, C. A. S., Brown, B., Wilson, L., Mittermaier, M., & Casati, B. (2019, janvier). Chapter 16 - Forecast Verification for S2S Timescales. In A. W. Robertson & F. Vitart (Eds.), *Sub-Seasonal to Seasonal Prediction* (pp. 337–361). Elsevier. Consulté le 2020-11-07, sur <http://www.sciencedirect.com/science/article/pii/B9780128117149000164> doi:

10.1016/B978-0-12-811714-9.00016-4

- Copernicus. (2019). *ERA5 monthly averaged data on single levels from 1979 to present*. ECMWF. Consulté le 2021-04-26, sur <https://cds.climate.copernicus.eu/doi/10.24381/cds.f17050d7> (type : dataset) doi: 10.24381/CDS.F17050D7
- Copernicus. (2021). *Seasonal forecasts*. Consulté le 2021-05-07, sur <https://climate.copernicus.eu/seasonal-forecasts>
- Doblas-Reyes, F. J. (2010). Seasonal prediction over Europe. , 15.
- Doblas-Reyes, F. J., García-Serrano, J., Lienert, F., Biescas, A. P., & Rodrigues, L. R. L. (2013, juillet). Seasonal climate predictability and forecasting : status and prospects. *Wiley Interdisciplinary Reviews : Climate Change*, 4(4), 245–268. Consulté le 2020-11-07, sur <http://doi.wiley.com/10.1002/wcc.217> doi: 10.1002/wcc.217
- Doblas-Reyes, F. J., Weisheimer, A., Déqué, M., Keenlyside, N., McVean, M., Murphy, J. M., ... Palmer, T. N. (2009). Addressing model uncertainty in seasonal and annual dynamical ensemble forecasts. *Quarterly Journal of the Royal Meteorological Society*, 135(643), 1538–1559. Consulté le 2021-05-27, sur <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/qj.464> (\_eprint : <https://rmets.onlinelibrary.wiley.com/doi/pdf/10.1002/qj.464>) doi: <https://doi.org/10.1002/qj.464>
- Dunstone, N., Smith, D., Scaife, A., Hermanson, L., Eade, R., Robinson, N., ... Knight, J. (2016, novembre). Skilful predictions of the winter North Atlantic Oscillation one year ahead. *Nature Geoscience*, 9(11), 809–814. Consulté le 2021-06-02, sur <https://www.nature.com/articles/ngeo2824> (Number : 11 Publisher : Nature Publishing Group) doi: 10.1038/ngeo2824
- Déqué, M. (2012). Deterministic Forecasts of Continuous Variables. In *Forecast Verification* (pp. 77–94). John Wiley & Sons, Ltd. Consulté le 2021-04-04, sur <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119960003.ch5> (Section : 5 \_eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/9781119960003.ch5>) doi: 10.1002/9781119960003.ch5
- ECMWF. (2014, janvier). *Long range* [Text]. Consulté le 2021-04-08, sur <https://www.ecmwf.int/en/forecasts/documentation-and-support/long-range>
- EFFIS. (s. d.). *Seasonal forecast*. Consulté le 2021-03-17, sur <https://effis.jrc.ec.europa.eu/about-effis/technical-background/seasonal-forecast-explained>
- Fereday, D. R., Maidens, A., Arribas, A., Scaife, A. A., & Knight, J. R. (2012, septembre). Seasonal forecasts of northern hemisphere winter 2009/10. *Environmental Research Letters*, 7(3), 034031. Consulté le 2021-04-28, sur <https://doi.org/10.1088/1748-9326/7/3/034031> (Publisher : IOP Publishing) doi: 10.1088/1748-9326/7/3/034031
- Ghosh, R., Müller, W. A., Baehr, J., & Bader, J. (2017, juin). Impact of observed North Atlantic multidecadal variations to European summer climate : a linear baroclinic response to surface heating. *Climate Dynamics*, 48(11), 3547–3563. Consulté le 2021-03-31, sur <https://doi.org/10.1007/s00382-016-3283-4> doi: 10.1007/s00382-016-3283-4
- Giorgi, F., & Mearns, L. O. (2002, mai). Calculation of Average, Uncertainty Range, and Reliability of Regional Climate Changes from AOGCM Simulations via the “Reliability Ensemble Averaging” (REA) Method. *Journal of Climate*, 15(10), 1141–1158. Consulté le 2021-04-21, sur [https://journals.ametsoc.org/view/journals/clim/15/10/1520-0442\\_2002\\_015\\_1141\\_coaura\\_2.0.co\\_2.xml](https://journals.ametsoc.org/view/journals/clim/15/10/1520-0442_2002_015_1141_coaura_2.0.co_2.xml) (Publisher : American Meteorological Society Section : Journal of Climate) doi: 10.1175/1520-0442(2002)015<1141:COAURA>2.0.CO;2
- Hagedorn, R., Doblas-Reyes, F. J., & Palmer, T. N. (2005). The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept. *Tellus A*, 57(3), 219–233. Consulté le 2021-04-07, sur <https://>

onlinelibrary.wiley.com/doi/abs/10.1111/j.1600-0870.2005.00103.x (\_eprint :  
https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1600-0870.2005.00103.x) doi: https://  
doi.org/10.1111/j.1600-0870.2005.00103.x

- Hamill, T. M. (2001, mars). Interpretation of Rank Histograms for Verifying Ensemble Forecasts. *Monthly Weather Review*, 129(3), 550–560. Consulté le 2021-04-10, sur [https://journals.ametsoc.org/view/journals/mwre/129/3/1520-0493\\_2001\\_129\\_0550\\_iorhfv\\_2.0.co\\_2.xml](https://journals.ametsoc.org/view/journals/mwre/129/3/1520-0493_2001_129_0550_iorhfv_2.0.co_2.xml) (Publisher : American Meteorological Society Section : Monthly Weather Review) doi: 10.1175/1520-0493(2001)129<0550:IORHFV>2.0.CO;2
- Hanna, E., & Cropper, T. E. (2017, février). North Atlantic oscillation. *Oxford Research Encyclopedia of Climate Science*. Consulté le 2021-06-02, sur <https://doi.org/10.1093/acrefore/9780190228620.013.22> (ISBN : 9780190228620)
- Hawkins, E., & Sutton, R. (2011, juillet). The potential to narrow uncertainty in projections of regional precipitation change. *Climate Dynamics*, 37(1), 407–418. Consulté le 2021-05-28, sur <https://doi.org/10.1007/s00382-010-0810-6> doi: 10.1007/s00382-010-0810-6
- Hudson, D. (2017). *Ensemble Verification Metrics*. Consulté sur <https://www.ecmwf.int/sites/default/files/elibrary/2017/17626-ensemble-verification-metrics.pdf>
- Ineson, S., Scaife, A. A., Knight, J. R., Manners, J. C., Dunstone, N. J., Gray, L. J., & Haigh, J. D. (2011, novembre). Solar forcing of winter climate variability in the Northern Hemisphere. *Nature Geoscience*, 4(11), 753–757. Consulté le 2021-03-31, sur <https://www.nature.com/articles/ngeo1282> (Number : 11 Publisher : Nature Publishing Group) doi: 10.1038/ngeo1282
- Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., ... Monge-Sanz, B. M. (2019, mars). SEAS5 : the new ECMWF seasonal forecast system. *Geoscientific Model Development*, 12(3), 1087–1117. Consulté le 2021-04-28, sur <https://gmd.copernicus.org/articles/12/1087/2019/> (Publisher : Copernicus GmbH) doi: 10.5194/gmd-12-1087-2019
- Johnston, R., Harris, R., Jones, K., Manley, D., Wang, W. W., & Wolf, L. (2019, août). Quantitative methods II : How we moved on - Decades of change in philosophy, focus and methods. *Progress In Human Geography*, 44(5). Consulté le 2021-06-01, sur <https://lirias.kuleuven.be/2850907> (Publisher : SAGE Publications) doi: 10.1177/0309132519869451
- Jolliffe, I. T., & Stephenson, D. B. (2012). Introduction. In *Forecast Verification* (pp. 1–9). John Wiley & Sons, Ltd. Consulté le 2021-04-04, sur <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119960003.ch1> (Section : 1 \_eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/9781119960003.ch1>) doi: 10.1002/9781119960003.ch1
- Jung, T., Vitart, F., Ferranti, L., & Morcrette, J.-J. (2011). Origin and predictability of the extreme negative NAO winter of 2009/10. *Geophys. Res. Lett.*, 38, L07701. Consulté le 2021-05-05, sur <http://dx.doi.org/10.1029/2011GL046786> doi: 10.1029/2011GL046786
- Kim, H.-M., Webster, P. J., & Curry, J. A. (2012, décembre). Seasonal prediction skill of ECMWF System 4 and NCEP CFSv2 retrospective forecast for the Northern Hemisphere Winter. *Climate Dynamics*, 39(12), 2957–2973. Consulté le 2021-05-05, sur <https://doi.org/10.1007/s00382-012-1364-6> doi: 10.1007/s00382-012-1364-6
- Krishnamurti, T. N., Kishtawal, C. M., Zhang, Z., LaRow, T., Bachiochi, D., Williford, E., ... Surendran, S. (2000, décembre). Multimodel Ensemble Forecasts for Weather and Seasonal Climate. *Journal of Climate*, 13(23), 4196–4216. Consulté le 2021-06-02, sur [https://journals.ametsoc.org/view/journals/clim/13/23/1520-0442\\_2000\\_013\\_4196\\_meffwa\\_2.0.co\\_2.xml](https://journals.ametsoc.org/view/journals/clim/13/23/1520-0442_2000_013_4196_meffwa_2.0.co_2.xml) (Publisher : American Meteorological So-

- ciety Section : Journal of Climate) doi: 10.1175/1520-0442(2000)013<4196:MEFFWA>2.0.CO;2
- Lorenz, E. N. (1963, mars). Deterministic Nonperiodic Flow. *Journal of Atmospheric Sciences*, 20, 130–148. Consulté le 2021-04-06, sur <http://adsabs.harvard.edu/abs/1963JAAtS...20..130L> doi: 10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2
- Lorenz, E. N. (1969). The predictability of a flow which possesses many scales of motion. *Tellus*, 21(3), 289–307. Consulté le 2021-04-07, sur <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.2153-3490.1969.tb00444.x> (\_eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.2153-3490.1969.tb00444.x>) doi: <https://doi.org/10.1111/j.2153-3490.1969.tb00444.x>
- Magdelaine, C. (2010, mars). *Un hiver 2009-2010 froid pour la France mais encore très doux au niveau mondial*. Consulté le 2021-06-01, sur [https://www.notre-planete.info/actualites/2327-hiver\\_2009-2010\\_froid\\_France\\_doux\\_monde](https://www.notre-planete.info/actualites/2327-hiver_2009-2010_froid_France_doux_monde)
- Maliniemi, V., Asikainen, T., & Mursula, K. (2014). Spatial distribution of Northern Hemisphere winter temperatures during different phases of the solar cycle. *Journal of Geophysical Research : Atmospheres*, 119(16), 9752–9764. Consulté le 2021-05-07, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2013JD021343> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1002/2013JD021343>) doi: <https://doi.org/10.1002/2013JD021343>
- Meehl, G. A., Goddard, L., Murphy, J., Stouffer, R. J., Boer, G., Danabasoglu, G., ... Stockdale, T. (2009, octobre). DECADAL PREDICTION Can It Be Skillful? *Bulletin of the American Meteorological Society*, 90(10), 1467–+. Consulté le 2021-04-07, sur <https://www.research.ed.ac.uk/en/publications/decadal-prediction-can-it-be-skillful> (Publisher : American Meteorological Society) doi: 10.1175/2009BAMS2778.1
- MetOffice. (s. d.). *The North Atlantic Oscillation*. Consulté le 2021-06-01, sur <https://www.metoffice.gov.uk/research/climate/seasonal-to-decadal/gpc-outlooks/ens-mean/nao-description>
- Murphy, A. H. (1993, juin). What Is a Good Forecast ? An Essay on the Nature of Goodness in Weather Forecasting. *Weather and Forecasting*, 8(2), 281–293. Consulté le 2021-04-05, sur [https://journals.ametsoc.org/view/journals/wefo/8/2/1520-0434\\_1993\\_008\\_0281\\_wiagfa\\_2\\_0\\_co\\_2.xml](https://journals.ametsoc.org/view/journals/wefo/8/2/1520-0434_1993_008_0281_wiagfa_2_0_co_2.xml) (Publisher : American Meteorological Society Section : Weather and Forecasting) doi: 10.1175/1520-0434(1993)008<0281:WIAGFA>2.0.CO;2
- MétéoFrance. (2021). Bulletin de prévisions saisonnières. , 4.
- Oldenborgh, G. J. v., Balmaseda, M. A., Ferranti, L., Stockdale, T. N., & Anderson, D. L. T. (2005, août). Evaluation of Atmospheric Fields from the ECMWF Seasonal Forecasts over a 15-Year Period. *Journal of Climate*, 18(16), 3250–3269. Consulté le 2021-05-07, sur <https://journals.ametsoc.org/view/journals/clim/18/16/jcli3421.1.xml> (Publisher : American Meteorological Society Section : Journal of Climate) doi: 10.1175/JCLI3421.1
- Orlov, A., Sillmann, J., & Vigo, I. (2020, février). Better seasonal forecasts for the renewable energy industry. *Nature Energy*, 5(2), 108–110. Consulté le 2021-03-17, sur <https://www.nature.com/articles/s41560-020-0561-5> (Number : 2 Publisher : Nature Publishing Group) doi: 10.1038/s41560-020-0561-5
- Palmer, T. (2002). The economic value of ensemble forecasts as a tool for risk assessment : From days to decades. *Quarterly Journal of the Royal Meteorological Society*, 128(581), 747–774. Consulté le 2021-05-04, sur <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1256/0035900021643593> (\_eprint : <https://rmets.onlinelibrary.wiley.com/doi/pdf/10.1256/0035900021643593>) doi: <https://doi.org/10.1256/0035900021643593>

- Palmer, T. (2006). Predictability of weather and climate : from theory to practice. In T. Palmer & R. Hagedorn (Eds.), *Predictability of Weather and Climate* (pp. 1–29). Cambridge : Cambridge University Press. Consulté sur <https://www.cambridge.org/core/books/predictability-of-weather-and-climate/predictability-of-weather-and-climate-from-theory-to-practice/DE313652E177CA2199D1E5C74837303B> doi: 10.1017/CBO9780511617652.002
- Palmer, T. (2020, novembre). 25.11.2020 : Tim Palmer - "Ensemble Prediction". Consulté le 2021-04-06, sur [https://www.youtube.com/watch?v=\\_mm3d1bv9Kw&ab\\_channel=PerspectivesClimate](https://www.youtube.com/watch?v=_mm3d1bv9Kw&ab_channel=PerspectivesClimate)
- Palmer, T., Doblas-Reyes, F. J., Weisheimer, A., & Rodwell, M. J. (2008, avril). Toward Seamless Prediction : Calibration of Climate Change Projections Using Seasonal Forecasts. *Bulletin of the American Meteorological Society*, 89(4), 459–470. Consulté le 2021-04-21, sur <https://journals.ametsoc.org/view/journals/bams/89/4/bams-89-4-459.xml> (Publisher : American Meteorological Society Section : Bulletin of the American Meteorological Society) doi: 10.1175/BAMS-89-4-459
- Richardson, D. S. (2006). Predictability and economic value. In T. Palmer & R. Hagedorn (Eds.), *Predictability of Weather and Climate* (pp. 628–644). Cambridge : Cambridge University Press. Consulté sur <https://www.cambridge.org/core/books/predictability-of-weather-and-climate/predictability-of-weather-and-climate-from-theory-to-practice/DE313652E177CA2199D1E5C74837303B> doi: 10.1017/CBO9780511617652.002
- Richardson, D. S. (2012). Economic Value and Skill. In *Forecast Verification* (pp. 167–184). John Wiley & Sons, Ltd. Consulté le 2021-04-04, sur <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119960003.ch9> (Section : 9 \_eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/9781119960003.ch9>) doi: 10.1002/9781119960003.ch9
- Riddle, E. E., Butler, A. H., Furtado, J. C., Cohen, J. L., & Kumar, A. (2013, août). CFSv2 ensemble prediction of the wintertime Arctic Oscillation. *Climate Dynamics*, 41(3), 1099–1116. Consulté le 2021-05-06, sur <https://doi.org/10.1007/s00382-013-1850-5> doi: 10.1007/s00382-013-1850-5
- Roberts, C. D., Senan, R., Molteni, F., Boussetta, S., Mayer, M., & Keeley, S. P. E. (2018, septembre). Climate model configurations of the ECMWF Integrated Forecasting System (ECMWF-IFS cycle 43r1) for HighResMIP. *Geoscientific Model Development*, 11(9), 3681–3712. Consulté le 2021-06-02, sur <https://gmd.copernicus.org/articles/11/3681/2018/> (Publisher : Copernicus GmbH) doi: 10.5194/gmd-11-3681-2018
- Scaife, A. A., Arribas, A., Blockley, E., Brookshaw, A., Clark, R. T., Dunstone, N., ... Williams, A. (2014). Skillful long-range prediction of European and North American winters. *Geophysical Research Letters*, 41(7), 2514–2519. Consulté le 2021-05-05, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014GL059637> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1002/2014GL059637>) doi: <https://doi.org/10.1002/2014GL059637>
- Shukla, J., & Kinter, J. L. (2006). Predictability of seasonal climate variations : a pedagogical review. In R. Hagedorn & T. Palmer (Eds.), *Predictability of Weather and Climate* (pp. 306–341). Cambridge : Cambridge University Press. Consulté le 2021-05-07, sur <https://www.cambridge.org/core/books/predictability-of-weather-and-climate/predictability-of-seasonal-climate-variations-a-pedagogical-review/A2BDF9A5CA7A4870FCA4783070093B7A> doi: 10.1017/CBO9780511617652.013
- Shukla, J., Sole, T., Fennessy, M., Kinter, J., & Paolino, D. (2006, avril). Climate Model Fidelity and Projections of Climate Change. *Geophysical Research Letters - GEOPHYS RES LETT*, 33. doi: 10.1029/2005GL025579
- Slingo, J., & Palmer, T. (2011, décembre). Uncertainty in weather and climate predic-

- tion. *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*, 369(1956), 4751–4767. Consulté le 2021-04-04, sur <https://royalsocietypublishing.org/doi/10.1098/rsta.2011.0161> (Publisher : Royal Society) doi: 10.1098/rsta.2011.0161
- Smith, D. M., Cusack, S., Colman, A. W., Folland, C. K., Harris, G. R., & Murphy, J. M. (2007, août). Improved Surface Temperature Prediction for the Coming Decade from a Global Climate Model. *Science*, 317(5839), 796–799. Consulté le 2021-05-07, sur <https://science.sciencemag.org/content/317/5839/796> (Publisher : American Association for the Advancement of Science Section : Report) doi: 10.1126/science.1139540
- Stockdale, T., Alonso-Balmaseda, M., Johnson, S., Ferranti, L., Molteni, F., Magnusson, L., ... Monge-Sanz, B. M. (2018). *SEAS5 and the future evolution of the long-range forecast system*. (Publisher : ECMWF) doi: 10.21957/z3e92di7y
- Sutton, R. T., & Hodson, D. L. R. (2005, juillet). Atlantic Ocean forcing of North American and European summer climate. *Science (New York, N.Y.)*, 309(5731), 115–118. doi: 10.1126/science.1109496
- Tippett, M. K., & Barnston, A. G. (2008, octobre). Skill of Multimodel ENSO Probability Forecasts. *Monthly Weather Review*, 136(10), 3933–3946. Consulté le 2021-04-04, sur <https://journals.ametsoc.org/view/journals/mwre/136/10/2008mwr2431.1.xml> (Publisher : American Meteorological Society Section : Monthly Weather Review) doi: 10.1175/2008MWR2431.1
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., ... Zhang, L. (2017, janvier). The Subseasonal to Seasonal (S2S) Prediction Project Database. *Bulletin of the American Meteorological Society*, 98(1), 163–173. Consulté le 2020-11-07, sur <https://journals.ametsoc.org/bams/article/98/1/163/69588/The-Subseasonal-to-Seasonal-S2S-Prediction-Project> (Publisher : American Meteorological Society) doi: 10.1175/BAMS-D-16-0017.1
- Vitart, F., & Robertson, A. W. (2019, janvier). Chapter 1 - Introduction : Why Subseasonal to Seasonal Prediction (S2S)? In A. W. Robertson & F. Vitart (Eds.), *Sub-Seasonal to Seasonal Prediction* (pp. 3–15). Elsevier. Consulté le 2021-04-05, sur <https://www.sciencedirect.com/science/article/pii/B9780128117149000012> doi: 10.1016/B978-0-12-811714-9.00001-2
- Wang, C., Liu, H., & Lee, S.-K. (2010). The record-breaking cold temperatures during the winter of 2009/2010 in the Northern Hemisphere. *Atmospheric Science Letters*, 11(3), 161–168. Consulté le 2021-04-28, sur <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/asl.278> (\_eprint : <https://rmets.onlinelibrary.wiley.com/doi/pdf/10.1002/asl.278>) doi: <https://doi.org/10.1002/asl.278>
- Weisheimer, A., & Palmer, T. N. (2014, juillet). On the reliability of seasonal climate forecasts. *Journal of The Royal Society Interface*, 11(96), 20131162. Consulté le 2021-04-05, sur <https://royalsocietypublishing.org/doi/10.1098/rsif.2013.1162> doi: 10.1098/rsif.2013.1162
- Weisheimer, A., Palmer, T. N., & Doblas-Reyes, F. J. (2011). Assessment of representations of model uncertainty in monthly and seasonal forecast ensembles. *Geophysical Research Letters*, 38(16). Consulté le 2021-04-07, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2011GL048123> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2011GL048123>) doi: <https://doi.org/10.1029/2011GL048123>
- Yang, D., Yang, X.-Q., Ye, D., Sun, X., Fang, J., Chu, C., ... Tang, Y. (2018). On the Relationship Between Probabilistic and Deterministic Skills in Dynamical Seasonal Climate Prediction. *Journal of Geophysical Research : At-*

*mospheres*, 123(10), 5261–5283. Consulté le 2021-05-03, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2017JD028002> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2017JD028002>) doi: <https://doi.org/10.1029/2017JD028002>

Zamo, M., & Naveau, P. (2018, février). Estimation of the Continuous Ranked Probability Score with Limited Information and Applications to Ensemble Weather Forecasts. *Mathematical Geosciences*, 50(2), 209–234. Consulté le 2021-06-01, sur <https://doi.org/10.1007/s11004-017-9709-7> doi: 10.1007/s11004-017-9709-7

Zelinka, M., Myers, T., Mccoy, D., Po-Chedley, S., Caldwell, P., Ceppi, P., ... Taylor, K. (2020, janvier). Causes of Higher Climate Sensitivity in CMIP6 Models. *Geophysical Research Letters*, 47. doi: 10.1029/2019GL085782

Årthun, M., Eldevik, T., Viste, E., Drange, H., Furevik, T., Johnson, H. L., & Keenlyside, N. S. (2017, juin). Skillful prediction of northern climate provided by the ocean. *Nature Communications*, 8(1), 15875. Consulté le 2021-03-31, sur <https://www.nature.com/articles/ncomms15875> (Number : 1 Publisher : Nature Publishing Group) doi: 10.1038/ncomms15875

Årthun, M., Kolstad, E. W., Eldevik, T., & Keenlyside, N. S. (2018). Time Scales and Sources of European Temperature Variability. *Geophysical Research Letters*, 45(8), 3597–3604. Consulté le 2021-03-17, sur <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2018GL077401> (\_eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1002/2018GL077401>) doi: <https://doi.org/10.1002/2018GL077401>

# Table des figures

1.1	Prévisions saisonnières probabilistes de la température de surface de l'air pour les mois de mars à mai 2021. La couleur bleue indique la probabilité d'un scénario plus froid que la normale, la rouge la probabilité d'un scénario plus chaud que la normale et la beige la probabilité d'un scénario proche de la normale. (MétéoFrance, 2021) . . . . .	1
1.2	Coefficient de corrélation entre la NAO et la réanalyse ERA-Interim de la température à 2 mètres pour les mois d'hiver (décembre à février) (1979-2015) (Hanna & Cropper, 2017). . . . .	4
2.1	Représentation 3D simplifiée de la dynamique de l'atmosphère montrant sa nature chaotique selon le système Lorenz (1963), extraite de Slingo et Palmer (2011).	6
2.2	Incertitudes pour les prévisions (Adapté de Slingo et Palmer (2011)) . . . . .	7
2.3	Incertitudes liées aux différents feedback. Les ordonnées représentent la valeur de feedback radiatif pour un scénario avec une abrupte quadruplication de CO <sub>2</sub> (Zelinka et al., 2020). . . . .	8
2.4	Importance relative des différentes sources d'incertitudes en fonction du temps pour la moyenne de température de surface globale décennale (Hawkins & Sutton, 2011). La <i>fractional uncertainty</i> représente l'incertitude divisée par le changement moyen attendu de température de surface, la courbe <i>internal variability</i> représente l'incertitude sur les conditions initiales, la courbe <i>model</i> celle provenant du modèle et la courbe <i>scenario</i> celle des conditions au frontières. . . . .	8
3.1	Sous-zones européennes basées sur Christensen et Christensen (2007). La zone étudiée est celle entourée par le cadre et rouge, et est agrandie sur la figure de droite. . . . .	13
3.2	Températures observées en fonction des températures prédites pour une cellule de la zone d'étude au mois de janvier. La droite en pointillés est la droite $y = x$ , la droite rouge est la droite de régression linéaire. . . . .	15
3.3	Exemples d'histogrammes de rang pour un modèle à biais négatif (en-haut à gauche), à biais positif (en-haut à droite), sous-dispersif (en bas à gauche), sur-dispersif (en bas à droite) et constant (milieu) (Callado et al., 2013) . . . . .	16
3.4	Exemples de diagrammes de fiabilité de prévisions saisonnières d'été avec le système 3 de l'ECMWF, pour a) la température de surface et b) les précipitations au-dessus du deuxième tercile (1981-2005) (Doblas-Reyes, 2010). Les lignes bleues indiquent la climatologie, la taille des cercles représente la fréquence relative de chaque probabilité de prévision, les barres grises donnent l'intervalle de confiance à 95% de la fréquence d'observation relative. . . . .	17

4.1	Valeurs des moyennes de température prédites et observées pour (a) novembre, (b) décembre, (c) janvier et (d) février. En noir sont représentées les prévisions de l'ECMWF avec un intervalle de confiance à 95% ainsi que les outliers de ces prévisions. Les croix bleues représentent les valeurs moyennes pour la zone d'étude prédites par la persistance en anomalies, les croix vertes celles prédites par la moyenne climatologique et les croix rouges les données de vérification. . . . .	18
4.2	Dérive du modèle de prévision saisonnière en fonction du temps. La courbe noire montre les températures moyennes prévues pour chaque mois par le modèle de l'ECMWF, la verte les températures moyennes prévues par la moyenne climatologique, la bleue les températures moyennes de la persistance en anomalies et la rouge la moyenne des données de vérifications. . . . .	19
4.3	Biais, corrélation de Pearson et erreur quadratique moyenne en fonction des mois. La courbe noire représente le modèle de l'ECMWF, la verte la moyenne climatologique et la bleue la persistance en anomalies. . . . .	21
4.4	Histogrammes de rang pour les mois de (a) novembre et (b) janvier. . . . .	22
4.5	Histogramme de rang des cellules corrigées du modèle de l'ECMWF entre 2016 et 2020 pour (a) novembre (b) décembre (c) janvier et (d) février. . . . .	22
4.6	Corrélation de Pearson entre les températures de surface prévues par le modèle de l'ECMWF et les données de vérification pour les mois de (a) novembre, (b) décembre et (c) janvier, de 1993 à 2020. Les croix bleues (vertes) sont placées là où la persistance en anomalies (la moyenne climatologique) présente une meilleure corrélation que le modèle de l'ECMWF. . . . .	23
4.7	Biais de température de surface du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a un biais moins élevé que le modèle. Les étoiles mauves montrent les cellules où les deux prévisions de contrôle ont un biais plus faible que celui du modèle de l'ECMWF. . . . .	24
4.8	Biais corrigé du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a un biais moins élevé que le modèle. . . . .	25
4.9	Erreur quadratique moyenne du modèle pour les mois de novembre (1), décembre (2) et février (3). Les croix vertes (bleues) montrent les cellules pour lesquelles la moyenne climatologique (persistance en anomalies) a une erreur quadratique moyenne moins élevée que le modèle. . . . .	26
4.10	Diagrammes de fiabilité par cellule du modèle de l'ECMWF pour (a) novembre, (b) décembre, (c) janvier et (d) février 1993 à 2020. Les points bleus représentent les valeurs inférieures au premier tercile, les rouges supérieurs au deuxième. La taille des cercles représente le nombre d'observations pour une probabilité donnée. . . . .	26
4.11	Effet d'une NAO négative en hiver sur les températures (MetOffice, s. d.). . . . .	27
4.12	Distribution prévue et température observée en (a) janvier et (b) février 2010. . . . .	28
4.13	Géopotential moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotential observés, en (a) janvier 2010 et (b) février 2010 (champ coloré). . . . .	28
4.14	Géopotential moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotential prédits, en (a) janvier 2010 et (b) février 2010 (champ coloré). . . . .	29
5.1	Erreur systématique de la valeur moyenne de température de surface du système 3 de l'ECMWF (un mois d'échéance de prévision, de 1981 à 2005) (Doblas-Reyes, 2010). . . . .	32

5.2	Biais annuel moyen de la température continentale à deux mètres (°C) par rapport à la <i>Climate Research Unit time series 4.01 data set</i> pour la période 1981-2010 (Roberts et al., 2018). . . . .	32
5.3	Diagramme de fiabilité des mois de décembre à février pour les températures à 2m supérieures au deuxième tercile de la distribution observée, pour la région européenne (35 à 75°N, 12.5°O à 42.5°E), de 1981 à 2016 (Johnson et al., 2019).	34
5.4	Géopotential moyen entre 1993 et 2009 (courbes bleues) et anomalie de géopotential (champ coloré) prédits pour le mois de février 2010 avec (a) cinq mois (b) quatre mois (c) trois mois (d) deux mois et (e) un mois d'échéance de prévision. La figure (f) montre le géopotential moyen et l'anomalie de géopotential observés pour la même période (données de vérification ERA5). . . . .	36
5.5	Performance de prévisions à 3, 5, 7 et 10 jours, pour les zones extra-tropicales (Bauer et al., 2015). La performance de prévision est la corrélation entre la prévision et l'analyse de vérification à la hauteur du niveau de 500hPa. Les valeurs supérieures à 60% indiquent des prévisions utiles, tandis que celles supérieures à 80% indique un grand degré de précision. . . . .	38
5.6	Illustration du CRPS Hudson (2017). PDF est la fonction de distribution de probabilité de la prévision et CDF la fonction de distribution cumulative de la prédiction. . . . .	38
5.7	Carte de CPRSS des températures à 2m pour SEAS5 (a) décembre à février et (b) juin à août et changements de score CPRSS entre SEAS4 et SEAS5 pour (c) décembre à février et (d) juin à août (Johnson et al., 2019). . . . .	39
5.8	Performance de corrélation d'anomalie de SEAS5 en Europe pour la température à 2 mètres, basée sur les hindcasts de 1981 à 2016 pour (a) mars à mai, (b) juin à août, (c) septembre à novembre et (d) décembre à février. Les points montrent les corrélations significatives à 95% (Stockdale et al., 2018). . . . .	40

# Liste des tableaux

4.1	Corrélations de Pearson, biais et erreurs quadratiques moyennes entre la température à deux mètres prédite par le modèle de l'ECMWF ou par les deux prévisions de contrôle et les valeurs de vérification de ERA5, pour les mois de novembre à février. . . . .	20
-----	---	----

# Biographie

## Coordonnées

Cécile Osy  
Chemin des blés, 113  
5024 Gelbressée (Belgique)  
cecileosy@hotmail.com  
0479/09.93.28

## Formation académique

2008 - 2014 : Études secondaires, à l'Institut de la Providence de Champion

2015-2019 : Bachelier en sciences géographiques, orientation générale, à l'Université Catholique de Louvain.

2019-2021 : Master [120] en sciences géographiques, orientation climatologie, à finalité approfondie, à l'Université Catholique de Louvain.

UNIVERSITÉ CATHOLIQUE DE LOUVAIN  
Faculté des sciences

Place des sciences, 2 bte L6.06.01, 1348 Louvain-la-Neuve, Belgique | [www.uclouvain.be/sc](http://www.uclouvain.be/sc)