


REPUBLIQUE DU CAMEROUN

Paix-Travail-Patrie

UNIVERSITE DE YAOUNDE I

CENTRE DE RECHERCHE ET DE
FORMATION DOCTORALE EN
SCIENCES, TECHNOLOGIE ET
GEOSCIENCES

UNITE DE RECHERCHE ET DE
FORMATION DOCTORALE EN
PHYSIQUE ET APPLICATION



REPUBLIC OF CAMEROON

Peace-Work-Fatherland

THE UNIVERSITY OF YAOUNDE I

POSTGRADUATE SCHOOL
OF SCIENCES, TECHNOLOGY AND
GEOSCIENCES

RESEARCH AND POSTGRADUATE
TRAINING UNIT FOR
PHYSICS AND APPLICATIONS

**Diagnostics des Prédicteurs atmosphériques pour une
Prévision Intra-Saisonnière Opérationnelle en Afrique
Centrale : application à l'agriculture et à la sécurité
alimentaire.**

Mémoire présenté et soutenu publiquement en vue de l'obtention du diplôme de
Master of Sciences in Physics

Spécialité : **Physique de l'Environnement Terrestre**

Option : **Sciences de l'Atmosphère**

par

BABE DOURANDI Edmond

Matricule : **20W2449**

Licencié en Physique

Sous la direction de :

Pr VONDOU Derbetini A.

Maître de Conférences

Université de Yaoundé I

Année Académique : 2023/2024



DÉDICACE

À

Ma mère MAIWASSO DJONSALA et
mon grand frère KIDWANG DOURANDI Gerard

REMERCIEMENTS

Je tiens en tout premier lieu à remercier mon Dieu qui m'a accordé la santé et la protection pour que je puisse finir ce mémoire dans des bonnes conditions.

Je tiens à remercier mon encadreur de mémoire Dr. IGRI MOUDI Pascal, pour avoir encadré ce travail bien qu'il soit difficile d'exprimer en quelques mots ma reconnaissance envers lui. Son expertise et sa rigueur scientifiques influenceront longtemps mes projets professionnels.

Ce travail n'aurait également pas pu être mené sans l'implication de Pr. VONDOU Derbetini Appolinaire, superviseur de mon travail, qui a pris le temps de répondre à mes questions et qui a fait preuve d'une grande écoute et d'une grande aide pendant cette période de rédaction.

J'adresse mes remerciements tout particuliers au Prof. Gerrit HOOGENBOOM, Professeur et chercheur émérite en Génie agricole et biologique et au Dr. Shelia VAKHTANG, développeur de l'outil de prévision CRAFT qui m'ont aidé dans compréhension d'une partie de cet outil de prévision de rendement des cultures qui reste notre priorité à l'avenir.

Mes remerciements vont tout droit à l'endroit des enseignants qui nous ont transmis les connaissances pour affronter notre carrière de recherche.

Merci NGNORA Bertin pour ton aide et la relecture attentive de mon mémoire.

Finalement, je n'oublie pas ma famille pour ses sacrifices et son soutien durant cette période d'études.

LISTE DES ABRÉVIATIONS ET ACRONYMES

ACP-UE	Pays d'Afrique, des Caraïbes et du Pacifique - Union Européenne
AMMA	<i>African Monsoon Multidisciplinary Analyses</i>
CAPC-AC	Centre d'Application et de Prévision Climatologique de l'Afrique Centrale
CCR	Centres Climatiques Régionaux
CDO	<i>Climate Data Operator</i>
CDSF	Fonds Spécial ClimDev-Afrique
CEPMET	Centre Européen de Prévision Météorologique à Moyen Terme
CHG	<i>Climate Hazards Group</i>
CHIRPS	<i>Climate Hazards group InfraRed Precipitation with Station data</i>
CPT	Climate Prediction Tool
CUA	Commission de l'Union Africaine
DMN	Direction de la Météorologie Nationale
ECMWF	<i>European Center for Medium-Range Weather Forecasts</i>
ENIAC	<i>Electronic Numerical Integrator Analyser and Computer</i>
ENSP	École Nationale Supérieure Polytechnique de Yaoundé
ERA-I	<i>ECMWF Reanalysis Interim</i>
ERA5	<i>ECMWF Reanalysis version five</i>
GFDRR	Facilité Mondiale pour la réduction des catastrophes et de relèvement
GFS	<i>Global Forecast System</i>
GIEC	Groupe d'experts Intergouvernemental sur l'Evolution du Climat
GROC	Relative Operational Characteristics Curve
MCG	Modèles de Circulation Générale
MJO	<i>Madden Julian Oscillation</i>
NASA	<i>National Aeronautics and Space Administration</i>
NAO	<i>North Atlantic Oscillation</i>
NCEP2	<i>National Center for Environmental Prediction</i>
NetCDF	<i>Network Common Data Form</i>

Liste des abréviations et acronymes

OMM	Organisation Météorologique Mondiale
PNT	Prévision Numérique du Temps
QZBD	<i>Quasi-Biweekly Zonal Dipole</i>
RPSS	<i>Ranked Probability Skill Score</i>
SMN	services météorologiques nationaux
TRMM	<i>Tropical Rainfall Measuring Mission</i>
UNISDR	Organisation des Nations Unies pour la Réduction des risques de Catastrophes
USGS-EROS	<i>United States Geological Survey Earth Resources Observation and Science Center</i>
USGS	<i>United States Geological Survey</i>
ZCIT	Zone de Convergence InterTropicale

RÉSUMÉ

Ce travail s'inscrit dans le cadre de l'opérationnalisation de la prévision intra-saisonnière appliquée à l'agriculture et à la sécurité alimentaire en Afrique central. Pour cela, l'interface PYCPT a été utilisé pour la prévision et l'analyse statistique/probabiliste. Les données d'observation des précipitations sont issues de CHIRPS sur une période de 1990 à 2019 et à une résolution de 5km. Les indices de la MJO, de l'ENSO, du QBO et les précipitations des différents modèles (suite des modèles NMME et UE-C3S) sont servis de prédicteurs atmosphériques afin de pouvoir détecter le lien entre ces paramètres. La méthode de Liebmann a été utilisée pour déterminer les débuts et les retraits des saisons de pluie. Une évaluation de la prévision a été faite en utilisant la méthode déterministe et probabiliste respectivement : Le coefficient de corrélation produit-moment de Pearson et le coefficient de corrélation de rang de Spearman, le score de compétence de probabilité classée (RPSS,anglais) et la généralisation de la courbe des caractéristiques opérationnelles relatives (GROC,anglais). Toutes ces méthodes ont contribué à détecter la corrélation entre la prévision et l'observation ou entre la prévision et la climatologie. Les résultats montrent une corrélation moyenne entre la prévision et l'observation où les valeurs atteignent parfois 0.6 et plus dans certaines zones à certaines périodes. Les méthodes probabilistes révèlent qu'il est bon d'utiliser la prévision dans la majeure partie du domaine d'étude en fournissant les valeurs positives pour le score RPSS et les valeurs supérieures à 50% pour le score GROC en plusieurs périodes (saisons, semaines). Le choix d'un modèle pour faire une prévision dépendra de l'appréciation de chaque prévisionniste combiné aux méthodes utilisées pour une zone et une saison données à étudier.

Mots clés : Prédicteurs atmosphériques, Prévision Intra-Saisonnière, Opérationnelle, Afrique Centrale, agriculture, sécurité alimentaire.

ABSTRACT

This work is part of the operationalization of intra-seasonal forecasting applied to agriculture and food security in Central Africa. The PYCPT interface was used for forecasting and statistical/probabilistic analysis. Rainfall observation data were obtained from CHIRPS over the period 1990 to 2019 at a resolution of 5km. MJO, ENSO, QBO indices and precipitation from different models (NMME and UE-C3S model suite) are used as atmospheric predictors in order to detect the link between these parameters. The Liebmann method was used to determine the start and end of the rainy season. An evaluation of the forecast was made using the deterministic and probabilistic method respectively : Pearson's product-moment correlation coefficient and Spearman's rank correlation coefficient, the Ranked Probability Skill Score (RPSS) and the Generalization of Relative Operational Characteristics Curve (GROC). All these methods have helped to detect the correlation between forecast and observation, or between forecast and climatology. The results show an average correlation between forecast and observation, with values sometimes reaching 0.6 or more in certain areas at certain periods. Probabilistic methods show that it is worth using forecasting in most of the study area, providing positive values for the RPSS score and values above 50% for the GROC score in several periods (seasons, weeks). The choice of a model to make a forecast will depend on the individual forecaster's judgement, combined with the methods used for a given area and season to be studied.

Keywords : Atmospheric predictors, Intra-seasonal forecasting, Operational, Central Africa, agriculture, food security

Liste des figures

Figure 1.1 –	Schéma de principe de la prévision d'ensemble. Sont représentés sur le schéma : la prévision déterministe (en bleu), les membres de la prévision d'ensemble (en noir) et l'observation (en vert)	6
Figure 1.2 –	Estimation qualitative de la compétence en matière de prévision basée sur une fourchette de prévisions allant des prévisions météorologiques à court terme aux prévisions saisonnières à long terme, y compris les sources potentielles de prévisibilité	9
Figure 1.3 –	Diagramme schématique mettant en évidence la relation entre la plage de prévision «étendue» intra-saisonnière à saisonnière (S2S) et d'autres échelles de temps de prévision, avec des exemples d'informations exploitables qui peuvent permettre la prise de décisions dans tous les secteurs (White et al., 2017).	10
Figure 1.4 –	Evolution des scores de compétence MJO (corrélations bivariées appliquées à WHI) depuis 2002, comme indiqué par les jours où la corrélation bivariée MJO atteint 0,6. Les scores de compétence MJO ont été calculés sur la moyenne d'ensemble des re-prévisions du CEPMMT produites au cours d'une année complète. Les barres verticales représentent l'intervalle de confiance à 95 % calculé à l'aide d'une procédure de rééchantillonnage bootstrap de 10 000.	14
Figure 1.5 –	Évolution des scores de compétences en SSW depuis 2004. Les scores quotidiens d'habileté SSW (corrélations appliquées à un indice SSW basé sur la différence de température à 50 hPa entre le pôle Nord et 30N sur toutes les longitudes) ont été calculés sur la moyenne d'ensemble des re-prévisions du CEPMMT d'octobre à mars et de l'ERA Interim. Les lignes bleue, rouge et marron indiquent le jour où la corrélation de l'indice SSW atteint respectivement 0,5, 0,6 et 0,8. Les barres verticales représentent l'intervalle de confiance à 95% calculé à l'aide d'une procédure de rééchantillonnage bootstrap de 10 000.	16

LISTE DES FIGURES

Figure 1.6 –	Moyenne climatologique des précipitations quotidiennes pour chaque jour de l'année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour 9,5°N, 14,5°W à partir de la moyenne GPCP sur 1997-2014. Les points magenta marquent l'étendue de la saison des eaux climatologique.	19
Figure 2.1 –	Topographie de l'Afrique Centrale	22
Figure 2.2 –	Diagramme temps-latitude des précipitations CHIRPS moyennées sur 8°E – 35°E.	23
Figure 2.3 –	Cumul annuel moyen de précipitations (mm) selon le fichier CHIRPS, période 1990-2019.	24
Figure 2.4 –	Schéma du flux de travail de PyCPT.	31
Figure 3.1 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase ElNiño et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019 . Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.	34
Figure 3.2 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase LaNiña et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019 . Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.	35
Figure 3.3 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase neutre et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.	36
Figure 3.4 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice MJO de la phase 1 et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.	38

LISTE DES FIGURES

Figure 3.5 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice MJO de la phase 8 et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %	39
Figure 3.6 –	Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice de l'Oscillation Quasi Bienal (QBO) et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %	40
Figure 3.7 –	Moyenne climatologique des précipitations quotidiennes pour chaque jour de l'année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour la zone du Centre d'Angola à partir de la moyenne CHIRPS sur 1990-2019. Le point noir (rouge) marque le début (la fin) de la saison des eaux climatologique.	41
Figure 3.8 –	Moyenne climatologique des précipitations quotidiennes pour chaque jour de l'année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour la zone de Yaoundé à partir de la moyenne CHIRPS sur 1990-2019. Les points noirs (rouges) marquent les débuts (les fins) de la saison des eaux climatologique.	42
Figure 3.9 –	Corrélation de Pearson pour les prévisions intra-saisonnières longues (sur plusieurs saisons).	43
Figure 3.10 –	Corrélation de Spearman pour les prévisions intra-saisonnières longues (sur plusieurs saisons).	44
Figure 3.11 –	Le score RPSS pour les prévisions intra-saisonnières longues (sur plusieurs saisons).	46
Figure 3.12 –	Le score GROC pour les prévisions intra-saisonnières longues (sur plusieurs saisons).	47
Figure 3.13 –	La corrélation de Pearson pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.	49

LISTE DES FIGURES

Figure 3.14 – La corrélation de Spearman pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.	50
Figure 3.15 – Le score RPSS pour les prévisions intrasaisonnières courtes, initialisé le 1 juin 2022.	51
Figure 3.16 – Le score GROC pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.	52

Liste des tableaux

Table 2.1 – Tableau caracteristiques des données de modèles (Siebert et al.,). 27

TABLE DES MATIÈRES

Table des matières

Dédicace	i
Remerciements	ii
Liste des abréviations et acronymes	iii
Résumé	v
Abstract	vi
Liste des figures	vii
Liste des tableaux	xi
Introduction Générale	1
1 Revue de la Littérature	3
1.1 Historiques de la prévision numérique	3
1.2 Prévisions météorologiques	5
1.2.1 Types de prévisions	5
1.3 Échelles de variabilité de prévisions	7
1.3.1 L'échelle synoptique	7
1.3.2 Prévisions sur l'échelle de temps S2S et variabilité intra-saisonnière . . .	8
1.3.3 Prévision à l'échelle saisonnière	12
1.4 Sources de prévisibilité (prédicteurs) intra-saisonnière et leur représentation dans le modèle ECMWF	12
1.4.1 MJO et ses télé-connexions	13
1.4.2 Réchauffements stratosphériques soudains et leur impact sur la basse troposphère	14
1.4.3 Conditions initiales du terrain	15
1.5 La prévision appliquée en agriculture	16

TABLE DES MATIÈRES

2	DOMAINE D'ÉTUDE, DONNÉES ET MÉTHODOLOGIE	21
2.1	Domaine d'étude	21
2.1.1	Topographie	21
2.1.2	Végétation	22
2.1.3	Climatologie et Précipitations	23
2.2	Données utilisées	25
2.2.1	Les donnés CHIRPS-2.0	25
2.2.2	Les données des modèles	25
2.3	Méthodes d'évaluation des prévisions	28
2.3.1	Méthodes déterministes	28
2.3.2	Méthodes probabilistes	28
2.3.3	PYCPT	30
3	Résultats et Discussions	33
3.1	Diagnostic des prédicteurs pour les prévisions	33
3.1.1	ENSO et Précipitations	33
3.1.2	MJO et Précipitations	37
3.1.3	QBO et Précipitations	40
3.2	Diagnostic climatologique des débuts et des retraits de saisons	41
3.3	Analyses des prévisions intra-saisonnières longues avec PYCPT	42
3.3.1	Méthodes statistiques	43
3.3.2	Méthodes probabilistes	45
3.4	Analyses des prévisions intra-saisonnières courtes avec PYCPT	48
3.4.1	Méthodes statistiques	48
3.4.2	Méthodes probabilistes	48
	Conclusion Générale et Perspectives	53
	Références	56

INTRODUCTION GÉNÉRALE

De nos jours, les secteurs d'application de la société s'intéresse de plus en plus à la compréhension et à l'utilisation d'une nouvelle génération de prévisions météorologiques à plage étendue qu'on appelle **prévisions intra-saisonnières aux prévisions saisonnières (S2S)** (White et al., 2017). Elles sont actuellement en cours de développement et d'opérationnalisation par les centres météorologiques du monde entier. Pourtant, les perspectives mensuelles et saisonnières à long terme sont opérationnelles dans certaines régions depuis de nombreuses années, l'échelle temporelle qui se situe entre les échelles de prévision à moyen et long terme (c'est-à-dire au-delà de 10 jours et jusqu'à 30 jours), a reçu une attention minimale jusqu'à présent (White et al., 2017). La plage de prévision intra-saisonnière à saisonnière est généralement considérée comme comblant l'écart entre les prévisions météorologiques et les perspectives mensuelles ou saisonnières (Figure 1.2) (Kirtman et al., 2014); (Vitart, 2014). Il est manifestement difficile de fournir des prédictions habiles sur les échelles de temps intra-saisonnières et mensuelles; cependant, les progrès récents ont suscité un intérêt croissant pour la prédiction S2S (Brunet et al., 2010). L'opérationnalisation de S2S et ses capacités axées sur les applications pour compléter les services de prévision existants offrent une opportunité significative aux secteurs tributaires du climats tels l'agriculture, la réduction de risque de catastrophe, la santé, l'énergie, la gestion de l'eau et autres (Reboita et al., 2010).

L'agriculture est un secteur économique essentiel et reste aujourd'hui le premier secteur d'activité dans de nombreux pays (Canal, 2014). Cependant, le bien-être de la culture est compromis par la diminution des précipitations, le potentiel changement climatique à long terme et les activités humaines (Igri et al., 2012). Avec une population mondiale en croissance exponentielle, les demandes alimentaires n'ont cessé de croître. Une augmentation considérable de la production mondiale de denrées alimentaires est ainsi nécessaire chaque année dans un contexte climatique de plus en plus sévère (Hiraishi et al., 2014). En effet, les systèmes agricoles sont très vulnérables à la variabilité du climat et les agriculteurs doivent composer avec ce facteur pour rentabiliser leur activité (Canal, 2014). Dans un contexte de changement climatique, la probabilité d'occurrence d'événements extrêmes est jugée à la hausse (Hiraishi

et al., 2014). Ces dernières années, la production agricole a été insuffisante dans plusieurs régions du monde (de 2007 à 2009 par exemple ; FAO, www.fao.org/worldfoodsituation/csdb/fr/) et qui a déclenché une crise alimentaire majeure en 2009 (Canal, 2014). C'est pourquoi il est souhaitable de renforcer et d'améliorer les outils permettant d'éviter ou au moins de limiter les situations d'insécurité alimentaires en AC. Tout l'enjeu consiste donc à anticiper les anomalies de rendement et de suggérer des solutions adéquates aux acteurs du monde agricole. Minimiser le risque associé à la hausse de variabilité naturelle du climat présente un grand intérêt afin d'accroître la productivité et la qualité des cultures. Cependant, les besoins humains pour ce qui est des approvisionnements fiables en aliments sains et nutritifs sont les mêmes partout dans le monde. Si l'agriculture revêt une importance capitale pour les pays en développement, c'est que d'une part le bon fonctionnement du secteur agricole est essentiel pour assurer la sécurité alimentaire et que, d'autre part, les produits agricoles constituent une source majeure du revenu national (Canal, 2014). Compte tenu de la variabilité climatique et des catastrophes naturelles liés à cette dernière sur l'environnement (inondations, sécheresses, etc) et sur l'activité économiques et sociale, nous avons la passion de donner notre modeste contribution dans la prévision de ces phénomènes. L'objectif est d'examiner dans quelle mesure les prévisions intra-saisonnières appliqués à l'agriculture et à l'insécurité alimentaire peuvent être opérationnalisées à l'échelle de l'Afrique Centrale. Pour cela, plusieurs modèles de prévision et les produits satellitaires sont utilisés pour déterminer les potentiels prédicteurs de la prévision intra-saisonnière afin d'accompagner les agriculteurs dans leurs activités.

La présentation de ce mémoire est conventionnelle. Le premier chapitre est consacré à la revue bibliographique. Le deuxième chapitre présente le domaine d'étude, les données utilisées et la méthodologie de l'évaluation des prédicteurs pour les prévisions et en fin le chapitre troisième ressort les résultats obtenus et les commentaires.

CHAPITRE 1

REVUE DE LA LITTÉRATURE

1.1 Historiques de la prévision numérique

La prévision numérique du temps est une discipline très jeune puisqu'elle s'est essentiellement développée au cours de la seconde moitié du XX^e siècle, bénéficiant de façon continue des progrès en matière d'outils de calcul automatique (Pailleux et al., 2015). Les techniques mises en œuvre permettent de résoudre, avec les méthodes du calcul numérique, les équations décrivant le comportement de l'atmosphère, c'est-à-dire de déterminer les valeurs futures de ses grandeurs caractéristiques en partant de valeurs initiales connues grâce aux observations météorologiques (Pailleux et al., 2015). Les modèles numériques d'atmosphère construits sur ce principe sont ainsi devenus les outils indispensables de la prévision du temps, supplantant progressivement les méthodes fondées sur l'application de règles de déplacement et d'évolution de structures atmosphériques identifiables (les centres d'action et les fronts) (Coiffier, 2000).

L'histoire de la prévision numérique du temps (PNT) a été jalonnée par un certain nombre d'étapes qui se sont révélées décisives pour l'évolution de cette discipline.

Dès 1904, le Norvégien Vilhelm Bjerknes reconnaît que la prévision du temps est fondamentalement un problème déterministe à valeurs initiales au sens mathématique du terme Coiffier (2000) : « Si, comme le pense chaque homme raisonnant scientifiquement, les phénomènes atmosphériques se développent à partir de ceux qui les précèdent suivant des lois précises, on peut en déduire que les conditions nécessaires et suffisantes pour une solution rationnelle de la prévision en météorologie sont les suivantes :

- on doit connaître avec une précision suffisante l'état de l'atmosphère à un instant donné ;

— on doit connaître avec une précision suffisante les lois selon lesquelles un état de l’atmosphère se développe à partir de l’état précédent. »

Entre 1916 et 1922, le Britannique Lewis Fry Richardson essaie de résoudre les équations de la prévision du temps de façon approchée avec les outils du calcul numérique. Il réalise même une prévision à six heures d’échéance qui se révèle complètement irréaliste (Coiffier, 2000).

En 1928, les mathématiciens allemands Courant, Friedrichs et Lewy étudient de façon systématique la manière de résoudre les équations aux dérivées partielles à l’aide des différences finies et précisent les contraintes à respecter lors de la numérisation.

En 1939, le Suédois Carl-Gustav Rossby montre que l’équation de conservation du tourbillon absolu permet d’interpréter correctement le déplacement observé des centres d’action atmosphériques.

En 1946, le premier calculateur électronique, l’Eniac (Electronic Numerical Integrator Analyser and Computer), voit le jour à l’université de Pennsylvanie située à Philadelphie (États-Unis), grâce à l’impulsion déterminante du mathématicien américain d’origine hongroise John Von Neumann

En 1948, l’Américain Jule Charney propose une simplification du système général d’équations, connue sous le nom d’approximation quasi-géostrophique, et retrouve comme cas particulier l’équation étudiée par Rossby (Coiffier, 2000).

Enfin, en 1950, J. Charney, le Norvégien R. Fjörtoft et J. von Neumann réalisent la première prévision numérique du temps (Besleaga, 1995). Ils utilisent pour cette expérience l’équation de conservation du tourbillon absolu et effectuent les calculs numériques sur le calculateur électronique Eniac, installé à Aberdeen (Maryland, États-Unis). Les résultats obtenus pour la prévision de l’altitude géopotentielle de la surface isobare 500 hPa, caractéristique de l’atmosphère moyenne, sont tout à fait encourageants et cette expérience historique marque ainsi le point de départ de la prévision numérique moderne. En réponse à Charney, qui lui avait fait parvenir l’article décrivant l’expérience, Richardson écrit en 1952 : « **Permettez-moi de vous féliciter ainsi que vos collaborateurs pour le remarquable succès que vous avez obtenu à Princeton et pour les perspectives d’amélioration que vous indiquez** » (Coiffier, 2000).

1.2 Prévisions météorologiques

1.2.1 Types de prévisions

Prévision déterministe

L'étude de l'évaluation de la prévision se proposant de répondre à la question : Pleuvra-t-il ou non demain dans une ville donnée ? permet d'appréhender les principaux aspects de la vérification d'un système de prévision (Rousseau, 2001). La définition précise de l'élément météorologique faisant l'objet de la prévision, le prédictand, est une condition nécessaire de sa vérification. L'utilisateur ne connaît pas toujours clairement le prédictand, en raison de la formulation souvent trop imprécise de la prévision. Une prévision de pluie doit se référer à un domaine d'espace et à un intervalle de temps précis. Ainsi, pluie demain sur une ville ne devrait pas être vérifié de la même façon selon que cela signifie qu'une pluie sera enregistrée par le pluviomètre du parc météorologique en un lieu, dans cette ville, entre 0 heures et 24 heures (ce prédictand est aisément observable par le service météorologique). Ou qu'il y aura une période de pluie en tout lieu de Paris entre 8 heures et 20 heures (ce prédictand est différent, tant par l'intervalle de temps que par le domaine concernés) (Rousseau, 2001). La vérification du second prédictand nécessite une analyse plus détaillée, s'appuyant à la fois sur les observations ponctuelles de pluviomètres et sur les images de radars météorologiques, qui pourra montrer qu'il aura plu sur une partie du domaine, mais non sur une autre. Cet exemple très simple montre la nécessité d'une définition précise du prédictand pour comprendre la prévision elle-même et pouvoir la vérifier. Nous supposons par la suite que le prédictand d'occurrence de précipitations aura fait l'objet d'une définition précise permettant de le comparer à une observation effective.

Prévision d'ensemble

A l'échéance de certaines prévisions, la prévision déterministe ne peut plus être utilisée (Canal, 2014). L'approche devient alors nécessairement probabiliste et requiert l'utilisation de techniques ensemblistes. Cela consiste à réaliser plusieurs jeux de prévisions, appelées membres, en représentant les différentes sources d'incertitude du système. Au final, on obtient non pas une prévision unique (appelée prévision déterministe), mais un ensemble de prévisions qui va être caractérisé par une fonction de probabilité et qui permettra de décrire succinctement la

distribution des variables d'intérêt pour une échéance donnée (Figure 1.1)(Canal, 2014).




FIGURE 1.1 – Schéma de principe de la prévision d'ensemble. Sont représentés sur le schéma : la prévision déterministe (en bleu), les membres de la prévision d'ensemble (en noir) et l'observation (en vert)

Plusieurs prévisions sont produites, variant de la dizaine à la cinquantaine selon les moyens numériques disponibles. Ce nombre doit être adapté afin d'apporter un intervalle d'incertitude stable et correctement associé au système étudié. La taille de l'ensemble et le choix des perturbations des conditions initiales sont des facteurs importants pour étudier la dispersion de l'ensemble et obtenir une mesure de la prévisibilité. Dans ce cas, il s'agit de représenter l'ensemble des incertitudes associées aux erreurs de représentation du champ des variables initiales(Canal, 2014).

Plusieurs méthodes existent : la plus simple consiste à réaliser plusieurs prévisions déterministes, démarrées à des dates successives (la prévision de la veille ou des jours à venir par

exemple) et constituer ensuite différents champs de conditions initiales du système. C'est la méthode de « lagged-average ». D'autres méthodes sont basées sur une approche utilisant des petites perturbations aléatoires (dite de Monte-Carlo). Elles visent à perturber un champ initial en tenant compte des observations incomplètes de l'atmosphère (il n'est pas possible d'observer toutes les variables, à tous les endroits et à tous les moments) et en cherchant le meilleur compromis entre cette observation et l'ébauche (à définir en pied de page) (Canal, 2014).

La prévision d'ensemble peut également porter sur la représentation des incertitudes de modélisation. En effet, les équations traduisant les lois physiques qui régissent les modèles climatiques ne sont pas parfaites (soit simplifiées, soit paramétrisées), car elles dépendent à la fois de la résolution du modèle lié aux moyens de calcul à disposition et à la représentation théorique d'un phénomène réel par un jeu d'équations (Canal, 2014). Ces différentes approximations utilisées dans la simulation de l'atmosphère introduisent une autre source d'incertitude dans la prévision. Pour la représenter, la prévision d'ensemble peut par exemple consister à utiliser plusieurs modèles. On parle alors de prévision multi-modèles. D'autres méthodes existent, comme perturber la physique du modèle ou encore introduire des perturbations stochastiques (Canal, 2014). La prévision d'ensemble permet ainsi d'établir un intervalle de prévisions du climat possible, sous forme de probabilité d'occurrence de tel ou tel scénario à différentes échéances.

La prévision d'ensemble est gourmande en calcul ; en revanche, c'est une application parfaitement adaptée aux supercalculateurs multiprocesseurs. Il y a quatre composantes principales qui contribuent au coût de calcul de la prévision d'ensemble :

- la construction des perturbations initiales ;
- la résolution du modèle d'intégration ;
- la taille (nombre de prévisions) de l'ensemble ;
- la longueur de l'intégration.

1.3 Échelles de variabilité de prévisions

1.3.1 L'échelle synoptique

A cette échelle, l'étape d'analyse repose sur l'identification de phénomènes météorologiques. Plusieurs de ces phénomènes peuvent exister simultanément dans l'atmosphère, à des échelles

spatio-temporelles diverses, du cumulus à l'anticyclone en passant par la perturbation. Traditionnellement, les météorologistes affectionnent tout particulièrement une échelle qu'ils nomment synoptique, du grec *synopticos* qui signifie littéralement qui embrasse d'un seul coup d'œil. Historiquement, la prévision synoptique est née de la recherche de structures caractéristiques qui pouvaient être reconnues d'un seul coup d'œil sur des documents où étaient pointées les différentes observations effectuées par un réseau de stations espacées d'environ 150 kilomètres (Dedebant et al., 1935). C'est ainsi que l'on a inventé le système nuageux (École française), la ligne de discontinuité et la perturbation constituée d'un front chaud et d'un front froid (École norvégienne). Les météorologistes constatèrent que ces phénomènes synoptiques se déplaçaient suivant des règles relativement simples et que l'on pouvait donc prévoir leur position future.

Aujourd'hui, la prévision reste fondée pour l'essentiel sur l'étude du cadre synoptique. Il s'agit d'une représentation conceptuelle de l'atmosphère composée d'un ensemble de phénomènes d'échelle synoptique, c'est-à-dire d'une dimension caractéristique de 1 000 à 2 500 km et d'une durée de vie d'un à trois jours. Fronts froids et fronts chauds restent les éléments de base de ce cadre synoptique, même si de nouveaux concepts s'imposent peu peu. La tâche du prévisionniste consiste à prévoir l'évolution de ce cadre synoptique afin d'en déduire ce que seront les conditions météorologiques futures, c'est-à-dire les éléments du temps sensible. La prévision numérique est le principal outil utilisé pour prévoir cette évolution. Ainsi, c'est cette dernière méthode qui est le fil directeur de notre travail.

1.3.2 Prévisions sur l'échelle de temps S2S et variabilité intra-saisonnière

Prévisions sur l'échelle de temps S2S

Une prévision climatique précise nécessite une bonne représentation des phénomènes météorologiques ainsi que des lois physiques sous-jacentes qui s'appliquent à toutes les échelles de temps de prévision (White et al., 2017). Alors que les prévisions météorologiques à court et moyen terme sont basées sur les conditions atmosphériques initiales, pour la prévision saisonnière, les conditions initiales du système couplé terre-océan sont plus importantes, les composantes de l'atmosphère variant rapidement souvent moins bien prédites et initialisées. L'échelle de temps S2S se situe entre ces plages de temps et est influencée à la fois par les conditions initiales de l'atmosphère et par les conditions aux limites évoluant plus lentement telles que les températures

de surface de la mer (SST), l'humidité du sol et les composants de la glace de mer. Ce sont ces différentes échelles de temps et d'espace de l'atmosphère, de la terre et de l'océan, et la capacité de les prédire, qui font de la prévision S2S un défi majeur (White et al., 2017).

Comme pour la prévision saisonnière, la compétence prédictive S2S repose sur plus que des conditions d'initialisation réalistes et SST, mais aussi sur des modes de circulation à grande échelle dans le système climatique, tels que l'oscillation El Niño-austral (ENSO), l'oscillation Madden-Julian (MJO), le dipôle de l'océan Indien et l'oscillation nord-atlantique, et leur influence connue sur des phénomènes météorologiques spécifiques, y compris des événements extrêmes (White et al., 2017).




FIGURE 1.2 – Estimation qualitative de la compétence en matière de prévision basée sur une fourchette de prévisions allant des prévisions météorologiques à court terme aux prévisions saisonnières à long terme, y compris les sources potentielles de prévisibilité

L'élaboration et l'application des prévisions météorologiques à moyenne échéance et des prévisions climatiques à échéance saisonnière ont marqué de nets progrès ces dernières décennies. Dans le cadre de prévision intra-saisonnière à saisonnière, les spécialistes du temps et du climat ont étudié ensemble cette échelle de temps intermédiaire ; ils ont mis à profit les connaissances et compétences communes et complémentaires qui ont acquises en matière de prévision. La variabilité intra-saisonnière fait généralement référence à des fluctuations à l'intérieur du cycle saisonnier. En Afrique de l'Ouest il s'agit en l'occurrence de phases sèches, ou de réduction des




FIGURE 1.3 – Diagramme schématisant la relation entre la plage de prévision «étendue» intra-saisonnière à saisonnière (S2S) et d'autres échelles de temps de prévision, avec des exemples d'informations exploitables qui peuvent permettre la prise de décisions dans tous les secteurs (White et al., 2017).

pluies, au cœur de la saison des pluies, donc entre mai-juin et septembre-octobre. Ces phases montrent deux périodicités moyennes différentes : autour de 15 jours et autour de 40 jours (Sultan et al., 2003). Une réduction des pluies pendant 15 ou 40 jours peut être critique pour l'agriculture et l'élevage dans des régions comme le Sahel (Meynadier, 2010). Bien qu'il s'agisse d'une échelle de variabilité cruciale pour les populations, les mécanismes à l'origine de cette variabilité ne sont pas encore tous connus.

Variabilité intra-saisonnière courte (10-25 jours)

Mounier et al. (2008) ont montré qu'il y avait deux modes de variabilité dans la gamme des périodicités de 10-25 jours. Le premier de ces modes appelé QZBD (pour Quasi-Biweekly Zonal Dipole) ou mode "guinéen" apparaît sur la côte Sud de l'Afrique de l'Ouest et sur l'Afrique Centrale. Il s'agit d'une modulation de la convection formant un dipôle est-ouest (entre l'Afrique

et l'Océan Atlantique). L'oscillation est stationnaire mais semble contrôlée par le passage d'une perturbation (onde) équatoriale. La modulation de la convection sur le continent africain fait intervenir l'advection d'humidité (phase positive) depuis l'océan vers le continent en réponse aux fluctuations de pression et température à la surface. Il trouve qu'il y a en moyenne 5.5 évènements de ce type par saison entre juin et septembre.

Le second mode à 10-25 jours, ou mode "sahélien" Sultan et al. (2003), est une perturbation de la convection (anomalie positive) dans la région sahélienne vers 15°N qui se propage vers l'ouest. Elle est associée à une circulation cyclonique à 700 hPa à l'avant qui advecte de l'air humide du sud et renforce l'anomalie de convection. Une cellule anticyclonique se forme à l'est qui advecte de l'air sec du nord et contribue au développement d'une anomalie négative de convection. Il est possible que ce mode soit dû à une onde de Rossby couplée à la convection (i.e. entretenue par les dégagements de chaleur dus à la convection). Les couplages entre la surface et l'atmosphère pourraient également contribuer au maintien et à la propagation de ce mode. Il prouve qu'il y a en moyenne 4.5 évènements de ce type par saison entre juin et septembre.

Variabilité intra-saisonnière longue (25 – 90 jours)

la variabilité de la convection au sein de la MAO a été reliée à l'activité de la MJO et dans une perspective plus large à l'impact de la mousson indienne sur la MAO via des ondes équatoriales. D'après Matthews et al (2004), la télé-connexion se fait par une interaction entre des ondes équatoriales de type Kelvin et les ondes de Rossby générées par la mousson indienne, se propageant respectivement vers l'est et l'ouest, qui se rencontrent au dessus de l'Afrique où elles renforcent la convection. Ces échelles expliquent entre 16 et 21% de la variance intra-saisonnière de la convection sur l'Afrique. L'étude statistique de Drobinski et al. (2009) basée sur les évènements intra-saisonniers dans la bande 25-90 jours a permis de caractériser les circulations atmosphériques associées à ce mode intrasaisonnier. En effet, cette variabilité se traduit par des anomalies convectives à l'est du lac Tchad se propageant lentement vers l'ouest sous l'influence notable des ondes de Rossby excitées depuis le bassin indien. Matthews et al. (2004) a montré que la plupart des évènements intra-saisonniers à l'échelle de 40 jours sur l'Afrique se projettent sur la structure grande échelle de la MJO.

1.3.3 Prévision à l'échelle saisonnière

La prévision saisonnière a démontré qu'il est possible de prévoir, malgré la nature chaotique de l'atmosphère, son état moyen à des échéances de trois à six mois (Palmer et Anderson, 1994). La prévision saisonnière se fonde sur le principe suivant : l'océan dont l'état évolue lentement, de manière prévisible, pilote le climat. Les modèles de prévision saisonnière, appelés aussi modèles de circulation générale (MCG) sont capables de prévoir correctement l'état moyen de la circulation atmosphérique. Ils savent prévoir, par exemple, les événements El Niño, La Niña et les oscillations de la zone de convergence intertropicale (ZCIT). Pour que les prévisions des MCG soient utilisables, il est nécessaire de les moyenner sur de larges régions et sur des périodes de temps d'environ trois mois.

Généralement, de telles prévisions sont peu adaptées aux utilisateurs. Ceux-ci attendent principalement des prévisions ayant une valeur socio-économique sur les phénomènes localisés dans le temps et l'espace qui ont un impact sur les activités humaines. Le défi de la descente d'échelle est de prévoir les conséquences aux échelles locales de la circulation de grande échelle prévue par les MCG. Pour y parvenir, deux grands courants méthodologiques coexistent : celui des dynamiciens et celui des statisticiens. Cependant, c'est dans les zones tropicales que la qualité des prévisions saisonnières est la meilleure (Palmer et Anderson, 1994) et que leur potentiel d'utilisation est le plus important.

1.4 Sources de prévisibilité (prédicteurs) intra-saisonnière et leur représentation dans le modèle ECMWF

Il existe une limite temporelle à la prévision déterministe du temps, qui se situe entre dix et vingt jours, durée correspondant à la mémoire de l'atmosphère (Lorenz, 1969). Cette durée est expliquée par l'introduction d'erreurs de petites échelles de temps, c'est-à-dire dans les conditions initiales de l'atmosphère et qui peuvent avoir un taux d'accroissement rapide. Dans ce cas, les incertitudes sur les conditions initiales ont un impact considérable sur l'état futur de l'atmosphère, affectant ainsi des échelles de temps plus grandes. C'est ce qui est appelé « l'effet papillon » (Canal, 2014). Celui-ci est d'autant plus important que l'état initial d'une prévision est incertain, notamment en raison de l'imprécision des systèmes d'observation. La prévisibilité

déterministe de systèmes chaotiques (tel que l’atmosphère peut l’être) est restreinte (Canal, 2014).

Plusieurs sources de prévisibilité pour l’intervalle de temps sub-saisonnier ont été identifiées au cours des dernières décennies. La présente section examine les liens entre la circulation extra-tropicale et la prévisibilité sub-saisonnaire avec l’oscillation Madden Julian et les tropiques, les réchauffements stratosphériques soudains et la troposphère et les conditions terrestres, comment ces liens sont simulés dans l’ensemble du CEPMMT et leur impact sur la capacité prédictive des prévisions mensuelles du CEPMMT (Vitart et al., 2014).

1.4.1 MJO et ses télé-connexions

L’oscillation Madden-Julian (MJO) est une source principale de prévisibilité dans les tropiques sur des échelles de temps supérieures à une semaine mais inférieures à une saison (Madden et Julian, 1971). L’indice de Wheeler et Hendon ((Yao et al., 2011)) a été appliqué à toutes les re-prévisions des modèles et à l’ERA-Interim (la version la plus récente et la plus précise de la réanalyse de l’ECMWF des dernières décennies, Dee et al 2011) sur la période 1995-2001 afin d’évaluer la capacité du système de prévisions mensuelles à prédire la MJO et de produire des composites pour les huit phases de la MJO (Vitart et al., 2014).

La figure 4 montre l’évolution d’un score de compétence MJO de 2002 à 2013 entre les re-prévisions moyennes d’ensemble et ERA-Interim. Dans cette figure, la ligne indique le jour de prévision où la corrélation bivariée a atteint 0,6. Si l’on considère la corrélation bivariée MJO de 0,6 comme une limite de la compétence de prévision de la MJO, le système de prévisions mensuelles du CEPMMT a démontré sa capacité à prévoir la MJO jusqu’à environ 15 jours en 2002. En 2013, la limite de 0,6 a été atteinte autour du 27e jour, ce qui suggère un gain moyen d’environ 1 jour d’avance par an. La différence des scores de compétence MJO entre 2002 et 2013 est statistiquement significative au niveau de confiance de 5 %.

Cassou (2008) a montré qu’il existe un lien entre la MJO et l’oscillation nord-atlantique (NAO) pendant le DJF. La probabilité d’une phase positive de la NAO (i.e. différence de pression atmosphérique au niveau de la mer entre la dépression islandaise et l’anticyclone des Açores) est augmentée de manière significative environ 10 jours après que la MJO soit en phase 3 (phase 3 + 10 jours), et diminue de manière significative environ 10 jours après la phase 6 de la MJO (phase 6 + 10 jours). La probabilité d’une phase négative de la NAO est diminuée (augmentée)

environ 10 jours après que la MJO soit en phase 3 (phase 6)(Vitart et al., 2014).




FIGURE 1.4 – Evolution des scores de compétence MJO (corrélations bivariées appliquées à WHI) depuis 2002, comme indiqué par les jours où la corrélation bivariée MJO atteint 0,6. Les scores de compétence MJO ont été calculés sur la moyenne d’ensemble des re-prévisions du CEPMMT produites au cours d’une année complète. Les barres verticales représentent l’intervalle de confiance à 95 % calculé à l’aide d’une procédure de rééchantillonnage bootstrap de 10 000.

1.4.2 Réchauffements stratosphériques soudains et leur impact sur la basse troposphère

Les réchauffements stratosphériques soudains (SSW), où le vortex polaire des vents d’ouest dans l’hémisphère hivernal ralentit brusquement (c’est-à-dire en l’espace de quelques jours) ou même inverse sa direction, accompagnés d’une augmentation de la température stratosphérique de plusieurs dizaines de kelvins, sont considérés comme une autre source potentielle de prévisibilité à l’échelle de temps sub-saisonnière (Vitart et al., 2014). Baldwin et Dunkerton (2001) ont montré une forte propagation apparente vers le bas des anomalies d’est et d’ouest de la stratosphère vers la troposphère à des échelles de temps mensuelles. Il est important de noter que ce phénomène tend à être suivi par des conditions d’est (NAO/AO négative) dans la troposphère (Jha, 2017) et les vents de la stratosphère tropicale sont caractérisés par l’oscillation quasi-biennale (QBO :

« Quasi Biennial oscillation ») (Canal, 2014). Les expériences de perturbation reproduisent également une NAO négative en réponse à un affaiblissement des vents stratosphériques à des échelles de temps sub-saisonniers et plus longues (Vitart et al., 2014).

La différence de température 50hPa entre 90°N et 30°N, moyennée sur toutes les longitudes, est utilisée comme indice pour les SSW (des résultats similaires ont été obtenus en utilisant un indice SSW différent basé sur le vent zonal à 10 hPa et 60°N). Les champs à 50 hPa ne sont archivés que depuis octobre 2004. Par conséquent, cette section ne prendra en compte que les re-prévisions qui ont été produites après 2004. La figure 10 montre que la corrélation de 0,6 est atteinte autour du jour 24 en 2013 (Vitart et al., 2014). Une amélioration notable de la qualité des prévisions depuis 2004 s’est produite en 2006, lorsque la résolution verticale du système de prévisions mensuelles du CEPMMT est passée de 40 à 62 niveaux verticaux, avec un niveau supérieur à environ 5 hPa au lieu de 10 hPa avant 2006. Les scores de compétence SSW se sont encore améliorés de manière significative en 2013 (période d’octobre 2013 à mars 2014) lorsque la résolution verticale des prévisions mensuelles a de nouveau été augmentée de 62 à 91 niveaux verticaux avec un niveau supérieur à 0,01 hPa (Vitart et al., 2014). Cela confirme que la résolution verticale, en particulier dans la stratosphère (les résolutions verticales de 91 et 62 étaient identiques dans la troposphère) a eu un impact positif sur la capacité de l’IFS à prévoir les SSW (Vitart et al., 2014).

1.4.3 Conditions initiales du terrain

Les projets GLACE (Global Land Atmosphere Coupling Experiment) et GLACE2 ont engagé plusieurs centres de recherche pour mener des expériences avec différents modèles du système terrestre partageant un protocole commun et des conditions aux limites égales. La configuration de l’IFS utilisée dans les expériences GLACE est documentée dans Vitart et al. (2008) et constitue la base du système de prévision mensuelle du CEPMMT connecté au système de prévision d’ensemble (Vitart et al., 2014). La première initiative GLACE, à laquelle le CEPMMT n’a pas participé, a donné lieu à d’importantes discussions scientifiques sur les thèmes suivants le rôle de la surface terrestre dans les prévisions à long terme. Les principaux résultats de ce projet comprennent des études de la prévisibilité de la température à 2 mètres (T2m) et des précipitations (P) exprimées sous forme d’anomalies par rapport au climat mensuel moyen prévu. L’une des limites de cette étude était l’absence de quantification du degré de prévisibilité et le




FIGURE 1.5 – Évolution des scores de compétences en SSW depuis 2004. Les scores quotidiens d’habileté SSW (corrélations appliquées à un indice SSW basé sur la différence de température à 50 hPa entre le pôle Nord et 30N sur toutes les longitudes) ont été calculés sur la moyenne d’ensemble des re-prévisions du CEPMMT d’octobre à mars et de l’ERA Interim. Les lignes bleue, rouge et marron indiquent le jour où la corrélation de l’indice SSW atteint respectivement 0,5, 0,6 et 0,8. Les barres verticales représentent l’intervalle de confiance à 95% calculé à l’aide d’une procédure de rééchantillonnage bootstrap de 10 000.

fait que la période était trop courte pour permettre de tirer des conclusions statistiquement significatives (Vitart et al., 2014).

Le projet GLACE2 a été conçu pour quantifier le gain de prévisibilité pour les anomalies de température à 2 mètres et de précipitations, lorsque des conditions initiales précises sont disponibles pour décrire la terre. Le protocole expérimental de GLACE2 consiste à exécuter une première série d’intégrations de modèles où la terre a été correctement initialisée (série 1) et une deuxième série d’intégrations (série 2) où les conditions initiales de la terre ont été randomisées (Vitart et al., 2014).

1.5 La prévision appliquée en agriculture

Avec l’utilisation de la prévision intrasaisonnière et saisonnière, il est donc possible de connaître une éventuelle anomalie en température et en précipitations des semaines et des

mois à venir. Ces deux variables ont une influence majeure sur l'évolution des cultures et cette information est précieuse pour une utilisation en agriculture. Une adaptation des pratiques agricoles en réponse à la prévision de conditions climatiques particulières peut être envisagée. Ces dernières années, de nombreuses études se sont intéressées au lien entre la variabilité du climat et l'agriculture (Canal, 2014). Les prévisions saisonnières offrent la possibilité d'anticiper les rendements agricoles et d'améliorer la gestion des cultures, en tirant profit des conditions favorables ou en réduisant les effets des conditions défavorables (Canal, 2014).

Le secteur agricole est l'un des groupes d'utilisateurs les plus avancés en termes d'utilisation des prévisions et des perspectives météorologiques pour soutenir les décisions opérationnelles sur le calendrier de l'irrigation, de la pulvérisation et de la récolte (White et al., 2017). Clements et coll. (2013) montrent que le calendrier S2S est très pertinent en agriculture, notant les études qui ont évalué l'utilisation des informations météorologiques en agriculture pour la gestion des cultures, les décisions d'irrigation, la commercialisation des produits, l'utilisation des intrants (par exemple les engrais) et le prix des produits de base. En utilisant une approche similaire au concept Ready-Set-Go!, en s'étendant vers le bas à partir de l'échelle saisonnière, une prévision saisonnière des totaux de précipitations pourrait éclairer les décisions stratégiques concernant les choix de plantation de cultures, tandis que les prévisions S2S des précipitations extrêmes ou des vagues de chaleur pourraient aider à la planification de l'irrigation et à l'application de pesticides / engrais (White et al., 2017). Les prévisions S2S pourraient être utilisées comme des mises à jour dynamiques d'un calendrier de culture existant, comme pour l'estimation des rendements des cultures pour aider à atténuer les problèmes de sécurité alimentaire mondiale (White et al., 2017). Des mécanismes régionaux tels que la forte oscillation intra-saisonnière, qui est une cause majeure des pauses de mousson pendant la saison de la mousson indienne, pourraient ajouter des informations précieuses pour la planification de l'irrigation. La base d'utilisateurs expérimentés du secteur agricole est très familière avec la nécessité d'exprimer des prévisions saisonnières en termes de caractéristiques météorologiques quotidiennes, telles que les périodes de sécheresse pendant les périodes de croissance critiques, et présente peut-être l'une des meilleures opportunités pour combler le fossé entre les échelles de temps et les prévisions climatiques. Étant donné que les impacts météorologiques ne sont que l'un des nombreux facteurs de stress qui façonnent les décisions des utilisateurs dans le secteur agricole, pour intégrer avec succès les prévisions S2S dans les pratiques de prise de décision existantes, des dialogues hautement

participatifs et spécifiques au contexte, aidés par des approches de modélisation rassemblant producteurs et utilisateurs de connaissances de disciplines diverses, sont nécessaires (White et al., 2017).

De nombreuses hypothèses ont été émises sur les changements passés des précipitations en Afrique, y compris les changements dans le calendrier du cycle saisonnier et les changements dans le début et la fin des saisons des pluies. Des témoignages d'agriculteurs de la région de l'Afrique de l'Ouest au sud du Sahel suggèrent un déplacement vers l'avant du début de la saison des pluies (Dunning et al., 2016). Toutefois, ce type de données n'est pas toujours révélateur de changements météorologiques et d'autres études portant sur cette région n'ont révélé aucune tendance significative (Dunning et al., 2016). Les changements futurs dans les schémas de circulation tropicale pourraient modifier la saisonnalité et entraîner une incertitude croissante dans le calendrier des saisons des pluies. Par exemple, l'extension des précipitations vers le nord et l'augmentation des précipitations du mois d'août au Sahel et les changements dans le début et la durée de la "petite saison sèche" qui se produit le long de la côte ouest-africaine pendant les mois d'été (Dunning et al., 2016). Ainsi, la connaissance des caractéristiques des saisons (début, fin, longueur, les pauses sèches etc....) dans une zone est précieuse pour fournir les informations aux agriculteurs afin de prendre des décisions éclairées pour leurs activités.

La méthode utilisée pour déterminer le début et la fin de la saison des pluies aux points de grille avec un régime annuel décrit ici est celle de Liebmann (Dunning et al., 2016). Dans un premier temps, la période de l'année où se produit la saison humide, appelée saison d'eau climatologique, doit être déterminée, afin de tenir compte des saisons qui s'étendent sur des années civiles. Tout d'abord, la moyenne climatologique des précipitations pour chaque jour de l'année civile, Q_i , où i va du 1er janvier au 31 décembre, est calculée (ligne rouge dans la figure 1.6) et la moyenne climatologique des précipitations quotidiennes $\bar{Q}$. A partir de là, on calcule l'anomalie climatologique le jour j , $C(d)$, est calculée :

$$C(d) = \sum_{i=1jan}^d (Q_i - \bar{Q})$$

où i va du 1er janvier au jour (d) pour lequel le calcul s'applique. Dans cet exemple, $C(d)$ est calculé pour chaque jour du 1er janvier au 31 décembre. La figure 1.6 représente $(Q_i - \bar{Q})$ par une ligne bleue et $C(d)$ par une ligne verte (Dunning et al., 2016).

Le jour du minimum de C marque le début de la saison d'eau climatologique, d_s , et le




FIGURE 1.6 – Moyenne climatologique des précipitations quotidiennes pour chaque jour de l’année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour 9,5°N, 14,5°W à partir de la moyenne GPCP sur 1997-2014. Les points magenta marquent l’étendue de la saison des eaux climatologique.

maximum marque la fin, d_e .

Dans la deuxième étape, les dates d’apparition sont calculées individuellement pour chaque année, en calculant l’anomalie pluviométrique journalière cumulée le jour D, $A(D)$ donnée par :

$$A(D) = \sum_{j=d_s-50}^D (R_j - \bar{Q})$$

où R_j est la pluviométrie du jour j et j est compris entre $d_s - 50$ et le jour considéré (D). $A(D)$ est calculé pour chaque jour de $d_s - 50$ à $j + 50$ pour chaque année. Le jour suivant le minimum dans $A(D)$ est le début, car ensuite les précipitations sont persistantes en termes d’occurrence, de durée et d’intensité, et le jour du maximum (après le minimum) est la date de cessation. Étant donné que la saison hydrologique climatologique peut potentiellement s’étendre sur plusieurs années civiles, le début et la fin ne sont pas calculés pour la première et la dernière année de chaque enregistrement (Dunning et al., 2016). Par contre, pour les points où il y a deux saisons des pluies par an, une méthode différente est nécessaire pour déterminer les périodes de l’année où les saisons des pluies, ou saisons des eaux climatologiques, se produisent (confert (Dunning

et al., 2016)).

Dans certaines régions, l'information apportée par les phases de l'ENSO suffit pour faire de la prévision fiable de rendement, sous certaines conditions : cela dépend de l'existence de télé-connexions apportées par l'ENSO. Les prévisions saisonnières de qualité sont surtout possibles aux latitudes tropicales, en relation avec une variabilité atmosphérique et océanique plus faible qu'aux latitudes moyennes.

CHAPITRE 2

DOMAINE D'ÉTUDE, DONNÉES ET MÉTHODOLOGIE

2.1 Domaine d'étude

2.1.1 Topographie

L'Afrique Centrale (20°S à 25°N et 5°E à 35°E) est principalement caractérisée par des espaces tabulaires ou par des plaines d'altitude varié pouvant influencer la distribution des vents (figure 2.1). Les plaines occupent surtout la bordure littorale, et sont drainées par des cours d'eau d'ordre secondaire, exception faite des fleuves Congo, Lac-Tchad et Niger. Dans l'intérieur des terres, les bas plateaux dominant ; les trois entités hydrographiques majeures sont les bassins du Congo, du Niger et du Lac-Tchad. Lac-Tchad et le Congo contribuent d'ailleurs à fournir des quantités non négligeables de vapeur d'eau à l'atmosphère. La cuvette tchadienne et congolaise sont en revanche plus basses, mais des massifs isolés peuvent y culminer à plus de 1500 ou 2000 m. Les massifs du Cameroun (4095 m), les Monts Tibesti (Tchad), le Plateau Batéké (au sud du Congo), les monts Mitumba (situé aux alentours de la vallée du rift) et le plateau de Bié (en Angola) sont les principales entités topographiques de la région. Leur développement spatial et altitudinal reste varié. Cependant, leur incidence sur la ressource en eau n'est pas négligeable, puisqu'ils contraignent le flux de mousson à des ascendances orographiques forcées qui en font de véritables châteaux d'eau pour l'Afrique Centrale (les fleuves Sanaga, le bassin du Lac-Tchad, Congo et Niger y prennent d'ailleurs leur source).




FIGURE 2.1 – Topographie de l'Afrique Centrale

2.1.2 Végétation

L'Afrique Centrale est recouverte d'une végétation essentiellement forestière, celle-ci cédant la place sur les franges nord et sud à des formations herbeuses plus ou moins boisées correspondant à une pluviométrie moins forte. Les grands types de végétation en Afrique Centrale sont (De Namur, 1990) :

- La forêt dense humide sempervirente (forme fléchie) qui se rencontre dans les zones à forte pluviométrie, de l'ordre de 2000-3000 mm/an, le long de la bordure atlantique du Cameroun et du Gabon, et à l'est du bassin du Congo, où elle est souvent mélangée à la forêt inondée. Elle est caractérisée par des essences à feuillage toujours vert. La défoliation n'est jamais totale, les arbres remplaçant leurs feuilles au fur et à mesure de leur chute.
- La forêt dense humide semi-décidue qui se caractérise physionomiquement par un mélange d'essences à feuillage toujours vert, et d'essences à feuillage caduc durant la saison sèche.

Ces forêts correspondent à une pluviosité de l'ordre de 1200-1600 mm/an pour les types les plus secs et de 1600-2000 mm/an pour les formes les plus humides.

- La forêt inondée qui occupe une grande partie de la Cuvette congolaise. C'est une forêt ombrophile, mais moins dense que la forêt de terre ferme. Les arbres sont de taille moyenne et adaptés aux conditions particulières de sols inondés.
- Dans cette région à dominante forestière se rencontrent également des savanes.
- La mangrove atlantique qui se développe sur le littoral dans les régions côtières basses, ainsi que le long des estuaires, sur un substrat vaseux. Au Cameroun, nous la trouvons à l'ouest du Mont Cameroun, ainsi qu'aux environs de Douala, dans l'estuaire du Cameroun.

2.1.3 Climatologie et Précipitations




FIGURE 2.2 – Diagramme temps-latitude des précipitations CHIRPS moyennées sur 8°E – 35°E.

La région à l'étude se situe entre 20°S à 25°N et 5°E à 35°E (Fig.2.1). Cette portion de la zone intertropicale africaine traversée par l'Équateur et bordée à l'ouest par l'Océan Atlantique représente pour l'essentiel les parties forestières. Le climat de cette région est sous la dépendance des anticyclones des Açores, Egypto-libyen, de Sainte-Hélène, Sud Africain, Indien et des flux et masses d'air qui leurs sont associés. Les saisons, essentiellement pluviométriques, sont déterminées par les positions respectives occupées par ces centres d'action et l'Équateur météorologique lors de leur migration sous l'influence du mouvement apparent du soleil. Les précipitations les

plus abondantes sont associées à la zone de convergence intertropicale (ZCIT)2.2 (Mpounza et Samba-Kimbata, 1990). Situé à cheval sur l'équateur, notre domaine d'étude appartient aux basses latitudes qui sont considérées comme une réserve énergétique.




FIGURE 2.3 – Cumul annuel moyen de précipitations (mm) selon le fichier CHIRPS, période 1990-2019.

L'Afrique Centrale offre une gamme de précipitations moyennes annuelles très diversifiées allant de plus humide (plus de 2000 mm) au moins humide (inférieur à 200 mm de précipitations) figure 2.3. Le plus grand contraste s'observe sur le littoral atlantique même où Debundscha au Cameroun dans la Baie de Biafra enregistre plus de 2500 mm et une partie du Tchad enregistre

moins de 200 mm de précipitations. Sur un territoire aussi vaste et présentant des conditions topographiques diverses, les régimes pluviométriques sont nécessairement nombreux et variés (Mpounza et Samba-Kimbata, 1990). Mais ils peuvent être regroupés en deux grandes familles : les régimes mono-modaux et les régimes bimodaux.

2.2 Données utilisées

2.2.1 Les données CHIRPS-2.0

Cette base de données pluviométriques disponibles sur l'ensemble de la planète nommée Climate Hazards group InfraRed Precipitation with Station data (CHIRPS) est issue de plusieurs études menées par notamment l'U.S. Geological Survey (USGS), les scientifiques du Climate Hazards Group (CHG) ainsi que la NASA. CHIRPS est ainsi le résultat d'un couplage de modèles de terrain, de stations pluviométriques et d'observations satellites permettant de construire une grille de haute résolution dont les erreurs sont corrigées grâce aux données terrain (Funk et al., 2015). Les experts de l'U.S. Geological Survey Earth Resources Observation and Science Center (USGS-EROS), en collaboration avec le Climate Hazards Group de l'Université de Santa Barbara en Californie, ont développé un jeu de données d'estimation de précipitations avec une couverture quasi-globale (50° – 50° N, 180° E – 180° W), selon une résolution de 0.05° de 1981 à nos jours : le Climate Hazards group InfraRed Precipitation with Stations (CHIRPS) (Funk et al., 2015). Ces données CHIRPS se présentent aussi sous forme de cartes spatialisées de précipitations à une résolution spatiale d'environ 5 km. Les images CHIRPS sont disponibles gratuitement et elles sont fournies en format Network Common Data Form (NetCDF). L'ensemble de données CHIRPS a été acquis via le site Web (ftp://ftp.chg.ucsb.edu/pub/org/chg/products/CHIRPS-2.0/global_daily/) pour les années 1990-2019.

2.2.2 Les données des modèles

Les prévisions intrasaisonnières et saisonnières sur les précipitations et sur les températures sont produites par la plupart des institutions de recherche sur le climat et les grands centres des prévisions (Konte, 2011). Elles sont conçues par ces structures sur la base de différentes méthodes :

- méthodes statistiques (modèle statistique) ;
- méthodes statistico-dynamiques (modèle statistico-dynamiques) ;
- méthode dynamiques (modèles dynamiques)

Les modèles statistiques : L'approche statistique consiste à rechercher des liens statistiques (télé-connections) entre certains indicateurs de la saison des pluies (indices pluviométriques) et des paramètres caractérisant l'état des systèmes atmosphérique et océanique. Ces liens peuvent être établis avec plusieurs techniques statistiques dont : la régression linéaire, l'analyse en composante principale (ACP), l'analyse en corrélation canonique (CCA), l'analyse en valeur singulière etc.. (Konte, 2011). De façon plus concrète, il s'agit de rechercher un modèle de régression linéaire multiple liant les indices de précipitation observés (prédicands, variables à expliquer) dans une zone climatique donnée (zone homogène du point de vue de la pluviométrie) et les Anomalies des Températures de Surface des Océans observées (ATSO) sur différents domaines océaniques qui sont les prédictors. Il s'agit d'établir, dans chaque zone climatique homogène, une relation entre les indices pluviométriques zonaux et les ATSO de ces différentes zones océaniques. Le modèle est conçu sur la base des données historiques (Konte, 2011). Ces indices sont des anomalies pluviométriques ou de Températures de Surface des Océans (TSO), entre la moyenne calculée sur une période de référence de 30 ans et la valeur annuelle.

Les modèles de prévision statistico-dynamiques sont basés à peu près sur le même principe que les modèles purement statistiques (Leroy et Céron, 2007). Dans ce cas, les prédictors sont les paramètres de sortie d'un modèle de circulation atmosphérique générale (GCM) forcé avec des TSO (prévues ou observés) ou bien les sorties d'un modèle couplé Océan-atmosphère. En général, les vents zonaux et méridionaux prévus par ces modèles sont utilisés comme prédictors. Dans certaines zones, les précipitations prévues par ces modèles peuvent être utilisées pour prévoir soit la température ou les précipitations. Sur la base de cette méthode et à l'aide du logiciel Climate Prediction Tool (CPT) mis au point par l'IRI, des modèles de réduction d'échelle de la prévision saisonnière peuvent être réalisés (Konte, 2011).

La méthode dynamique C'est une technique basée sur l'utilisation des modèles de circulation atmosphérique générale couplés (océan-atmosphère, océan-atmosphère-terre) ou non (forcés par des SST). Dans le but d'améliorer la performance des modèles de prévision, l'utilisation de plusieurs modèles et un ensemble de conditions aux limites (prévision d'ensembles multi-modèle) est pratiquée par les grandes institutions de production de prévisions saisonnières

dynamiques (Konte, 2011).

Dans cette étude, les données MCG sont extraites de l'ensemble multi-modèle nord-américain (NMME) et de la suite Copernicus de l'Union européenne (C3S). Le tableau 2.1 ci-dessous présente les modèles, les résolutions des modèles, les informations de référence, la période des données accessibles aux modèles et les variables prédictives utilisées dans cette étude (Siebert et al.,). Les données des modèles ont été extraites des sites web suivants ;

NMME : <https://iridl.ldeo.columbia.edu/SOURCES/.Models/.NMME/>

EU : <https://iridl.ldeo.columbia.edu/SOURCES/.EU/.Copernicus/.CDS/.C3S/>

Bien que d'autres modèles et variables prédictives existent dans les deux suites de modèles, l'accent a été mis ici sur l'utilisation de modèles opérationnels et de variables prédictives qui fonctionnaient bien avec PyCPT. l'utilisation de modèles opérationnels et de variables prédictives qui fonctionnent bien avec l'interface PyCPT dans sa configuration actuelle. Un plus large éventail d'études exploratoires pourrait être possible à l'avenir, au fur et à mesure que les capacités de PyCPT seront améliorées (Siebert et al.,).

TABLE 2.1 – Tableau caractéristiques des données de modèles (Siebert et al.,).

Modèles NMME	Predicteurs	Période temporelle	Résolution spatiale(°)
NASA-GEOSS2S	Précipitations	1981-2021	1x1
COLA-RSMAS-CCSM4	Précipitations	1982-2021	1x1
NCEP-CFSv2	Précipitations	1982-2021	1x1
Modèles EU C3S	Predicteurs	Période temporelle	Résolution spatiale(°)
ECMWF-SEAS5	Précipitations	1981-2021	1x1
DWD-GCFS2.1	Précipitations	1993-2021	1x1
CMCC-SPS3.5	Précipitations	1993-2021	1x1

2.3 Méthodes d'évaluation des prévisions

2.3.1 Méthodes déterministes

Corrélation de Pearson et de Spearman

Le coefficient de corrélation produit-moment de Pearson et le coefficient de corrélation de rang de Spearman ont été développés il y a plus d'un siècle (De Winter et al., 2016). Le coefficient de corrélation de Pearson de l'échantillon R_p est défini selon l'équation 2.1

$$R_p = \frac{\sum_{i=1}^N x_i y_i}{\sqrt{\sum_{i=1}^N x_i^2 \sum_{i=1}^N y_i^2}} \quad (2.1)$$

Le coefficient de corrélation de Spearman R_s est calculé de la même manière que R_p , sauf que R_s est calculé après que x et y ont été transformés en valeurs comprises entre 1 et N (équation 2.2). Lors du calcul de R_s , un classement dit fractionnaire est utilisé, ce qui signifie que le rang moyen est attribué en cas d'égalité. Par exemple, supposons que les deux plus petits nombres de x soient égaux, ils seront tous deux classés 1,5 (c'est-à-dire $[1+2]/2$) (De Winter et al., 2016). Là encore, un centrage de la moyenne est d'abord effectué (par soustraction de la valeur de la moyenne).

$$R_s = \frac{\sum_{i=1}^N x_{i,r} y_{i,r}}{\sqrt{\sum_{i=1}^N x_{i,r}^2 \sum_{i=1}^N y_{i,r}^2}} \quad (2.2)$$

2.3.2 Méthodes probabilistes

Nous utilisons ici le score de compétence de probabilité classée (RPSS,anglais) et une généralisation de la courbe des caractéristiques opérationnelles relatives (GROC,anglais) aux trois catégories de prévisions collectivement (Barnston et al., 2010).

Score de compétence de probabilité classée

Le RPSS est une extension du score de compétence de Brier à plus de deux catégories, qui commence par le calcul du score de probabilité classé (RPS). Le RPS est l'erreur de probabilité au carré, cumulée sur l'ensemble des catégories de prévision par ordre croissant, entre la probabilité de la prévision catégorielle et la " probabilité " observée correspondante (100 % de probabilité attribuée à la catégorie observée, 0% pour les autres catégories) (Barnston et al., 2010). Un RPS élevé indique une erreur de prévision plus importante. Le RPSS est positif lorsque le

RPS des prévisions est inférieur à celui d'une prévision de référence choisie (ici, la prévision climatologique d'une probabilité d'un tiers pour chaque catégorie) (Barnston et al., 2010). Le RPSS est défini par l'équation 2.3.

$$RPSS = 1 - \frac{RPS_{fct}}{RPS_{ref}} \quad (2.3)$$

Où fct fait référence aux prévisions, et ref se réfère à une prévision de référence telle que 1/3 pour chaque catégorie de tercile. Ici,

$$RPS = \frac{1}{nfct} \sum_{ifct=1}^{nfct} \left[\sum_{icat=1}^{ncat} (PCUM_{fct_{icat}} - PCUM_{obs_{icat}})^2 \right]$$

Où icat est le numéro de la catégorie, ncat est le nombre total de catégories, ifct est le numéro de la prévision, et nfct est le nombre total de prévisions.

Si $RPSS < 0\%$ alors la prévision a été ratée. Elle est moins bonne que la climatologie. De ce fait, dans ces zones mieux vaut utiliser la climatologie.

Si $RPSS > 0\%$ alors la prévision est bonne. Elle est meilleure que la climatologie, donc utilisable.

Si $RPSS = 100\%$, on dit que la prévision est parfaite.

généralisation de la courbe des caractéristiques opérationnelles relatives (GROC en anglais)

Ce score ROC généralisé (GROC) est la proportion de toutes les paires disponibles d'observations de catégories différentes dont les prévisions de probabilité sont discriminées dans la bonne direction. Le score a une échelle intuitive qui est attrayante pour de nombreux non-spécialistes : il a une valeur attendue de 50 % pour les stratégies de prévision inutiles (deviner ou prévoir toujours les mêmes probabilités), et les bonnes prévisions auront un score supérieur à 50 %, atteignant 100 % dans le cas d'une discrimination parfaite (Barnston et al., 2010). GROC est défini par l'équation 2.4 ci-dessous.

$$GROC = \frac{\sum_{k=1}^{m_\nu-1} \sum_{l=k+1}^{m_\nu} \sum_{i=1}^{n_k} \sum_{j=1}^{n_l} I(p_{k,i}, p_{l,j})}{\sum_{k=1}^{m_\nu-1} \sum_{l=k+1}^{m_\nu} n_k n_l} \quad (2.4)$$

Où $I(p_{k,i}, p_{l,j}) = 1, 0.5$, ou 0 , selon que la différence dans les prévisions de probabilité était dans le bon sens, était neutre ou était dans le mauvais sens, respectivement (confère (Mason, 2013) pour la formule permettant de déterminer quel résultat $I(p_{k,i}, p_{l,j})$ s'est produit). Ici, m_ν est le nombre de catégories, k et l identifient les différentes catégories observées dont les

prévisions sont comparées, i et j sont les nombres de prévisions dans les catégories spécifiées. Le numérateur additionne les résultats $I(p_{k,i}, p_{l,j})$ sur toutes les paires de prévisions qualifiées ; Le dénominateur contient le nombre de paires (Barnston et al., 2010).

GROC = 50% équivaut à un ROC de 0.5 qui appartient à la diagonale du graphe représentant la climatologie, dans ce cas le modèle n'a pas de skill donc ne détecte rien

GROC proche de 100% équivaut à un ROC proche de 1 qui signifie que le modèle est très performant.

GROC en deçà de 50%, le modèle fait moins bien que la climatologie (en-dessous de la diagonale).

En plus des méthodes d'évaluation des prévisions décrites ci-dessus, d'autres existent qui sont contenues dans une bibliothèque python, appelée **PYCPT** que nous utiliserons pour réaliser la vérification des prévisions.

2.3.3 PYCPT

PyCPT est une bibliothèque Python pour l'analyse statistique et la prévision des données climatiques. Elle fournit une gamme d'outils pour l'analyse des séries temporelles, y compris l'analyse des tendances, la décomposition saisonnière et l'analyse des corrélations. saisonnière et l'analyse des corrélations. Ces outils peuvent être utilisés pour identifier des modèles et des relations dans les données climatiques, qui peuvent ensuite être utilisés pour développer des prévisions pour les conditions climatiques sous-saisonnières (Muñoz et al., 2019).

Les prévisions infra-saisonnières constituent un domaine de recherche important dans le domaine de la science du climat, notamment dans des régions comme l'Afrique Centrale où le climat est fortement influencé par l'oscillation Madden-Julian (MJO) et d'autres facteurs climatiques à grande échelle qui agissent sur une échelle de temps de plusieurs semaines à quelques mois. En développant des prévisions sous-saisonnières, il est possible d'anticiper les changements des conditions climatiques et de prendre des mesures pour se préparer et s'adapter à ces changements.

Les analyses sous-jacentes à cette étude ont été réalisées à l'aide du nouvel outil Climate Predictability Tool (PyCPT) de l'IRI, basé sur Python (Muñoz et al., 2019). Le script Python de PyCPT appelle le logiciel existant Climate Predictability Tool (CPT) pour effectuer des analyses statistiques de la sortie d'un ou de plusieurs modèles climatiques par rapport à un ensemble de données d'observation au choix de l'utilisateur. Comme avec CPT, l'utilisateur

peut examiner la sortie brute du modèle sans correction des statistiques de sortie du modèle, ou peut effectuer une correction de la statistique de sortie du modèle, ou faire une prévision basée sur le MOS à l'aide de la régression en principale (PCR) ou l'analyse de corrélation canonique (CCA). Conformément aux développements plus récents de l'IRI, les itérations récentes de PyCPT permettent également à l'utilisateur d'effectuer des analyses à l'aide de la régression logistique étendue (ELR) (Siebert et al.,).

Utilisation de PYCPT

Pour utiliser PyCPT pour les prévisions sous-saisonnières, la première étape consiste à acquérir et à pré-traiter les données climatiques pertinentes. Il peut s'agir de données sur la température, les précipitations et d'autres variables climatiques, ainsi que de données sur la MJO et d'autres facteurs climatiques à grande échelle. Les données doivent être nettoyées, validées et mises en forme dans un format de série temporelle adapté à l'analyse (Simon J. Mason, 2020).

L'interface PyCPT permet aux utilisateurs de présélectionner un certain nombre de modèles potentiels et leurs données d'observation, les variables prédictives d'intérêt, les domaines du prédicteur et du prédictand, la période de la fenêtre d'entraînement et les détails de la période de prévision (saison et année cibles, délai de prévision). Une fois ces sélections effectuées, PyCPT permet à l'utilisateur de faire des prévisions qui sont calibrées et corrigées du biais sur la base d'un modèle individuel et où les prévisions des modèles individuels sont ensuite combinées pour former une prévision d'ensemble multi-modèle (Siebert et al.,). PyCPT fournit également une évaluation de la compétence des prévisions et des mesures de compétence pour les modèles individuels et l'ensemble multi-modèle. Les prévisions résultantes sont ensuite encadrées dans un format objectif, avec la distribution de probabilité complète pour chaque emplacement dans le domaine du prédictand. Cela permet une plus grande flexibilité de la part de l'utilisateur (Siebert et al.,). Le flux de travail de PyCPT est illustré dans la figure 2.4 ci-dessous.



FIGURE 2.4 – Schéma du flux de travail de PyCPT.

Dans cette analyse, en raison des contraintes des modèles EU-Copernicus mentionnées dans le tableau 1, la fenêtre d'entraînement a été 1993-2016. Les données d'observation CHIRPS couvrent une grande période. La méthodologie de prévision choisie pour cette étude est l'analyse de corrélation canonique (CCA), car il est généralement démontré que cette méthode produit des prévisions robustes lorsque les données du prédicteur et du prédicand sont sous forme de tableau (Siebert et al.,). Bien que les atouts de l'ACC pour déterminer les modèles spatiaux qui expliquent la variance maximale soient connus depuis longtemps, il est nécessaire de limiter le nombre de composantes principales utilisées afin d'éviter les prédictions fallacieuses ou artificielles. À cette fin, PyCPT et CPT permettent également aux utilisateurs de sélectionner un nombre maximum de modes à prendre en compte dans la prévision (Siebert et al.,).

PyCPT est un outil puissant pour les prévisions sous-saisonnières dans les régions au climat complexe et variable. Sa gamme d'outils et de modèles statistiques, combinée à sa facilité d'utilisation et à son intégration avec Python, en font une ressource précieuse pour les météorologues, les climatologues, les chercheurs et les décideurs. En utilisant PyCPT pour développer des prévisions sous-saisonnières précises et fiables, il est possible de mieux anticiper les impacts du changement climatique et de s'y adapter. Cela peut contribuer à réduire les risques et les coûts associés aux événements météorologiques extrêmes, à protéger les populations vulnérables et à promouvoir le développement durable (Muñoz et al., 2019).

CHAPITRE 3

RÉSULTATS ET DISCUSSIONS

3.1 Diagnostic des prédicteurs pour les prévisions

3.1.1 ENSO et Précipitations

La distribution spatiale (phase ElNino figure 3.1) sur notre domaine d'étude des coefficients de corrélation de Pearson montre en tenant compte de la zone pluvieuse une dominance des valeurs positives aux des mois : de Janvier, mars, avril et de août à décembre où les valeurs maximales avoisinent 0.6 dans certaines zones. De plus, les niveaux de significativité sont signalés dans ces zones à valeurs positives (excepté quelques parties négatives). Par contre, les valeurs négatives dominent les mois de février et de mai à juillet.

La distribution spatiale (phase LaNina figure 3.2) des coefficients de corrélation de Pearson montre en tenant compte de la zone pluvieuse et de seuil de significativité à 95% une dominance des valeurs positives aux mois : de mars à juin et d'octobre où les valeurs maximales dépassent 0.6 (ici ces fortes valeurs sont parfois dues au petite taille de l'échantillon) dans certaines zones. En outre, les valeurs négatives sont plus dominantes aux mois de janvier, juillet, août , septembre,novembre et décembre.

La figure 3.3 est la représentation spatiale des coefficients de Pearson entre l'indice de phase neutre de ENSO et l'anomalie de précipitations. Nous remarquons que les valeurs positives sont perceptiblement dominantes sur tous les mois (excepté le mois de mars qui présente une dominance négative).

Les valeurs positives prouvent que les deux paramètres évoluent dans le même sens, c'est à dire que quand la température de surface de la mer dépasse la normale au dans la zone




FIGURE 3.1 – Corrélacion mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase ElNiño et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019 . Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.




FIGURE 3.2 – Corrélacion mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase LaNiña et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019 . Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.




FIGURE 3.3 – Corrélacion mensuelle moyenne (tous les mois) en un point entre l'indice ENSO de la phase neutre et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.

de l'ENSO alors les précipitations dépassent également la normale dans ces zones de valeurs positives de notre domaine d'étude et c'est le contraire pour les zones de valeurs négatives.

3.1.2 MJO et Précipitations

La phase 1 de l'indice MJO montre une bonne corrélation avec l'anomalie positive des précipitations sur la majeure partie du domaine et les mois ; cela prouve qu'elle amplifie la hauteur des précipitations, excepté le mois d'avril (figure 3.4). Les valeurs maximales avoisinant 0.6 sont localisées plus en RDC et qui indiquent signification à un niveau de confiance de 95 % correspondant à ces valeurs maximales. Ainsi, quand la MJO est dans sa phase 1 aux mois de février et de mars, la majeure partie de la RDC se trouve dans l'excédent des précipitations. De même, si on est au mois de juin (c'est la partie du Sud de la RDC qui en excès) et juillet (c'est la partie du Sud-Est qui est plus concernée). L'excédent des précipitations du mois de mai à l'Extrême-Nord du Cameroun et le Centre du Tchad pourrait être associé au passage de la MJO dans ces zones. En outre, au mois d'avril il y a réduction des précipitations au Gabon, à l'Ouest du Congo Brazzaville et une petite partie de l'Est du Cameroun.




FIGURE 3.4 – Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice MJO de la phase 1 et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.

La phase 8 de l'indice MJO montre quant à elle une bonne corrélation avec l'anomalie positive des précipitations aux mois : de janvier à mars, de mai, juin et de septembre à décembre ; cela prouve qu'elle amplifie la hauteur des précipitations pendant ces période également. Par contre, aux mois d'avril, juillet et août le passage de la MJO phase 8 inhibe les précipitations (figure 3.5). Les valeurs maximales proche de 0.6 sont localisées (à l'Ouest et Nord-Est de la RDC au mois de février, au Sud de la RDC pour mars, à l'Ouest et au Sud du Cameroun, etc..) et qui indiquent les valeurs de corrélation significatives à un niveau de 95 % correspondant à ces valeurs maximales.




FIGURE 3.5 – Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice MJO de la phase 8 et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %.

3.1.3 QBO et Précipitations

La figure 3.6 est la représentation spatiale mensuelle moyenne des coefficients de Pearson entre l'indice de QBO et l'anomalie de précipitations. Nous remarquons que les valeurs positives sont perceptiblement dominantes sur tous les mois. Cependant, les maxima de corrélations avec le niveau 95% de signification sont localisées en RDC, sud du Congo Brazza et Nord de l'Angola pour le janvier, en RCA et Cameroun en avril. En outre, les valeurs négatives sont minimales et les plus faibles se trouvent au Tchad au mois de juillet.




FIGURE 3.6 – Corrélation mensuelle moyenne (tous les mois) en un point entre l'indice de l'Oscillation Quasi Bienal (QBO) et l'anomalie des précipitations (CHIRPS) sur la période 1990-2019. Les points noirs indiquent les valeurs de corrélation de Pearson significatives à un niveau de 95 %

3.2 Diagnostic climatologique des débuts et des retraits de saisons




FIGURE 3.7 – Moyenne climatologique des précipitations quotidiennes pour chaque jour de l’année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour la zone du Centre d’Angola à partir de la moyenne CHIRPS sur 1990-2019. Le point noir (rouge) marque le début (la fin) de la saison des eaux climatologique.

L’application de la prévision à l’agriculture commence par la connaissance des débuts et des fins des pluies pour pouvoir déterminer les saisons afin de fournir les informations météorologiques et climatologiques adéquates aux agriculteurs. Ainsi le diagnostic des débuts et des fins de saisons dans un endroit précis retient notre attention dans cette partie ; c’est pourquoi les figures 3.6 et 3.7 montrent la détection des saisons au Centre de l’Angola et au centre du Cameroun (Yaoundé) respectivement. Il ressort de l’analyse que cette partie de l’Angola est dans une zone monomodale donc sa saison commence en moyenne le **07 octobre** et s’achève en moyenne le **10 avril** (environ 6 mois de longueur). Par contre, Yaoundé est dans une zone bimodale (deux saisons) qui sont : la première commence autour du **13 mars** et finit autour du **03 juillet** (presque 4 mois) et la deuxième commence en moyenne le **18 août** et s’achève au tour du

06 novembre (pratiquement 4 mois également).




FIGURE 3.8 – Moyenne climatologique des précipitations quotidiennes pour chaque jour de l’année (rouge), anomalie climatologique de la moyenne journalière des précipitations (bleu) et anomalie climatologique cumulée de la moyenne journalière des précipitations (vert) pour la zone de Yaoundé à partir de la moyenne CHIRPS sur 1990-2019. Les points noirs (rouges) marquent les débuts (les fins) de la saison des eaux climatologique.

3.3 Analyses des prévisions intra-saisonnières longues avec PYCPT

Six combinaisons différentes de suites de modèles et 3 variables ont été utilisées comme prédicteurs potentiels pour les différentes saisons montrées sur les figures ci-dessous en utilisant les données observées de CHIRPS comme prédicteurs : Précipitations NMME, précipitations EU-C3S, précipitations NMME+EU-C3S. Les résultats de cette analyse sont présentés ci-dessous en figures avec les corrélations et les scores probabilistes.

3.3.1 Méthodes statistiques

De manière générale, les figures 3.9, 3.10 montrent que la corrélation du modèle NASA-GEOS2S est inférieure à celle de la plupart des autres modèles (à l'exception des bonnes valeurs de corrélation sur les côtes angolaises et une bonne partie du Gabon pendant la saison Apr-Jun).




FIGURE 3.9 – Corrélation de Pearson pour les prévisions intra-saisonnières longues (sur plusieurs saisons).

Cependant, en prenant les saisons individuellement, nous pouvons faire des analyses comme suit :

- le modèle CMCC montre une meilleure corrélation pour la saison Feb-Apr ;
- le modèle NCEP est meilleur pour la saison Mar-May par rapport aux autres qui donne




FIGURE 3.10 – Corrélation de Spearman pour les prévisions intra-saisonnières longues (sur plusieurs saisons).

des bonnes valeurs des corrélations en Angola d'autant plus que la figure 3.7 montre la fin de la saison de pluie en avril ;

- la saison Apr-Jun révèle plutôt la bonne compétence du modèle nord américain, NASA ;
- le modèle DWD de l'EU montre une meilleure valeur des corrélations pour la saison May-Jul ;
- la saison Jun-Aug montre une ambiguïté dans le choix du meilleur modèle. Cependant, comme c'est la période où le ZCIT est à son maximum au Nord, nous pouvons dire que le modèle NCEP est adapté mais en restant modérer dans notre choix parce que cette saison est l'une des plus importantes dans le domaine de l'agriculture sur zone d'étude ;
- en ce qui concerne la saison Jul-Sep, le modèle ECMWF montre des meilleures valeurs de corrélations ;
- le modèle ECMWF semble montrer également des meilleures valeurs de corrélations pour la saison Aug-Oct ;
- pour la saison Sep-Nov, les modèles ECMWF et NCEP montrent des meilleures valeurs de corrélations ;
- enfin pour la saison Oct-Dec, le modèle CMCC montre des meilleures valeurs de corrélations par rapport aux autres.

Pour une prévision particulière et dans une zone bien définie, le choix des modèles n'est pas le même comme ci-dessus parce que cette analyse ci-haut est faite de manière générale sur notre domaine d'étude. Par exemple pour étudier la saison février-avril au Cameroun, il est préférable d'utiliser le modèle NASA-GEOSS2S alors que dans l'ensemble c'est le modèle CMCC qui a été choisi.

3.3.2 Méthodes probabilistes

L'analyse de la carte de pourcentage de cas de prévisions meilleures ou moins bonnes que la climatologie (Méthode RPSS), a révélé que sur une période d'entraînement (1993 à 2016), les valeurs positives sont dans la majeure partie du domaine d'étude pour la plus part des modèles, alors la prévision est meilleure que la climatologie, donc utilisable. Les maxima sont réparties au Sud de l'Angola durant les saisons mai-juillet et juin-août. Par contre, les valeurs négatives sont

le plus souvent localisées au Nord du Tchad, quelques fois au Sud-Est de la RDC, au Nord-Est et Sud-Est de l'Angola. Ainsi, dans ces zones l'utilisation de la climatologie est meilleure que la prévision (figure 3.11).




FIGURE 3.11 – Le score RPSS pour les prévisions intra-saisonnières longues (sur plusieurs saisons).

La distribution spatiale de score GROC (figure 3.12) montre une performance similaire de tous les modèles pour la saison février-avril où les meilleures valeurs sont localisées en RDC et RCA (prévision meilleure que la climatologie donc à utiliser) alors que les faibles valeurs sont au Sud du Tchad et l'Extrême-Nord du Cameroun (climatologie mieux à utiliser). Pour les saisons mars-mai, avril-juin et mai-juillet les grandes valeurs sont reparties en RDC et en Angola par la majorité des modèles. Ces derniers semblent s'accorder en montrant les maxima de




FIGURE 3.12 – Le score GROC pour les prévisions intra-saisonnières longues (sur plusieurs saisons).

données au Nord du Tchad et quelques fois à l'Est de la RDC pour les saisons juin-août, juillet-septembre et août-octobre. Les grandes valeurs de GROC pour les saisons septembre-novembre et octobre-décembre sont spatialement distribuées en Angola, en RDC et au Cameroun. Les parties blanches sont dues aux valeurs manquantes.

3.4 Analyses des prévisions intra-saisonnières courtes avec PYCPT

3.4.1 Méthodes statistiques

Corrélations de Pearson et de Spearman

Les figures 3.13 et 3.14 représentent la distribution spatiale des corrélations de Pearson et de Spearman respectivement. L'analyse des ces figures montre que le modèle ECMWF est mieux pour la première semaine que les autres parce que la figure 2.2 indique qu'au mois de juin, les précipitations se localisent entre 10°S et 15°N. En tenant toujours compte de la localisation des précipitations pour ce mois, le modèle CFSv2_SubX semble être robuste par rapport aux autres modèles pour la deuxième semaine.




FIGURE 3.13 – La corrélation de Pearson pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.

Pour la semaine 3, comme on peut le voir ci-dessous, tant pour la corrélation de Pearson que pour la corrélation de Spearman, le modèles qui produit les prévisions les plus robustes/habiles pour la période d'entraînement sont les précipitations de ECMWF, bien que les prévisions fournies par le modèle CFSv2_SubX offrent également un certain potentiel. Par ailleurs, le modèle CFSv2_SubX montre des meilleures valeurs des deux corrélations pour la semaine 3 au 4 et tout le mois de juin.




FIGURE 3.14 – La corrélation de Spearman pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.

3.4.2 Méthodes probabilistes

Scores RPSS et GROC

L'analyse de la figure 3.15 montre que le modèle ECMWF produit des bonnes prévisions par rapport aux autres modèles de manière générale sur notre domaine. Cependant, si l'étude est localisée au Tchad ou au Nord du Cameroun, il est souhaitable de choisir le CFSv2_SubX qui donne de meilleures prévisions dans ces zones. De même, le modèle ESRL est plus performant au Nord du Cameroun pour la deuxième semaine durant ce mois. Les valeurs négatives de RPSS indiquent que la climatologie est meilleure par rapport aux prévisions dans ces zones. La figure 3.16 montre plus ou moins une concordance entre les modèles dans l'ensemble, bien




FIGURE 3.15 – Le score RPSS pour les prévisions intrasaisonnières courtes, initialisé le 1 juin 2022.

qu'en entrant dans une analyse détaillée, nous détectons certaines différences soit en fonction

des zones, soit en fonction de valeurs etc. La zone où la performance des modèles est faible se focalise plus au Centre de la RDC dont les valeurs de GROC sont comprises entre 40-50%. Les zones où toutes les valeurs sont supérieures à 50% indiquent que les modèles y sont performants.




FIGURE 3.16 – Le score GROC pour les prévisions intra-saisonnières courtes, initialisé le 1 juin 2022.

De toutes ces méthodes décrites ci-dessus, le choix d'un modèle pour faire une prévision dépendra de l'appréciation de chaque prévisionniste, de la ou les méthodes utilisée, de la zone et de la saison à étudier.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Les prédicteurs atmosphériques pour une prévision intra-Saisonnière Opérationnelle en Afrique Centrale ont été diagnostiqués par les méthodes statistiques telles que les corrélations de Pearson et de Spearman et par les méthodes probabilistes comme les scores RPSS et GROC. L'application de cette prévision à l'agriculture et à l'insécurité alimentaire nous a poussée à diagnostiquer également les débuts et les fins des saisons dans quelques zones de notre domaine d'étude par la méthode de Liebmann décrite par Dunning et al. en 2016. Ces diagnostics sont faits sur la période de 1990 à 2019 pour les prédicteurs à grande échelle : ENSO, QBO et MJO et les périodes d'entraînement de 1993 à 2016 (prévision intra-saisonnière longue) puis de 1901 à 1981 (prévision intra-saisonnière courte) pour les prédicteurs qui sont dans la bibliothèque PYCPT qui est l'outil de l'opérationnalisation de notre prévision. Les données des différents modèles (la suite des modèles NMME et EU-C3S) sont utilisées pour faire la prévision et celles de référence CHIRPS pour valider ces prévisions numériques.

Une étude climatologique (1990-2019) mensuelle a été menée pour établir le lien entre les précipitations et les indices ENSO, MJO et QBO afin d'aider les prévisionnistes dans la production des informations climatologiques/météorologiques pour assister les agriculteurs dans leurs activités. La connaissance des prédicteurs atmosphériques à grande échelle est nécessaire pour une bonne prévision, qu'elle soit climatique, saisonnière, intra-saisonnière ou même journalière. Cependant, la corrélation de Pearson est utilisée pour détecter ce lien entre l'anomalie des précipitations et les trois indices.

Ainsi, les coefficients de corrélation de la phase ElNino montre une dominance des valeurs positives aux mois : de Janvier, mars, avril et de aout à décembre où les valeurs maximales avoisinent 0.6 dans certaines zones avec les niveaux de significativité dans ces zones à valeurs positives (excepté quelques parties). Les valeurs négatives sont dominantes aux mois de février et de mai à juillet. Pour la phase LaNina, une dominance des valeurs positives est aux mois de mars à juin et d'octobre où les valeurs maximales dépassent 0.6 (ici ces fortes valeurs sont parfois dues au petite taille de l'échantillon) dans certaines zones. En outre, les valeurs négatives

Conclusion Générale et Perspectives

sont plus marquées aux mois de janvier, juillet, aout, septembre, novembre et décembre. les valeurs positives sont perceptiblement dominantes sur tous les mois (excepté le mois de mars qui présente une dominance négative) pour la phase neutre de l'ENSO.

Des huit phases de la MJO nous avons analysé deux (phase 1 et 8) qui montrent des bonnes corrélations avoisinant 0.6 en valeur maximale qui sont localisées en RDC et indiquent les valeurs de corrélation significatives à un niveau de 95 % correspondant à ces valeurs maximales. Ainsi, quand la MJO est dans sa phase 1 aux mois février et mars, la majeure partie de la RDC se trouve dans l'excédent des précipitations, de même si on est au mois de juin (c'est la partie du Sud de la RDC qui en excès) et juillet (c'est la partie du Sud-Est qui est plus concernée). L'excédent des précipitations du mois de mai à l'Extrême-Nord du Cameroun et le Centre du Tchad pourrait être associé au passage de la MJO dans ces zones. En outre, au mois d'avril il y a réduction des précipitations au Gabon, à l'Ouest du Congo Brazzaville et une petite partie de l'Est du Cameroun. La phase 8 de l'indice MJO montre quant à elle une bonne corrélation avec l'anomalie positive des précipitations aux mois de janvier à mars, de mai, de juin et de septembre à décembre ; cela prouve qu'elle amplifie la hauteur des précipitations pendant cette période également. Par contre, aux mois d'avril, juillet et aout le passage de la MJO phase 8 inhibe les précipitations.

Les maxima de corrélations avec le niveau 95% de signification entre l'indice QBO et l'anomalie sont localisées en RDC, au sud du Congo Brazza et au Nord de l'Angola pour le mois de janvier, en RCA et au Cameroun en avril. En outre, les valeurs négatives sont minimales et les plus faibles se trouvent au Tchad au mois de juillet.

le diagnostic climatologique des débuts et des retraits de saisons montre que l'Angola est dans une zone monomodale donc sa saison commence en moyenne le 07 octobre et s'achève en moyenne le 10 avril (environ 6 mois de longueur). Par contre, Yaoundé est dans une zone bimodale (deux saisons) qui sont : la première commence en moyenne le 13 mars et finit en moyenne le 03 juillet (pratiquement 4 mois) et la deuxième commence autour du 18 aout et s'achève au tour du 06 novembre (pratiquement 4 mois également).

L'analyse des cartes de corrélations issues de PYCPT montre que le choix d'un modèle pour une prévision dépend de zone d'étude, de la saison et de l'expérience du prévisionniste. Par exemple, la saison Jun-Aug montre une ambiguïté dans le choix du meilleur modèle. Cependant, comme c'est la période où le ZCIT est à son maximum au Nord, nous pouvons dire que le

Conclusion Générale et Perspectives

modèle DWD est adapté mais en restant modérer dans notre choix parce que cette saison est l'une des plus importantes dans le domaine de l'agriculture dans notre domaine d'étude. Les valeurs maximales sont localisées à l'Est de la RDC et pouvant atteindre 0.622. De plus, pour cette même saison, les méthodes probabilistes (RPSS et GROC) montrent un accord entre les modèles qui fournissent presque les mêmes résultats.

L'analyse des cartes de vérification des prévisions intra-saisonnière courte (semaines ou mois) montre que le modèle ECMWF est mieux pour la première semaine (de juin 2022) que les autres parce que la figure 2.2 indique qu'en ce mois, les précipitations se localisent entre 10°S et 15°N. En tenant toujours compte de la localisation des précipitations pour ce mois, le modèle CFSv2_SubX semble être robuste par rapports aux autres modèles pour la deuxième et troisième semaine, pour la semaine 34 et tout le mois de juin. Les plus grandes valeurs de corrélation sont situées entre 0.5 et 0.7. De plus, les méthodes RPSS et GROC montrent une performance moyenne des modèles sur la majeure partie du domaine donc ces modèles peuvent être utilisés.

L'analyse pour l'opérationnalisation des prévisions étant faite, l'application complète de ces prévisions à l'agriculture et à la sécurité alimentaire nous projette dans l'univers de la prévision ou la projection de croissance et le rendement des cultures par variétés en utilisant le modèle agronomique DSSAT dans la suite de nos travaux à venir.

Références

- Barnston, A.G., S. Li, S.J. Mason, D.G. DeWitt, L. Goddard, and X. Gong, 2010 : Verification of the first 11 years of iri's seasonal climate forecasts. *Journal of Applied Meteorology and Climatology*, **49**, 493–520.
- Besleaga, N., 1995 : Les débuts de la prévision numérique ; l'intégration grapho-analytique. *Rubrique : Histoire*.
- Brunet, G., M. Shapiro, B. Hoskins, M. Moncrieff, R. Dole, G.N. Kiladis, B. Kirtman, A. Lorenc, B. Mills, R. Morss et al., 2010 : Collaboration of the weather and climate communities to advance subseasonal-to-seasonal prediction. *Bulletin of the American Meteorological Society*, **91**, 1397–1406.
- Canal, N., 2014 : *Application à l'agriculture de la prévision saisonnière : évaluation à l'échelle de la France*. Ph. D. thesis, Université Paul Sabatier Toulouse III.
- Coiffier, J., 2000 : Un demi-siècle de prévision numérique du temps. *La météorologie*, 11–31.
- De Namur, C., 1990 : Aperçu sur la végétation de l'Afrique centrale atlantique. *Paysages quaternaires de l'Afrique centrale atlantique*. ORSTOM, Paris, 60–67.
- De Winter, J.C., S.D. Gosling, and J. Potter, 2016 : Comparing the pearson and spearman correlation coefficients across distributions and sample sizes : A tutorial using simulations and empirical data. *Psychological methods*, **21**, 273.
- Dedebant, G., P. Wehrlé, and P. Wherlé, 1935 : La mécanique de l'atmosphère et des grands milieux fluides fondée sur les concepts d'échelle et de probabilité. *Thalès*, **2**, 53–81.
- Dunning, C.M., E.C. Black, and R.P. Allan, 2016 : The onset and cessation of seasonal rainfall over africa. *Journal of Geophysical Research : Atmospheres*, **121**, 11–405.
- Funk, C., A. Verdin, J. Michaelsen, P. Peterson, D. Pedreros, and G. Husak, 2015 : A global satellite-assisted precipitation climatology. *Earth System Science Data*, **7**, 275.
- Hiraishi, T., T. Krug, K. Tanabe, N. Srivastava, J. Baasansuren, M. Fukuda, and T. Troxler, 2014 : 2013 supplement to the 2006 ipcc guidelines for national greenhouse gas inventories : Wetlands. *IPCC, Switzerland*.
- Igri, P.M., D. Vondou, R.S. Tanessong, and F.K. Mkankam, 2012 : Assessing the improvement of severe weather prediction over western africa in wrf by 3dvar data assimilation system using conventional and radiance observational data. In : *Erad-The*

Références bibliographiques

Seventh European Conference On Radar In Meteorology And Hydrology.

Jha, P.K., 2017 : Using seasonal climate forecasts to predict rice yield over nepal's terai.

Kirtman, B.P., D. Min, J.M. Infanti, J.L. Kinter, D.A. Paolino, Q. Zhang, H. Van Den Dool, S. Saha, M.P. Mendez, E. Becker et al., 2014 : The north american multimodel ensemble : phase-1 seasonal-to-interannual prediction ; phase-2 toward developing intraseasonal prediction. *Bulletin of the American Meteorological Society*, **95**, 585–601.

Konte, O., 2011 : Vérification des prévisions climatiques saisonnières sur les précipitations en afrique de l'ouest (presao) sur la période juillet-août-septembre (jas) de 1998–2010, au sénégal. available from : https://www.academia.edu/3784013/evaluation_of_the_seasonal_forecast_of_rainfall [accessed 16 novembre 2023].

Lorenz, E.N., 1969 : Atmospheric predictability as revealed by naturally occurring analogues. *Journal of Atmospheric Sciences*, **26**, 636–646.

Madden, R.A., and P.R. Julian, 1971 : Detection of a 40–50 day oscillation in the zonal wind in the tropical pacific. *Journal of Atmospheric Sciences*, **28**, 702–708.

Mason, S.J., 2013 : Guidance on verification of operational seasonal climate forecasts. *World Meteorological Organization, Commission for Climatology XIV Technical Report*.

Meynadier, R., 2010 : *Analyse multi-échelle du cycle de l'eau dans la mousson africaine à l'aide d'observations GPS*. Ph. D. thesis, Université Pierre et Marie Curie-Paris VI.

Mpounza, M., and M. Samba-Kimbata, 1990 : Aperçu sur le climat de l'afrique centrale occidentale. *Paysages quaternaires de l'Afrique centrale atlantique, ORSTOM*, 31–41.

Muñoz, Á., A. Robertson, T. Turkington, and S. Mason, 2019 : Pycpt : A python interface and enhancement for iri's climate predictability tool.

Pailleux, J., J.F. Geleyn, R. El Khatib, C. Fischer, M. Hamrud, J.N. Thépaut, F. Rabier, E. Andersson, D. Salmond, D. Burridge et al., 2015 : Les 25 ans du système de prévision numérique du temps ifs/arpège. *La météorologie*.

Palmer, T.N., and D.L.T. Anderson, 1994 : The prospects for seasonal forecasting—a review paper. *Quarterly Journal of the Royal Meteorological Society*, **120**, 755–793.

Reboita, M.S., R.P. Da Rocha, T. Ambrizzi, and E. Caetano, 2010 : An assessment of the latent and sensible heat flux on the simulated regional climate over southwestern south atlantic ocean. *Climate dynamics*, **34**, 873–889.

Rousseau, D., 2001 : Un critère général d'évaluation des prévisions déterministes et

- probabilistes-application aux prévisions locales diffusées sur internet. *La météorologie*.
- , Siebert, A., P. Ryser, D. Ndiaye, M.L. Diop, A. Mbengue, A. Sal, O. Konte, O. Ndiaye, S. Trzaska, A.W. Robertson et al. A multi-model approach to forecasting seasonal rainfall in senegal. *Available at SSRN 4092901*.
- Simon J. Mason, Michael K. Tippett, L.S.Á.G.M., 2020 : Climate predictability tool version 16.5.8.
- Sultan, B., S. Janicot, and A. Diedhiou, 2003 : The west african monsoon dynamics. part i : Documentation of intraseasonal variability. *Journal of Climate*, **16**, 3389–3406.
- Vitart, F., 2014 : Evolution of ecmwf sub-seasonal forecast skill scores. *Quarterly Journal of the Royal Meteorological Society*, **140**, 1889–1899.
- Vitart, F., G. Balsamo, R. Buizza, L. Ferranti, S. Keeley, L. Magnusson, F. Molenti, and A. Weisheimer, 2014 : *Sub-seasonal predictions*. European Centre for Medium-Range Weather Forecasts.
- White, C.J., H. Carlsen, A.W. Robertson, R.J. Klein, J.K. Lazo, A. Kumar, F. Vitart, E. Coughlan de Perez, A.J. Ray, V. Murray et al., 2017 : Potential applications of subseasonal-to-seasonal (s2s) predictions. *Meteorological applications*, **24**, 315–325.
- Yao, W., H. Lin, and J. Derome, 2011 : Submonthly forecasting of winter surface air temperature in north america based on organized tropical convection. *Atmosphere-ocean*, **49**, 51–60.