



HAL
open science

Détection, caractéristiques et prédictibilité des évènements à potentiels forts impacts humains sur les villes ouest-africaines : cas des vagues de chaleur

Cédric Gacial Ngoungué Langué

► To cite this version:

Cédric Gacial Ngoungué Langué. Détection, caractéristiques et prédictibilité des évènements à potentiels forts impacts humains sur les villes ouest-africaines : cas des vagues de chaleur. Climatologie. Université Paris-Saclay, 2023. Français. NNT : 2023UPASJ021 . tel-04472426

HAL Id: tel-04472426

<https://theses.hal.science/tel-04472426>

Submitted on 22 Feb 2024

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

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

Détection, caractéristiques et
prédictibilité des événements à
potentiels forts impacts humains
sur les villes ouest-africaines :
cas des vagues de chaleur
*Detection, characteristics and predictability of
potential strong human impacts events on
West African cities : a case study of heat waves*

Thèse de doctorat de l'université Paris-Saclay

École doctorale n° 129, sciences de l'environnement d'Île-de-France
(SEIF)

Spécialité de doctorat : Sciences du climat, de l'atmosphère et des
océans, terrestres et planétaire

Graduate School : Géosciences, climat, environnement et planètes

Thèse préparée à l'unité de recherche **LATMOS** (Université Paris-Saclay, UVSQ,
CNRS) sous la direction de **Cyrille FLAMANT**, directeur de recherche, la
co-direction de **Christophe LAVAYSSE**, chargé de recherche

Thèse soutenue à Paris, le 12 Octobre 2023, par

Cédric Gacial NGOUNGUÉ LANGUÉ

Composition du jury

Membres du jury avec voix délibérative

Hélène BROGNIEZ Maîtresse de conférence, HDR, UVSQ (LATMOS)	Présidente
Cathryn BIRCH Professeure Universités de Leeds	Rapporteur & Examinatrice
Vincent MORON Professeur des universités, HDR, AMU (CEREGE)	Rapporteur & Examineur
Alessandra GIANNINI Professeure des universités, HDR, ENS (LMD)	Examinatrice
Romain ROEHRIG Chercheur Météo-France (CNRM)	Examineur
Benjamin SULTAN Directeur de Recherche IRD (Espace-Dev)	Examineur

Titre : Détection, caractéristiques et prédictibilité des événements à potentiels forts impacts humains sur les villes ouest-africaines : cas des vagues de chaleur

Mots clés : Détection, caractéristiques, prédictibilité, vagues de chaleur, apprentissage automatique, Afrique de l'ouest.

Résumé : Les vagues de chaleur constituent une réelle menace pour l'Homme et son environnement. Sous l'effet du changement climatique, les vagues de chaleur deviendront plus fréquentes et intenses. Les conditions climatiques en Afrique de l'ouest rendent la région favorable aux vagues de chaleur. La première partie de ce travail a été consacrée au monitoring des vagues de chaleur dans 15 villes ouest-Africaines situées sur les régions côtière et continentale. Trois sources d'incertitude ont été identifiées dans la détection d'une vague de chaleur : la première est liée aux données de réanalyse, la seconde repose sur le choix du seuil utilisé pour la définition de la vague de chaleur, et la dernière est la méthodologie utilisée. Les vagues de chaleur nocturnes associées à T_w sont plus fréquentes que celles détectées avec AT, T_{2m} , UTCI. Ceci montre que l'humidité joue un rôle important dans l'occurrence des vagues de chaleur nocturnes, augmentant ainsi le nombre d'événements concomitants (jour et nuit consécutivement) sur le nord du Sahel. La variabilité inter-annuelle des vagues de chaleur dans les différentes régions a mis en évidence pour les 3 indicateurs (AT, T_{2m} , T_w) des années particulièrement chaudes avec une fréquence élevée d'événements : 1998, 2005, 2010, 2016, 2019 et 2020, correspondant pour la plupart aux années El Nino. La région GU est plus touchée par les vagues de chaleur au cours de la dernière décennie (2012-2020) que les régions CONT et ATL. Toutefois, les vagues de chaleur les plus persistantes et les plus intenses se produisent dans la région CONT. Un renforcement de la fréquence, de la durée et de l'intensité des vagues de chaleur est observé durant la dernière décennie. Dans la deuxième partie de ce travail, nous nous sommes intéressés à l'aspect prédictibilité des vagues de chaleur. Une première étude de la prédictibilité des vagues de chaleur a été conduite en utilisant les modèles de prévision intra-saisonnière à saisonnière du CEPMMT et UKMO. Les modèles

de prévision présentent de meilleures performances par rapport à une climatologie de référence, principalement pour les prévisions à court terme (deux semaines à l'avance) dans les trois régions. Les vagues de chaleur nocturnes sont plus prévisibles que les vagues de chaleur diurnes. D'après les valeurs de FAR obtenues, seulement 15 à 30% des jours de vague de chaleur prédits par les modèles sont effectivement observés dans les réanalyses, respectivement pour les semaines 5 et 2. Le modèle du CEPMMT émet moins de fausses alertes que UKMO pour les prévisions à court terme. Bien que les modèles démontrent des performances en matière de détection des vagues de chaleur par rapport à une climatologie de référence, leur capacité à prédire l'intensité des événements reste faible même pour de courtes échéances. La prédictibilité des vagues de chaleur a été effectuée en utilisant des méthodes d'apprentissage automatique. La méthode BRF présente de meilleures performances par rapport aux deux autres. Le modèle BRF présente de meilleures performances pour la détection des vagues de chaleur par rapport aux modèles de prévision intra-saisonnière dans les trois régions. La prédictibilité des vagues de chaleur par méthode de prédicteurs de grande échelle tels que la dépression thermique Saharienne (SHL) a été abordée en utilisant deux modèles de prévision saisonnière du centre européen et Météo-France. Le but de cette étude est d'évaluer la représentation et la prévisibilité de la SHL à l'échelle saisonnière. Les modèles sont capables de représenter le cycle saisonnier moyen de la SHL et de capturer certaines caractéristiques de sa variabilité inter-annuelle comme la tendance au réchauffement observée durant les années 2010. En utilisant les outils de correction de biais, les résultats mettent en évidence la capacité des modèles à représenter la variabilité intra-saisonnière de la SHL, mais les performances des modèles restent faibles pour une échéance supérieure à un mois.

Title : Detection, characteristics and predictability of potential strong human impacts events on West African cities : a case study of heat waves

Keywords : Detection, characteristics, predictability, heat waves, machine learning, west africa.

Abstract : Heat waves (HWs) are a real threat to humans and their environment. Due to climate change, heat waves will become more frequent and more intense. Climatic conditions in West Africa make the region more vulnerable to heat waves. West African cities are highly populated centers, and when it comes to the impact of heat waves on human activities, it's important to study these events at these scales. This study aims to monitor heat waves in major West African cities and evaluate their predictability in subseasonal to seasonal forecast models. The first part of this work focuses on monitoring heat waves in fifteen cities over West Africa located in coastal and continental regions. Three sources of uncertainty encountered in the heat wave detection process were identified : the first related to reanalysis data, the second to the choice of threshold used to define a heat wave, and the last to the methodology adopted. The inter-annual variability of heat waves in the different regions highlighted particularly hot years with a high frequency of heat wave events for all the three indicators AT, T2m, Tw : 1998, 2005, 2010, 2016, 2019 and 2020, mostly corresponding to El Niño years. The GU region has been more affected by heat waves over the past decade (2012-2020) than the CONT and ATL regions. However, the most persistent and intense heat waves occurred in the CONT region. An increase in the frequency, duration and intensity of heat waves has been observed over the last decade (2012-2020), probably due to global warming acting on extreme events." In the second part of this study, we focused on the predictability aspect of heat waves. A preliminary study of the predictability of heat waves has been carried out for the period 2001-2020 using subseasonal to seasonal forecast models from the European Centre for Medium-Range Weather Forecasts (ECMWF) and the United Kingdom Meteorological Office (UKMO). The forecast models perform

better than a reference climatology, particularly for short-term forecasts (up to two weeks) in all the three regions. Nighttime heatwaves are more predictable than daytime heatwaves. According to the FAR values, only 15 to 30% of the predicted heatwave days by the models are actually observed in the reanalyses, respectively for lead weeks 5 and 2. This suggests that the models overestimate the duration of heat waves compared with ERA5 reanalysis. ECMWF issues fewer false alarms than UKMO for short-term forecasts. Although the models show skills to detect heat waves compared to a reference climatology, their ability to forecast the intensity of events remains weak even for a short lead time. The predictability of heat waves was performed using machine learning methods. The BRF model demonstrated better heat wave detection skills than subseasonal forecast models in all the three regions. The BRF model considerably improves heat wave detection in forecast models, but on the other hand it generates a high rate of false alarms. The predictability of heat waves using large-scale predictors such as the Saharan Heat Low (SHL) was investigated using two seasonal forecast models : the fifth version of the European Center Seasonal Forecast Model "SEAS5" and the seventh version of the Météo-France Seasonal Forecast Model "MF7". The models show skills on the representation of the mean seasonal cycle of the SHL and capture some characteristics of its inter-annual variability, such as the warming trend observed during the 2010s. SEAS5 makes a more realistic representation of the climatic trend of the SHL compared to MF7. Using bias correction techniques, the results highlight the capacity of the models to represent the intra-seasonal variability of the SHL. Bias correction helps to improve the Continuous Ranked Probability Score (CRPS), but the skills of the model remain low for lead times beyond one month.

Dédicace

À mon père Emmanuel LANGUÉ,

À ma mère Eugénie LANGUÉ,

À ma famille.

Remerciements

Avant toute chose, je rends grâce à Dieu pour toutes ses bienfaits dans ma vie. Si j'ai pu mener à bien ce projet de thèse du début à la fin, c'est par ta grâce Seigneur.

Ce vol d'une durée 3 ans et 3 mois en direction des extrêmes de température, avait pour co-pilotes mes directeurs de thèse Cyrille Flamant et Christophe Lavaysse.

À Cyrille "*the Boss manager*", je te dis un merci particulier pour toute la confiance que tu as témoignée à mon égard, et aussi le côté administratif que tu m'as fait découvrir en échangeant quotidiennement avec le service des ressources humaines. Ton expérience et ta vision orientée papier ont été très déterminants pour ma thèse.

À Christophe "*the team leader*", je te remercie pour ta bienveillance, ton hospitalité, ta patience, ta disponibilité, tes conseils durant nos échanges. Malgré la distance, tu t'es toujours montré disponible, je pouvais te joindre à tout moment via "Whatsapp", même le weekend. J'ai beaucoup appris à tes côtés durant ces trois années, je te remercie de m'avoir fait confiance dès le 1er jour de l'entretien. Notre première rencontre à Grenoble autour d'un verre de vin a été un fait marquant pour moi, et le début d'une longue série de verres dont je m'abstiendrai d'énumérer ici. Je n'oublierai pas de mentionner ta rigueur scientifique et ton esprit critique que tu as su me transmettre;

je poursuis dans le même élan en remerciant les membres du comité de thèse Mathieu Vrac et Philippe Peyrillé qui de loin ont apportés leur contribution à ce travail. Un merci particulier à toi Mathieu, tu as toujours été disponible pour des échanges et je repartais de là toujours avec de nouvelles pistes à explorer. Ton regard extérieur et ton esprit critique ont été déterminants pour cette thèse;

je remercie particulièrement Arona Diedhiou pour son implication dans le projet STEWARD; un grand merci également à toute l'équipe HMCIS du côté de l'Institut des Géosciences et de l'Environnement à Grenoble;

je remercie également par la même occasion l'Agence Nationale de la Recherche (ANR) à travers le projet STEWARD pour le financement de ce projet de thèse;

je remercie très solennellement le directeur du LATMOS François Ravetta, pour l'accueil au sein du laboratoire durant toute cette période;

je profite également pour remercier les membres du jury qui ont accepté d'évaluer ce travail malgré leurs diverses occupations particulièrement Hélène Brogniez, Vincent Moron, Cathryn Birch, Benjamin Sultan, Romain Roehrig et Mathieu Vrac;

Un merci à l'endroit du directeur du Centre National de la Recherche Scientifique (CNRS) et toute son équipe pour avoir validés mon recrutement pour ce projet de thèse;

je tenais vraiment à rendre un dernier hommage à Matthieu Roy Barman, l'un des précurseurs de cette aventure dans le domaine de la recherche aux côtés de Hélène Brogniez qui m'ont donnés cette opportunité à travers la Bourse Idex Paris Saclay en 2018. Même après le Master tu prenais toujours de mes nouvelles, tu étais toujours disponible quand je te sollicitais. Aujourd'hui, j'aurai été content de te le dire de vive voix, ça y est "J'ai terminé Matthieu, je suis docteur Cédric", mais la nature en a décidé autrement. Repose en paix Matthieu!!!

je remercie tout le personnel de l'Université Paris Saclay en particulier Laurence Monseiller pour l'accueil et l'accompagnement durant ces trois années;

je remercie mes amis avec qui je partage mon quotidien, les moments de réjouissance et les moments difficiles. Un merci particulier à Sidiki Sanogo, Landry Enguelle, Foutse, Leclair Anjipu, Willy Magloire, Alex Piedjou, Yvan Tatou, Rolland Nkpesu, Lionnel Tondji, Charlène Djomo, Maurin Zouzoua, Etoutou, Koffi. Vous êtes tellement nombreux, je ne saurais citer tout le monde. Je vous souhaite à tous beaucoup de réussite dans vos carrières;

je tiens à remercier tous ceux qui de près ou de loin ont contribué à la réalisation de ce projet

de thèse ;

j'ai gardé le meilleur pour la fin, ceux-là que j'aime plus que tout au monde : ma famille. Je vous dis une fois de plus merci pour votre soutien démesuré ;

je ne saurais clôturer cette série de remerciements sans penser à toi maman, toi qui sais me reconforter quand je perds espoir, je te dis mille et une fois merci maman. Puisse le seigneur tout puissant te bénir abondamment.

Résumé

Les vagues de chaleur constituent une réelle menace pour l'Homme et son environnement. Sous l'effet du changement climatique, les vagues de chaleur deviendront plus fréquentes et intenses. D'après le dernier rapport du Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC), les régions équatoriales sont les plus affectées par le changement climatique par rapport aux régions situées aux latitudes moyennes. Les conditions climatiques en Afrique de l'ouest rendent la région propice à l'occurrence des vagues de chaleur. En Afrique, les zones urbaines constituent des centres de forte concentration démographique. De fait, les impacts des vagues de chaleur sur la santé de l'Homme seront plus importants dans ces régions. Ainsi donc, dans le cadre de cette thèse nous nous intéresserons au monitoring des vagues de chaleur, et par la suite à leur prédictibilité à l'échelle intra-saisonnière dans les grandes villes ouest-Africaines.

La première partie de ce travail a été consacrée au monitoring des vagues de chaleur dans quinze villes ouest-Africaines situées sur les régions côtière et continentale. Les villes ont été regroupées en trois régions climatiques sur la base des études antérieures et l'analyse de l'évolution des vagues de chaleur dans les différentes régions comme suit : la région côtière atlantique "ATL", la région côtière Guinéenne "GU" et la région continentale "CONT". Trois sources d'incertitudes ont été identifiées dans le processus de détection d'une vague de chaleur : la première est liée aux données utilisées, la seconde repose sur le choix du seuil utilisé pour la définition de la vague de chaleur, et la dernière est la méthodologie utilisée. Quatre indicateurs ont été utilisés : la température apparente " AT ", la température à 2-mètre " T_{2m} ", l'indice bioclimatique (Universal Thermal Climate Index) " $UTCI$ " et la température du thermomètre mouillé " T_w " dérivés à partir de " T_{2m} ", du vent à 10-m, l'humidité relative, la pression de vapeur saturante et/ou

une combinaison des quatre variables. Les vagues de chaleur nocturnes associées à T_w sont plus fréquentes que celles détectées avec AT , T_{2m} , $UTCI$. Ceci montre que l'humidité joue un rôle important dans l'occurrence des vagues de chaleur nocturnes, augmentant ainsi le nombre d'événements concomitants (jour et nuit consécutivement) sur le nord du Sahel. La variabilité inter-annuelle des vagues de chaleur dans les différentes régions a mis en évidence pour les 3 indicateurs (AT , T_{2m} , T_w) des années particulièrement chaudes avec une fréquence élevée d'événements : 1998, 2005, 2010, 2016, 2019 et 2020, correspondant pour la plupart aux années El Niño. La région GU est plus affectée par les vagues de chaleur au cours de la dernière décennie (2012-2020) par rapport aux régions CONT et ATL. Toutefois, les vagues de chaleur les plus persistantes et les plus intenses se produisent dans la région CONT. Un renforcement de la fréquence, de la durée et de l'intensité des vagues de chaleur est observé durant la dernière décennie (2012-2020).

Dans la deuxième partie de ce travail, nous nous sommes intéressés à l'aspect prédictibilité des vagues de chaleur. Une première étude de la prédictibilité des vagues de chaleur a été conduite sur la période 2001-2020 en utilisant les modèles de prévision intra-saisonnière du Centre Européen de Prévisions Météorologiques à Moyen terme (CEPMMT) et du Centre Britannique de prévisions météorologiques (UKMO). Les modèles de prévision présentent de meilleures performances par rapport à la climatologie des événements dans la réanalyse ERA5, principalement pour les prévisions à court terme (deux semaines à l'avance) dans les trois régions. Les vagues de chaleur nocturnes sont plus prévisibles que les vagues de chaleur diurnes. D'après les valeurs de taux de Fausses alarmes (False Alarm Rate) obtenues, seulement 15 à 30% des jours de vague de chaleur prédits par les modèles sont effectivement observés dans les réanalyses, respectivement pour les semaines 5 et 2. Cela suggère que les modèles surestiment la durée des vagues de chaleur par rapport à la réanalyse ERA5. Le modèle du CEPMMT émet moins de fausses alertes que UKMO pour les prévisions à court terme. Bien que les modèles démontrent des performances en matière de détection des vagues de chaleur par rapport à une climatologie de référence, leur capacité à prédire l'intensité des événements reste faible même pour de courtes échéances.

La prédictibilité des vagues de chaleur a été effectuée en utilisant des méthodes d'apprentis-

sage automatique. Trois modèles d'apprentissage ont été analysés notamment la méthode de forêt aléatoire "Random Forest (RF)", une variante de la méthode de forêt aléatoire adaptée aux données déséquilibrées "Balanced Random Forest (BRF)" et la méthode de vecteur de support "Support Vector Machine (SVM)". La méthode BRF présente de meilleures performances par rapport aux deux autres. Le modèle BRF présente de meilleures performances pour la détection des vagues de chaleur par rapport aux modèles de prévision intra-saisonnière dans les trois régions. Le modèle BRF améliore considérablement la détection des vagues de chaleur dans les modèles de prévision, en contrepartie, il génère un taux élevé de fausses alertes.

La prédictibilité des vagues de chaleur par méthode de prédicteurs de grande échelle tels que la dépression thermique Saharienne (SHL) a été abordée en utilisant deux modèles de prévision saisonnière : la cinquième version du modèle de prévision saisonnière de centre européen "SEAS5" et la septième version du modèle de prévision saisonnière de Météo-France "MF7". Le but de cette étude est d'évaluer la représentation et la prévisibilité d'une des grandes composantes atmosphériques de la mousson Ouest-Africaine dans les modèles de prévision saisonnière. Les modèles sont capables de représenter le cycle saisonnier moyen de la SHL et de capturer certaines caractéristiques de sa variabilité inter-annuelle comme la tendance au réchauffement observée durant les années 2010. SEAS5 représente de manière plus réaliste la tendance climatique de la SHL que MF7. En utilisant les outils de correction de biais, les résultats mettent en évidence la capacité des modèles à représenter la variabilité intra-saisonnière de la SHL. La correction des biais contribue à améliorer le score de la prévision (Continuous Ranked Probability Score "CRPS"), mais les performances des modèles restent faibles pour une échéance supérieure à un mois.

Abstract

Heat waves are a real threat to humans and their environment. Due to climate change, heat waves will become more frequent and more intense. According to the latest IPCC report, equatorial regions are more affected by climate change than mid-latitude regions. Climatic conditions in West Africa make the region more vulnerable to heat waves. In Africa, cities are highly populated centers, and when it comes to the impact of heat waves on human activities, it's important to study these events at these scales. This study aims to monitor heatwaves in major West African cities and evaluate their predictability at subseasonal time scale.

The first part of this work focuses on the monitoring heat waves in fifteen cities over West African located in coastal and continental regions. The cities were grouped into three climate regions based on previous studies and the analysis of heat waves evolution in the following regions : the Atlantic coastal region "ATL", the Guinean coastal region "GU" and the continental region "CONT". Three sources of uncertainty encountered in the heat wave detection process were identified : the first related to reanalysis data, the second to the choice of threshold used to define a heat wave, and the last to the methodology adopted. Four indicators were used : the apparent temperature " AT ", 2-meter temperature " $T2m$ ", Universal Thermal Climate Index " $UTCI$ " and wet bulb temperature " Tw ", derived from " $T2m$ ", wind at 10 meters, relative humidity, saturated vapor pressure and/or a combination of these four variables. The inter-annual variability of heat waves in the different regions highlighted particularly hot years with a high frequency of heat wave events for all the three indicators (AT , $T2m$, Tw) : 1998, 2005, 2010, 2016, 2019 and 2020, mostly corresponding to El Niño years. The GU region has been more affected by heat waves over the past decade (2012-2020) than the CONT and ATL regions. However, the most persistent

and intense heat waves occurred in the CONT region. An increase in the frequency, duration and intensity of heat waves has been observed over the last decade (2012-2020), probably due to global warming acting on extreme events."

In the second part of this study, we focused on the predictability aspect of heat waves. A preliminary study of the predictability of heat waves has been carried out for the period 2001-2020 using subseasonal to seasonal forecast models from the European Centre for Medium-Range Weather Forecasts (ECMWF) and the United Kingdom Meteorological Office (UKMO). The forecast models perform better than a reference climatology, particularly for short-term forecasts (up to two weeks) in all the three regions. Nighttime heatwaves are more predictable than daytime heatwaves. According to the FAR values, only 15 to 30% of the predicted heatwave days by the models are actually observed in the reanalyses, respectively for lead weeks 5 and 2. This suggests that the models overestimate the duration of heat waves compared with ERA5 reanalysis. ECMWF issues fewer false alarms than UKMO for short-term forecasts. Although the models show skills to detect heat waves compared to a reference climatology, they suffer on the proper representation of the intensity of events even for short lead time.

The predictability of heat waves was performed using machine learning methods. Three machine learning models were analyzed, namely the Random Forest (RF) method, a variant of Random Forest adapted to imbalanced data called Balanced Random Forest (BRF), and the Support Vector Machine (SVM) method. The BRF method outperformed the other two. The BRF model demonstrated better heat wave detection skills than subseasonal forecast models in all the three regions. The BRF model considerably improves heat wave detection in forecast models, but on the other hand it generates a high rate of false alarms.

The predictability of heat waves using large-scale predictors such as the Saharan Heat Low (SHL) was investigated using two seasonal forecast models : the fifth version of the European Center Seasonal Forecast Model "SEAS5" and the seventh version of the Météo-France Seasonal Forecast Model "MF7". The models show skills on the representation of the mean seasonal cycle of the SHL and capture some characteristics of its inter-annual variability, such as the warming

trend observed during the 2010s. SEAS5 makes a more realistic representation of the climatic trend of the SHL compared to MF7. Using bias correction techniques, the results highlight the capacity of the models to represent the intra-seasonal variability of the SHL. Bias correction helps to improve the Continuous Ranked Probability Score (CRPS), but the skills of the model remain low for lead times beyond one month.

Table des matières

1	Introduction	1
1.1	Contexte sociétal	1
1.2	Contexte scientifique	3
1.3	Organisation du manuscrit	9
2	Généralités sur les vagues de chaleur : Définition, caractéristiques et mécanismes de formation	11
2.1	Définition	11
2.2	Détection de vagues de chaleur	12
2.2.1	Critère de détection et indicateurs	12
2.2.2	Seuil de détection : absolu ou relatif	21
2.3	Mécanismes et processus de formation	22
2.3.1	les phénomènes météorologiques synoptiques : anticyclones	23
2.3.2	les rétroactions entre la surface du sol et l’atmosphère	25
2.3.3	les phénomènes climatiques de grande échelle	26
2.4	Caractéristiques des vagues de chaleur	27
2.5	Outils pour la prévision des vagues de chaleur	29
2.5.1	modèles de prévision du temps	29
2.5.2	méthodes d’apprentissage automatique	34
3	Quelle approche pour estimer la température dans les zones côtières à partir des données à grandes échelles ou de réanalyse?	35

3.1	Généralités sur les méthodes de descente d'échelle	35
3.2	Problématique de l'étude	38
3.3	Représentation des villes dans le maillage de ERA5 (Dakar, Abidjan)	41
3.4	Étude de la variabilité spatiale de la température dans le maillage de ERA5	42
3.4.1	Variabilité spatiale de la température au voisinage d'un point grille de ERA5 .	42
3.4.2	Variabilité spatiale de la température au voisinage des stations météorologiques	43
3.5	Estimation de la température à l'échelle locale à partir des données de réanalyse ERA5	44
3.5.1	Interpolation bilinéaire	45
3.5.2	Interpolation basée sur le proche voisin avec contrainte sur le LSM	46
3.5.3	Interpolation par méthode de gradient linéaire avec contrainte sur le LSM . .	46
3.5.4	Interpolation basée sur la direction du vent	48
3.6	Évaluation des différentes méthodes d'interpolation	49
3.7	Conclusion et perspectives	54
4	Incertitudes sur le monitoring des vagues de chaleur dans les villes Ouest Africaines	55
4.1	Introduction	55
4.2	Résumé de l'article sur le monitoring des vagues de chaleur en Afrique de l'Ouest : Incertitudes, caractérisation et évolution récente	60
4.3	Article sur le monitoring des vagues de chaleur en Afrique de l'Ouest : Incertitudes, caractérisation et évolution récente	62
4.4	Discussion sur l'origine des vagues de chaleur en zone côtière	84
4.5	Conclusion et perspectives	89
5	Prévisibilité des vagues de chaleur dans les villes ouest-Africaines à l'échelle intra-saisonnière	93
5.1	Introduction	93
5.2	Résumé de l'article Article sur la prévisibilité des vagues de chaleur	97

5.3	Article sur la prévisibilité des vagues de chaleur dans les villes ouest-Africaines à l'échelle intra-saisonnière	98
5.4	Discussion sur le comportement des modèles	131
5.5	Conclusion et perspectives	133
6	Utilisation des méthodes d'apprentissage automatique pour l'optimisation de la prévision des vagues de chaleur dans les modèles de prévision intra-saisonnière	135
6.1	Introduction	135
6.2	Région	137
6.2.1	Région d'étude	137
6.3	Données utilisées	138
6.3.1	Réanalyse ERA5	138
6.3.2	Modèles de prévision intra-saisonnière	138
6.4	Méthodes	141
6.4.1	Random Forest (Forêt aléatoire) "RF" + Synthetic Minority Oversampling Technique (SMOTE)	141
6.4.2	Balanced Random Forest (Forêt aléatoire équilibrée) - BRF	145
6.4.3	Support Vector Machine - SVM	145
6.4.4	Métrique d'évaluation des méthodes d'apprentissage automatique : F1-score	147
6.4.5	Implémentation des modèles de Machine learning	149
6.5	Résultats	151
6.5.1	Évaluation des modèles d'apprentissage automatique	151
6.5.2	Inter-comparaison entre les modèles d'apprentissage automatique et les modèles de prévision intra-saisonnière	154
6.6	Conclusion et perspectives	160
7	Prévisibilité de potentiels prédicteurs aux vagues de chaleur en Afrique de l'Ouest	163
7.1	Introduction	163

7.2	Résumé de l'article sur la prévision de la dépression thermique Saharienne à l'échelle saisonnière	169
7.3	Article sur la prévision de la dépression thermique Saharienne à l'échelle saisonnière	170
7.4	Discussion	191
7.5	Conclusion et perspectives	197
8	Conclusions and perspectives	199
8.1	Conclusions	199
8.2	Perspectives	204
A	Monitoring des vagues de chaleur dans les villes ouest-Africaines	207
B	Prévisibilité des vagues de chaleur de l'échelle intra-saisonnière à l'échelle saisonnière dans les villes ouest-Africaines	229
C	Utilisation des méthodes d'apprentissage automatique pour l'optimisation des prévisions des vagues de chaleur dans les modèles de prévisions intra-saisonnières	243
D	Prévisibilité de potentiels prédicteurs aux vagues de chaleur en Afrique de l'Ouest	263

Table des figures

1.1	Répartition géographique de quelques études portant sur les vagues de chaleur.	4
2.1	Diagramme d'évolution du Heat Index en fonction de l'humidité relative et la température ambiante, tiré du site de la NOAA (https://www.weather.gov/ama/heatindex)	17
2.2	Échelle d'évolution de l'intensité du UTCI et ses impacts sur le stress thermique (Błażejczyk et al., 2014)	20
2.3	Schéma de formation d'une vague de chaleur associé à un anticyclone(University and College)	24
2.4	Bilan radiatif net à la surface : impact de l'humidité du sol a) cas d'un sol humide , b) cas d'un sol sec.(Alexander, 2011)	26
2.5	Classification des vagues de chaleur au Sahel en fonction de leur fréquence moyenne et de leur intensité à partir des données Global Surface Summary of the Day (GSOD) de la National Oceanic and Atmospheric Administration (NOAA) sur la période 1979-2014 (Oueslati et al., 2017)	29
2.6	Illustration des différents types de prévision du temps en fonction : a) l'échéance de prévision et b) les applications (White et al., 2017).	32
2.7	Illustration de l'approche "Ready-Set-Go" pour la prévision des cyclones tropicaux (Vitart and Robertson, 2018)	33
3.1	Illustration de la méthode de downscaling (Khan and Pilz, 2018)	38
3.2	Carte topographique de l'Afrique de l'Ouest. Les villes représentées en bleue sur la carte sont les villes d'intérêt pour l'étude des vagues de chaleur dans la suite de ce travail. . .	39

3.3	<i>Carte de contraste terre-mer en Afrique de l'Ouest obtenue à partir des données ERA5.</i>	40
3.4	<i>Répresentation des villes de Dakar et Abidjan dans le maillage de ERA5. Les croix vertes et les traits noirs foncés représentent respectivement les points de grille ERA5 et les traits de côte. les villes sont représentées en gris.</i>	41
3.5	<i>Corrélation au voisinage du point ERA5 le plus proche de la station : (a-b) Dakar et (c-d) Abidjan. Le point vert représente le point ERA5 le plus proche de la station.</i>	43
3.6	<i>Corrélation au voisinage des stations météorologiques : (a-b) Dakar et (c-d) Abidjan. Le point vert représente cette fois la station météorologique.</i>	44
3.7	<i>Illustration de la méthode d'interpolation bilinéaire. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes.</i>	45
3.8	<i>Illustration de la méthode d'interpolation plus proche voisin avec contrainte sur le LSM. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes. La croix rouge représente le point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.5$.</i>	46
3.9	<i>Illustration de la méthode d'interpolation basé sur un gradient linéaire avec contrainte sur le LSM. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes. La croix rouge représente le point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.5$.</i>	47
3.10	<i>Illustration de la méthode d'interpolation basée sur la direction du vent.</i>	49
3.11	<i>Évaluation de différentes méthodes d'interpolation par rapport aux données station sur les villes de Dakar (a-d) et Abidjan (e-h). La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées et les données observées.</i>	51
3.12	<i>Évaluation de différentes méthodes d'interpolation par rapport aux données station en utilisant une méthode de débiaisage du signal interpolé sur les villes de Dakar (a-c) et Abidjan (d-f). La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées débiaisées et les données observées.</i>	52

3.13	Évaluation de la sensibilité de la méthode de plus proche par rapport au sein de LSM choisi : 1) $LSM \geq 0.75$ et 2) $LSM=1$. La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées et les données observées.	53
4.1	Méthode de détection des vagues de chaleur.	58
4.2	Chronologie des événements El Niño [http://www.bom.gov.au/climate/history/enso/]	85
4.3	Évolution interannuelle des anomalies de SST sur la période 1993-2020. Les anomalies annuelles de la SST sont calculées par rapport à la moyenne de la SST sur la période. Les années en rouge sont des années de pics de vague de chaleur enregistrées dans les 3 régions.	86
4.4	Analyse du lien entre les anomalies de SST et les jours de vague de chaleur sur la période 1993-2020 en utilisant la réanalyse ERA5 et les valeurs maximales de T_{2m} dans les différentes régions : a) ATL, b) GU , c-d) CONT. "SST_A" et "SST_G" représentent les blocs utilisés pour calculer les anomalies moyennes de SST respectivement pour les régions ATL et CONT (voir [Fig.3.3.1]). Les anomalies sont calculées comme la différence entre la SST mensuelle et les valeurs climatologiques mensuelles de SST sur l'ensemble de la période. Pour chaque année, les anomalies annuelles de SST sont calculées en fonction des jours de vague de chaleur. Les axes X et Y représentent respectivement la fréquence des jours de canicule et les anomalies de SST. Les points gris représentent les années de la période 1993-2020.	87

4.5	<i>Évolution saisonnière des anomalies de SST et les jours de vague de chaleur sur la période 1993-2020 en utilisant la réanalyse ERA5 et les valeurs maximales de T_{2m} dans les différentes régions : a) ATL, b) GU , c-d) CONT. "SST_A" et "SST_G" représentent les blocs utilisés pour calculer les anomalies moyennes de SST respectivement pour les régions ATL et CONT (voir [Fig.3.3.1]). Les anomalies sont calculées comme la différence entre la SST mensuelle et les valeurs climatologiques mensuelles de SST sur l'ensemble de la période. Pour chaque année, les anomalies annuelles de SST sont calculées en fonction des jours de vague de chaleur. Les axes X et Y représentent respectivement les mois de l'année et la fréquence mensuelle des anomalies de SST (et les jours de vague de chaleur) sur toute la période. Les courbes bleues et grises représentent respectivement l'évolution saisonnière des anomalies de SST et des jours dans les vagues de chaleur.</i>	88
6.1	<i>Région d'étude</i>	137
6.2	<i>Illustration de la méthode random Forest (Forêt aléatoire)</i>	143
6.3	<i>Illustration de la méthode SMOTE sur les données minoritaires. Le petit rond rouge est l'observation minoritaire initiale.</i>	144
6.4	<i>Illustration de la méthode SVM</i>	147
6.5	<i>Évaluation des prévisions des différentes méthodes d'apprentissage automatique en utilisant T_{min} sur la période de test dans les différentes régions : a) AT, b) CONT et c) GU. Les méthodes d'apprentissage ont été appliquées sur les différents modèles de prévision (CEPMMT et UKMO) chaque ville et semaine; et par la suite le F1-score a été calculé et regroupé par région. Les ronds de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant en entrée les prévisions du modèle CEPMMT. Les croix de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant cette fois en entrée les prévisions du modèle UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du F1-score.</i>	153

- 6.6 *Évaluation des prévisions des différentes méthodes d'apprentissage automatique en utilisant Tmax sur la période de test dans les différentes régions : a) AT, b) CONT et c) GU. Les méthodes d'apprentissage ont été appliquées sur les différents modèles de prévision (CEPMMT et UKMO) chaque ville et semaine; et par la suite le F1-score a été calculé et regroupé par région. Les ronds de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant en entrée les prévisions du modèle CEPMMT. Les croix de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant cette fois en entrée les prévisions du modèle UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du F1-score. 154*
- 6.7 *Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmin dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de hit-rate associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du hit-rate. 157*
- 6.8 *Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmin dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de GSS associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du GSS. 158*

6.9 *Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmin dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs du FAR associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du FAR. 159*

7.1 *Région d'étude et les différents blocs de SHL analysés. 166*

7.2 *Évaluation de la variabilité inter-annuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août et Septembre de 1993-2016 en utilisant la moyenne mensuelle de T850 sur le domaine SHL central à différents échéances : **a) - e)** Avril, **f) - j)** Mai et **k) - o)** Juin. "S5_B", "S5_C" représentent respectivement le CRPS évalué en utilisant respectivement les prévisions brutes et corrigées de SEAS5 avec la méthode CDF-t. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. "MS_C" représente le CRPS évalué à partir des prévisions du multi-modèle formé par les prévisions corrigées SEAS5 et MF7 avec la méthode CDF-t. Le calcul a été effectué en utilisant le membre de l'ensemble à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs du score CRPS et l'axe des abscisses, les produits utilisés pour le calcul du CRPS. 193*

7.3 *Évaluation de la variabilité inter-annuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août, Septembre de 1993-2016 en utilisant la moyenne mensuelle de T850 sur le Sahara à différents échéances : **a) - e)** Avril, **f) - j)** Mai et **k) - o)** Juin. "S5_B", "SS5_C" représentent respectivement le CRPS évalué en utilisant les prévisions brutes/corrigées de SEAS5 avec la méthode CDF-t. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. "MS_C" représente le CRPS évalué à partir des prévisions du multi-modèle formé par les prévisions corrigées de SEAS5 et MF7 avec la méthode CDF-t. Le calcul a été effectué en utilisant l'ensemble des membres à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs du score CRPS et l'axe des abscisses, les produits utilisés pour le calcul du CRPS. 194*

7.4	<i>Évaluation de la variabilité interannuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août, Septembre de 1993-2016 en utilisant T850 journalier sur : a) CSHL et b) le Sahara à différentes échéances : a) - e) Avril, f) - j) Mai et k) - o) Juin. "S5_B" / "SS5_C" représentent respectivement la métrique RMSE évaluée à l'aide des prévisions SEAS5 brutes/corrigées. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. Le calcul a été effectué en utilisant le membre non perturbé à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs de la RMSE.</i>	195
7.5	<i>Évaluation de la variabilité interannuelle de la SHL dans les modèles de prévision saisonnière (SEAS5, MF7) séparément pour les mois de Juin, Juillet, Août, Septembre au cours de la période 1993-2016 en utilisant le T850 journalier sur : a) CSHL et b) le Sahara. "S5_B" / "MF7_B" représentent respectivement les prévisions brutes SEAS5/MF7. Le calcul a été effectué en utilisant l'ensemble des membres des modèles. L'axe Y indique les valeurs du score CRPS et l'axe X, le temps en jours.</i>	196
C.1	<i>Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmax dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de hit-rate associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du hit-rate.</i>	244
C.2	<i>Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmax dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de GSS associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du GSS.</i>	245

C.3	<i>Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmax dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs du FAR associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du FAR.</i>	246
C.4	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Nouakchott pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	247
C.5	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Dakar pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	248
C.6	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Conakry pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	249
C.7	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Monrovia pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	250
C.8	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Bamako pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	251

C.9	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Ouagadougou pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	252
C.10	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Niamey pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	253
C.11	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Yamoussoukro pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	254
C.12	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Abidjan pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	255
C.13	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Accra pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	256
C.14	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Lomé pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	257
C.15	<i>Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Cotonou pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.</i>	258

C.16 *Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Lagos pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles. 259*

C.17 *Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Abuja pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles. 260*

C.18 *Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Douala pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles. 261*

Liste des tableaux

5.1	Table de contingence	95
6.1	Table de contingence	148
6.2	Liste des prédicteurs utilisés.	151

Chapitre 1

Introduction

1.1 Contexte sociétal

Les aléas climatiques représentent une réelle préoccupation pour l'Homme et son environnement. Depuis la dernière décennie, la terre connaît un réchauffement global sans équivoque d'origine anthropique. Sous l'effet de ce réchauffement, l'on assiste à une recrudescence des événements extrêmes et à un renforcement de leurs intensités ([Meehl and Tebaldi, 2004](#); [Russo et al., 2014b](#); [Moore et al., 2015](#); [Stott, 2016](#); [Mann et al., 2017](#)), suscitant ainsi davantage l'attention de la communauté scientifique. Les vagues de chaleur de par leurs impacts néfastes sur différents secteurs d'activité de l'Homme (santé, économie, infrastructures, agriculture, transport) et sur les écosystèmes se positionnent parmi les extrêmes climatiques les plus dangereux à travers la planète ([Huynen et al., 2001](#); [Braga et al., 2002](#); [Kovats and Hajat, 2008](#); [Hajat et al., 2007](#); [Anderson and Bell, 2009](#); [Gasparrini and Armstrong, 2011](#); [Rocklöv et al., 2014](#)). Elles entraînent un dysfonctionnement physiologique chez les populations pouvant conduire à des décès chez les plus vulnérables (personnes âgées et jeunes enfants) ([Johnson et al., 2005](#); [Åström et al., 2011](#); [Loughnan, 2014](#); [Liss et al., 2017](#); [Nicholls and Strengers, 2018](#)). En effet, les personnes âgées sont prédisposées à des troubles liés à la chaleur, notamment en raison des changements physiologiques associés au vieillissement ([Worfolk, 2000](#)). Les périodes prolongées de températures diurnes et nocturnes élevées créent un stress physiologique cumulatif sur le corps humain (Fi-

[scher and Schär, 2010](#); [Kueh et al., 2017](#)), qui se manifeste de multiples façons (par des éruptions cutanées, des crampes, des “coups de chaleur”, des insolation, la déshydratation), et qui exacerbe les principales causes de décès, y compris les maladies respiratoires, cardiovasculaires, certaines formes de diabète, les maladies rénales, les accidents vasculaires cérébraux, ainsi que les maladies vectorielles et infectieuses (dengue, paludisme, maladies gastro-intestinales, légionelloses, etc.). Les vagues de chaleur peuvent être associées à des épisodes de sécheresse entraînant des feux de brousse conduisant à une dégradation de la qualité de l'air pouvant causer des pathologies respiratoires et cardiovasculaires chez les populations. En conséquence, les vagues de chaleur déclenchent souvent des urgences de santé publique et entraînent une surmortalité. Ces extrêmes de température sont amplifiés en milieu urbain. En effet, le taux d'humidité, la présence de canyons urbains provoqués par l'encaissement entre les bâtiments, les déserts urbains liés à l'absence de végétation, les sources de chaleur diffuses supplémentaires (densité de la population, voitures, goudron, climatiseurs, etc.) et les brumes dues à la pollution : le “smog” contribuent à renforcer et multiplier les effets des vagues de chaleur. C'est ce qu'on appelle l'effet des “îlots de chaleur urbains”, qui conduisent à des températures plus élevées dans les centres urbains plutôt que dans les campagnes environnantes.

Durant les deux dernières décennies, des événements caniculaires assez marquants se sont produits à travers le monde. On peut citer entre autres la canicule de 2003 en France, qui fut très dévastatrice entraînant une surmortalité importante, de l'ordre de 14000 personnes ([Fouillet et al., 2006](#)). Les températures enregistrées au cours de cette période ont avoisiné des valeurs record autour de 37°C. Cet événement s'est étendu sur deux semaines; ce qui est assez exceptionnel. A celle-ci, l'on peut rajouter la vague de chaleur survenue en Russie en 2010 faisant de nombreuses destructions et plus de 11000 décès ([Shaposhnikov et al., 2014](#)). Durant cet épisode caniculaire, la température a atteint les 38°C, provoquant d'immenses incendies dans les régions voisines de Moscou et engendrant à leur tour, une augmentation de la concentration en monoxyde de Carbone dans la troposphère. Ce gaz étant très néfaste pour la santé des populations. La canicule de Chicago en 1995 fut également très violente avec des températures avoisinant les 41°C. Cette canicule a causé des pertes en vies humaines et des milliers d'hospitalisations. Elle a

été très redoutable pour les personnes âgées et démunies car ne pouvant pas s'offrir des moyens de climatisation pour faire face à la forte chaleur (Karl and Knight, 1997). L'on peut mentionner également les épisodes caniculaires en cours depuis fin Juin 2023 dans l'état d'Arizona aux États-Unis et plus précisément sa capitale Phoenix, qui endure des températures excédant les 43°C depuis plus de 20 jours. Le continent Africain n'est pas épargné par ces aléas climatiques, d'après une étude réalisée par l'UNICEF, une grande partie du continent est exposée en moyenne à 5 vagues de chaleur par an. En Avril 2010, l'Afrique du Nord a été frappée par une vague de chaleur avec des températures journalières maximales dépassant la barre des 40°C et des températures journalières minimales au-dessus de 27°C sur une période de 5 jours; cet événement a été horrible pour les populations et a engendré de nombreux dégâts matériels. En Mai 2013, une vague extrêmement violente frappa la ville Sénégalaise de Matam avec des températures atteignant parfois les 50°C à l'ombre. Cet événement était à la fois persistant durant la journée et la nuit, il a fait 18 morts en 10 jours chez les personnes du 3^{ème} âge. La Mauritanie a connu une vague de chaleur très ravageuse en Mai 2013 également, les températures maximales dépassaient les 46°C causant la mort de plus de 25 personnes parmi les personnes âgées et les enfants. L'Afrique de l'Ouest de par sa localisation géographique entre les tropiques, reste un environnement propice aux vagues de chaleur. Compte tenu de la vulnérabilité et de la capacité d'adaptation des pays Africains, ces événements sont très mal vécus dans cette partie de la planète.

1.2 Contexte scientifique

Les vagues de chaleur ont été étudiées de long en large dans diverses régions dont les plus dominantes sont l'Europe, l'Australie, les États-Unis et dans une mineure partie l'Afrique avant les années 2010 [Fig.1.1]. Les premières études de vagues de chaleur en Afrique plus précisément en zone Sahélienne vont voir le jour avec le projet **ACACIS** (Alerte aux Canicules Au Sahel et à leurs Impacts sur la Santé) dont l'objectif était d'investiguer les mécanismes et processus de formation des vagues de chaleur ainsi que leur prédictibilité. Ce projet s'est déroulé sur quatre ans (2014-

2018) principalement au Sénégal et au Burkina.

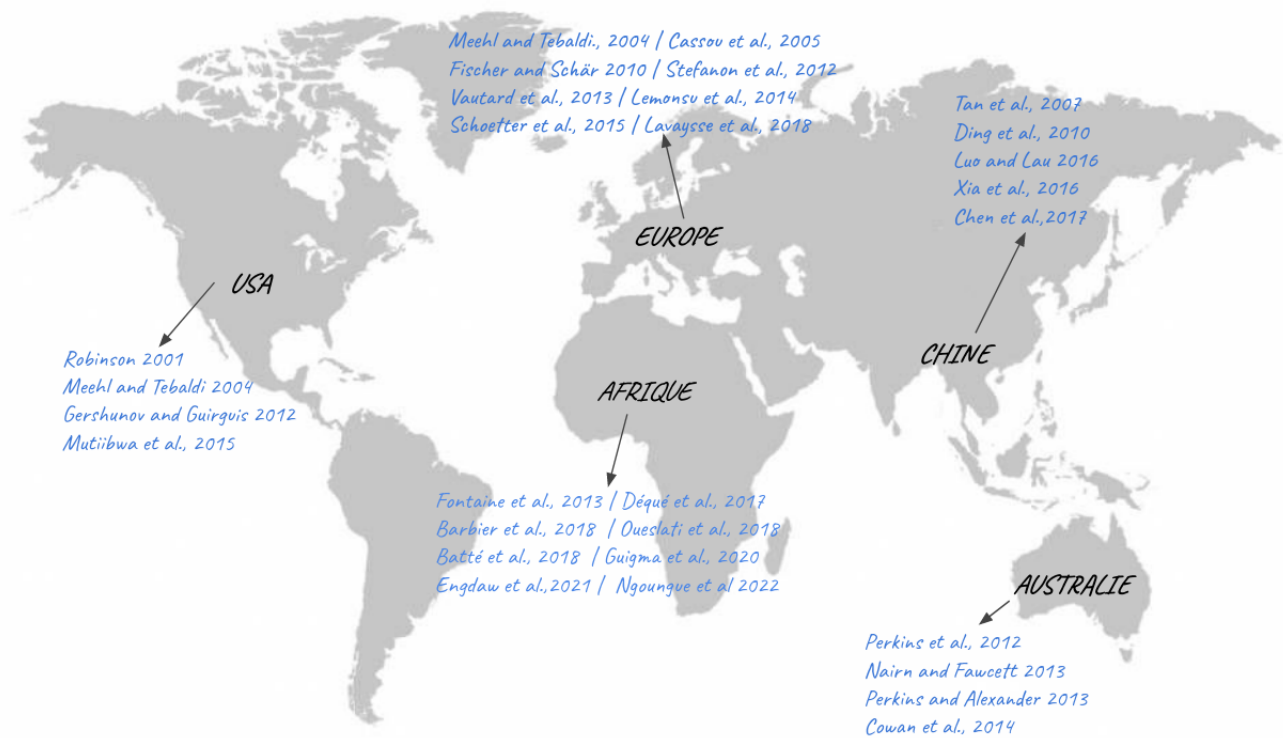


Figure 1.1 – Répartition géographique de quelques études portant sur les vagues de chaleur.

Malgré la sonnette d'alarme déclenchée par le projet ACACIS, les vagues de chaleur restent encore très peu connues du grand public en Afrique sub-Saharienne. L'Afrique de l'Ouest connaît un climat très chaud et sec dans la région du Sahel, et un climat chaud et humide sur la côte Guinéenne. Les conditions climatiques en Afrique de l'Ouest font de cette région un cadre propice à l'occurrence des vagues de chaleur. Quelques travaux ont été menés dans la région en vue d'améliorer la connaissance sur les processus responsables de ces événements. [Moron et al. \(2016\)](#) ont analysé les tendances des températures extrêmes dans le nord de l'Afrique tropicale en utilisant des observations et des données reconstruites sur la période 1979–2014. Ils ont montré que les indices de vagues de chaleur (Tmax, Tmin) dans la région étaient fortement corrélés avec les indices El Niño (ENSO). [Barbier et al. \(2018\)](#) ont étudié la variabilité intra-saisonnière des vagues de chaleur au Sahel durant le printemps en utilisant le jeu de données maillées Berkeley Earth Surface Temperature (BEST) et des réanalyses : la réanalyse intermédiaire du Centre européen pour les prévisions météorologiques à moyen terme (ERA-Interim), la réanalyse rétrospective Modern-Era

pour la recherche et les applications de la NASA (MERRA) et la réanalyse du National Centers for Environmental Prediction (NCEP-2) sur la période 1950-2012. Ils ont défini les vagues de chaleur en utilisant les anomalies Tmin/Tmax. Ils ont montré que la fréquence et la durée des vagues de chaleur diminuent lorsqu'on avance dans la saison de Mars en Juillet. Ils ont également trouvé des divergences dans les caractéristiques, la variabilité et les tendances climatiques des vagues de chaleur dans les différents produits. [Largeron et al. \(2020\)](#) ont investigué les mécanismes responsables de la vague de chaleur d'avril 2010 en Afrique du Nord en utilisant à la fois l'ensemble de données BEST et les simulations climatiques de la composante atmosphérique du modèle climatique du CNRM. Ils ont montré un lien étroit entre les vagues de chaleur sur le Sahara et les flux de chaleur solaire incident et émis par la surface. Un autre résultat important de ce travail est l'effet radiatif de la vapeur d'eau sur les températures minimales pendant la période des vagues de chaleur. Ceci peut conduire à des conditions de chaleur extrême pendant la nuit et causer la mort des personnes âgées. [Guigma et al. \(2020a\)](#) ont étudié les caractéristiques des vagues de chaleur au Sahel en utilisant différents indices thermiques basés sur la température, la vitesse du vent, l'humidité relative en utilisant la réanalyse ERA5 sur la période 1979–2018. Ils ont constaté que la plupart des régions du Sahel connaissent en moyenne une ou deux vagues de chaleur par an, d'une durée de 3 à 5 jours. Ils ont également montré que l'est du Sahel connaissait des événements plus fréquents et plus persistants. Ils ont identifié l'advection de la chaleur en provenance de la zone équatoriale vers le Sahel et l'effet radiatif de l'humidité comme les principaux moteurs des vagues de chaleur au Sahel.

Certaines des études précédentes menées dans la région Sahélienne n'utilisent que les températures maximales et minimales quotidiennes ([Moron et al., 2016](#); [Barbier et al., 2018](#)) pour la détection des vagues de chaleur, ignorant ainsi l'influence potentielle de l'humidité et du vent. D'autres prennent en compte l'effet de l'humidité dans la définition de la vague de chaleur [Guigma et al. \(2020a\)](#), mais les informations sur la variabilité inter-annuelle et saisonnière des événements détectés sont absentes, alors qu'elles sont d'un intérêt capital pour les décideurs politiques et les gouvernements afin de développer des systèmes d'alerte précoce.

Une étude plus récente réalisée par [Engdaw et al. \(2022\)](#), a évalué les tendances des vagues

de chaleur sur l'Afrique au cours de la période 1980-2018 en utilisant la version 4.03 des données d'observation de l'Unité de recherche sur le climat (CRU TS4.03), les données BEST ainsi que les données de réanalyse suivantes : ERA5, MERRA-2 et la réanalyse de l'Agence météorologique Japonaise (JRA-55). Ils ont mis en évidence de grandes différences dans la tendance et l'évolution temporelle des indices de vagues de chaleur entre les différentes réanalyses. Ils ont identifié un pic de chaleur sur l'Afrique du Nord et de l'Ouest en 2010 ainsi qu'en 2016 sur l'Afrique de l'Est et du Sud. Ils ont observé un réchauffement significatif et une augmentation de la fréquence des vagues de chaleur dans toutes les régions d'Afrique. Cette étude de [Engdaw et al. \(2022\)](#) s'est focalisée uniquement sur les vagues de chaleur sèche sur un large domaine de l'Afrique de l'Ouest [20°W-20°E,10°S-15°N]; la durée des vagues de chaleur n'a pas été abordée, ni l'évolution des vagues de chaleur humide.

Les vagues de chaleur les plus meurtrières ne sont pas seulement dues aux températures élevées, mais aussi à l'effet de l'humidité ([Steadman, 1979a,b](#)); les conditions chaudes et humides (comme c'est le cas dans les régions côtières) peuvent être plus dangereuses que des conditions équivalentes chaudes mais sèches ([Wehner et al., 2017](#)). Les vagues de chaleur humide, qui sont les plus dangereuses pour la santé humaine, n'ont pas été étudiées dans les travaux précédents. En se référant à [Steadman \(1979a,b\)](#), on peut légitimement s'interroger sur l'effet de l'humidité sur la fréquence des vagues de chaleur et sur l'évolution des vagues de chaleur humide dans les villes d'Afrique de l'Ouest. Sur la base d'études antérieures, de nombreuses définitions de vague de chaleur ont été proposées, conduisant à une divergence dans les résultats. En effet, il n'existe pas de définition universelle d'une vague de chaleur; selon le contexte de l'étude, certains indicateurs et définitions peuvent être adoptés. Ainsi, nous pouvons nous questionner sur les potentielles sources d'incertitude rencontrées dans la détection des vagues de chaleur. La réponse à ces deux premières interrogations constitue la première contribution de ce travail de thèse à l'état de connaissance sur les vagues de chaleur en Afrique de l'Ouest.

Un autre aspect très important des vagues de chaleur c'est leur prédictibilité. L'impact des vagues de chaleur sur les activités de l'Homme accroît la nécessité d'avoir des prévisions fiables à des échelles de temps intra-saisonnière à saisonnière afin d'anticiper les risques et élaborer

des solutions appropriées (Lowe et al., 2016). La prévisibilité des vagues de chaleur en Afrique de l'Ouest aux échelles intra-saisonnière à saisonnière est un secteur encore très peu exploré. À notre connaissance, deux études jusqu'ici ont été réalisées dans la région sur cette thématique. Batté et al. (2018) ont étudié la prédictibilité des vagues de chaleur à des échelles de temps intra-saisonnières et saisonnières en utilisant respectivement le modèle de Météo-France dans le cadre du projet Subseasonal to Seasonal (S2S) et la cinquième version du système de prévision saisonnière (MF5) de Météo-France sur la période 1993-2014. Pour évaluer les compétences des modèles à l'échelle saisonnière, ils ont défini deux indices à partir de la base de données de l'équipe d'experts sur la détection et les indices du changement climatique (ETCCDI), à savoir l'indice de durée des vagues de chaleur (HWDI) et le nombre de vagues de chaleur par saison (HWPP) en utilisant la température apparente et la température à 2 m. À l'échelle intra-saisonnière, ils ont utilisé la température apparente et les anomalies T2m en remplacement au HWDI et au HWPP. Ils ont constaté qu'à l'échelle saisonnière, la capacité de MF5 à reproduire les anomalies inter-annuelles de la durée des vagues de chaleur est limitée au niveau des points de grille en raison de la forte variabilité spatiale dans la région, mais elle est significative lorsque l'on prend la moyenne sur la région du Sahel [10°N-20°N, 10°W-20°E]. À l'échelle intra-saisonnière, les performances du modèle diminuent au-delà d'une semaine. Guigma et al. (2021b) ont évalué la prévisibilité des vagues de chaleur au Sahel à l'échelle intra-saisonnière en utilisant le système de prévision à long terme du CEPMMT (ENS-ext), ERA5 et les données maillées de BEST pour l'évaluation sur la période 1998–2017. Leur approche est basée sur la prévision de la probabilité d'occurrence des vagues de chaleur. Ils montrent que le modèle ENS-ext est capable de prévoir les vagues de chaleur Sahéliennes jusqu'à 2 semaines à l'avance. Ils montrent également que pour de longues échéances, les vagues de chaleur nocturnes sont plus prévisibles que les événements diurnes. Les villes Ouest-Africaines représentant des centres de forte concentration des populations, l'impact des vagues de chaleur en milieu urbain serait plus important que dans les villages ou les localités reculé(e)s. De fait, une étude de la prédictibilité des vagues de chaleur dans les villes ouest-Africaines s'avère primordiale pour aider les populations à se préparer pour faire face à ces événements dévastateurs. C'est dans cette perspective, que s'inscrit la deuxième contribution

de ce travail de thèse.

La prévision des extrêmes climatiques tels que les vagues reste un véritable challenge pour les modèles de prévision (Zhu and Li, 2018). Les vagues de chaleur représentant un potentiel danger pour les populations, il serait important de développer des outils permettant de fournir des prévisions fiables sur l'occurrence de ces événements afin de déployer des stratégies d'adaptation adéquates. Depuis quelques années, les méthodes d'apprentissage automatique sont de plus en plus utilisées dans les sciences du climat. Ainsi, plusieurs modèles d'apprentissage automatique ont été développés pour prédire la température et les événements de température extrême. Naing and Htike (2015) ont utilisé la méthode de forêt aléatoire "Random Forest (RF)" pour la prévision des variations de températures mensuelles dans la région de Kuala Lumpur. La méthode de forêt aléatoire a été comparée avec d'autres méthodes telles que le "K-nearest neighbours (KNN)", "Radial Basic Function (RBF) network" et les perceptrons multi-couches. La méthode de forêt aléatoire réalise de meilleures performances par rapport aux autres méthodes. Khan et al. (2019) ont utilisé une variante de forêt aléatoire appelée "Quantile Random Forest (QRF)" pour la détection des vagues de chaleur au Pakistan à partir de la prédiction de la température maximale journalière. Le modèle QRF a pu prédire quelques dates de déclenchement des vagues de chaleur en Mai, Juin et Juillet avec des incertitudes de +/- 5 jours. Dans la même lancée, Khan et al. (2021) utilisent un autre algorithme d'apprentissage automatique le "Support Vector Machine (SVM)" pour la détection des vagues de chaleur au Pakistan cette fois à partir du nombre de jours associés aux vagues de chaleur en période estivale. Les résultats obtenus ont démontré le potentiel de la méthode SVM à réaliser des prévisions fiables des vagues de chaleur. Giamalaki et al. (2022) ont étudié la prédictibilité des vagues de chaleur marines en utilisant un modèle de forêt aléatoire. Le modèle de forêt aléatoire a été capable de prévoir des températures extrêmes de surface de la mer à des échéances de quelques semaines. Miloshevich et al. (2023) en utilisant un réseau de neurones convolutionnels, ont réussi à prédire 15 jours à l'avance à partir des paramètres dynamiques évoluant rapidement (champ de géopotential à 500hPa), l'occurrence des vagues de chaleur persistances avec des durées de 14 jours sur la France. Le modèle de réseau de neurones a montré des capacités à prédire sur des échéances plus longues l'occurrence

des vagues de chaleur en utilisant des paramètres physiques évoluant lentement (humidité du sol). Sur la base des résultats des études antérieures, nous avons exploré le potentiel de ces méthodes d'apprentissage en vue d'optimiser les prévisions des vagues de chaleur réalisées par les modèles de prévision intra-saisonnière. Cette étude préliminaire est une première dans la région et constitue la troisième contribution de ce travail de thèse.

Il a été démontré dans les études antérieures que les vagues de chaleur pourraient être influencées par des phénomènes de grande échelle comme El Niño (Moron et al., 2016). Guigma et al. (2021a) ont mis en évidence des liens entre les vagues de chaleur au Sahel et les modes d'oscillation tropicaux principalement l'oscillation Madden-Julian. En plus d'être un élément clé du système de mousson ouest-Africaine, la dépression thermique Saharienne de par son activité, peut générer des conditions atmosphériques favorables à l'occurrence des vagues de chaleur au Sahel. La dépression thermique Saharienne étant plus simple à détecter que le phénomène El Niño, nous évaluons son évolution dans les modèles de prévision afin de déduire des informations pour améliorer la prédictibilité des vagues de chaleur à l'échelle saisonnière. Cette étude constitue la quatrième contribution de ce travail de thèse.

1.3 Organisation du manuscrit

Le reste du manuscrit est organisé comme suit :

- le [chapitre 2](#) présente les généralités sur les vagues de chaleur ;
- nous décrivons au [chapitre 3](#), la méthode d'interpolation d'interpolation utilisée pour estimer les données locales à partir des données de grande échelle ;
- le [chapitre 4](#) est consacré monitoring des vagues dans les villes ouest-Africaines ;
- le [chapitre 5](#) quant à lui, porte sur la prédictibilité par méthode directe des vagues de chaleur dans les villes ouest-Africaines ;
- le [chapitre 6](#) traite de la prédictibilité des vagues de chaleur en Afrique de l'ouest par méthode d'apprentissage automatique ;

- l'évaluation de la représentation et de la prévisibilité de la dépression thermique dans les modèles de prévision saisonnière sont abordées au *chapitre 7*;
- et enfin, au *chapitre 8*, nous terminons par une conclusion générale sur ce travail de thèse et des perspectives pour des études futures.

Chapitre 2

Généralités sur les vagues de chaleur :

Définition, caractéristiques et mécanismes de formation

2.1 Définition

Une vague de chaleur encore connue sous l'appellation canicule est un phénomène météorologique très souvent associé à une élévation des températures diurne et/ou nocturne. La définition d'une vague de chaleur varie énormément selon les régions géographiques. Plus généralement, une vague de chaleur se définit comme une succession de jours consécutifs durant lesquels les températures à la surface sont très chaudes par rapport à la normale. À cet effet, Les vagues de chaleur sont donc perçues comme des extrêmes de chaleur prolongés. Il n'existe pas de définition universelle décrivant une vague de chaleur; cependant une définition pourrait être faite en fonction du contexte de l'étude (impacts sur la santé, l'environnement, les infrastructures, l'agriculture) ([Perkins and Alexander, 2013](#)). La prise en compte du contexte de l'étude est un élément très important pour la définition d'une vague de chaleur car les vagues de chaleur néfastes pour la santé ne le seront pas nécessairement pour le secteur agricole ou environnemental. Environnement Canada par exemple lancera une alerte de vague de chaleur lorsque les températures

extérieures sont supérieures à 30°C et des valeurs de l'indice humidex supérieures à 40. L'indice humidex est un indice bio-climatique combinant à la fois la température et l'humidité relative afin de déterminer la température ressentie par le corps humain (Smojer-Tomic et al., 2003). À Toulouse cette fois, Météo-France parlera de vague de chaleur lorsque, durant 3 jours et 3 nuits, les températures maximales seront supérieures à 36°C et les températures minimales supérieures à 21°C. L'agence Chinoise de météorologie quant à elle, émettra une alerte si les températures journalières maximales sont supérieures à 35°C sur une période minimale de 3 jours (Tan et al., 2007). La méthodologie utilisée pour détecter une vague de chaleur peut conduire à de grosses incertitudes dans les résultats obtenus : les propriétés d'une vague de chaleur définies avec des critères différents pour une même application ne seront pas identiques. Ainsi, malgré de diverses études réalisées sur les vagues de chaleur, obtenir une définition de ces dernières qui fait l'unanimité reste un véritable challenge.

2.2 Détection de vagues de chaleur

De façon générale, le processus de détection d'une vague de chaleur passe par les étapes suivantes : le choix des grandeurs atmosphériques (température, humidité relative, vent, etc.), le choix du seuil (absolu ou basé sur des quantiles), le calcul du seuil (fixe ou fenêtre glissante), la définition du critère d'évaluation (mcg, 2015).

2.2.1 Critère de détection et indicateurs

2.2.1.1 Critère de détection basé sur la température journalière maximale

Plusieurs études sur la détection des vagues de chaleur ont été menées en utilisant uniquement la température journalière maximale (Tmax). Russo et al. (2014b) étudiant les tendances futures des vagues de chaleur à travers le globe, proposent une définition d'une vague de chaleur comme étant une période de 3 jours consécutifs où Tmax est supérieure au quantile 90. Dans leur cas, le quantile 90 est calculé pour chaque jour en utilisant une fenêtre glissante de 31

jours autour du jour considéré. [Fischer and Schär \(2010\)](#) adoptent une approche similaire à celle de [Russo et al. \(2014b\)](#) avec une définition différente de la vague de chaleur. Ils considèrent une vague de chaleur comme étant une période d'au moins 6 jours consécutifs où les conditions définies par [Russo et al. \(2014b\)](#) sont satisfaites. [Schoetter et al. \(2015\)](#), en utilisant la Tmax définissent une vague de chaleur comme une période de 3 jours consécutifs où la Tmax est supérieure au quantile 98. Le quantile 98 est calculé sur toute la période et est fixe sur toute la saison. Cette définition de [Schoetter et al. \(2015\)](#) est plus adaptée pour la détection des vagues de chaleur extrêmes et des études d'impacts environnementaux et énergétiques. L'inconvénient majeur de ces méthodes basées uniquement sur la Tmax est l'ignorance totale du facteur humidité très important pour des études d'impacts humains. Les vagues de chaleur détectées à partir de cette méthode sont des vagues de chaleur sèches associées directement à l'irradiation solaire.

2.2.1.2 Critère de détection basé sur la température journalière maximale/minimale

Certains travaux adoptent une double approche dans la détection des vagues de chaleur en utilisant la Tmax ou Tmin. Dans cette approche, ils détectent à la fois des vagues de chaleur associées à Tdmax d'une part, et Tmin d'autre part. [Perkins et al. \(2012\)](#) s'intéressant aux vagues de chaleur sur l'Australie, considèrent une vague de chaleur comme une période de 3 jours consécutifs où $T_{max} > \text{quantile } 90$ ou $T_{min} > \text{quantile } 90$ calculé à partir de Tmax/Tmin respectivement. Le quantile 90 est calculé en utilisant une fenêtre glissante de 15 jours autour du jour considéré. [Gershunov and Guirguis \(2012\)](#), étudiant les vagues de chaleur aux USA adoptent la même définition que [Perkins et al. \(2012\)](#) mais avec quelques modifications principalement la valeur du seuil égal au quantile 95 fixe sur toute la saison. Cette méthode permet d'évaluer la variabilité des vagues de chaleur en fonction de Tmax et Tmin. [Lavaysse et al. \(2019\)](#) étudient la prédictibilité des vagues de chaleur européennes en combinant les deux précédentes définitions. Ils définissent donc une vague de chaleur comme une période de 3 jours consécutifs avec $T_{max} > \text{quantile } 90$ et $T_{min} > \text{quantile } 90$ calculé à partir de Tmax/Tmin respectivement. Le calcul du quantile 90 se fait sur une fenêtre glissante centrée sur le jour donné. Cette approche prend en compte l'évolution de Tmax et Tmin ; elle est bien adaptée pour des études d'impacts sur les humains. [Cowan et al. \(2014\)](#) défi-

nissent une vague de chaleur comme une période durant laquelle $T_{max} >$ quantile 90 sur 3 jours consécutifs et $T_{min} >$ quantile 90 les 2^{ème} et 3^{ème} jours de cette période de 3 jours. Le quantile 90 est calculé ici en utilisant une fenêtre glissante de 15 jours. Ces deux méthodes permettent de détecter des vagues de chaleur potentiellement dangereuses pour la santé car les effets des vagues de chaleur sont plus importants lorsqu'il n'y a pas d'atténuation de température dans la nuit.

2.2.1.3 Critère de détection basé sur la température journalière

D'autres études au lieu de se focaliser sur les extrêmes de température, utilisent l'ensemble du signal journalier. C'est le cas de [Stefanon et al. \(2012\)](#) qui définissent une vague de chaleur comme un période de 4 jours consécutifs avec des anomalies de température à la climatologie sont au-dessus du quantile 95. Le quantile 95 est considéré fixe sur toute la saison et est calculé sur les anomalies. Ils rajoutent également une contrainte spatiale afin de déterminer l'extension de la vague de chaleur. Cette méthode permet d'analyser le signal intra-saisonnier de température afin de déterminer la variabilité intra-saisonnaire des extrêmes.

2.2.1.4 Critère de détection basé sur la température journalière moyenne

Cette méthode utilise uniquement la température moyenne journalière (T_{moy}) (moyenne entre T_{min} et T_{max}). Cette grandeur a été utilisée par [Nairn and Fawcett \(2015\)](#) afin de construire un indice bio-météorologique prenant en compte l'excès de chaleur et le stress thermique : il s'agit du Excess Heat Factor (EHF). Le EHF est composé de deux indices : le Excess Heat Index (EHI) [Nairn and Fawcett \(2013\)](#) et le Excess Heat Index-acclimatization (EHI_{accl}) [Nairn and Fawcett \(2013\)](#), et est obtenu à partir de la formule suivante :

$$EHF = EHI_{sig} * \max(1, EHI_{accl}) \quad (2.1)$$

[mcg \(2015\)](#)

Un EHF positif indiquera la présence de vagues de chaleur. Cet indice est utilisé par le bureau australien de météorologie (Bureau of Meteorology (BoM)) pour le suivi des vagues de chaleur. Perkins et al. (2012), définissent une vague de chaleur comme étant une période de 3 jours consécutifs où le EHF est positif. Fontaine et al. (2013a) utilisent directement la T_{moy} pour la détection des vagues de chaleur au Sahel. Cette fois la vague de chaleur désigne une période de 4 jours consécutifs avec $T_{moy} >$ quantile 90 calculé à partir d'une fenêtre glissante de 5 jours autour du jour considéré.

a) Le Excess Heat Index (EHI_{sig})

L'indice EHI_{sig} représente l'anomalie de Température moyenne sur trois jours par rapport à une valeur climatologique de référence (le quantile 95 de la température moyenne entre 9h du matin et 9h du soir sur une période de référence). Il a été développé par le Bureau Australien de Météorologie (BoM) Nairn and Fawcett (2013) pour détecter et caractériser les vagues de chaleur. Les valeurs positives du EHI_{sig} indiquent un excès de chaleur par rapport à la valeur de référence ou encore des vagues de chaleur de forte intensité Perkins et al. (2012). Il se calcule à partir de la formule suivante :

$$EHI_{sig} = \frac{1}{3}(T_j + T_{j+1} + T_{j+2}) - T_{95} \quad (2.2)$$

$$T_j = \frac{T_{max(j)} + T_{min(j)}}{2} \quad (2.3)$$

$T_j/T_{j+1}/T_{j+2}$ représentent la température moyenne pour les jours $j/j + 1/j + 2$;

T_{95} représente le quantile 95 climatologique de la température moyenne;

$T_{max(j)}/T_{min(j)}$ représentent la température maximale/minimale du jour j ;

T_j et EHI_{sig} sont en °C.

b) Le Excess Heat Index-acclimatization

Le EHI_{accl} est similaire au EHI_{sig} à la seule différence qu'il représente l'anomalie de tem-

pérature moyenne sur 3 jours consécutifs par rapport à la moyenne de la température moyenne sur les 30 jours précédents. Il a été développé par le BOM (Nairn and Fawcett, 2013), et permet d'évaluer le stress thermique en prenant une éventuelle acclimatation à court terme. Le EHI_{accl} est calculé à partir de la formule suivante :

$$EHI_{accl} = \frac{1}{3}(T_j + T_{j+1} + T_{j+2}) - \frac{1}{3}\left(\sum_{k=1}^{30} T_{j-k}\right) \quad (2.4)$$

T_j et EHI_{accl} sont donnés en °C.

2.2.1.5 Critère de détection basé sur la température, l'humidité relative, vitesse du vent

De nombreux indices bio-météorologiques ou indices de confort ont été développés et approuvés conjointement par l'Organisation Mondiale de la Météorologie (OMM) et l'Organisation Mondiale de la Santé (OMS). Ces indices combinent plusieurs grandeurs atmosphériques et rendent compte du stress thermique ressenti par le corps humain, par conséquent très adaptés pour des études d'impact climat-santé.

a) Le Heat Index (HI)

Le HI combine à la fois la température et l'humidité relative pour déterminer la température apparente (température réelle ressentie par le corps humain). Lorsque l'humidité relative est élevée, le taux d'évaporation est faible; ceci entraîne une faible évacuation de la chaleur par l'organisme. Le HI est utilisé par la NOAA (National Oceanic and Atmospheric Administration) aux USA et est effectif lorsque la température est supérieure à 26°C (80°F) et l'humidité relative au moins égale à 40%. Le HI se calcule à partir de la formule suivante :

$$HI = -42.379 + 2.04901523(T_f) + 10.14333127(RH) - 0.22475541(T_f)RH - (6.83783 * 10^{-3})(T_f^2) - (5.481717 * 10^{-2})RH^2 + (1.22874 * 10^{-3})(T_f^2)RH + (8.5282 * 10^{-4})(T_f)RH^2 - (1.99 * 10^{-6})(T_f^2)(RH^2) \quad (2.5)$$

mcg (2015)

Les grandeurs T_f et RH représentent respectivement la température ambiante exprimée en degré Fahrenheit et l'humidité relative en pourcentage.

Robinson (2001) en considérant comme indice le HI, défini une vague de chaleur comme une période de 2 jours consécutifs durant laquelle le HI_{max} associé à T_{dmax} est supérieur à 105°F ou le HI_{min} associé à T_{dmin} est supérieur à 80°F. Oueslati et al. (2017) reprennent l'approche utilisée par Robinson (2001) avec des modifications sur le calcul du seuil de HI et la contrainte temporelle. Ils définissent à cet effet un seuil égal au quantile 90 fixe sur toute la période d'étude (1981-2010) en supposant l'humidité relative constante durant la journée calculée à partir de T_{2m} et D_{2m} (respectivement température à 2 m et température du point de rosée à 2 m). Ils définissent un critère temporel d'au moins 3 jours pour détecter une vague de chaleur. L'évolution du HI en fonction de la température et l'humidité relative est illustrée à la figure ci-dessous [Fig2.1].

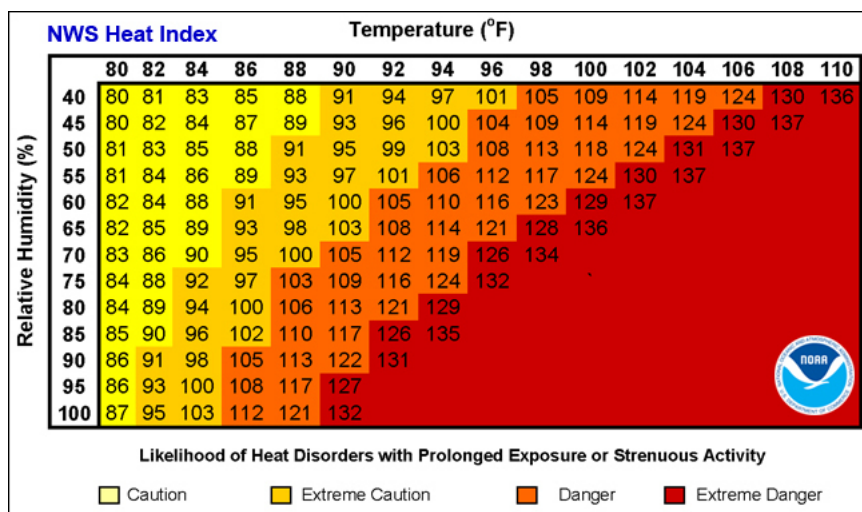


Figure 2.1 – Diagramme d'évolution du Heat Index en fonction de l'humidité relative et la température ambiante, tiré du site de la NOAA (<https://www.weather.gov/ama/heatindex>)

b) Wet bulb Temperature (Tw)

La température du thermomètre mouillé (T_w) prend en compte à la fois la température du thermomètre sec et l'humidité relative (HR). T_w est une variable clé pour la santé humaine et le stress thermique, car dans les environnements chauds, l'évaporation est le principal processus par lequel les corps se refroidissent. Elle met ainsi en évidence le rôle de l'humidité dans le processus de refroidissement du corps. Cette variable a été développée par (Stull, 2011); lorsque HR

est à son maximum ($\simeq 100\%$), T_w est égale à la température ambiante (température du thermomètre sec). Par contre pour un air sec, c'est-à-dire contenant un taux d'humidité faible, la T_w reste inférieure à la température ambiante. Pas étonnant que les vagues de chaleur sèches soient très bien vécues par rapport rapport aux vagues de chaleur humides. L'expression de T_w en fonction de la température ambiante et de HR est donnée par :

$$T_w = T * \operatorname{atan}\left[\frac{A(HR + B)}{2}\right] + \operatorname{atan}(T + HR) - \operatorname{atan}(HR - C) + D * (HR)^{\frac{3}{2}} * (\operatorname{atan}(E * HR)) - F \quad (2.6)$$

(Stull, 2011), (HR désigne l'humidité relative, elle est exprimée en pourcentage. Par exemple 32 pour $HR=32\%$). T représente la température ambiante, $A = 0.151977$, $B = 8.313659$, $C = 1.676331$, $D = 0.00391838$, $E = 0.023101$, $F = 4.686035$ sont les coefficients définis par Stull.

Yu et al. (2021a) ont utilisé la variable T_w pour évaluer l'évolution des vagues de chaleur humides en Eurasie pendant l'été durant la période 1979-2017. Ainsi, ils définissent une vague de chaleur comme une période de 3 jours consécutifs durant laquelle $T_w >$ quantile 90 calculé sur l'ensemble de la période.

c) La température apparente (AT)

Encore appelée température ressentie, c'est un indice de chaleur développé par Steadman (1984) permettant d'évaluer les sensations de froid ou chaleur en fonction de la température ambiante, le vent et l'humidité relative. Elle correspond à un ajustement de la température ambiante en fonction de la teneur en humidité de l'air. Si l'humidité relative est supérieure à une certaine valeur de référence, la température apparente serait supérieure à la température ambiante; dans le cas contraire, elle serait inférieure à la température ambiante. Une version plus simplifiée de cet indice est le HI présenté ci-dessus. La température apparente se présente sous deux formes, l'une incluant le flux radiatif [Eq.2.7] et l'autre non [Eq.2.8]. Les formulations utilisées par le BoM sont les suivantes :

$$AT = T_a + 0.348 * e - 0.70 * ws + 0.70 * \frac{Q}{(ws + 10)} - 4.25 \quad (2.7)$$

$$AT = T_a + 0.33 * e - 0.70 * ws - 4.00 \quad (2.8)$$

mcg (2015)

T_a : la température du thermomètre sec exprimée en degré Celsius, ($^{\circ}C$)

e : la pression de vapeur d'eau saturante exprimée en (hPa),

ws : la vitesse du vent à 10m exprimée en (m/s),

Q : le flux radiatif net absorbé par unité de surface du corps (W/m^2).

Guigma et al. (2020a) dans leur étude portant sur la caractérisation des vagues de chaleur Sahéliennes définissent un critère de détection basé sur la température apparente. Ainsi, ils considèrent une vague de chaleur comme une période minimale de trois jours consécutifs durant laquelle la température apparente maximale (respectivement minimale) serait supérieure au quantile 75; et les anomalies de température apparente par rapport à la climatologie journalière excédant le quantile 90.

d) Universal Thermal Climate Index (UTCI)

Le UTCI est un indice bioclimatique développé par la Société Internationale de Biométéorologie (ISB) en 2009 et a adopté par l'OMM permettant de représenter le stress thermique induit par les conditions météorologiques sur le corps humain. Cet indice fournit une description plus réaliste du confort thermique car prenant en compte plusieurs grandeurs atmosphériques. Pour une combinaison de température de l'air, température radiative moyenne, humidité et vitesse du vent, le UTCI désigne la température équivalente qui produirait dans le corps humain la même réponse thermique (production de sueur, frissons, humidité cutanée etc.) que l'environnement réel. La différence entre le UTCI et la température réelle (Offset) dépend des valeurs à l'instant

de la température de l'air et la température radiative moyenne, la vitesse du vent et l'humidité (exprimée en terme de vapeur d'eau ou d'humidité relative). Le UTCI est donné par l'expression suivante :

$$UTCI = f(T_a, T_{mrt}, v_a, v_p) = T_a + \text{Offset}(T_a, T_{mrt}, v_a, v_p) \quad (2.9)$$

mcg (2015)

T_a : la température de l'air (°C),

T_{mrt} : la température radiative moyenne (°C),

v_p : la pression de vapeur d'eau saturante exprimée en (hPa),

v_a : la vitesse du vent (m/s).

UTCI (°C)	Stress category
UTCI > 46	Extreme heat stress
38 < UTCI < 46	Very strong heat stress
32 < UTCI < 38	Strong heat stress
26 < UTCI < 32	Moderate heat stress
9 < UTCI < 26	No thermal stress
0 < UTCI < 9	Slight cold stress
-13 < UTCI < 0	Moderate cold stress
-27 < UTCI < -13	Strong colds stress
-40 < UTCI < -27	Very strong cold stress
UTCI < -40	Extreme cold stress

Figure 2.2 – Échelle d'évolution de l'intensité du UTCI et ses impacts sur le stress thermique (Błażejczyk et al., 2014)

Di Napoli et al. (2019) ont étudié le lien entre le stress thermique et les périodes de forte mortalité en utilisant le UTCI. Ils définissent une vague de chaleur comme une période de 3

jours consécutifs durant laquelle les valeurs minimales/maximales de *UTCI* sont supérieures au quantile 95 associé respectivement aux valeurs minimales/maximales de *UTCI*. [Guigma et al. \(2020a\)](#) considèrent une vague de chaleur comme une période minimale de trois jours consécutifs durant laquelle le *UTCI* maximal (respectivement minimal) serait supérieure au quantile 75; et les anomalies de *UTCI* par rapport à la climatologie journalière excédant le quantile 90.

2.2.1.6 Critère de détection basé sur les anomalies de température journalière

Dans certaines études plutôt que d'utiliser les valeurs de température brute pour la détection des vagues de chaleur, les auteurs utilisent les anomalies de température journalière. [Stefanon et al. \(2012\)](#) dans leur étude portant sur la classification des vagues de chaleur en Europe et en zone méditerranéenne, définissent une vague de chaleur comme une période minimale de 4 jours consécutifs où l'on enregistre des anomalies de température par rapport à la climatologie supérieure au quantile 95 des anomalies calculées sur toute la période d'étude (1950-2009). Le quantile 95 des anomalies journalières est calculé en utilisant une fenêtre glissante de 10 jours autour du jour considéré sur la période d'étude. [Barbier et al. \(2018\)](#) en analysant les caractéristiques et tendances passées des vagues de chaleur au Sahel, adoptent la définition suivante : "un événement est considéré comme une vague de chaleur si les anomalies journalières de température minimale ou maximale sont supérieures au quantile 90 des anomalies de température minimale ou maximale respectivement. Ils appliquent aussi une contrainte spatiale pour supprimer les vagues de chaleur se produisant sur de petites localités dans la région.

2.2.2 Seuil de détection : absolu ou relatif

Les vagues de chaleur sont des phénomènes météorologiques caractérisées par des températures anormalement chaudes au-dessus des valeurs seuils sur une période minimale de 3 jours. La notion de seuil est capitale dans la définition d'une vague de chaleur et fortement dépendante de la région et des applications de l'étude. De façon générale, le seuil est défini sous deux formes : absolu ou relatif. Le choix d'un seuil absolu se fait de façon empirique en référence à la climatologie de la région d'étude. La méthode de détection des vagues de chaleur basée sur

un seuil absolu est très adapté dans des régions marquées par une forte saisonnalité, des amplitudes thermiques assez importantes entre les saisons (été et hiver); comme c'est le cas dans latitudes moyennes. [Robinson \(2001\)](#) adoptent une approche similaire et définissent une vague de chaleur comme une période minimale de 2 jours durant laquelle les valeurs journalières minimales/maximales du Heat index sont supérieurs à 80°/105°F. L'agence chinoise de météorologie utilise une définition plus classique de la vague de chaleur comme une période minimale de 3 jours avec les températures journalières maximales supérieures à 35°C ([Tan et al., 2007](#); [Bai et al., 2014](#)). L'inconvénient principal de cette approche repose sur la définition du seuil qui doit-être réajusté pour des applications à d'autres régions. La méthode de détection de vague de chaleur utilisant un seuil relatif est la plus répandue; elle est très appropriée pour les régions caractérisées par un faible cycle saisonnier surtout quand l'étude est effectuée sur toute la saison. Cette méthode est facilement transférable à d'autres régions mais peut très vite s'avérer complexe pour le calcul du seuil journalier de référence. Le seuil journalier de référence représente très souvent la climatologie du seuil journalier sur la période d'étude. Cette approche a été utilisée dans de nombreux travaux antérieurs ([Fischer and Schär, 2010](#); [Perkins et al., 2012](#); [Perkins and Alexander, 2013](#); [Stefanon et al., 2012](#); [Cowan et al., 2014](#); [Fontaine et al., 2013a](#); [Russo et al., 2014b](#); [Déqué et al., 2017-08-01](#); [Oueslati et al., 2017](#); [Barbier et al., 2018](#); [Lavaysse et al., 2018a](#)). Une autre approche consiste à combiner un seuil absolu et un seuil relatif pour la détection des vagues de chaleur. Cette méthode peut être très utile dans les latitudes moyennes surtout si la détection des vagues de chaleur se fait sur toute la saison. En rajoutant une valeur absolue du seuil, l'on pourra éliminer les vagues de chaleur se produisant durant les périodes froides qui pourraient être présentes avec l'utilisation unique d'un seuil relatif. Cette méthode est très utilisée en Asie ([Ding et al., 2010](#); [You et al., 2017](#); [Wang et al., 2017](#)).

2.3 Mécanismes et processus de formation

Les vagues de chaleur se produisent indépendamment d'une région à une autre. Elles peuvent avoir une origine très locale ou alors résulter des interactions à grande échelle. Il n'existe pas de

configuration standard conduisant à l'occurrence d'une vague de chaleur, cependant quelques études réalisées ont mis en évidence certains mécanismes. Les mécanismes les plus récurrents sont entre autres :

- les phénomènes météorologiques synoptiques : anticyclones ;
- les rétroactions entre l'humidité des sols et l'atmosphère ;
- les phénomènes climatiques de grande échelle : El Nino.

2.3.1 les phénomènes météorologiques synoptiques : anticyclones

Un anticyclone désigne une zone de haute pression atmosphérique. La circulation atmosphérique est régie par un ensemble de mouvements de masse d'air entre les zones dépressionnaires et les centres de haute pression. Durant leur déplacement, les anticyclones peuvent s'arrêter au dessus d'une localité et y rester de façon anormale pendant plusieurs jours : on parle dans ce cas de blocage anticyclonique. Des études ont montré que les vagues de chaleur dans les latitudes moyennes sont généralement associées à un blocage anticyclonique ([Charney and DeVore, 1979](#); [Coughlan, 1983](#); [Kautz et al., 2022](#)). Dans ce cas de figure, l'anticyclone peut être situé :

- dans la même région que la vague de chaleur : cas des événements se produisant dans l'hémisphère nord (les événements de 2003 en France ([Trigo et al., 2005](#)) et 2010 en Russie ([Matsueda, 2011](#)); 1995 aux USA ([Meehl and Tebaldi, 2004](#)));
- à côté de la région affectée par la vague de chaleur ([Pezza et al., 2012](#); [Marshall et al., 2014](#); [Boschat et al., 2015](#)), dans ce cas le système d'anticyclone se trouve au dessus de la mer (cas de l'Australie) et aura tendance à pomper de l'air chaud et sec vers la région voisine produisant ainsi des conditions favorables à l'établissement des vagues de chaleur.

Dans le premier cas cité ci-dessus, l'anticyclone se trouvant au dessus de la région affectée, va empêcher l'advection de l'air dans la localité et aura tendance à comprimer l'air vers la surface; ce qui va provoquer son réchauffement [Fig2.3]. La présence de cet anticyclone s'oppose à la pénétration des vents et nuages dans la localité; du fait du manque de refroidissement, la température va augmenter davantage d'où le réchauffement intense. Ce phénomène peut durer

aussi longtemps que l'anticyclone demeurerait au-dessus de la zone.

En Afrique de l'ouest, [Fontaine et al. \(2013a\)](#) ont établi que les vagues de chaleur Sahéliennes sont associées à des anomalies positives de température à basse altitude sur le Sahel et le Sahara, ainsi qu'à une circulation cyclonique à basse et moyenne altitude sur le Maroc. Cette dynamique à grande échelle est associée à une configuration d'ondes de Rossby qui atténue les vents de nord-est de basse altitude (Harmattan). [Guigma et al. \(2020a\)](#) quant eux ont montré que les vagues de chaleur sur la partie est du Sahel sont associées à une anomalie de circulation cyclonique de basse altitude sur le nord de l'Afrique, contre une anomalie de circulation anticyclonique pour les vagues de chaleur sur le Sahel occidental. Lorsque l'activité convective est faible sur la bande Guinéenne, le flux nord-est associé assure le transport d'air chaud de l'est du Sahel/Sahara vers la côte du Sahel occidental; inversement, un renforcement de l'activité convective dans la région Guinéenne, favorise le transport de l'humidité du Golfe de Guinée vers le Sahel à travers le flux de mousson (e.g, [Lothon et al., 2008](#); [Couvreur et al., 2010](#)) conduisant à des conditions propices à l'occurrence des vagues de chaleur.




Figure 2.3 – Schéma de formation d'une vague de chaleur associé à un anticyclone([University and College](#))

2.3.2 les rétroactions entre la surface du sol et l'atmosphère

Les interactions entre la surface du sol et l'atmosphère dépendent fortement de la teneur en humidité du sol [Fig2.4]. Ces interactions sont régies par trois grandeurs physiques : le flux de chaleur sensible, flux de chaleur latente et le flux radiatif net. Le flux radiatif net représente la quantité d'énergie solaire reçue par la surface. Le flux de chaleur latente quant à lui désigne la quantité d'énergie absorbée lors d'un changement d'état à température constante. Et enfin, le flux de chaleur sensible est la quantité d'énergie échangée entre deux ou plusieurs corps sans transition de phase. En fonction de la teneur en humidité du sol, l'on pourra envisager les cas suivants :

- Pour les sols humides, le flux de chaleur latente serait très important par rapport au flux de chaleur sensible en raison de la forte évaporation de l'eau contenue dans le sol. Ainsi l'eau contenue dans le sol aura tendance à diminuer la réflectance du sol ; ce qui contribuera à une absorption importante du flux radiatif incident. De ce fait, la vapeur d'eau transférée vers l'atmosphère via l'évaporation contribuera à la formation des nuages qui entraînera le refroidissement de l'atmosphère[Fig2.4a] ;
- Pour les sols secs, le flux de chaleur sensible devient plus important par rapport au flux de chaleur latente et la quantité d'humidité transférée vers l'atmosphère très faible. La réflectance du sol devient très élevée, et par conséquent la quasi-totalité du flux radiatif incident est retournée vers l'atmosphère ; ce qui amplifiera le réchauffement. Ce processus empêche la formation des nuages dans la couche atmosphérique. Ce processus peut accentuer la sécheresse des sols [Fig2.4b].

De nombreux travaux ont mis en évidence un lien entre la teneur en humidité du sol et la variabilité saisonnière des températures extrêmes (e.g., [Fischer et al., 2007a,b](#); [Lorenz et al., 2010](#); [Stefanon et al., 2012](#); [Miralles et al., 2014](#)). ([Hirschi et al., 2011](#); [Mueller and Seneviratne, 2012](#)) ont montré que le déficit d'humidité dans le sol favorise l'occurrence des extrêmes de température d'où le lien avec les vagues de chaleur. [Largerion et al. \(2020\)](#) ont analysé la vague de chaleur d'avril 2010 en Afrique du Nord en utilisant à la fois l'ensemble de données BEST et les simulations climatiques de la composante atmosphérique du modèle climatique du Centre National de

Recherches Météorologiques (CNRM). Ils ont mis en évidence un lien étroit entre les vagues de chaleur sur le Sahara et les flux de chaleur de surface entrants. Un autre résultat important de ce travail est le pouvoir radiatif de la vapeur d'eau sur les températures minimales pendant la période des vagues de chaleur. Cela peut conduire à des conditions de chaleur extrême pendant la nuit et causer la mort de personnes âgées.




Figure 2.4 – Bilan radiatif net à la surface : impact de l'humidité du sol a) cas d'un sol humide , b) cas d'un sol sec.(Alexander, 2011)

2.3.3 les phénomènes climatiques de grande échelle

Les phénomènes climatiques de grande échelle peuvent avoir des conséquences immédiates ou à long terme sur l'occurrence des vagues de chaleur. Les blocages anticycloniques responsables des vagues de chaleur en Europe sont très souvent associés au mode de variabilité Nord Atlantique (NAO : North Atlantic Oscillation). Le phénomène ENSO (El Niño Southern Oscillation) a un impact sur la variabilité des températures extrêmes et les vagues de chaleur en Afrique de l'Ouest (e.g, Moron et al., 2016; Oueslati et al., 2017). La grande majorité des événements extrêmes détectés en Afrique par Russo et al. (2016a) sont associés à une phase El Niño du phénomène ENSO. Le phénomène El Niño se caractérise par un réchauffement anormal de la température de la surface de la mer, il prend naissance dans l'océan Pacifique oriental et s'étend aux côtes du Pérou et de l'Équateur. Les résultats des travaux de Guigma et al. (2021a) ont montré que les modes de variabilité tropicaux (Madden Julian Oscillation (MJO), les ondes équatoriales de Rossby

et Kelvin) ont une grande influence sur l'occurrence des vagues de chaleur Sahéliennes et, dans une moindre mesure, sur leur intensité. Selon leurs activités convectives, ils peuvent soit augmenter soit réduire la fréquence des vagues de chaleur, la MJO étant le plus important des trois ci-dessus [Guigma et al. \(2021a\)](#).

2.4 Caractéristiques des vagues de chaleur

Au cours la dernière décennie, l'on a observé une recrudescence des extrêmes de chaleur ([Luber and McGeehin, 2008](#); [Engdaw et al., 2022](#)) suscitant l'attention de la communauté scientifique et des politiques, et cette tendance a été confirmée pour les siècles à venir par les projections climatiques ([Kharin et al., 2007](#); [Fischer and Schär, 2010](#); [Perkins et al., 2012](#); [Russo et al., 2014b](#); [Lau and Nath, 2014](#); [Cowan et al., 2014](#); [Perkins-Kirkpatrick et al., 2016](#)). De tels événements se caractérisent par leur durée, intensité et fréquence. La durée d'une vague de chaleur traduit la persistance de l'événement observé. Sous la recommandation de l'Organisation Mondiale de la Météorologie (OMM), une vague de chaleur est définie sur une période de 3 jours ([Perkins et al., 2012](#); [Russo et al., 2014b](#); [Oueslati et al., 2017](#); [Lavaysse et al., 2018a](#); [Guigma et al., 2020a](#)). Il est important de rappeler ici que le choix de la durée d'une vague de chaleur dépend fortement du contexte de l'étude. Elle varie très rapidement d'une étude à une autre; il n'existe pas de valeur standard. Elle peut dans certains cas être fixée à 2 jours ([Robinson, 2001](#)), 4 jours ([Stefanon et al., 2012](#); [Fontaine et al., 2013a](#)) et 6 jours ([Fischer and Schär, 2010](#)). La fréquence renseigne sur l'occurrence des événements dans une région et permet d'identifier les zones les plus affectées et les années spécifiques de pic d'événements. L'intensité quant à elle reste une caractéristique assez importante pour une vague de chaleur. Elle est une métrique essentielle pour effectuer une classification des événements les plus violents et dangereux pour les populations. Elle est plus importante que le paramètre durée car une vague de chaleur se produisant sur une longue période avec des intensités moyennes ou faibles n'aura pas le même impact qu'une se produisant sur une plus courte période avec de fortes valeurs d'intensité. L'intensité d'une vague de chaleur est déterminée plus souvent en référence au seuil utilisé pour la détection pour la détection de

la vague de chaleur; et représente donc la somme des excédents journaliers par rapport au seuil de référence journalier durant la période d'occurrence de l'événement (Gershunov and Guirguis, 2012). Lavaysse et al. (2018a) définissent deux indices pour le calcul de l'intensité des vagues de chaleur basés sur des anomalies de température par rapport aux seuils climatologiques journaliers dans un cas, et par rapport à un seuil climatologique constant dans un second cas. Ces deux indices sont importants pour des applications respectivement dans le domaine agricole et pour des impacts sur la santé des populations. Du fait de la grande diversité existante dans la définition d'une vague de chaleur, plusieurs formulations sont utilisées pour le calcul de l'intensité de cette dernière. Certains auteurs définissent l'intensité d'une vague de chaleur comme l'anomalie de température entre le jour le plus chaud dans la vague de chaleur la plus chaude et température moyenne sur la période d'étude (Perkins and Alexander, 2013; Cowan et al., 2014). Oueslati et al. (2017) utilisant les indices de stress thermique tels que le Heat index (HI), définissent l'intensité des vagues comme la moyenne des maximums journaliers de HI sur l'ensemble des événements détectés. Russo et al. (2015) combinent à la fois la durée et l'intensité dans un indicateur appelé "Heat wave Magnitude Index daily" (HWMId) pour caractériser l'impact d'une vague de chaleur. Le HWMId est une amélioration du Heat Wave Magnitude Index (HWMI) (Russo et al., 2014b) qui désigne le maximum des amplitudes de toutes les vagues de chaleur détectées durant une année. Le HWMId représente la somme des amplitudes thermiques des jours consécutifs composant une vague de chaleur. Certaines études utilisent à la fois la durée, l'intensité et la surface affectée pour définir la sévérité d'une vague de chaleur (Schoetter et al., 2015).

Fischer and Schär (2010) analysant l'évolution des caractéristiques des vagues de chaleur en Europe, détectent entre 1.1 et 2 jours de vague de chaleur par été sur la période 1961-1990. Les événements détectés pour les plus persistants s'étendent sur une semaine avec des intensités maximales comprises entre 25.6 et 38.6°C. Cowan et al. (2014) étudient l'évolution des vagues de chaleur estivales en Australie sur la période 1950-2005. Ils détectent en moyenne entre 0.5 et 3.5 jours de vague de chaleur par été. Les vagues de chaleur les plus persistantes s'étendent sur 3 à 4 jours au sud de l'Australie et 5 à 6 jours au nord, avec des intensités maximales variant entre 10°C au sud et 3°C au nord. Oueslati et al. (2017) ont réalisé une classification des vagues de

chaleur au printemps Sahélien [Fig.2.5]. Ils ont mis en évidence deux années particulières : 1998 et 2010 durant lesquelles les événements les plus extrêmes en terme d'intensité et de couverture spatiale ont été enregistrés.

	HW frequency	Mean intensity	Mean duration	Mean spatial extent
First HW category	Very frequent: > 20 days yr^{-1} (i.e., > 720 HW days in 36 years)	$51 \leq \text{HImax} < 54^\circ \text{C}$; dangerous	3–5 days	2%–8% (1–4 stations)
Second HW category	Frequent: $0.5\text{--}2$ days yr^{-1} (i.e., 18–72 HW days in 36 years)	$54 \leq \text{HImax} < 56^\circ \text{C}$; extremely dangerous	3–9 days	8%–20% (4–10 stations)
Third HW category	Rare: < 0.5 days yr^{-1} (i.e., < 18 HW days in 36 years)	$\text{HImax} \geq 56^\circ \text{C}$; extremely dangerous	9–15 days	2%–4% (1–2 stations)

Figure 2.5 – Classification des vagues de chaleur au Sahel en fonction de leur fréquence moyenne et de leur intensité à partir des données Global Surface Summary of the Day (GSOD) de la National Oceanic and Atmospheric Administration (NOAA) sur la période 1979-2014 (Oueslati et al., 2017)

2.5 Outils pour la prévision des vagues de chaleur

2.5.1 modèles de prévision du temps

L'évolution des tendances futures des événements météorologiques se fait de façon classique à partir des modèles de prévision du temps. L'on distingue en fonction de l'échéance de prévision, quatre types de prévision du temps [Fig.2.6] : la prévision météorologique qui couvre une période allant de quelques jours à 2 semaines, la prévision intra-saisonnière allant de 2 semaines à 2 mois, la prévision saisonnière de 1 à 6 mois et enfin les projections climatiques sur des périodes plus longues de l'ordre de quelques décennies. La prévision saisonnière a été longuement utilisée (Ingram et al., 2002; Meza et al., 2008; Roncoli et al., 2009; Tall, 2010; Sultan et al., 2010; Hansen et al., 2011; Troccoli, 2010; Tall et al., 2012; Doblas-Reyes et al., 2013) afin de déterminer la tendance au cours de la saison de l'évolution de certaines variables atmosphériques telles que la température, les précipitations, les particules de poussière. Ces informations sont capitales pour les agriculteurs par exemple afin d'ajuster leurs cultures, et aussi pour les services sanitaires afin de se préparer pour une meilleure prise en charge des patients. En 2008, les prévisions saisonnières émises lors du Forum sur les perspectives climatiques saisonnières pour l'Afrique de l'Ouest (PRE-

SAO) annonçaient un risque élevé de précipitations supérieures à la normale pour la saison des pluies de Juillet à Septembre. Avec des probabilités de précipitations supérieures à la normale de 0,45, ces prévisions indiquaient une augmentation notable du risque de fortes précipitations (Tall et al., 2012). Lorsque ces informations sont parvenues au bureau de la Fédération internationale des Sociétés de la Croix-Rouge et du Croissant-Rouge (FICR) pour l'Afrique de l'Ouest et du Centre, elles ont entraîné des changements significatifs dans les opérations de réponse aux inondations de l'organisation. Le bureau régional de la FICR a réquisitionné des fonds avant les inondations prévues, a prépositionné des stratégies de secours en cas de catastrophe dans des lieux stratégiques en Afrique de l'Ouest pour venir en aide à 9500 familles, et a ainsi procédé à la mise à jour de ses plans d'urgence en cas d'inondation, et enfin a alerté les communautés vulnérables et les décideurs dans toute la région. Cette préparation basée sur des prévisions saisonnières a permis de réduire le nombre de vies, de biens et de moyens de subsistance perdus à cause des inondations, par rapport à l'année précédente 2007, durant laquelle des inondations similaires avaient fait plus de 300 victimes dans la région. Les prévisions sont très utiles pour avoir des informations sur la tendance des événements au cours de la saison, toutefois, les informations relatives au suivi des événements ne sont pas assez fiables dans ce type de prévision. Ainsi pour combler le gap entre les prévisions météorologiques à court-terme et saisonnières à plus long terme, les prévisions intra-saisonnières ont vu le jour. En 2013, le Programme Mondial de Recherche sur le Climat (PMRC) conjointement avec le Programme Mondial de Recherche Météorologique (PMRM) ont lancé un projet appelé "Subseasonal to Seasonal" (S2S) sur une période de cinq ans (Vitart and Robertson, 2018). L'objectif est d'améliorer la qualité des prévisions à l'échelle intra-saisonnière. Les prévisions S2S sont d'une grande importance pour les services humanitaires (Croix Rouge, ONG) afin de mettre en place un concept d'alerte précoce "**Ready-Set-Go**" qui permet d'agir rapidement avant l'occurrence d'une potentielle catastrophe naturelle. Le concept "Ready-Set-Go" a été initié par le Centre du Climat de la Croix-Rouge (International Research Institute for Climate and Society (IRI)) pour la gestion des catastrophes naturelles à partir des prévisions à court et à long terme. Cette approche s'organise autour de trois phases :

- la phase "**Ready**", dans cette première phase, les prévisions saisonnières sont utilisées

pour le monitoring des événements à l'échelle intra-saisonnière. Les informations obtenues des prévisions saisonnières permettent de déclencher un plan d'urgence comme la formation des volontaires devant agir face à la catastrophe, la mise à jour des plans de contingence et la mise en place des systèmes d'alerte précoce;

- la phase "**Set**", dans cette deuxième phase, on se rapproche de la date d'échéance de la catastrophe. Cette fois, ce sont les prévisions intra-saisonnières qui sont utilisées pour alerter les volontaires précédemment formés et les communautés locales;
- la phase "**Go**", dans cette dernière phase, nous sommes rendus à quelques jours de la date d'échéance de l'événement. À cet effet, les prévisions à court terme sont utilisées pour déclencher les alertes des volontaires, diffuser les instructions à suivre aux communautés et procéder à l'évacuation des populations si nécessaire.

Un exemple de mise en pratique de ce concept a été réalisé par [Vitart and Robertson \(2018\)](#) pour la prévision des cyclones tropicaux [Fig.2.7]. À l'échelle saisonnière, les modèles initialisés au 1^{er} Novembre prévoyaient déjà une forte activité des cyclones tropicaux dans le bassin Australien de Décembre à Mars avec un niveau de confiance supérieur à la climatologie. En suivant l'événement de plus près à l'échelle intra-saisonnière, les prévisions émises le 13 Janvier pour la période du 26 Janvier au 04 Février indiquent une probabilité de cyclogenèse entre 20 et 30% dans la région. À moyen terme, la probabilité de cyclogenèse selon les prévisions réalisées le 27 Janvier sur une période de 5 à 12 jours est de 90%, ce qui largement suffisant pour déclencher les actions.

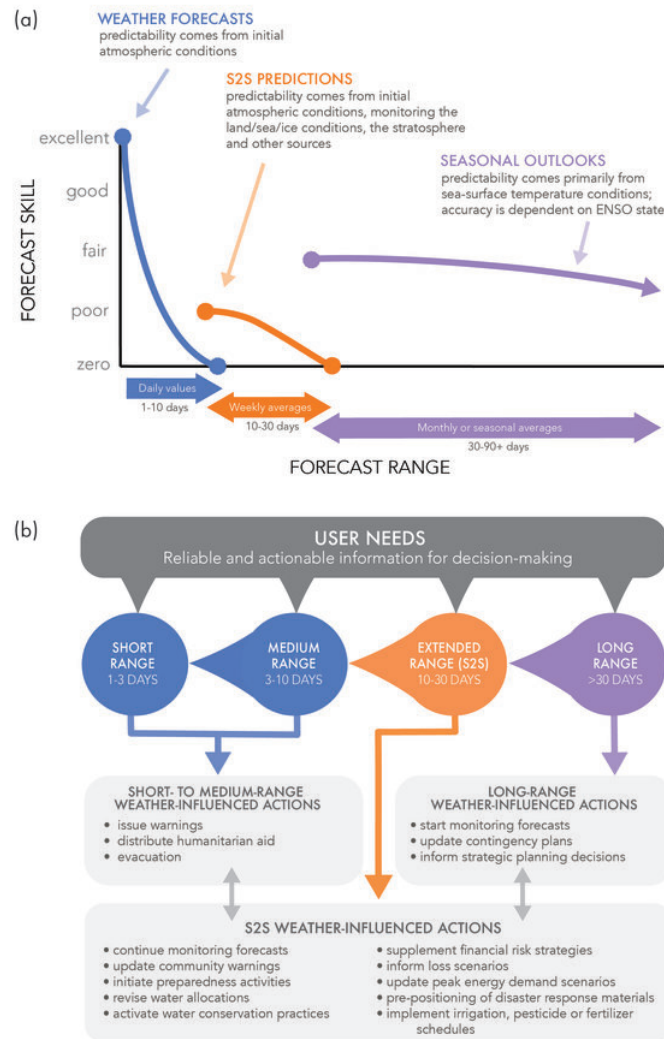


Figure 2.6 – Illustration des différents types de prévision du temps en fonction : a) l'échéance de prévision et b) les applications (White et al., 2017).

Figure 2.7 – Illustration de l'approche "Ready-Set-Go" pour la prévision des cyclones tropicaux (Vitart and Robertson, 2018)

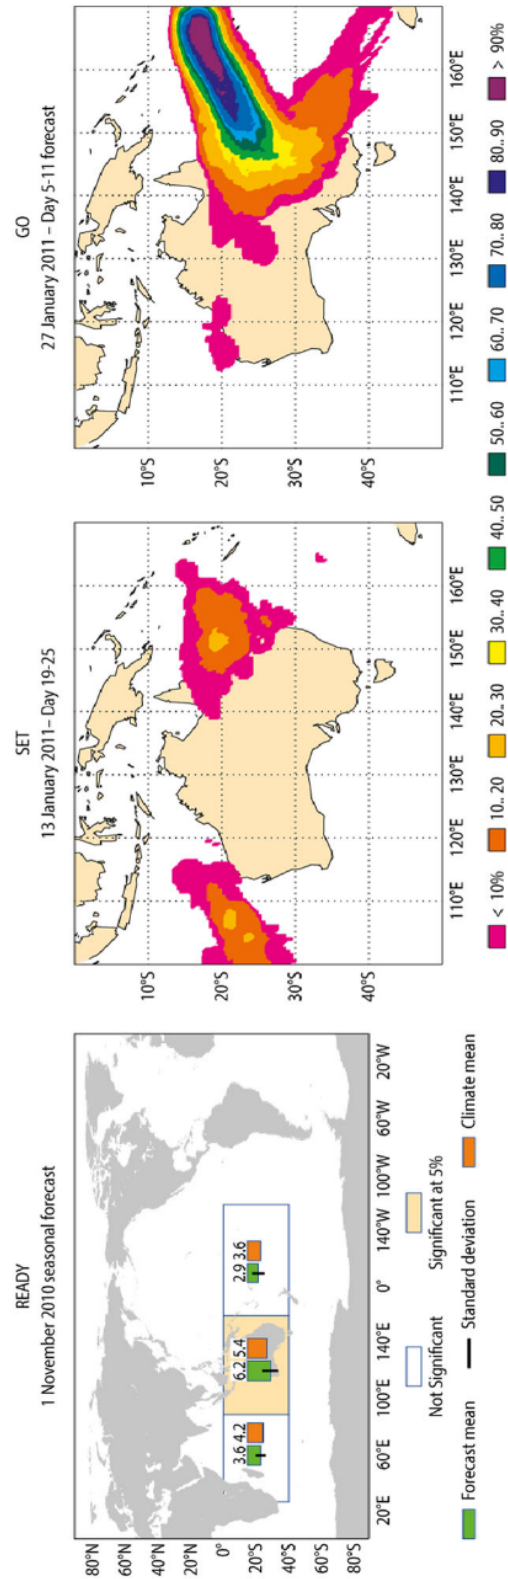


Fig. 3 Tropical cyclone YASI (26 January–4 February 2011). Prediction of tropical cyclones at different time ranges from ECMWF seasonal and ensemble forecasting systems. The left panel shows a seasonal forecast of hurricane frequency starting on 1st November 2010 and covering the period December 2010 to May 2011. Green bars represent the predicted frequency of hurricane-intensity cyclones compared to observed climatology (orange). The black bars show the 5% level of confidence. The middle panel shows the probability of a tropical cyclone strike within 300 km from the ECMWF extended range forecast starting on 13 January 2011 at the time range day 19–25, and the right panel the strike probabilities from the ECMWF medium range forecast starting on 27 January 2011 at the time range day 5–11

2.5.2 méthodes d'apprentissage automatique

Au cours des dernières décennies, des progrès considérables ont été réalisés dans le secteur de l'informatique conduisant à l'apparition de nouvelles disciplines telles que l'apprentissage automatique. Encore connu sous l'appellation "Machine learning", l'apprentissage automatique est un domaine à la frontière entre l'informatique et les Mathématiques utilisant des méthodes statistiques afin de procurer aux ordinateurs la capacité d'apprendre des données et de construire des relations dans le but d'effectuer des tâches pour lesquelles ils n'ont pas été explicitement programmés. De nos jours, les méthodes d'apprentissage automatique ont démontré leur capacité à réaliser des tâches très complexes telles que la reconnaissance d'images, la reconnaissance vocale, la traduction automatique, la détection des fraudes, la conduite assistée et très prochainement les consultations médicales. Durant les deux dernières décennies, ces méthodes ont vu leur application s'accroître de façon exponentielle dans les sciences du climat plus précisément pour la prévision à court et long terme, l'assimilation des données, la classification des régimes de temps à partir des caractéristiques de circulation atmosphérique, la compréhension des processus physiques. Des études récentes ont établi le potentiel des modèles d'apprentissage automatique (réseaux de neurones notamment) pour la prévision météorologique (Dueben and Bauer, 2018; Scher and Messori, 2019; Weyn et al., 2019). Bien que les performances des modèles d'apprentissage soient loin de remettre en question les capacités des modèles physiques (Weyn et al., 2019), ils s'avèrent très utiles pour améliorer les modèles physiques (Schneider et al., 2017), ajuster leurs paramétrisations (Brenowitz and Bretherton, 2018; Gentine et al., 2018) et déterminer l'incertitude dans les prévisions météorologiques (Scher and Messori, 2019). De nombreux projets internationaux autour d'application des méthodes d'intelligence artificielle dans les sciences du climat ont vu le jour notamment le projet "innovative Machine Learning to constrain Aerosol-cloud CLimate Impacts (iMIRACLI)" qui vise à améliorer les connaissances sur les impacts des aérosols et des nuages, les projet "CLimate INTelligence (CLINT)" et "eXtreme events : Artificial Intelligence for Detection and Attribution (XAIDA)" qui s'intéressent à la détection, aux origines et à l'attribution des événements extrêmes.

Chapitre 3

Quelle approche pour estimer la température dans les zones côtières à partir des données à grandes échelles ou de réanalyse ?

3.1 Généralités sur les méthodes de descente d'échelle

Les modèles numériques de prévision du temps utilisés dans les centres météorologiques ont connu de nombreuses améliorations au cours de ces dernières décennies, ceci grâce à une meilleure compréhension du système climatique et de sa dynamique (interactions entre ses différentes composantes) mais aussi aux multiples avancées dans le domaine du calcul haute performance. Aujourd'hui, il est possible de prévoir la variabilité saisonnière et interannuelle du climat mais aussi de réaliser des projections climatiques pour les décennies à venir. Ces avancées considérables de la prévision du temps constituent un énorme potentiel pour satisfaire les besoins de la société mondiale en informations climatiques et environnementales à l'échelle journalière ou saisonnière, annuelle ou décennale et même à plus longue échéance. Toutefois, la résolution spatiale des modèles reste un véritable problème. Les études climatiques classiques se font à partir

de modèles numériques appelés GCM (General Circulation Model) qui couvrent l'ensemble du globe, représentent la dynamique de l'atmosphère et ses lois physiques. Pour des raisons de limitation de la puissance de calcul des ordinateurs disponibles, ces modèles possèdent généralement une résolution spatiale de l'ordre de quelques centaines de kilomètres. Cette résolution ne permet pas de résoudre certains processus et phénomènes physiques régionaux qui influencent le climat d'une région particulière du globe (îles, relief complexe, vents régionaux, structure spatiale des précipitations, circulation océanique de petite échelle). De même, à cette résolution, ces modèles ne permettent pas de fournir des données assez précises (spatialement) pour tous les utilisateurs de données climatiques en vue de développer des modèles d'impacts (impacts potentiels du changement climatique sur le tourisme, sur les ressources en eau, sur les maladies tropicales, sur les écosystèmes marins, sur la production d'énergie renouvelables, etc). Ces domaines ont besoin de simulations à plus haute résolution spatiale. Le dernier inconvénient des modèles globaux est leur faible capacité à simuler les événements extrêmes (vents violents, précipitations intenses) qui sont souvent liés à des phénomènes ou à des forçages de petites échelles. Pour ces raisons, une transformation des prévisions à grande échelle vers des prévisions pertinentes à l'échelle locale s'impose [Fig.3.1] : c'est la "**régionalisation**" encore appelée "**downscaling**". Le downscaling consiste donc à déduire des informations pertinentes à haute résolution à partir des variables à faible résolution. La régionalisation peut se faire suivant une approche dynamique, dans ce cas, on parlera de : downscaling dynamique ; ou alors suivant une approche statistique : downscaling statistique.

Le downscaling dynamique repose essentiellement sur des modèles régionaux, les équations de la dynamique atmosphérique sont résolues à des mailles plus fines mais uniquement pour quelques régions. Il existe trois méthodes distinctes pour modéliser le climat à l'échelle régionale :

- la première méthode consiste à utiliser un GCM à très haute résolution et couvrant l'ensemble du globe. C'est cette approche qui est utilisée dans le modèle ARPEGE-Climat du Centre National de Recherches Météorologiques (CNRM) (Elguindi et al., 2011);

- la seconde méthode utilise les modèles globaux dont la grille peut-être étirée pour renforcer la résolution spatiale dans la zone d'étude (zoom sur une région donnée). C'est le cas des modèles ARPEGE-Climat de Météo-France, LMD-Z de l'Institut Pierre Simon Laplace (IPSL) étirés sur l'Europe et la mer Méditerranée (Déqué and Piedelievre, 1995; Déqué et al., 1998; Déqué, 2007; Gibelin and Déqué, 2003)
- la troisième méthode repose sur l'utilisation des modèles à aire limitée. Ces modèles couvrent seulement une partie du globe et sont forcés à partir des modèles de plus faible résolution (GCM, réanalyses). Le modèle CNRM-ALADIN est un exemple de modèle à aire limitée; il permet de réaliser des prévisions avec de résolutions très fines (jusqu'à 10km) (Colin et al., 2010; Druge et al., 2019). Depuis quelques années, un nouveau modèle à aire limitée a été développé au CNRM : le modèle CNRM-AROME permettant de raffiner les simulations jusqu'à des résolutions kilométriques (Termonia et al., 2018; Lucas-Picher et al., 2022).

Malgré les progrès réalisés dans le secteur du calcul haute performance, les moyens et coûts de calcul nécessaires à la résolution des équations physiques à l'échelle régionale contraignent l'utilisation des modèles régionaux sur des régions spécifiques.

Le downscaling statistique consiste à déterminer en utilisant des méthodes statistiques des relations et corrélations existantes entre les données à grande échelle (provenant de GCM et réanalyses par exemple) et des variables observées à fine échelle (provenant des stations météorologiques). Cette approche permet ainsi d'estimer les données locales plus rapidement et nécessite pas de moyens de calculs assez coûteux. En pratique, l'approche statistique de downscaling repose sur trois grandes familles de méthodologies (Wilby and Wigley, 1997) :

- les méthodes par fonction de transfert, elles ont pour but de "traduire" directement les données à grande échelle en valeurs locales grâce à des régressions linéaires ou non-linéaires. Les deux méthodes basées sur les fonctions de transfert les plus utilisées sont : la méthode CDF-t (Cumulative Distribution Function – Transform) (Michelangeli et al., 2009a; Lavaysse et al., 2012; Vrac et al., 2012) et la méthode quantile-mapping (Gudmundsson et al., 2012; Maraun, 2013).

- Les méthodes par “générateurs de temps” (ou “générateurs stochastiques”) permettent de simuler des variables climatiques (telles que les précipitations ou la température) à partir des fonctions de densité de probabilités (Semenov and Barrow, 1997; Semenov et al., 1998). Ces générateurs sont calibrés de manière à ce que les simulations reproduisent certaines propriétés statistiques des observations locales (Richardson, 1981; Robertson et al., 2004).
- Les méthodes par “types de temps” reposent sur la classification non-supervisée des situations (généralement journalières) de circulation atmosphérique à grande échelle en régimes de temps récurrents. Ces méthodes supposent ensuite que chaque type de temps donné est toujours associé aux mêmes conditions météorologiques locales (Huth, 2001; Vrac et al., 2007).




Figure 3.1 – Illustration de la méthode de downscaling (Khan and Pilz, 2018)

3.2 Problématique de l'étude

L'Afrique de l'Ouest est délimitée au nord par le désert du Sahara, à l'ouest et au sud par l'océan Atlantique et à l'est par un ensemble de chaînes montagneuses le long de la frontière orientale du Tchad [Fig.3.2]. Une grande partie de la région se trouve en zone côtière par consé-

quent subit des influences océanique et continentale : c'est le cas des villes étudiées dans ce travail (schématisées sur la [Fig.3.2]). Compte tenu de la faible couverture spatiale des données d'observation en Afrique de l'Ouest, les données de la cinquième version de réanalyse du Centre Européen de Prévisions Météorologiques à Moyen Terme (ERA5, (Hersbach, 2016)) sont très souvent utilisées en remplacement aux données de station car elles présentent une meilleure couverture spatiale (Barbier et al., 2018; Guigma et al., 2021a; Ngoungue Langue et al., 2021, 2023). De fait, la réanalyse sera utilisée comme référence pour cette étude. Par contre, ces données de réanalyse présentent une résolution spatiale assez grossière pour représenter les processus se déroulant à l'échelle locale. Ainsi, il se pose donc deux problèmes :

- le manque de données station météorologique dans la région ;
- la représentativité des données de réanalyse à l'échelle locale.

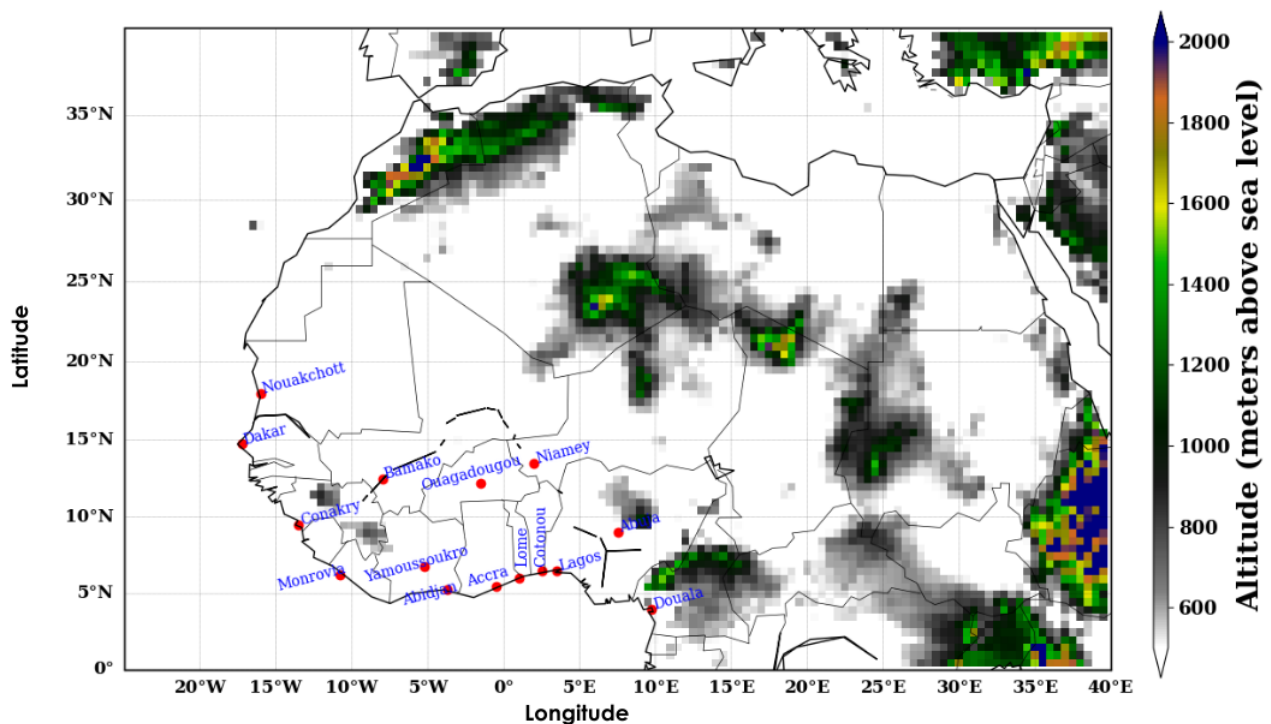


Figure 3.2 – Carte topographique de l'Afrique de l'Ouest. Les villes représentées en bleu sur la carte sont les villes d'intérêt pour l'étude des vagues de chaleur dans la suite de ce travail.

Pour s'affranchir de ces deux problèmes, il faudra établir une relation entre les variables à l'échelle locale et les données de réanalyse correspondantes à grande échelle en prenant en

compte l'influence océanique sur certaines parties de la région. L'influence du flux océanique dans la région va être évaluée à partir du masque terre-mer connu en anglais sous l'appellation Land Sea Mask (LSM). Le masque terre-mer est un champ invariable contenant la fraction de terre en un point donné. Ses valeurs sont comprises entre 0 (si le point de grille est entièrement recouvert d'eau) et 1 (si le point de grille est entièrement recouvert de terre) [Fig.3.3]. Un point de grille est considéré comme terrestre s'il est composé à plus de 50% de terre, sinon il est considéré comme maritime (océan ou eaux intérieures, par exemple rivières, lacs, etc.). Ce choix binaire de l'affectation des points terre-mer entraîne une légère sous-représentation des terres dans le modèle du Centre Européen [<https://confluence.ecmwf.int/display/FUG/Land-Sea+Mask>]. La distribution du masque terre-mer dépend fortement de la qualité de la carte de la couverture terrestre mondiale utilisée et de sa résolution horizontale (la résolution nominale actuelle est d'environ 300 m). Des difficultés apparaissent également lorsque de petites îles, des parties d'îles ou des côtes couvrent la moitié ou moins d'une maille. Les petits lacs peuvent ne pas être pris en compte par le masque terre-mer.

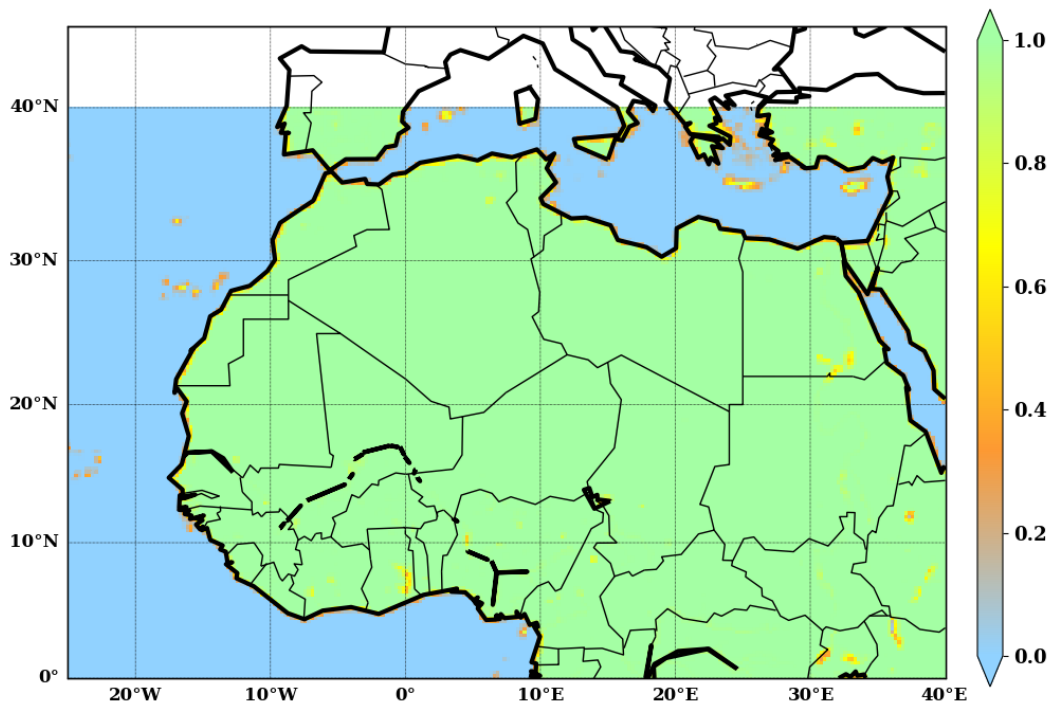


Figure 3.3 – Carte de contraste terre-mer en Afrique de l'Ouest obtenue à partir des données ERA5.

3.3 Représentation des villes dans le maillage de ERA5 (Dakar, Abidjan)

Les données ERA5 sont interpolées sur une grille régulière avec une résolution spatiale de $0.25^\circ \times 0.25^\circ$ et représentent des valeurs ponctuelles. Dans le cadre de ce travail, nous nous intéressons principalement aux grandes métropoles Ouest-Africaines ayant des démographies assez importantes [Fig.3.2]. Les villes Ouest-Africaines présentent pour la plupart une extension spatiale inférieure à $25 \text{ km} \times 25 \text{ km}$. La question qui se pose à ce niveau est celle de la représentation des villes à l'intérieur de la maille de ERA5. Plusieurs cas peuvent être envisageables, la ville se trouve à l'intérieur de la maille (cas le plus simple), la ville se trouve entre deux ou plusieurs mailles de ERA5 (cas le plus complexe). Une illustration de la représentation des villes est faite à la [Fig.3.4] pour les villes de Dakar et Abidjan. On peut remarquer que les bordures est et ouest de la ville de Dakar sont situées sur deux points de grille ERA5 différents. La ville d'Abidjan quant à elle, se positionne entre deux mailles voisines de ERA5, ce qui complexifie davantage la tâche pour l'estimation des grandeurs météorologiques à partir des données de réanalyse ERA5. Ces deux villes sont situées dans la zone côtière, et donc subissent une influence océanique et continentale.

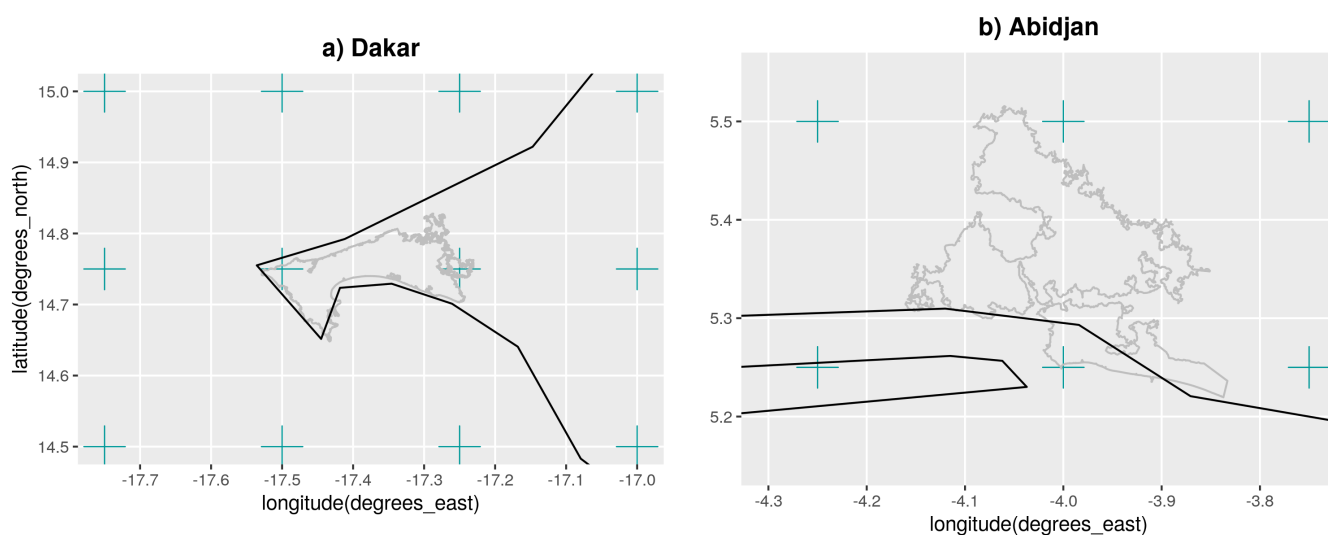


Figure 3.4 – Représentation des villes de Dakar et Abidjan dans le maillage de ERA5. Les croix vertes et les traits noirs foncés représentent respectivement les points de grille ERA5 et les traits de côte. les villes sont représentées en gris.

3.4 Étude de la variabilité spatiale de la température dans le maillage de ERA5

Parmi l'ensemble des variables atmosphériques disponibles dans les réanalyses ERA5, la température à 2 mètre du sol (T2m) apparaît comme une variable d'intérêt majeur pour la détection des vagues de chaleur. De ce fait, nous allons analyser la variabilité spatiale de la température dans le maillage de ERA5 en utilisant les données de station météorologiques implantées dans ces deux villes. Les données de deux stations ont pu être récupérées auprès de nos partenaires à savoir : la station de l'Anacim située à Dakar-Yoff au Sénégal, et la station de la Sodexam située à l'aéroport Félix Houphouët Boigny à Abidjan en Côte d'Ivoire. Il s'agit de données de température minimale (Tmin) et maximale (Tmax) sur la période 1973-2018 et 2005-2017 respectivement pour Dakar et Abidjan.

3.4.1 Variabilité spatiale de la température au voisinage d'un point grille de ERA5

Comme nous l'avons mentionné précédemment ces deux villes subissent de part leur localisation sur la côte une double influence océanique et continentale. Ceci étant, il est donc nécessaire d'investiguer dans un premier temps la distribution des données de température au voisinage des points de grille de ERA5 très proches des stations de mesure à Dakar et Abidjan. Pour ce faire, nous calculons la corrélation entre le point de grille ERA5 le plus proche de la station et les points de grille ERA5 situés dans son voisinage dans un domaine de 20 x 20 points de grille [Fig.3.5]. De façon générale, on observe dans les deux villes une très forte corrélation entre le point de grille de référence ERA5 (le plus proche de la station) et les points de grille ERA5 situés sur la partie océanique. Ce qui traduit une forte représentation du flux océanique dans l'estimation de la température dans les données ERA5 en zone côtière. La perte de corrélation sur la partie continentale est très marquée pour Tmax et Tmin respectivement à Dakar et Abidjan [Fig.3.5].

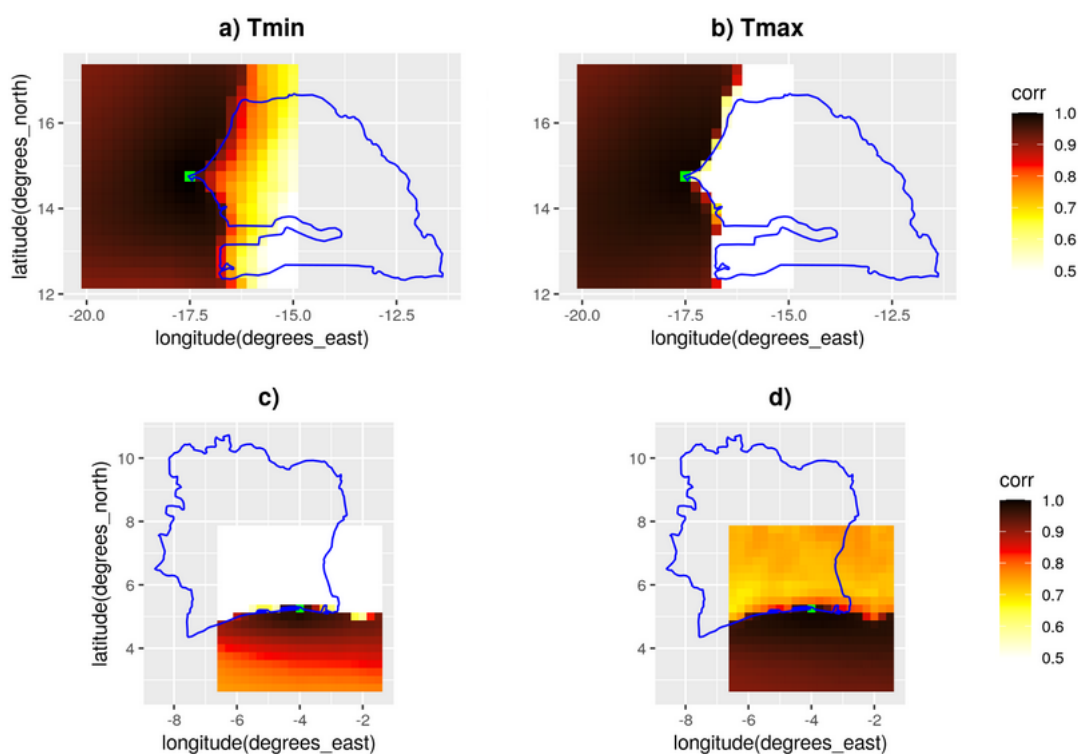


Figure 3.5 – Corrélation au voisinage du point ERA5 le plus proche de la station : (a-b) Dakar et (c-d) Abidjan. Le point vert représente le point ERA5 le plus proche de la station.

3.4.2 Variabilité spatiale de la température au voisinage des stations météorologiques

Dans cette partie, nous évaluons cette fois la corrélation entre les données de station et les points de grille ERA5 dans le même domaine que celui défini précédemment. On observe cette fois-ci au voisinage de Dakar, un gradient ouest-est de corrélation avec de fortes valeurs de corrélation sur la partie continentale [Fig.3.6]. Ce gradient de corrélation est très marqué avec Tmax et les valeurs de corrélation sont comprises entre 0.8 et 0.9. On constate donc que la station météo à Dakar est fortement influencée par les processus physiques se produisant sur la partie continentale contrairement à ce que l'on a observé précédemment en évaluant la corrélation autour du point de grille ERA5 [Fig.3.5]. Au voisinage de la station à Abidjan, on observe un gradient de corrélation sud-nord avec Tmin en accord les résultats observés sur Dakar. Par contre, on a un gradient inversé (sud-nord) avec Tmax traduisant une forte corrélation entre la station météo

et les points de grille situés sur la partie océanique. Cette différence entre Tmax à Dakar et à Abidjan pourrait résulter des forçages et des processus à l'échelle locale.

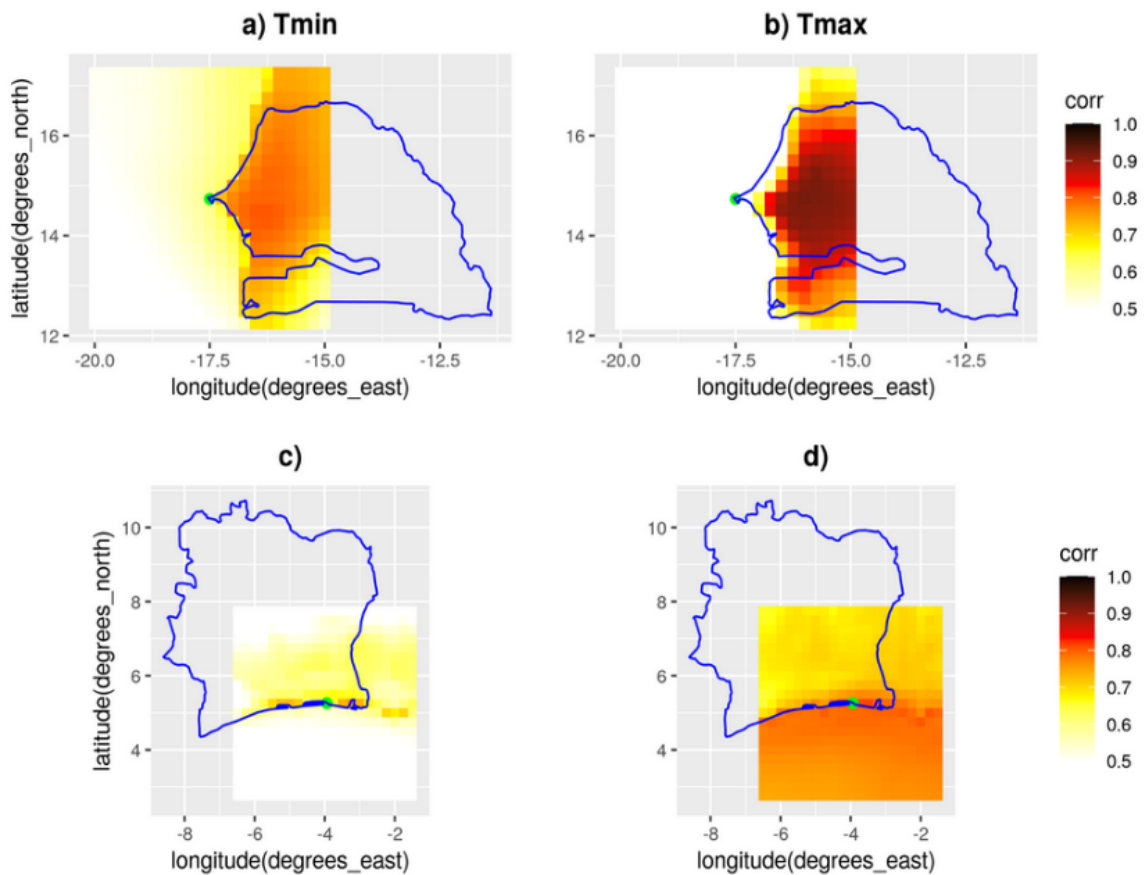


Figure 3.6 – Corrélation au voisinage des stations météorologiques : (a-b) Dakar et (c-d) Abidjan. Le point vert représente cette fois la station météorologique.

3.5 Estimation de la température à l'échelle locale à partir des données de réanalyse ERA5

Les données de station n'étant pas disponibles pour toutes les villes et sur l'ensemble de la plage temporelle de l'étude, nous utiliserons les données de réanalyse ERA5. Certes les données de réanalyse ERA5 présentent une résolution spatiale assez grossière, mais elles sont plus représentatives des vagues de chaleur se produisant dans une ville que les stations locales isolées. Toutefois, il faudra passer par une méthode d'interpolation pour estimer la température à l'échelle locale à partir des réanalyses. Nous sommes bien conscients que les données de réana-

lyse ne permettent pas la prise en compte des îlots de chaleur urbains. De fait, nous intéresserons aux événements se produisant dans l'environnement de la ville. L'évaluation de la variabilité spatiale de la corrélation entre les données de station et les réanalyses (ERA5) pour T2m, a révélé de fortes valeurs de corrélation sur le continent [Fig.3.6]. Ceci montre alors une bonne corrélation entre les stations en zone côtière et les points de grille ERA5 situés sur la partie continentale. Sachant qu'un point de grille est défini comme terrestre s'il possède un $LSM \geq 0.5$, il serait important de prendre ce facteur en compte lors de la définition des méthodes d'interpolation. Pour mener à bien cette étude, nous avons défini plusieurs méthodes d'interpolation linéaire et non linéaire.

3.5.1 Interpolation bilinéaire

Cette approche consiste à définir une maille formée de quatre points de grille autour de la station afin d'estimer la température locale [Fig.3.7]. Cette interpolation se fait par une fonction quadratique et prend en compte la contribution de chacun des points de la maille pour l'estimation de la nouvelle donnée (Kirkland and Kirkland, 2010). Cette première méthode ne prend pas en compte la contrainte sur le contraste terre-mer.

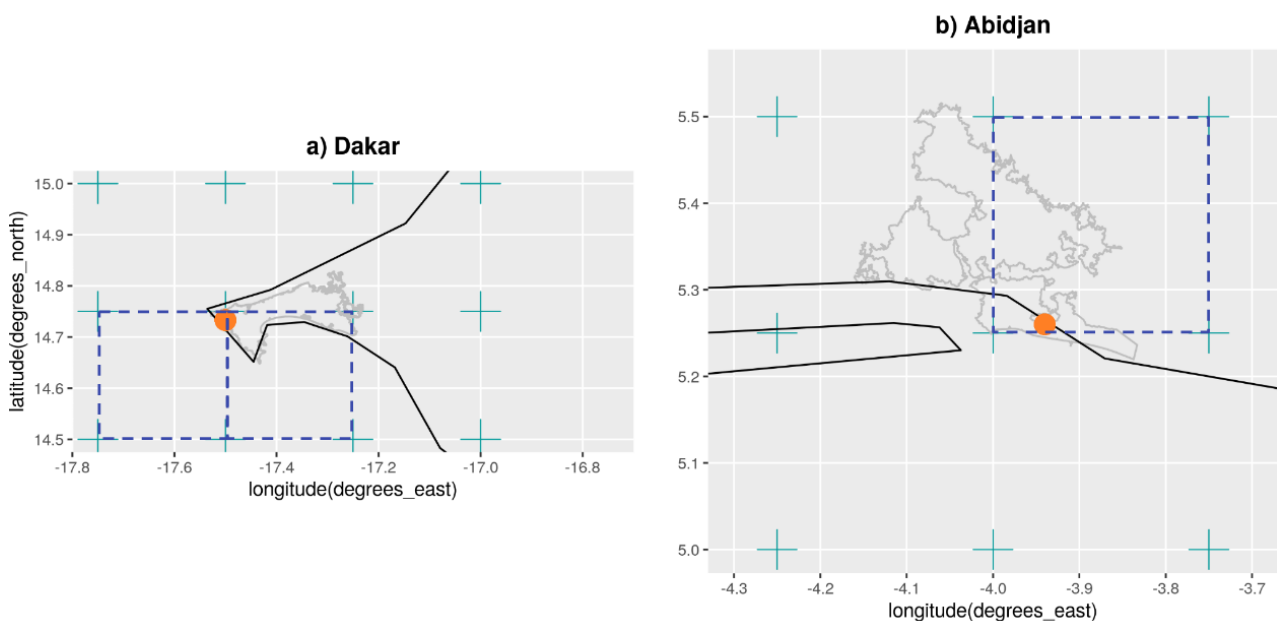


Figure 3.7 – Illustration de la méthode d'interpolation bilinéaire. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes.

3.5.2 Interpolation basée sur le proche voisin avec contrainte sur le LSM

Cette approche consiste à estimer la température locale à partir du point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.5$. Compte tenu de cette contrainte, la température locale au niveau de la station Anacim par exemple, sera estimée à partir de grille ERA5 représenté par la croix rouge et non par la croix verte la plus proche de la station (voir [Fig.3.8]).

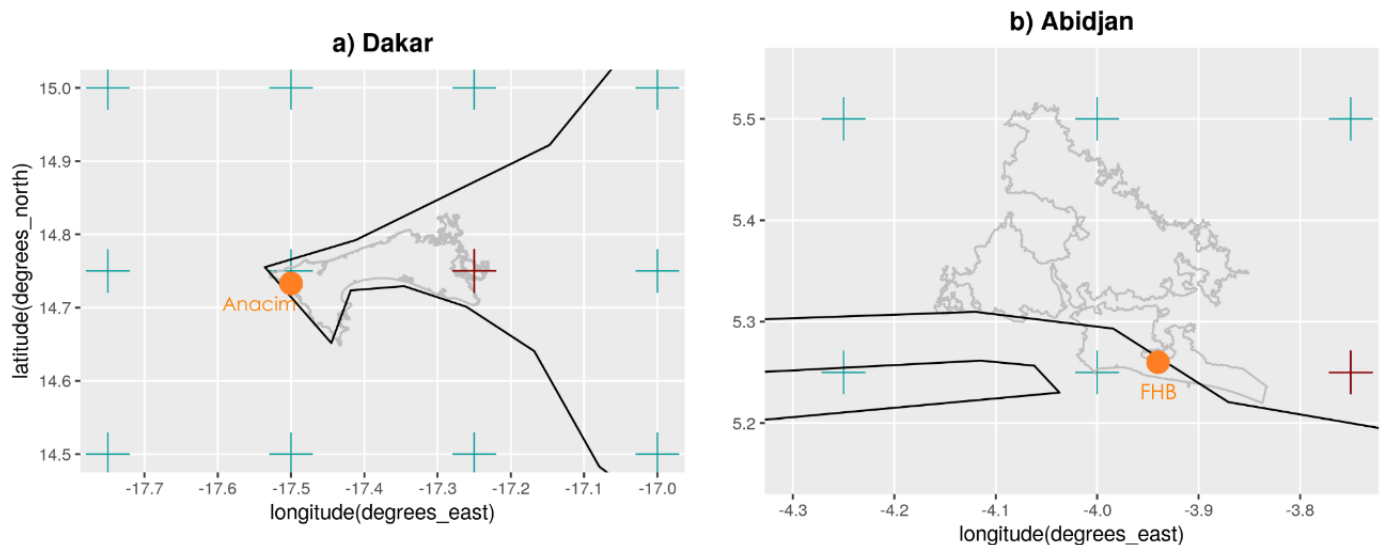


Figure 3.8 – Illustration de la méthode d'interpolation plus proche voisin avec contrainte sur le LSM. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes. La croix rouge représente le point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.5$.

3.5.3 Interpolation par méthode de gradient linéaire avec contrainte sur le LSM

Cette approche considère que le gradient de température entre deux points de grille est linéaire. Pour ce faire, nous définissons une fonction affine permettant de relier la station météo au point de grille ERA5 le plus proche avec un $LSM \geq 0.5$. Cette fonction affine n'est rien d'autre qu'une droite d'équation $y = ax + b$ que nous allons prolonger jusqu'à son intersection avec la prochaine verticale reliant par les points de grille ERA5 situés à la même longitude (il s'agit de droite en trait discontinu de couleur noire sur la figure [Fig.3.9]). On va donc s'intéresser principalement aux trois points S , M_1 et M_2 (voir [Fig.3.9]), et en évaluant la variation de température

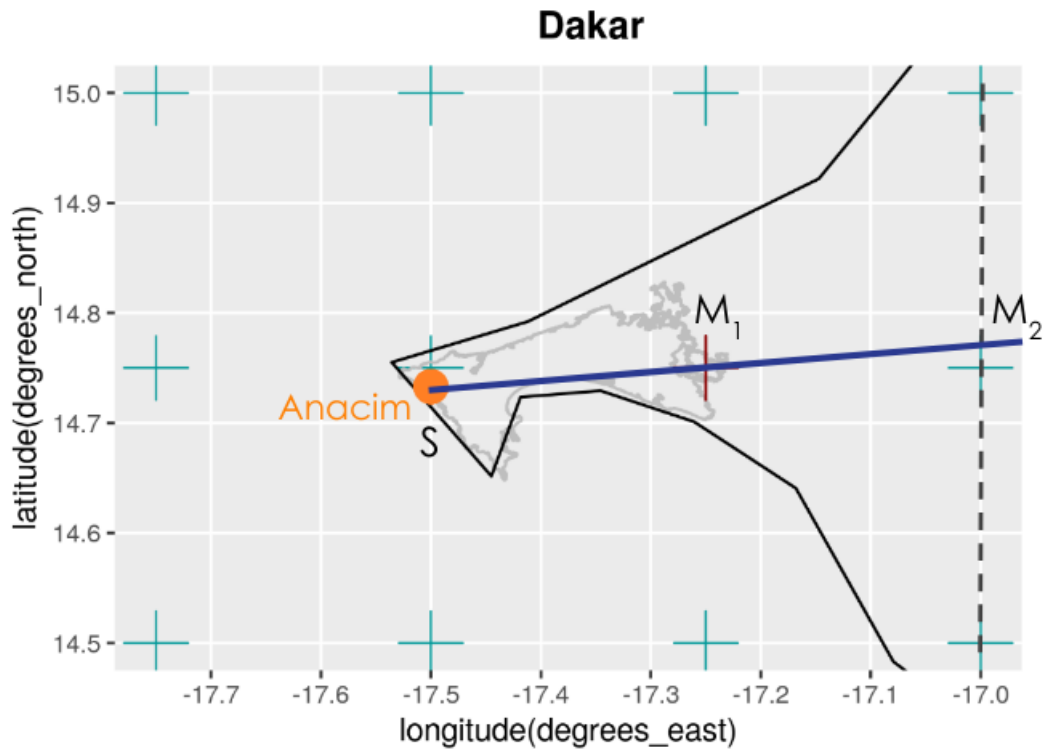


Figure 3.9 – Illustration de la méthode d'interpolation basé sur un gradient linéaire avec contrainte sur le LSM. les croix vertes représentent les points de grille ERA5 et les ronds plein en orange, les stations météo dans les villes. La croix rouge représente le point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.5$.

entre (T_s, T_1) et (T_s, T_2) , on a :

$$\Delta T = T_1 - T_2 \quad (3.1)$$

$$\Delta T' = T_s - T_1 \quad (3.2)$$

De proche en proche, par un règle de trois, la température au niveau de la station est donnée par la relation suivante :

$$T_s = T_1 + \frac{\Delta T}{d} x d' \quad (3.3)$$

avec $d = d(M_1, M_2) = M_1 M_2$ et $d' = d(S, M_1) = S M_1$

3.5.4 Interpolation basée sur la direction du vent

La différence entre cette approche et les précédentes, est la prise en compte de la dynamique atmosphérique dans l'estimation de la température à l'échelle locale. Pour ce faire, nous nous intéressons à l'évolution de la vitesse du vent surtout sa direction au cours du temps. Dans le maillage des données ERA5, nous définissons trois points de grille nommés respectivement "ERA5-ref", "ERA5-Cont" et "ERA5-Ocean" tel que décrits ci-dessous (voir [Fig.3.10]) :

- "ERA5-ref" désigne le point de grille ERA5 le plus proche de la station météo sans contrainte sur le LSM;
- "ERA5-Cont" représente le point de grille ERA5 le plus proche de la station météo avec un LSM compris entre]0.9,1];
- "ERA5-Ocean", il s'agit du point de grille ERA5 le plus proche de la station météo avec un $LSM \leq 0.1$.

Étant donné que dans ce travail, nous étudions les vagues de chaleur journalières et nocturnes associées respectivement à Tmin et Tmax, nous allons déterminer les valeurs de la vitesse du vent aux instants où Tmin et Tmax ont été détectées. Ce calcul de la vitesse du vent se fait à partir de l'évolution de la température au point ERA5-ref. Ainsi deux cas de figure peuvent se présenter :

- Si la valeur du vecteur vitesse est inférieure à 0, le vent pointe vers l'ouest ou le sud respectivement pour les stations à Dakar et Abidjan. Dans ce cas, le vent souffle du continent vers l'océan alors l'estimation de la température de la station se fera en utilisant le point de grille ERA5-Cont [Fig.3.10].
- Si la valeur du vecteur vitesse est supérieure à 0, le vent pointe vers l'est ou le nord respectivement pour les stations à Dakar et Abidjan. Dans ce cas, le vent souffle de l'océan vers le continent alors l'estimation de la température de la station se fera en utilisant le point de grille ERA5-Ocean [Fig.3.10].

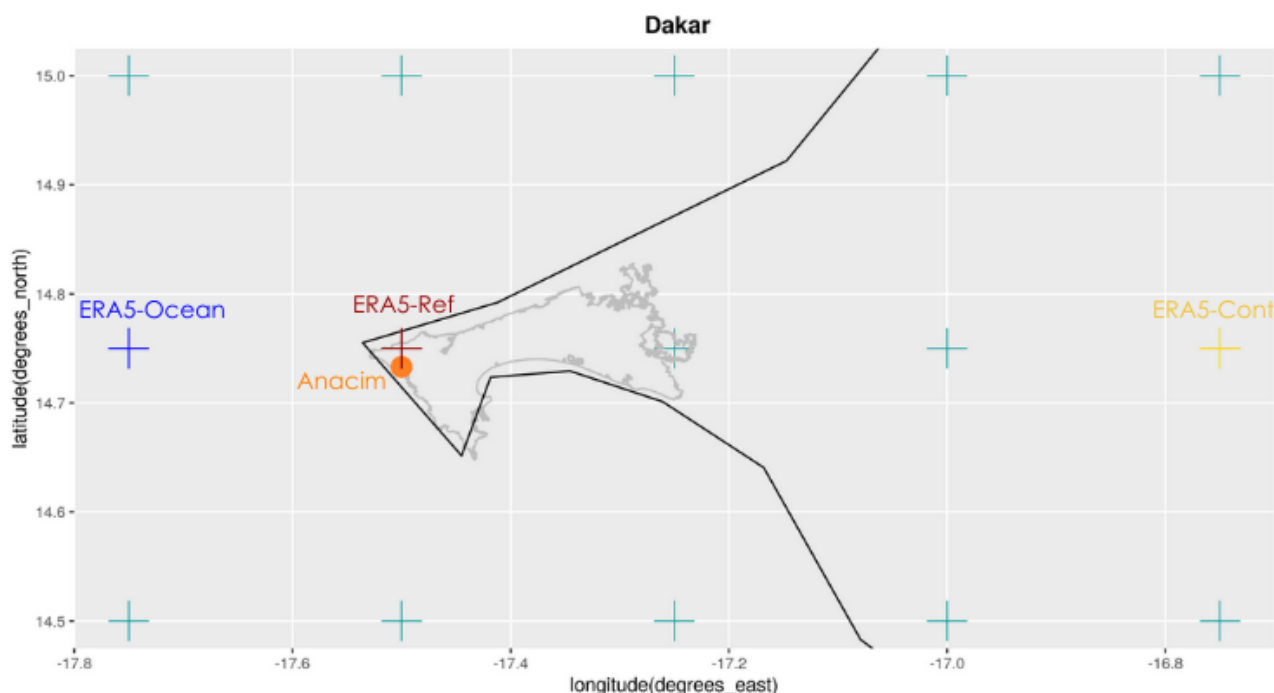


Figure 3.10 – Illustration de la méthode d'interpolation basée sur la direction du vent.

3.6 Évaluation des différentes méthodes d'interpolation

Les différentes méthodes d'interpolation énoncées ci-dessus ont été toutes évaluées par rapport aux données de station afin de trouver la meilleure technique d'interpolation. L'évaluation de ces différentes méthodes s'effectue par le calcul des anomalies de corrélation (ACC) entre les données estimées suivant chacune des méthodes et les données station [Fig.3.11]. L'ACC représente tout simplement la corrélation entre les anomalies. Comparée à la corrélation simple, l'ACC est plus stricte car le cycle saisonnier qui a tendance à booster la corrélation a été retiré en calculant les anomalies. D'après l'analyse des corrélations obtenues sur la station de Dakar, les méthodes d'interpolation définies à partir du gradient linéaire [Fig.3.11 c)] et le plus proche voisin de la station avec $LSM \geq 0.5$ [Fig.3.11 b)] présentent de meilleures performances par rapport aux deux autres. On note aussi une meilleure corrélation avec Tmax par rapport à Tmin ; ceci pourrait être justifié par le fort gradient de corrélation observé entre le point de station à Dakar et les points de grille ERA5 situés sur la partie continentale. Sur la station d'Abidjan, la méthode d'interpolation reposant sur le plus proche voisin se démarque légèrement des trois autres [Fig.3.11

(e-h)]. Nous avons également testé une approche de débiaisage du signal interpolé en utilisant la méthode de correction de biais CDF-t avant le calcul de l'ACC [Fig3.12]. Les valeurs de corrélation obtenues avec le signal interpolé débiaisé sont légèrement inférieures à celles obtenues avec le signal interpolé biaisé. De ce fait, il n'est donc pas nécessaire de débiaiser le signal interpolé à partir des données ERA5. En prenant en compte, les spécificités de chacune des méthodes, nous utiliserons pour la suite de notre étude comme méthode d'interpolation, la méthode du plus proche voisin de la station avec un $LSM \geq 0.5$. Nous avons également effectué une analyse de la sensibilité de cette méthode par au seuil de LSM choisi. À cette fin, nous avons défini deux seuils : un seuil à 0.75 et un autre seuil à 1. En fait, il s'agit pour chacune des 2 approches, d'interpoler la donnée à l'échelle locale à partir du point de grille ERA5 le plus proche de la station avec un $LSM \geq 0.75$ et un $LSM=1$. Les valeurs de corrélation obtenues pour ces deux méthodes sont très proches [Fig.3.13]. La méthode de plus voisin avec un $LSM \geq 0.5$ englobe les deux méthodes citées ci-dessus. En comparant les résultats des trois méthodes de plus proches voisin ($LSM \geq 0.5$, $LSM \geq 0.75$ et $LSM=1$), on retrouve des corrélations assez comparables. L'on peut en déduire de cette analyse, une faible sensibilité de la méthode de plus proche voisin au seuil de LSM choisi lorsque le point se trouve sur le continent.

Figure 3.11 – Évaluation de différentes méthodes d'interpolation par rapport aux données station sur les villes de Dakar (a-d) et Abidjan (e-h). La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées et les données observées.

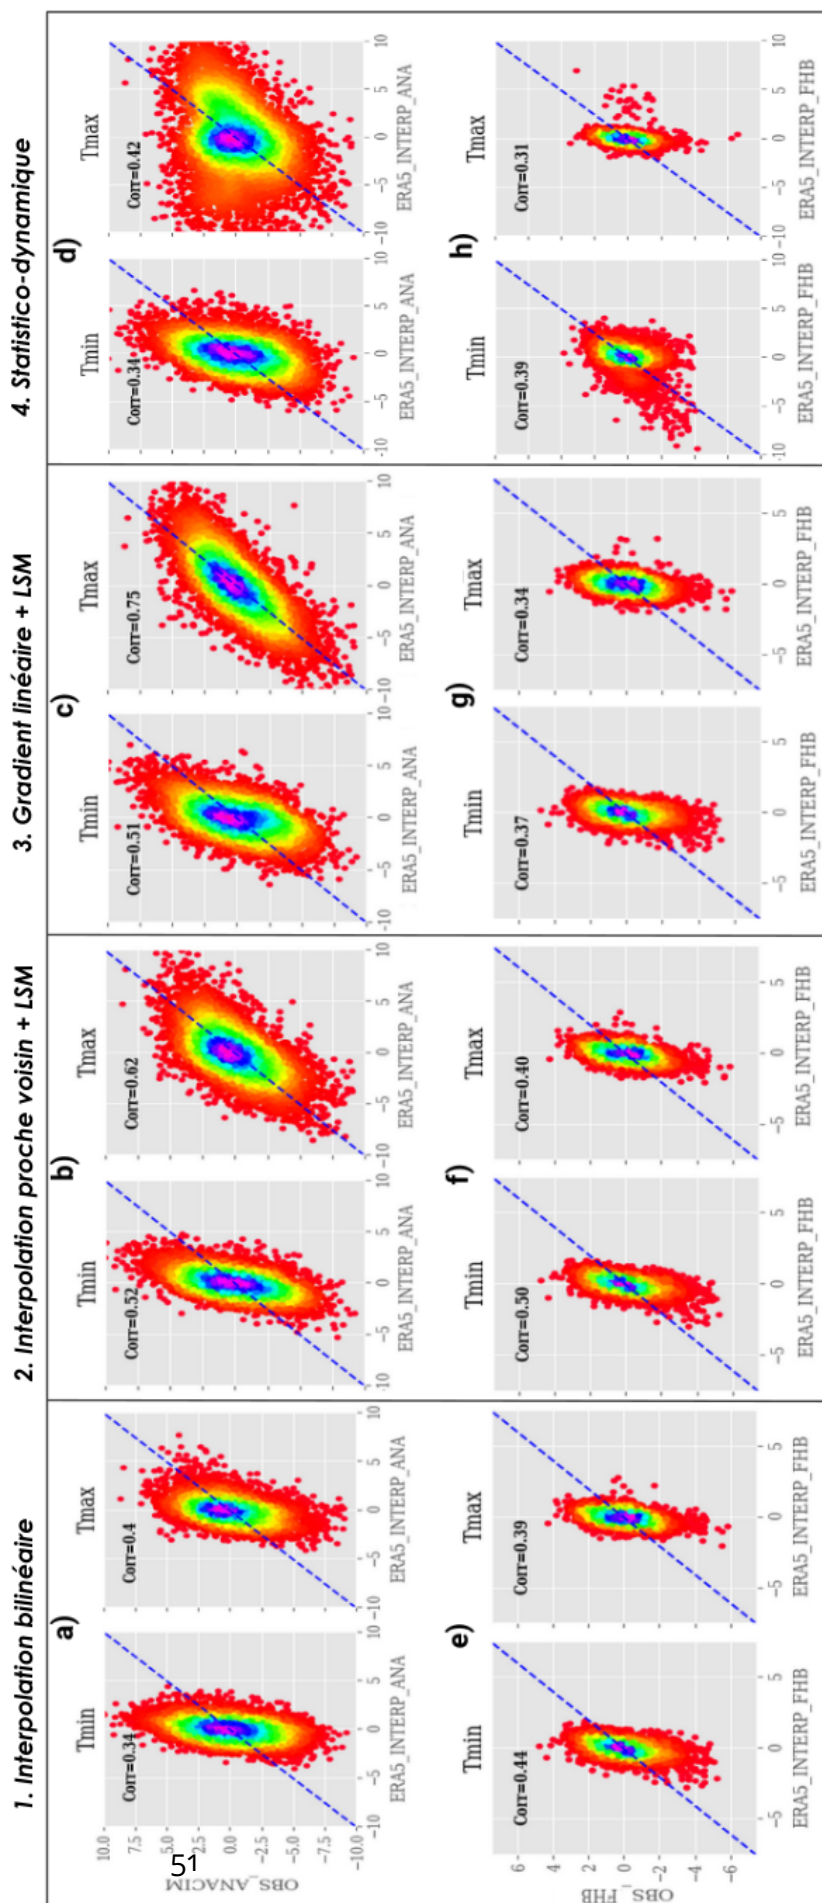
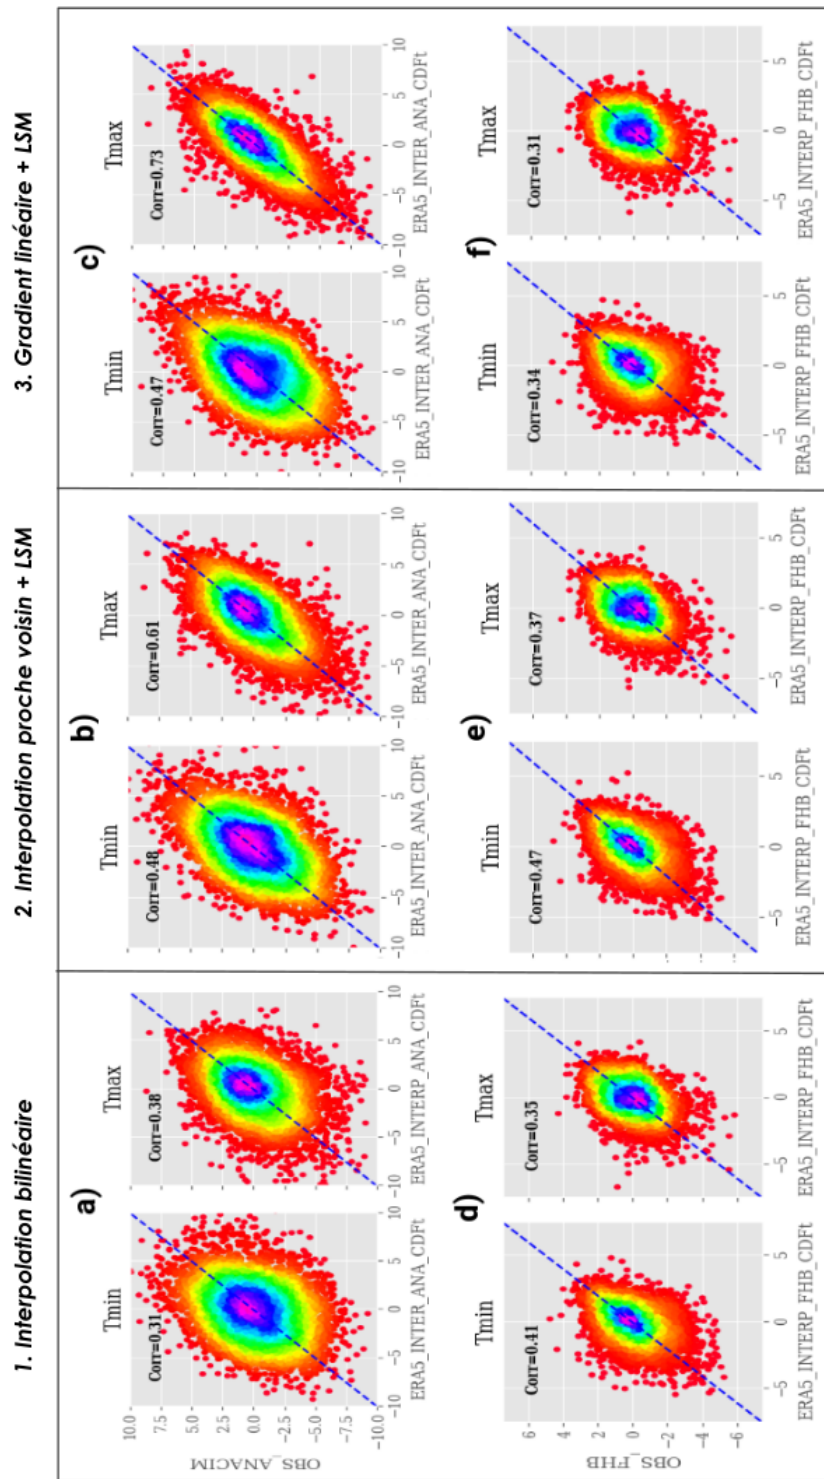


Figure 3.12 – Évaluation de différentes méthodes d'interpolation par rapport aux données station en utilisant une méthode de débiaisage du signal interpolé sur les villes de Dakar (a-c) et Abidjan (d-f). La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées débiaisées et les données observées.



1. proche voisin avec $lsm \geq 0.75$

2. proche voisin avec $lsm = 1$

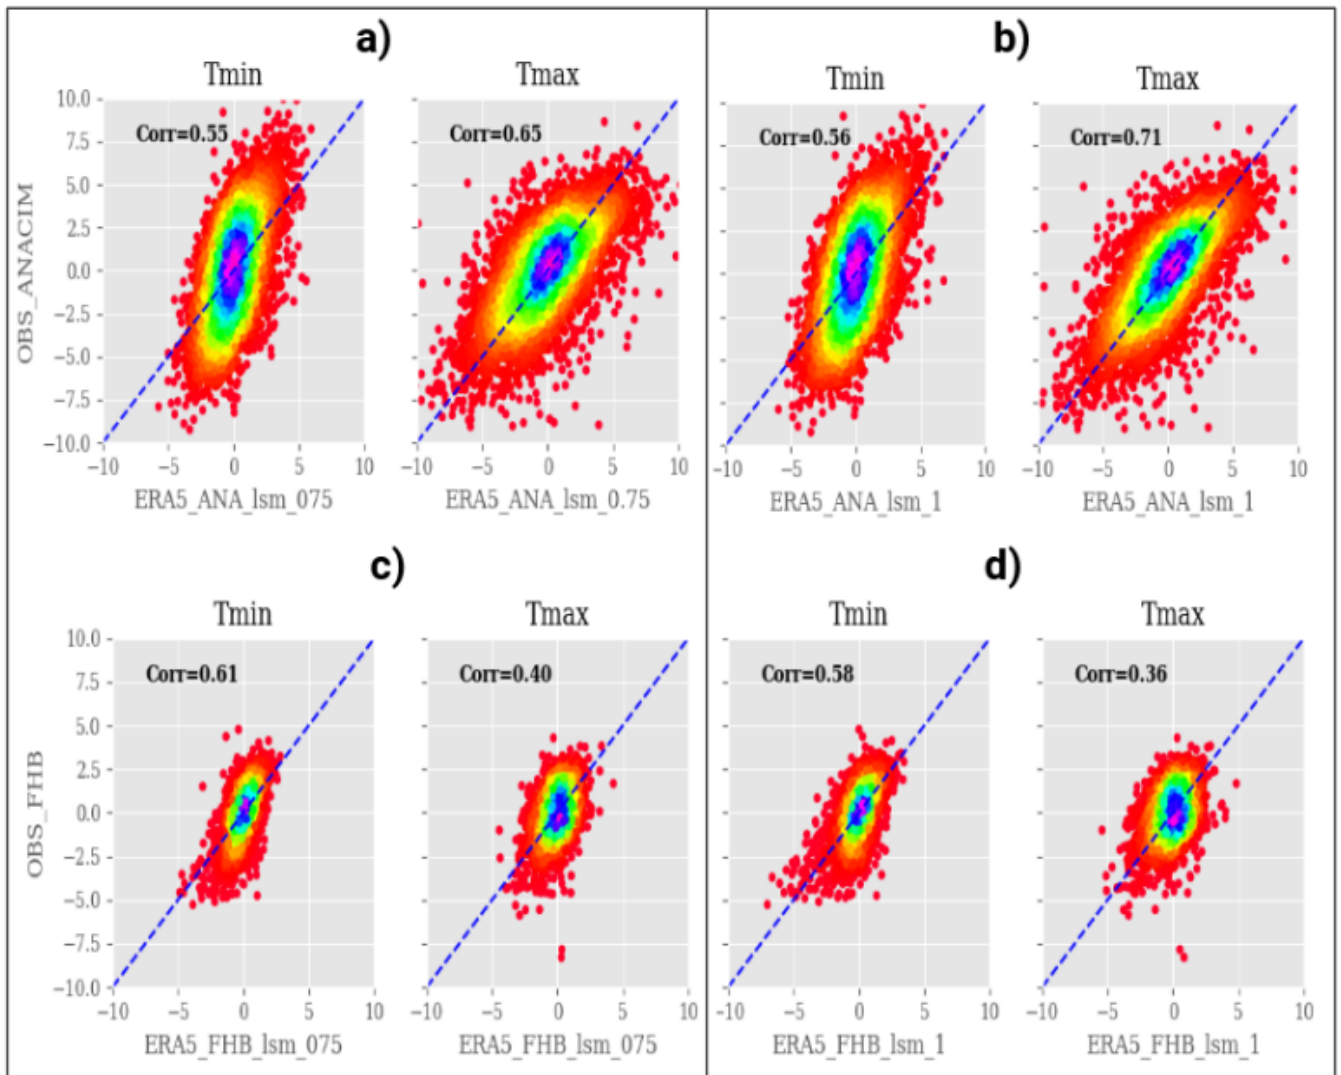


Figure 3.13 – Évaluation de la sensibilité de la méthode de plus proche par rapport au sein de LSM choisi : 1) $LSM \geq 0.75$ et 2) $LSM = 1$. La droite bleue en trait discontinu représente la première bissectrice ($y=x$). Les axes des abscisses et des ordonnées indiquent respectivement les données interpolées et les données observées.

3.7 Conclusion et perspectives

Dans cette partie, il était question de déterminer une approche permettant d'estimer la température à l'échelle de la station à partir des données de réanalyse de résolution plus large. Plusieurs méthodes d'interpolation ont été testées parmi lesquelles : une interpolation bilinéaire, une interpolation basée sur le plus proche voisin de la station avec un $LSM \geq 0.5$, une interpolation basée sur le gradient linéaire et une interpolation non linéaire prenant en compte la dynamique atmosphérique. Certaines des méthodes citées plus haut ont été établies à partir d'un résultat fondamental de cette étude : la forte corrélation entre les données de la station météo et les points de grille ERA5 situés dans la partie continentale. L'évaluation de chacune de ces méthodes d'interpolation par rapport aux données station à Dakar et Abidjan a été effectuée en calculant le coefficient de corrélation entre les anomalies des deux jeux de données (ACC). La méthode d'interpolation basée sur le plus proche voisin de la station avec un $LSM \geq 0.5$ se démarque des autres avec de meilleures corrélations à la fois sur Dakar et Abidjan pour Tmin et Tmax. On note également des corrélations plus élevées avec Tmax par rapport à Tmin.

Bien que la méthode de plus proche voisin avec $LSM \geq 0.5$ soit retenue dans le cadre de nos travaux, elle pourrait être toutefois améliorée afin d'obtenir des données interpolées se rapprochant davantage des données stations. L'on pourrait penser par exemple à intégrer plus de dynamique atmosphérique dans cette approche. Ceci reste une question ouverte qui fera l'objet de futures études.

Chapitre 4

Incertitudes sur le monitoring des vagues de chaleur dans les villes Ouest Africaines

4.1 Introduction

Les vagues de chaleur font partie des aléas climatiques les plus dangereux affectant la planète. Elles touchent à la fois la population, son environnement et ses activités; engendrant ainsi une augmentation de la morbidité, des maladies respiratoires et cardio-vasculaires chez les plus vulnérables (ex, [Huynen et al., 2001](#); [Braga et al., 2002](#); [Kovats and Hajat, 2008](#); [Hajat et al., 2007](#); [Anderson and Bell, 2009](#); [Gasparrini and Armstrong, 2011](#); [Rocklöv et al., 2014](#)). Durant les dernières décennies, une intensification des températures extrêmes a été observée sur plusieurs régions entraînant ainsi des dégâts tant sur le plan humanitaire que matériel. Cette tendance au réchauffement favorise l'occurrence des périodes chaudes conduisant ainsi à une recrudescence des événements caniculaires. L'Afrique de l'Ouest de par sa localisation géographique entre les tropiques, reste un environnement propice aux vagues de chaleur. Compte tenu de la vulnérabilité et de la capacité d'adaptation des pays Africains, ces événements sont très mal vécus dans cette partie de la planète.

Une vague de chaleur est un phénomène météorologique très souvent associé à une période de hausse des températures diurne et/ou nocturne. La définition d'une vague de chaleur repose

sur trois éléments clés : le seuil, la durée et l'indicateur utilisé. De fait des valeurs différentes du seuil, de la durée et de l'indicateur contribuent à une divergence dans la définition des vagues de chaleur (Smith et al., 2013) et par conséquent dans les résultats des études. Les vagues de chaleur peuvent être définies à partir de variables météorologiques quotidiennes telles que la température à 2-mètre du sol (T_{min} , T_{moy} et T_{max}) (ex, Fontaine et al., 2013b; Beniston et al., 2017; Ceccherini et al., 2017; Déqué et al., 2017; Batté et al., 2018; Lavaysse et al., 2018b; Engdaw et al., 2022; Ngoungue Langue et al., 2023), les anomalies journalières de température (ex, Stefanon et al., 2012; Barbier et al., 2018), la température du thermomètre mouillé (Tw_{mean} (Yu et al., 2021b), Tw_{min} et Tw_{max} (Ngoungue Langue et al., 2023)) ou encore les indices de stress thermique (ex, Robinson, 2001; Fischer and Schär, 2010; Perkins et al., 2012; Guigma et al., 2020b) en utilisant des seuils relatifs ou absolus. L'utilisation de seuils absolus est bien adaptée à la détection des vagues de chaleur au cours de l'année dans les régions où le cycle saisonnier est bien marqué. C'est le cas des latitudes moyennes par exemple où l'amplitude thermique saisonnière de $T2m$ est importante, de l'ordre de 20°C. Dans les régions tropicales, cette méthode n'est pas adaptée car l'amplitude thermique saisonnière est fortement réduite (environ 6°C). Par conséquent, un seuil relatif pour la détection des vagues de chaleur est adopté dans notre étude puisque notre région d'intérêt est l'Afrique de l'Ouest. Généralement, une vague de chaleur se définit comme une période minimale de trois jours consécutifs durant laquelle les températures journalières sont au-dessus d'un seuil climatologique journalier (quantile 90) calculé sur la période 1993-2020 (Perkins et al., 2012; Perkins and Alexander, 2013; Russo et al., 2014a; Déqué et al., 2017; Batté et al., 2018).

L'Afrique de l'Ouest connaît un climat très chaud et sec dans la région du Sahel, ainsi qu'un climat chaud et humide le long de la côte Guinéenne. Les conditions climatiques en Afrique de l'Ouest rendent la région propice à l'occurrence de vagues de chaleur, qui auront des impacts néfastes tant sur le plan sanitaire (populations et écosystèmes naturels) que sur les plans économique et agricole. L'économie en Afrique de l'Ouest repose en grande partie sur l'agriculture qui à son tour reste fortement dépendante des conditions climatiques (précipitations et sécheresses). De nombreuses études sur les vagues de chaleur ont été menées en Europe, en Amérique et

en Asie afin de comprendre les processus à l'origine de ces dernières dans le but de développer des outils opérationnels pour leur monitoring et des systèmes d'alerte (Météo-France, Environnement Canada, l'Agence Chinoise de météorologie pour ne citer que ceux-là). Cependant, en Afrique, les vagues de chaleur restent encore très peu documentées et méconnues du grand public. Les études réalisées sur le continent sont faites pour la plupart à l'échelle régionale en définissant des domaines d'étude. Toutefois, étant donné l'impact des vagues de chaleur sur la population, et sachant que les centres urbains regorgent une grande partie de cette dernière, il est important de s'intéresser également à l'évolution de ces événements à ces échelles spatiales. C'est dans cette perspective, que nous apportons notre contribution à travers ce travail. Pour mener à bien cette étude, nous avons identifié quinze villes de forte densité de population que nous avons regroupées en trois régions climatiques (Voir Fig.1 dans l'article sur le monitoring des vagues de chaleur) sur la base des études antérieures ([Moron et al., 2016](#)) et de l'évolution des vagues de chaleur dans chacune de ces régions. Les régions sont organisées comme suit :

- la région continentale "CONT", regroupe les villes de Bamako, Ouagadougou, Niamey;
- la région côtière Atlantique "ATL", regroupe les villes de Nouakchott, Dakar, Monrovia, Conkary;
- la région côtière Guinéenne "GU", regroupe les villes de Yamoussoukro, Abidjan, Lomé, Abuja, Lagos, Accra, Cotonou et Douala.

Comme mentionné ci-dessus, il n'existe pas de formulation universelle pour une vague de chaleur. Cette grande variété dans la définition de cette dernière est source d'incertitudes dans les résultats de différentes études. Ainsi dans le cadre de ce travail, notre premier objectif est de mettre en évidence les potentielles sources d'incertitude dans la détection des vagues de chaleur. Quatre types d'incertitude ont été évaluées :

- la première est liée aux jeux de données utilisés (les réanalyses ERA5 du Centre Européen et MERRA la seconde version de réanalyse de la NASA);
- le choix du seuil utilisé pour la détection de l'événement;
- la méthodologie utilisée pour définir la vague de chaleur;

— l'indicateur utilisé pour la détection de l'événement.

Les données de réanalyse présentent des différences qui vont engendrer des écarts dans la fréquence et les caractéristiques des événements détectés. Le choix du seuil également aura une grande influence sur les caractéristiques des vagues de chaleur (durée et intensité). Pour évaluer la sensibilité des caractéristiques des vagues de chaleur par rapport au seuil, nous avons défini 4 seuils en fonction des études antérieures : les quantiles 75, 80, 85 et 90. La méthodologie ici repose sur le choix des indicateurs pour la définition des vagues de chaleur. Trois types de vague de chaleur ont été étudiées : les vagues de chaleur journalières, nocturnes et celles qui se produisent le jour et la nuit concomitamment [Fig.4.1].

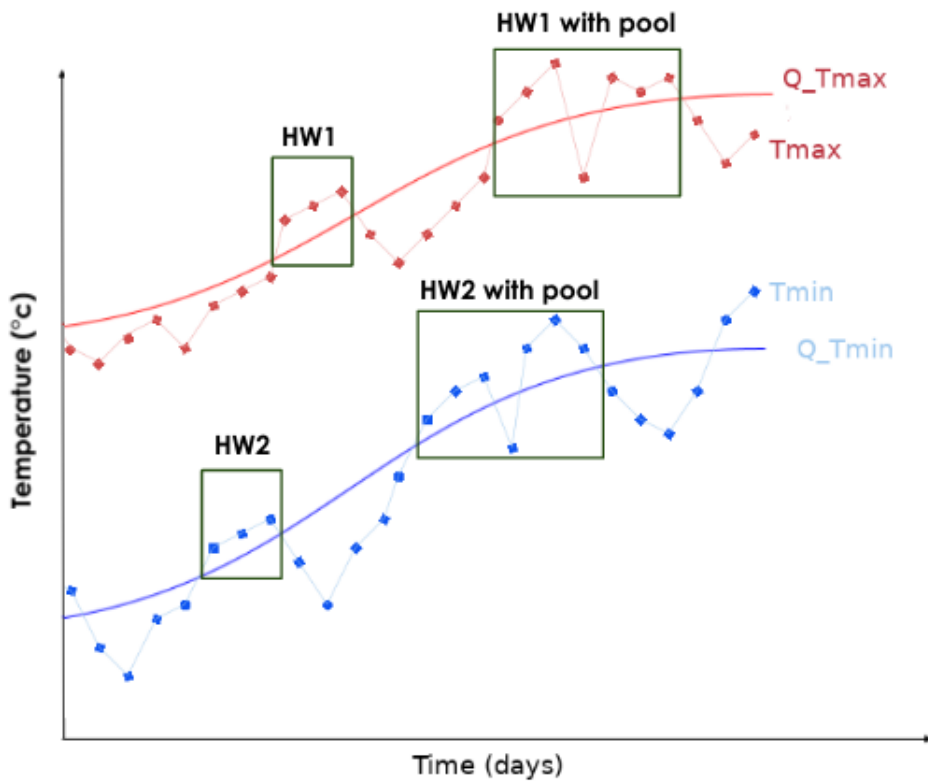


Figure 4.1 – Méthode de détection des vagues de chaleur.

Les vagues de chaleur analysées ont été détectées à partir de quatre indicateurs basés sur la température à 2-m du sol, l'humidité relative à 2-m, le vent à 10-m et une combinaison de ces trois variables pour en déduire des indicateurs plus élaborés tels que la température apparente (AT), la température du thermomètre mouillé (Tw) et le Universal Thermal Comfort Index ($UTCI$) (Di Napoli et al., 2021).

Le second objectif consiste à évaluer l'évolution récente des vagues de chaleur. À cette fin, nous analysons l'évolution temporelle (interannuelle et saisonnière) de la fréquence, la durée et l'intensité des vagues de chaleur au cours des trois dernières décennies. La méthode utilisée dans ce travail pour le calcul de l'intensité des vagues de chaleur est adaptée à partir de celle développée par [Lavaysse et al. \(2018b\)](#) pour le monitoring des extrêmes de température en Europe. La durée d'une vague de chaleur est ainsi définie comme le nombre total de jours chauds enregistrés durant cette dernière. Les jours chauds sont des jours de vague de chaleur dont les valeurs quotidiennes des indicateurs sont supérieures aux seuils quotidiens. La formule ayant servi au calcul de la durée des vagues de chaleur est la suivante :

$$\mathbf{duration} = \sum_{i=1}^N \sum_j^d \delta_j \quad (4.1)$$

avec $\delta_j = 1$ si $T_j >$ quantile 90 journalier et $\delta_j = 0$ si $T_j <$ quantile 90 journalier , N représente le nombre total de vagues de chaleur par point de grille et d le nombre de jours chauds.

L'intensité de la vague de chaleur est définie comme la somme des excédents journaliers des valeurs quotidiennes des indicateurs par rapport à une valeur climatologique fixe dans une séquence de jours chauds. Cette étude s'inscrit dans le cadre du projet ANR STEWARD qui s'intéresse aux impacts humains des extrêmes climatiques. De ce fait, le calcul de l'intensité a été effectué en utilisant le valeur minimale de la climatologie journalière sur toute la période. Cette approche est mieux adaptée pour évaluer la sévérité d'une vague de chaleur et son impact humain.

4.2 Résumé de l'article sur le monitoring des vagues de chaleur en Afrique de l'Ouest : Incertitudes, caractérisation et évolution récente

L'objectif de ce travail est tout d'abord d'évaluer les incertitudes potentielles rencontrées dans la détection des vagues de chaleur et ensuite d'analyser leur tendance récente dans les villes d'Afrique de l'Ouest au cours de la période 1993-2020. Pour ce faire, nous utilisons deux produits de réanalyse à l'état de l'art, à savoir ERA5 et MERRA, ainsi que deux ensembles de données de stations locales, à savoir Yoff Dakar au Sénégal et Aéroport Félix Houphouët Boigny Abidjan en Côte d'Ivoire. Une estimation des données de station provenant des réanalyses est traitée en utilisant une technique d'interpolation : le plus proche voisin de la station avec un masque terre-mer ≥ 0.5 ; les températures interpolées des stations locales de Dakar et d'Abidjan, montrent une corrélation légèrement meilleure avec ERA5 qu'avec MERRA. Trois types d'incertitudes sont discutés : le premier type d'incertitude est lié aux réanalyses elles-mêmes, le deuxième est lié à la sensibilité de la fréquence et de la durée des vagues de chaleur aux valeurs seuils utilisées pour les surveiller, et le dernier est lié au choix des indicateurs et à la méthodologie utilisée pour définir les vagues de chaleur. Trois types de vagues de chaleur ont été analysés, à savoir celles qui se produisent le jour, la nuit et simultanément le jour et la nuit. Quatre indicateurs ont été utilisés pour analyser les vagues de chaleur, basés sur la température à 2-m, l'humidité, le vent à 10-m ou une combinaison de ces indicateurs. Nous avons constaté que l'humidité joue un rôle important dans les événements nocturnes; les événements concomitants détectés avec la température du thermomètre mouillé sont plus fréquents et situés dans le nord du Sahel. Des vagues de chaleur fortes et plus persistantes sont observées dans la région CONT. Pour tous les indicateurs, nous avons identifié 6 années avec une fréquence significativement plus élevée d'événements (1998, 2005, 2010, 2016, 2019 et 2020) probablement en raison de températures de surface de la mer plus élevées dans l'océan Atlantique équatorial correspondant à des événements El Nino pour certaines années. Une augmentation significative de la fréquence, de la durée et de l'intensité

des vagues de chaleur dans les villes a été observée au cours de la dernière décennie (2012-2020); on pense qu'il s'agit d'une conséquence du changement climatique agissant sur les événements extrêmes.

**4.3 Article sur le monitoring des vagues de chaleur en
Afrique de l'Ouest : Incertitudes, caractérisation et
évolution récente**



Heat wave monitoring over West African cities: uncertainties, characterization and recent trends

Cedric Gacial Ngoungue Langue^{1,2}, Christophe Lavaysse^{2,3}, Mathieu Vrac⁴, and Cyrille Flamant¹

¹Laboratoire Atmosphères, Milieux, Observations Spatiales (LATMOS) – UMR 8190 CNRS/Sorbonne Université/UVSQ, 78280 Guyancourt, France

²CNRS, IRD, G-INP, IGE, Université Grenoble Alpes, 38000 Grenoble, France

³Joint Research Centre (JRC), European Commission, 21027 Ispra, VA, Italy

⁴Laboratoire des Sciences du Climat et de l'Environnement, CEA Saclay l'Orme des Merisiers, UMR 8212 CEA/CNRS/UVSQ, Université Paris-Saclay and IPSL, 91191 Gif-sur-Yvette, France

Correspondence: Cedric Gacial Ngoungue Langue (cedric-gacial.ngoungue-langue@latmos.ipsl.fr)

Received: 1 July 2022 – Discussion started: 25 July 2022

Revised: 11 January 2023 – Accepted: 10 March 2023 – Published: 5 April 2023

Abstract. Heat waves can be one of the most dangerous climatic hazards affecting the planet, having dramatic impacts on the health of humans and natural ecosystems as well as on anthropogenic activities, infrastructures and economy. Based on climatic conditions in West Africa, the urban centres of the region appear to be vulnerable to heat waves. The goals of this work are firstly to assess the potential uncertainties encountered in heat wave detection and secondly to analyse their recent trend in West Africa cities during the period 1993–2020. This is done using two state-of-the-art reanalysis products, namely the fifth-generation European Centre for Medium-Range Weather Forecasts (ECMWF) reanalysis (ERA5) and Modern-Era Retrospective analysis for Research and Applications (MERRA), as well as two local station datasets, namely Dakar–Yoff in Senegal and Aéroport Félix Houphouët-Boigny, Abidjan, in Côte d'Ivoire. An estimate of station data from reanalyses is processed using an interpolation technique: the nearest neighbour to the station with a land sea mask ≥ 0.5 . The interpolated temperatures from local stations in Dakar and Abidjan show slightly better correlation with ERA5 than with MERRA. Three types of uncertainty are discussed: the first type of uncertainty is related to the reanalyses themselves, the second is related to the sensitivity of heat wave frequency and duration to the threshold values used to monitor them, and the last one is linked to the choice of indicators and the methodology used to define heat waves. Three sorts of heat wave have been analysed, namely those occurring during daytime, nighttime, and both

daytime and nighttime concomitantly. Four indicators have been used to analyse heat waves based on 2 m temperature, humidity, 10 m wind or a combination of these. We found that humidity plays an important role in nighttime events; concomitant events detected with wet-bulb temperature are more frequent and located over the northern Sahel. Strong and more persistent heat waves are found in the continental (CONT) region. For all indicators, we identified 6 years with a significantly higher frequency of events (1998, 2005, 2010, 2016, 2019 and 2020), possibly due to higher sea surface temperatures in the equatorial Atlantic Ocean corresponding to El Niño events for some years. A significant increase in the frequency, duration and intensity of heat waves in the cities has been observed during the last decade (2012–2020); this is thought to be a consequence of climate change acting on extreme events.

1 Introduction

Since the industrial revolution, the Earth has experienced global warming related to human activity (Hartmann et al., 2013; Intergovernmental Panel on Climate Change – IPCC – report 2021; Eyring et al., 2021). The last report of the IPCC shows that this warming will exceed 1.5 °C with respect to the IPCC baseline of 1850–1900 under different Shared Socioeconomic Pathways (SSPs) in 2100 if the rate of greenhouse gas emissions is not reduced. This warming

climate not only contributes to the occurrence of extreme events but also tends to reinforce their intensity (Fischer and Schär, 2010; Engdaw et al., 2022; IPCC report 2021). Heat waves appear as one of the most dangerous climatic hazards affecting the planet due to their impacts on several sectors (Perkins, 2015). The health sector is the most affected; heat waves act on the thermal comfort of the body, leading to an increase in morbidity and respiratory and cardiovascular diseases among the most vulnerable population (children and the elderly) (e.g. Huynen et al., 2001; Braga et al., 2002; Hajat et al., 2007; Kovats and Hajat, 2008; Anderson and Bell, 2009; Gasparrini and Armstrong, 2011; Rocklöv et al., 2014). Heat waves are “silent killers” because their impacts on human health are not usually instantaneous (Loughnan, 2014). In 2003, an intense heat wave occurred in France, killing more than 14 000 people (Fouillet et al., 2006). During this event, temperatures sometimes reached 37 °C, a record since 1950. This event was very persistent and lasted 2 weeks in France. In addition to this event, the Russian heat wave in 2010 caused numerous destruction (dysfunction of railway stations, interruption of energy production) and more than 11 000 deaths (Shaposhnikov et al., 2014). Temperatures sometimes reached 38 °C and generated huge fires in the neighbouring regions of Moscow and a high concentration of carbon monoxide in the troposphere. In April 2010, northern Africa was affected by a severe heat wave with daily maximum temperatures frequently exceeding 40 °C and daily minimum temperatures over 27 °C for more than 5 consecutive days (Largerón et al., 2020).

Heat waves are natural disasters often associated with an increase in daytime and/or nighttime temperatures. More generally, they are defined as a period of consecutive days during which temperatures are much hotter than normal. There is no universal formulation describing a heat wave; however a definition could be made according to the context of the study (health, environment, infrastructure, agriculture, energy supply). From a physiological point of view, the severity of a heat wave is measured through its duration and intensity.

West Africa experiences a very hot and dry climate over the Sahel region and a hot and humid climate over the Guinea coast. The climatic conditions over West Africa make the region vulnerable to heat waves when it comes to not only the health of humans and natural ecosystems but also agriculture. Many studies on heat waves have been carried out in Europe. However, heat waves in Africa are still not well documented. Moron et al. (2016) analysed the trends of extreme temperatures in northern tropical Africa from observations and reconstructed data. They show that heat wave indices over the region were highly correlated with the El Niño–Southern Oscillation indices (ENSO). Barbier et al. (2018) investigated the intraseasonal variability of large-scale heat waves during spring using the Berkeley Earth Surface Temperatures (BEST) gridded dataset and the following reanalyses: the European Centre for Medium-Range Weather Fore-

casts interim reanalysis (ERA-Interim), Modern-Era Retrospective analysis for Research and Applications (MERRA; see Sect. 2.2 for more details), and the National Centers for Environmental Prediction Reanalysis 2 (NCEP-2). They defined heat waves using anomalies of minimum/maximum values of the 2 m temperature. They found some discrepancies in the characteristics, variability and climatic trends of heat waves in the different products. Largerón et al. (2020) analysed the April 2010 heat wave in North Africa using both the BEST dataset and climate simulations from the atmospheric component of the Centre National de Recherches Météorologiques (CNRM) climate model. They showed a strong link between heat waves over the Sahara and the incoming heat surface fluxes. Another important result of this work is the radiative effect of water vapour on minimum temperatures during the heat wave period. This can lead to extreme heat conditions during the night and the death of elderly people. Guigma et al. (2020) analysed the characteristics and thermodynamics of Sahelian heat waves using different thermal indices based on temperature, wind speed and relative humidity derived from fifth-generation ECMWF reanalysis (ERA5; see Data section for more details). They found that most of the regions in the Sahel experience on average one or two heat waves per year with a duration of 3–5 d and severe magnitude. They have also shown that the eastern Sahel experiences more frequent and longer events. They identified heat advection and the greenhouse effect of moisture as the main drivers of Sahelian heat waves. Some of the previous studies conducted over the Sahelian band only use the daily maximum and minimum temperatures (e.g. Moron et al., 2016; Barbier et al., 2018) for the detection of heat waves, thereby ignoring the potential influence of humidity and wind speed. Others take into account the effect of humidity in the heat wave definition (e.g. Guigma et al., 2020), but information about the interannual and seasonal variability of events detected is missing, even though this is very important for policymakers and governments to take into account in order to develop early alert systems. Recently, Engdaw et al. (2022) studied the trends of heat waves over Africa during the period 1980–2018 using observations from the Climate Research Unit Time-Series version 4.03 (CRU TS4.03) and BEST datasets as well as the following reanalysis datasets: ERA5, MERRA-2 and the Japanese Meteorological Agency’s 55-year reanalysis (JRA-55). They highlighted large differences in both the trend and the temporal evolution of heat wave indices between the different reanalyses. They found a peak of heat over northern and western Africa in 2010 as well as in 2016 over eastern and southern Africa. They noticed significant warming and an increase in heat wave occurrence in all the regions in Africa. However, Engdaw et al. (2022) focused only on dry heat waves over a large domain of West Africa (10° S–15° N, 20° W–20° E); the duration of heat waves was not addressed and nor was the evolution of wet heat waves.

The most lethal heat waves are due not only to high temperatures but also to the effect of humidity (Steadman, 1979a, b); hot and humid conditions (as is the case in coastal regions) can be more dangerous than equivalently hot but dry conditions (Wehner et al., 2017). Wet heat waves, which are the most dangerous for human health, were not investigated in previous works. Following Steadman (1979a, b), one can legitimately wonder about the effect of humidity on the frequency of heat waves and on the evolution of humid heat waves in West African cities. Based on previous studies, many definitions of heat wave have been proposed, leading to different results. Indeed there is no universal definition of a heat wave; depending on the research applications, some indicators and definitions can be adopted. Thus, we can question the potential sources of uncertainty found in heat wave analysis.

The goals of this paper are (i) to highlight the potential uncertainties encountered in the heat wave detection process and (ii) to analyse the recent trend and characteristics of dry and wet heat waves over a selection of West African cities grouped into climatic regions. To achieve these objectives, we first assess the biases in the reanalyses (ERA5, MERRA) using ERA5 as a reference; then, a sensitivity analysis of the frequency of heat waves with respect to the threshold values, indicators and methods applied to define heat waves is addressed. Finally, we assess the spatial and temporal variability (seasonal and interannual) of heat waves and their characteristics in different climatic regions over West Africa.

The remainder of this article is organized as follows: in Sect. 2, we present the regions of interest and the data used for this work; the description of the methodology is also provided. Section 3 contains the main results of this study following the methodology described in Sect. 2. In Sect. 4, the uncertainty in the reanalyses and the origin of coastal heat waves are discussed. Section 5 provides a conclusion and some perspectives for future works.

2 Region of interest, data and methods

2.1 Region of interest

The current study is conducted over West Africa, which is located over the domain 5–20° N, 15° W–10° E, and spans the Atlantic coast to Chad and the Gulf of Guinea to the southern fringes of the Sahara (Fig. 1). The climate in West Africa is mostly influenced by the West African monsoon flux, which governs the rainy season and thus the rain-fed agriculture. The West Africa region has a semi-arid and hot climate with a dry season (Köppen classification BSh or BWh). This climate corresponds to an alternation between a short wet season and a very long dry season. The West Africa region shows high climate variability at a regional and local scale. In this study, we are interested in the coastal and continental parts of West Africa. We have therefore identified three re-

gions based on their location and climate variability on which we have conducted our analyses. The choice of these regions is coherent with Moron et al. (2016), who used a hierarchical-clustering approach to define some city blocks over West Africa. The 15 cities investigated here were classified into the three following regions:

- continental zone (CONT hereafter) including the cities of Bamako, Ouagadougou and Niamey (Fig. 1);
- coastal Atlantic zone (ATL hereafter) including the cities of Dakar, Nouakchott, Monrovia and Conakry (Fig. 1);
- coastal Guinean zone (GU hereafter) including the cities of Yamoussoukro, Abidjan, Lomé, Abuja, Lagos, Accra, Cotonou and Douala (Fig. 1).

The CONT and GU regions are very similar to the clusters found by Moron et al. (2016) (see figure under the title “Clusters membership” in Moron et al., 2016). The ATL region is a specific case because not all cities belonging to the region are present in the clusters defined by Moron et al. (2016). Therefore, we analysed the spatial variability of heat wave characteristics for each city. In this way, we found a consistent pattern across cities (see Fig. S1 in the Supplement for maximum T_{2m} values using the 90th percentile as a threshold), and we grouped them to form the ATL block.

2.2 Data

Reanalysis products are often taken as an alternative solution to observational weather and climate data due to availability and accessibility problems, particularly in data-sparse regions such as Africa (Gleixner et al., 2020). In this work, to access information with a regular spatial grid and a large horizontal coverage, we used two state-of-the-art reanalysis products: the fifth-generation European Centre for Medium-Range Weather Forecasts (ECMWF) reanalysis (ERA5; Hersbach et al., 2020) and the Modern-Era Retrospective analysis for Research and Applications, version 2 (MERRA-2; Gelaro et al., 2017), from the National Oceanic Atmospheric Administration (NOAA) (in the following, we will use “MERRA” to refer to MERRA-2). ERA5 reanalysis has a native spatial resolution of 0.28125° (~ 31 km) with 137 hybrid sigma–pressure levels from the surface up to 80 km, yet downloaded data are interpolated to a regular latitude–longitude grid of 0.25° × 0.25°. ERA5 is produced using 4D-Var data assimilation and the Cycle 41r2 (Cy41r2) of the ECMWF Integrated Forecasting System (IFS), which was operational in 2016. MERRA reanalysis has a spatial resolution of 0.625° × 0.5° with 42 standard pressure levels. MERRA uses an upgraded version of the Goddard Earth Observing System model version 5 (GEOS-5) data assimilation system and the Gridpoint Statistical Interpolation (GSI) analysis scheme of Wu et al. (2002). MERRA is produced using a 3D-Var data assimilation algorithm. These two reanalyses

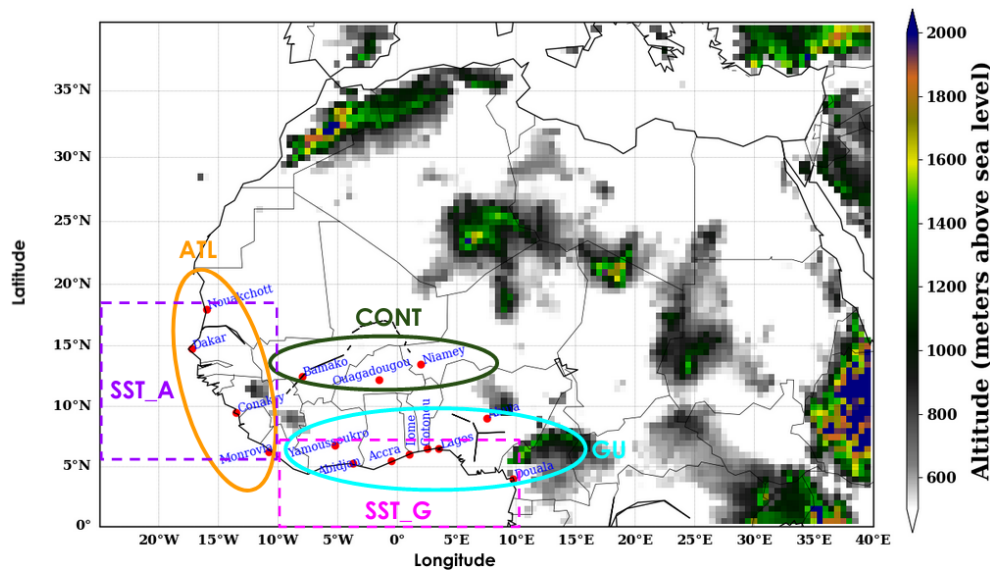


Figure 1. Topographic map of West Africa using ERA5 elevation data. The circles on the map represent the different climatic zones: ATL (coastal Atlantic zone), CONT (continental zone) and GU (coastal Guinean zone). The two boxes named SST_A and SST_G represent the boxes used to analyse the links between sea surface temperature (SST) and heat waves for the ATL and GU regions respectively. The y and x axes represent the latitude and longitude respectively. The colour bar shows the elevation in metres over the region.

datasets can be accessed through the Climserv database from the Institut Pierre-Simon Laplace (IPSL) server. To be consistent in our analyses, we transformed the spatial resolution of MERRA from $0.625^\circ \times 0.5^\circ$ to $0.25^\circ \times 0.25^\circ$ to match the one of ERA5; this is done using a first-order conservative interpolation. We use hourly data covering the period from 1 January 1993 to 31 December 2020 for both ERA5 and MERRA. Our choice of ERA5 and MERRA to conduct this study is supported by some previous work showing that these two reanalyses included among the most relevant used in African regions (e.g. Barbier et al., 2018; Ngoungue Langué et al., 2021; Engdaw et al., 2022). As the main objective here is to process heat wave detection, we focus on atmospheric variables at the surface such as 2 m temperature (T_{2m}), 2 m relative humidity (RH), 2 m dewpoint temperature, 2 m specific humidity, 10 m wind components, and water vapour pressure (e) from which wet-bulb temperature (T_w) and apparent temperature (AT; McGregor et al., 2015) were derived. These atmospheric variables have a significant impact on human thermal comfort (McGregor et al., 2015). Daily minimum and maximum values were calculated for T_{2m} , T_w , AT and the universal thermal comfort index (UTCI; Di Napoli et al., 2021). AT is similar to the heat index developed by Steadman (1984). The climate variables e , T_w , AT and RH were calculated using the following formulas:

$$e = 6.1121 \cdot \exp\left(\frac{17.502 \cdot T}{240.97 + T}\right) \quad (1)$$

(Buck, 1981; Alduchov and Eskridge, 1996),

$$T_w = T \cdot \operatorname{atan}\left[A(\operatorname{RH} + B)^{\frac{1}{2}}\right] + \operatorname{atan}(T + \operatorname{RH}) - \operatorname{atan}(\operatorname{RH} - C) + D \cdot (\operatorname{RH})^{\frac{3}{2}} \cdot (\operatorname{atan}(E \cdot \operatorname{RH})) - F \quad (2)$$

(Stull, 2011) (RH is given as a percentage, for example 32 for RH = 32 %),

$$AT = T + 0.33 \times 10^{-0.70} \cdot W_s - 4.00 \quad (3)$$

(McGregor et al., 2015).

RH is computed differently based on the variables available in the products. The first formula is used to compute RH in ERA5, and the second is used for MERRA.

$$\operatorname{RH} = 100 \cdot \frac{\exp\left(\frac{a \cdot T_d}{b + T_d}\right)}{\exp\left(\frac{a \cdot T}{b + T}\right)} \quad (4)$$

(August, 1828; Magnus, 1844; Alduchov and Eskridge, 1996),

$$\operatorname{RH} = 0.263 \cdot p \cdot q \cdot \left[\exp\left(\frac{17.67 \cdot (T - T_0)}{T - 29.65}\right)\right]^{-1} \quad (5)$$

(<https://earthscience.stackexchange.com/questions/2360/how-do-i-convert-specific-humidity-to-relative-humidity>, last access: 3 April 2023), where $a = 17.625$, $b = 243.04$, $A = 0.151977$, $B = 8.313659$, $C = 1.676331$, $D = 0.00391838$, $E = 0.023101$, $F = 4.686035$ and $T_0 = 273.16$ K. T (°C), T_d (°C), T_0 (K), p (hPa), W_s (m s^{-1})

and q are the ambient temperature, dewpoint temperature, reference temperature, pressure, wind speed and specific humidity respectively.

The land sea mask dataset used in this work was derived from ERA5 reanalysis; it can be accessed on the Copernicus Climate Data Store (CDS). T_{2m} daily maximum and minimum observations at Dakar–Yoff station in Senegal and Aéroport Félix Houphouët-Boigny (FHB) station in Côte d’Ivoire were used to evaluate our interpolation method. This is due to the fact that we do not have access to other station data in these regions. The data from Dakar–Yoff extend from 1 January 1973 to 31 December 2018 and contain almost 16 % missing values, and the data from Aéroport FHB extend from 1 January 2005 to 31 December 2017 and contain 0.35 % missing values. These data were provided by colleagues from the Agence Nationale de l’Aviation Civile et de la Météorologie (ANACIM) for the Dakar–Yoff station and from the Institut des Géosciences de l’Environnement (IGE) for the Aéroport FHB station.

2.3 Methods

2.3.1 Estimation of atmospheric variables at the scale of cities

Reanalysis datasets used for weather studies are generally run at a global scale; therefore information at a local scale is missing in many regions; this is a critical issue in regions where there is a lack of observation stations as is the case for African cities. To overcome this problem, downscaling methods can sometimes be used. In this work, we study phenomena at the scale of the cities, and reanalyses (ERA5 and MERRA) have too coarse a spatial resolution. The scales of the reanalyses are more representative of the spatial variability of a heat wave occurring in a city than at an isolated local station. Nevertheless, some validation of the test stations needs to be done, in particular to find the best interpolation technique to estimate local temperatures from the reanalyses. This is especially important over the coastal regions. Indeed, most of the cities used in this study are located along the coast and influenced by the ocean air masses (see Fig. 1). The evaluation of the spatial variability of the correlation between the local-scale variable (station) and reanalyses (ERA5) for T_{2m} , for example, showed high correlation values over the continent (Fig. S2) (Dakar, Abidjan). This suggests that the station data are well correlated with ERA5 grid points which are located on the continent; it is therefore necessary to know whether an ERA5 grid point is over the continent or not before applying an interpolation technique. To estimate the proportion of land on a grid point, we used the land sea mask (lsm) with values ranging from 0 to 1. The land sea mask is a measure of the land occupation on a grid point. An lsm of 0 means no land (a grid point located in the ocean), and an lsm of 1 means that the model cell is fully covered by land. Therefore, to estimate the climate variables over the cities

Table 1. Land sea mask (lsm) of West African towns used in this study.

Towns	Latitude	Longitude	lsm
Dakar	14.75	−17.25	0.6
Abidjan	5.25	−3.75	0.5
Nouakchott	18	−16	continent
Conakry	9.5	−13.5	0.5
Monrovia	6.25	−10.75	0.6
Bamako	12.5	−8	continent
Yamoussoukro	6.75	−5.25	continent
Ouagadougou	12.25	−1.5	continent
Accra	5.5	−0.5	0.8
Lomé	6	1	0.5
Niamey	13.5	2	continent
Cotonou	6.5	2.5	0.7
Lagos	6.5	3.5	0.5
Abuja	9	7.5	continent
Douala	4	9.75	0.9

from reanalyses, we use the nearest grid point of reanalyses to the station which satisfies an lsm equal to or greater than 0.5 (see Table 1 for lsm values of all the cities considered in this study). This approach was chosen after evaluating different methods such as the following (see Fig. S3a for more details):

- a bilinear interpolation using the four nearest grid points of reanalyses around the station (panels a and d in Fig. S3a),
- a linear gradient approach which considers the gradient of temperature constant between two grid points based on a linear interpolation with a condition placed on the lsm value (≥ 0.5) (panels c and f in Fig. S3a),
- the selection of the nearest grid point of reanalyses from the station with different values of lsm (≥ 0.5 , 0.75 and 1; we show only results for lsm ≥ 0.5) (panels b and e in Fig. S3a),
- a dynamical interpolation approach taking into account the effect of winds (not shown).

The interpolation method was applied to ERA5 and MERRA, and the resulting estimated data were compared to the station data by correlation analysis. We found that ERA5 appears to be slightly better than MERRA at both stations (Dakar and Abidjan) for minimum and maximum T_{2m} values (Fig. S3b).

2.3.2 Heat wave detection

Heat waves are usually defined as consecutive days of extremely hot temperatures above a threshold temperature value (e.g. Tan et al., 2010; Gasparrini and Armstrong, 2011;

Perkins and Alexander, 2013; Wang et al., 2019). Many factors can affect the definition of a heat wave, including the end-user sectors (human health, infrastructures, transport, agriculture) and also the climatic conditions of the regions (Perkins and Alexander, 2013). Therefore, there is no universal and standard definition of a heat wave (Perkins, 2015; Oueslati et al., 2017; Shafiei Shiva et al., 2019). Different thresholds, duration and indicators contribute to the divergence in the definition of heat waves (Smith et al., 2013). Heat waves can be defined from daily meteorological variables such as daily raw temperature (T_{\min} , T_{mean} and T_{\max}) (e.g. Fontaine et al., 2013; Beniston et al., 2017; Ceccherini et al., 2017; Déqué et al., 2017; Batté et al., 2018; Barbier et al., 2018; Lavaysse et al., 2018; Engdaw et al., 2022), mean daily wet-bulb temperature (Yu et al., 2021) or heat stress indices (e.g. Robinson, 2001; Fischer and Schär, 2010; Perkins et al., 2012a; Guigma et al., 2020) using relative or absolute thresholds. The use of absolute thresholds is well suited to detecting heat waves during the year in regions where the seasonal cycle is well marked. In mid-latitudes for example, the seasonal thermal amplitude of $T_{2\text{m}}$ is large, approximately 20°C . In tropical regions this method is not suitable, since the seasonal thermal amplitude is strongly reduced (6°C). Therefore, a relative threshold for heat wave detection is adopted in our study, since our region of interest is West Africa. Some authors use the daily anomalies of temperature to define heat waves (e.g. Stefanon et al., 2012; Barbier et al., 2018). Most of the previous studies are focused on daytime or nighttime heat waves, ignoring events which occur during the day and night concomitantly. This type of heat wave is very dangerous for human health because the body suffers from heat stress during the day and night (Lavaysse et al., 2018). In our case, we defined three methods to detect specific types of heat waves (namely those occurring during daytime, nighttime, and both daytime and nighttime concomitantly) using the daily minimum and maximum values of $T_{2\text{m}}$ ($T_{2\text{m},\min}$, $T_{2\text{m},\max}$), T_{w} ($T_{\text{w},\min}$, $T_{\text{w},\max}$), AT (AT_{\min} , AT_{\max}) and UTCI (UTCI_{\min} , UTCI_{\max}) as indicators. The selected atmospheric variables have been used for heat wave detection in previous studies; they take into account some key parameters (air temperature, wind, humidity, radiant temperature) to assess the body heat stress, and they are easy to compute. The methods applied are defined below:

- *Method 1.* A heat wave is defined as a consecutive period of at least 3 d during which the daily maximum value of an indicator exceeds the calendar 90th percentile of daily maximum values of the indicator computed over the whole period (see HW1 in Fig. 2). This approach is useful for monitoring daytime heat wave events. Daytime events will be more associated with incoming solar radiation.
- *Method 2.* A heat wave is defined as a consecutive period of at least 3 d during which the daily minimum value of an indicator exceeds the calendar 90th per-

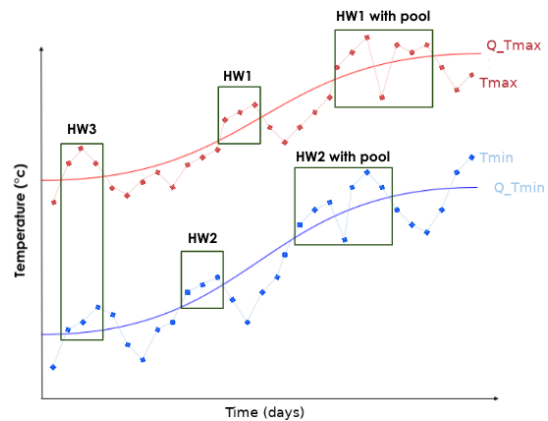


Figure 2. Schematic illustration of heat wave detection process: HW1/HW2 represents heat waves associated with maximum/minimum temperature and HW3 is heat waves detected at the same time in maximum and minimum temperatures. The red/blue lines with squares are max/min daily temperatures. Solid red/blue lines are max/min thresholds. The x and y axes represent the time in days and the temperature in degrees Celsius respectively. The term “with pool” refers to the pooling of two (or more) events separated by 1 d below the daily threshold. This figure shows the different types of heat wave investigated in this work.

centile of daily minimum values of the indicator computed over the whole period (see HW2 in Fig. 2). This approach is useful for monitoring nighttime heat wave events. Nighttime events can be related to the moisture content of the region.

- *Method 3.* A heat wave is defined as a consecutive period of at least 3 d during which daily minimum and maximum values of an indicator exceed the calendar 90th percentiles of daily minimum and maximum values respectively (see HW3 in Fig. 2). This method is most appropriate for extreme events that occur both during the day and at night and are very harmful for human health.

The 90th percentile is calculated for each calendar day of the year using an 11 d moving window centred on the day under study. The use of a moving window allows the seasonal cycle to be taken into account in the calculation of percentiles. The use of a relative threshold is more appropriate as it is easily replicable in other regions. When two heat wave events are separated by 1 d with an indicator value below the daily 90th percentile, they are pooled together to form a single event (see Fig. 2).

2.3.3 Heat wave characteristics

Once a heat wave is detected, some key characteristics are derived, namely duration and intensity. Some studies use the heat wave magnitude index daily (HWMId) to assess the severity of heat waves (e.g. Russo et al., 2016; Ceccherini et

al., 2017). The HWMI_d focuses on strong heat waves; using this measure, the total intensity of all detected events cannot be assessed. In our study, the methodology applied to compute the duration and intensity of heat waves has been developed by Lavaysse et al. (2018) for monitoring extreme temperatures in Europe. We define the heat wave duration as the total number of hot days in heat waves. Hot days are heat wave days with daily values of the indicators above the daily thresholds. The heat wave duration is computed using the following expression:

$$\text{duration} = \sum_{i=1}^N \sum_j^d \delta_j, \tag{6}$$

where $\delta_j = 1$ if $T_j >$ daily 90th percentile and $\delta_j = 0$ if $T_j <$ daily 90th percentile and N represents the total number of heat waves per grid point and d the number of hot days in a heat wave. The Kronecker δ_j is used here because we pooled together heat waves separated by 1 d to form single events. For example, two heat waves of 4 and 3 d respectively separated by 1 d below the threshold will be counted as a single event with a duration of 7 d. For each block defined previously, the duration of heat waves is computed as the average of the duration of heat waves over the cities belonging to the same block. This also applies to the intensity.

The intensity of a heat wave has been defined as the sum of the daily exceedances of daily values of indicators above the climatological daily threshold in a sequence of hot days. This study is part of the Agence National de la Recherche STEWARD (STatistical Early WArning systems of weather-related Risks from probabilistic forecasts, over cities in West Africa) project, which focuses on the human impacts of climate extremes. Therefore, the climatological daily threshold is chosen to be constant over the whole period, and it is defined as the minimum of the daily climatology thresholds over the study period. This approach allows us to properly assess the severity of a heat wave and its potential human impacts. The expression of the intensity is given by

$$I_1 = \sum_{t=1}^{N_d} \text{bool}_{\max,t,w} \cdot (X_{\max,t,w} - \min(Q_{\max,w})), \tag{7}$$

$$I_2 = \sum_{t=1}^{N_d} \text{bool}_{\min,t,w} \cdot (X_{\min,t,w} - \min(Q_{\min,w})), \tag{8}$$

$$I_3 = \sum_{t=1}^{N_d} \text{bool}_{\min-\max,t,w} \cdot (X_{\max,t,w} - \min(Q_{\max,w})) + \sum_{t=1}^{N_d} \text{bool}_{\min-\max,t,w} \cdot (X_{\min,t,w} - \min(Q_{\min,w})). \tag{9}$$

I_1 , I_2 and I_3 are intensities associated with HW₁, HW₂ and HW₃ respectively. $X_{\max,t,w}/X_{\min,t,w}$ denotes daily maximum/minimum values of indicators at the grid point w . $Q_{\max,w}/Q_{\min,w}$ represents daily maximum/minimum threshold of the indicators at the grid point w .

$\text{bool}_{\max,t,w}$ and $\text{bool}_{\min,t,w}$ are Boolean time series which contain 0 if the day is not part of a heat wave and 1 if the day is part of a heat wave for maximum and minimum daily values of the indicators respectively. $\text{bool}_{\min-\max,t,w}$ is a Boolean time series which indicates 1 if the day is part of a heat wave detected simultaneously with both the minimum and the maximum values of indicators and 0 if this is not the case. N_d is the length in days of the study period. The mean duration and intensity are used to assess the severity of the heat wave.

2.3.4 Evaluation of the products using statistical metrics (hit rate, ACC, GSS)

Most regions in Africa suffer from a lack of observations due to a small number of available weather stations. To access information over a large domain, we use ERA5 and MERRA reanalysis datasets, which are very consistent in representing large-scale processes in the Saharan area (Ngoungue Langué et al., 2021). The coherence of reanalyses at a regional scale was assessed using statistical metrics such as the hit rate, the anomaly correlation coefficient (ACC) and the Gilbert skill score (GSS). The hit rate and GSS are used to evaluate hot days in the reanalyses.

Hit rate

The hit rate, also known as the “hit”, is a measure of the fraction of events detected in an evaluated dataset knowing that the events occur in the reference at the same time. It is given by the following formula:

$$\text{hit} = \frac{\text{TP}}{\text{TP} + \text{FP}}. \tag{10}$$

TP denotes true positives, which are events correctly detected by the two datasets at the same time; FP denotes false positives, which are events not detected by the evaluated dataset but that occurred in the reference. Hit values range from 0 to 1; hit = 1 means that all the events observed in the evaluated dataset occurred in the reference.

Previous work such as Olauson (2018) and Ramon et al. (2019) have shown that ERA5 provides a good representation of various near-surface meteorological variables including near-surface humidity and wind speed, in comparison to others reanalyses, including MERRA. Therefore for the computation of the hit, we chose ERA5 as the reference and MERRA as the evaluated dataset.

ACC

The ACC is similar to a linear correlation, the only difference being that it is calculated using the anomalies of the variables with respect to the climatology. This metric is stricter than the simple correlation and not sensitive to the seasonal cycle, which tends to increase the correlation between the

Table 2. Contingency table.

2×2 contingency table		Event observed	
		Yes	No
Event forecast	Yes	<i>A</i>	<i>B</i>
	No	<i>C</i>	<i>D</i>

products. ACC takes values between -1 and 1 . $ACC = 1$ indicates a perfect correlation between the products. For example, to compute the ACC between ERA5 and MERRA using the variable T_{2m} in this study, we firstly compute the anomalies between each reanalysis and their respective climatologies and then we compute the correlation between the resulting anomalies.

GSS

The GSS, known also as the equitable threat score (ETS), measures the fraction of observed events that are correctly predicted, adjusted for hits associated with random chance. The GSS does not take into account positive outcomes due to chance. It is stricter than the hit rate; the GSS takes values between $\frac{-1}{3}$ and 1 . $GSS = 0$ indicates no skill or no correlation, while $GSS = 1$ indicates perfect skill. Given a contingency table (see Table 2), the computation of the GSS is done by the following formula:

$$GSS = \frac{A - CH}{A + B + C - H}, \quad (11)$$

with CH given by

$$CH = \frac{(A + B)(A + C)}{A + B + C + D}. \quad (12)$$

3 Results

3.1 Uncertainties in the reanalysis products

The first step of this work consists in assessing the evolution of T_{2m} in the ERA5 and MERRA reanalyses. The climatological state (annual mean) of T_{2m} in ERA5 and MERRA has been evaluated over the West Africa region from 1 January 1993 to 31 December 2020 (Fig. 3a–b). Both reanalyses show very similar climatologies of T_{2m} : a north–south gradient of the temperature. The Sahel region appears to be warmer than the Guinean region; this is because of the advection of cold air coming from the Atlantic Ocean to the Guinea coast. This fresh air tends to cool down temperatures in this region. The bias between ERA5 and MERRA is computed using ERA5 as reference (Fig. 3c). MERRA shows a cold bias with respect to ERA5 over the Sahel region and

Guinean zone except in some countries (e.g. Guinea-Bissau, Sierra Leone, Liberia) where we observe a hot bias. The biases between ERA5 and MERRA are around $\pm 2^\circ\text{C}$. The bias highlighted between ERA5 and MERRA is very significant for heat wave detection. Thereafter, we evaluated the temporal consistency between the two reanalyses by computing the ACC for T_{2m} , AT and T_w (see Fig. 3d–i). We observed a weak correlation over the south of the Sahel and Guinean region of around 0.5 (0.7) for maximum (minimum) values of T_{2m} and AT (see Fig. 3d–e and g–h). This could be explained by the presence of a strong diurnal cycle in the region associated with high variability during the day and less variability during the night. This will lead to high variability in the daily maximum values compared to the daily minimum values. T_w shows a uniform repartition of correlation between ERA5 and MERRA of around 0.85 except in the Guinean region with maximum values. Good agreement between the two products is found with T_w . We can infer from this result that T_w has a more stable signal than T_{2m} and AT. Knowing that heat waves are defined as extreme events, it is important to evaluate the consistency of the reanalysis products for the representation of extreme values. The hit rate and GSS were calculated in terms of hot days using T_{2m} , and we noticed very low values between the two reanalysis products over the southern Sahel and Guinean region of around 0.25 (see Fig. S4). Similar results have been found with T_w (not shown). The lack of coherence between ERA5 and MERRA on the representation of hot days would result in discrepancies in the number of heat wave events derived from the two reanalyses. The analysis of heat wave frequency in the two products using T_{2m} and AT shows big differences over the coastal region (see Fig. S5). This is very consistent with the ACC results shown earlier. These discrepancies in the ERA5 and MERRA reanalyses in West Africa were also highlighted by Engdaw et al. (2022). The potential origins of these differences are explored in Sect. 4. The spatial variability of heat wave occurrence in ERA5, using T_{2m} and AT as indicators, is very similar regardless of the methods applied for heat wave detection. This strong correlation between T_{2m} and AT is also observed when using MERRA reanalysis (see Fig. S6). Even if the reanalyses show discrepancies over the south of the Sahel and coastal region with respect to key variables, the correlation between the variables is preserved.

3.2 Sensitivity of heat wave detection to threshold values

As discussed earlier in Sect 2.3.2, “Heat wave detection”, the threshold value used for heat wave monitoring has a significant impact on heat wave characteristics. The threshold value is generally tailored to the application that is to be carried out. In this part of the work, we investigate the sensitivity of heat wave frequency to different thresholds. To achieve this goal, we define four relative threshold values calculated over the entire period: the 75th, 80th, 85th and 90th daily percentiles.

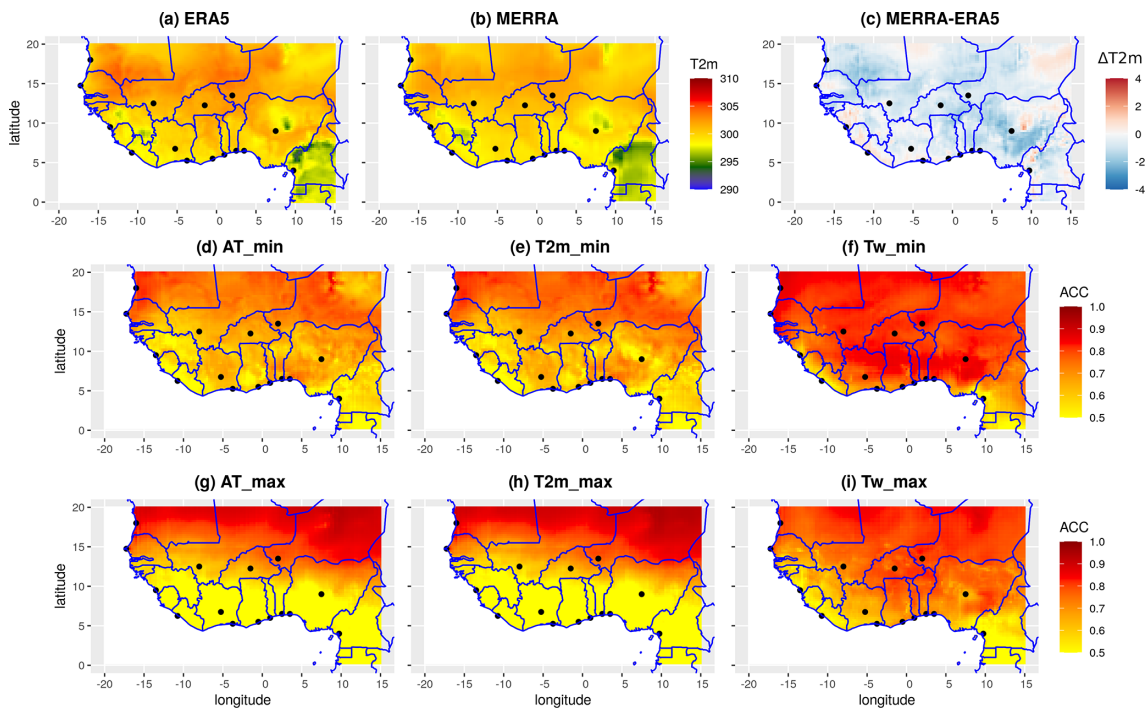


Figure 3. Assessment of the evolution of some atmospheric variables in the reanalyses data: (a–b) climatology state of T_{2m} over 1993–2020 for ERA5 and MERRA respectively; (c) climatological bias between MERRA and ERA5 using ERA5 as reference (ΔT_{2m}); (d–f)/(g–i) anomaly of correlation between MERRA and ERA5 respectively for min/max values using AT, T_{2m} and T_w variables. The x and y axes represent the longitude and latitude in degrees respectively. The colour bars show the temperature (T_{2m}) in kelvins and the values of the anomaly of temperature (ACC) respectively. The black points in the map represent the cities of interest analysed in this work (see the “Region of interest” section for more details); this applies for all the maps in the paper.

The choice of these thresholds for assessing changes in heat wave characteristics is based on previous work. Many studies use the 90th percentile to define a heat wave (e.g. Fischer and Schär, 2010; Perkins et al., 2012a; Déqué et al., 2017; Lavaysse et al., 2018; Barbier et al., 2018); other studies use the 75th percentile (Guigma et al., 2020). Based on these studies, we decided to test the sensitivity of threshold values from the third quartile (75th percentile) to the 90th percentile by steps of 5% to quantify significant changes in heat wave frequency. As we are studying extreme events, it is not relevant to go below the third quartile; knowing also that this study focuses on human impacts of heat waves, the 90th percentile is enough as a maximum threshold. Heat wave detection is treated separately for these four thresholds (see Fig. S7). The sensitivity of heat wave frequency or duration with respect to the thresholds (75th, 80th, 85th, 90th percentiles) is treated independently for the four thresholds; this is done by calculating the linear evolution coefficient over each grid point. The linear evolution coefficient is defined as the slope of the linear regression line fitted between the threshold values (Q_{75} , Q_{80} , Q_{85} , Q_{90}) and the number of events associated with each threshold (NQ_{75} , NQ_{80} , NQ_{85} , NQ_{90}) or their corresponding duration (DQ_{75} , DQ_{80} , DQ_{85} ,

DQ_{90}). The calculation of the linear evolution coefficient is carried out according to the following steps:

- After processing for heat wave detection at each grid point for the four thresholds separately, we compute for each of them the frequency and duration of heat waves.
- Then we fit a regression line between the threshold values (Q_{75} , Q_{80} , Q_{85} , Q_{90}) and their corresponding frequency or duration. This is done for each grid point.
- Finally, the changes in heat wave occurrence/duration from the 75th to 90th percentiles at each grid point are given by the computation of the slope of the regression line fitted at step 2 between the threshold values and their corresponding heat wave occurrence/duration.

We are aware that this regression based on four points is not very robust; nevertheless it makes it possible to obtain information on the evolution of the heat wave characteristics with respect to the thresholds. We therefore assessed the significance of the slope values with respect to the thresholds using a confidence level of 95%. The significance of the slope was evaluated using a two-sided chi-squared statistics test (Pandis, 2016).

The linear evolution is given by the following equations:

$$N = a_w \cdot \text{threshold} + b_w, \quad (13)$$

$$D = a'_w \cdot \text{threshold} + b'_w, \quad (14)$$

where a_w , a'_w and b_w , b'_w are the slopes and intercepts of the regressions at the grid point w for heat wave frequency and duration respectively.

This analysis is conducted with T_{2m} and T_w extracted from MERRA and ERA5 reanalyses. We find a high spatial variability in the sensitivity of heat wave occurrence to the threshold values over West African regions (Figs. S8 and S9). Some regions are more sensitive than others; this can be explained by a strong seasonal cycle of the T_{2m} and T_w signals in those regions. We observe small changes in the frequency and duration of heat waves with respect to the thresholds when using the minimum and maximum values of T_{2m} or T_w (Figs. S8c, f, 4c, f and S9c, f); this is related to the small sample size of events detected with method 3 (see Sect. 2.3.2 for more details). As the results show, the frequency of heat waves can be expected to increase with decreasing threshold values (see Figs. S8 and S7). Heat waves detected using low threshold values are very persistent and last for several days (Fig. 4 shows an illustration with T_{2m} used as an indicator). This can be explained by the fact that when using a low threshold value, one can expect to have many days with temperature values above the daily threshold. Conversely, for heat waves detected with high threshold values, the duration of the events is considerably reduced. This is statistically coherent because the number of consecutive days with temperature above the threshold will decrease as the threshold increases. In general, we find that the duration of heat waves is more sensitive to the threshold values than their frequency. This is very coherent because the persistence of a heat wave will be mainly affected by the threshold values used for the detection.

3.3 Sensitivity of heat wave detection to the choice of indicators and methods applied

We have shown that the heat wave detection is very sensitive to threshold values. Based on the literature review and the application of this work, for the rest of the study, we use the 90th percentile for heat wave analyses (e.g. Fischer and Schär, 2010; Perkins et al., 2012a; Perkins and Alexander, 2013; Fontaine et al., 2013; McGregor et al., 2015; Russo et al., 2016; Mutiibwa et al., 2015; Oueslati et al., 2017; Déqué et al., 2017; Batté et al., 2018; Barbier et al., 2018; Lavaysse et al., 2018; Yu et al., 2021; Engdaw et al., 2022) using ERA5 reanalysis (Fig. 5). We identified four indicators – T_{2m} , T_w , AT and UTCI – from which heat wave detection was processed using three different methods (see Sect. 2.3 for more details). We notice that the occurrences of daytime and nighttime heat waves (Fig. 5a–d, e–h) are in the same range of values, while for concomitant events (Fig. 5i–l), the occurrence

of heat waves is drastically reduced by $\frac{1}{4}$. This could be explained by the facts that nighttime and daytime heat waves do not necessarily occur at the same time and their origins are totally different. Daytime heat waves will be mainly influenced by incoming solar radiation, while nighttime heat waves will be mainly influenced by the water vapour content of the air mass (Barbier et al., 2018; Largeron et al., 2020). We observe a high occurrence of nighttime heat waves over the coastal region from Guinea to Cameroon (Fig. 5a–d) linked to moist air coming from the Atlantic Ocean in the region during the night; daytime heat waves are more frequent in the Sahel and north-east of the Sahara (Fig. 5e–h) due to hot temperatures over the continental regions. When analysing nighttime heat wave events from each indicator (Fig. 5a–d), it appears that T_w heat waves are more frequent than T_{2m} /AT/UTCI events. It seems that T_w is more sensitive to humidity than the other indicators (see formula of T_w); this could explain the high frequency of events observed during the night in the coastal region. Regarding daytime heat waves (Fig. 5e–h), the spatial variability of events is more consistent for all the indicators in the Sahelian zone. However, some differences are observed: an increase in heat wave occurrence over the coastal region with T_w is noticed compared to T_{2m} , AT and UTCI. The detection of heat wave events with method 3 shows that T_w events are more frequent than T_{2m} /AT/UTCI events with a maximum of occurrence located over the northern Sahel. This means that daytime and nighttime heat waves occur frequently and simultaneously over the Sahel with T_w . From this result, we can deduce that humidity plays a major role in the occurrence of concomitant heat waves, which are very dangerous for human health. In this section, we show the high sensitivity of heat wave detection to the methodology applied and to the variables used as indicators. The role of humidity in heat wave occurrence in the coastal region has also been highlighted. Similar results are found with MERRA reanalysis (not shown).

In summary, the heat wave detection is influenced by many parameters: the dataset, threshold values, indicators and methodology used to define such an event. There is a high dependency between these parameters and the climatic region investigated. We illustrate the sensitivity of heat wave characteristics to the previous parameters in the CONT region (Fig. 6), as well as the ATL and GU regions (see Figs. S10 and S11) using ERA5 and MERRA reanalyses.

3.4 Monitoring of heat waves over West Africa regions

In this section, we analyse the spatial variability of heat waves in three climate regions (CONT, ATL and GU; see the “Region of interest” section for more details) using T_{2m} , AT and T_w as indicators and reanalysis data. Although ERA5 is slightly better than MERRA when compared to station data (Fig. S3b), we have evaluated the recent evolution of heat waves in both reanalyses. To do so, we firstly assessed the interannual variability of heat waves and their characteris-

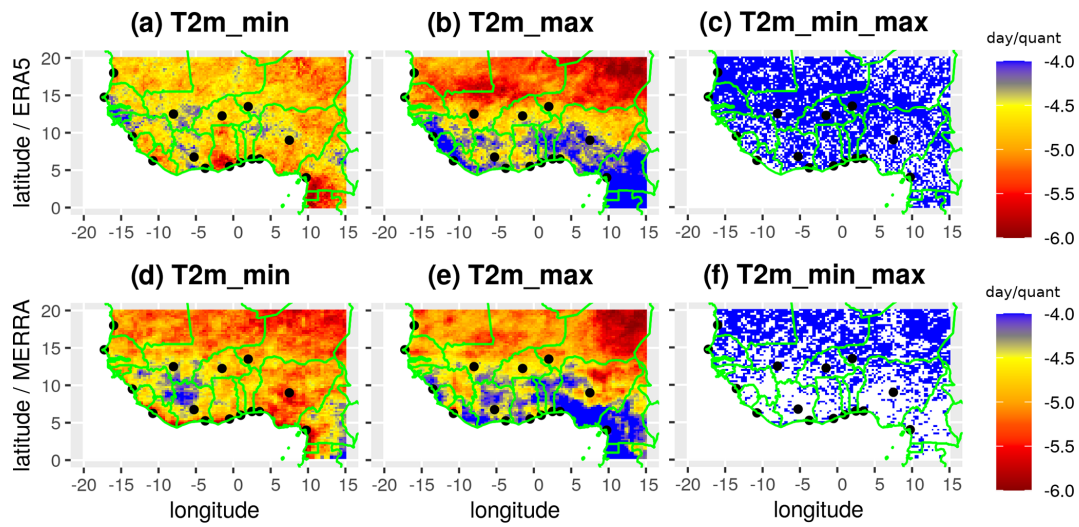


Figure 4. Evolution of the heat wave duration with respect to the threshold values using T_{2m} as an indicator for (a–c) ERA5 and (d–f) MERRA respectively. The figure shows the slope of the regression line in days per percentile, which is computed by fitting a linear regression between the threshold values (Q75, Q80, Q85, Q90) and their corresponding heat waves’s duration (DQ75, DQ80, DQ85, DQ90). The x and y axes represent the longitude and latitude in degrees respectively. The colour bar shows the values of the slope. The white blanks indicate non-significant changes in the duration of heat waves per percentile. The significance of the slope of the regression line has been computed using a two-sided chi-squared test.

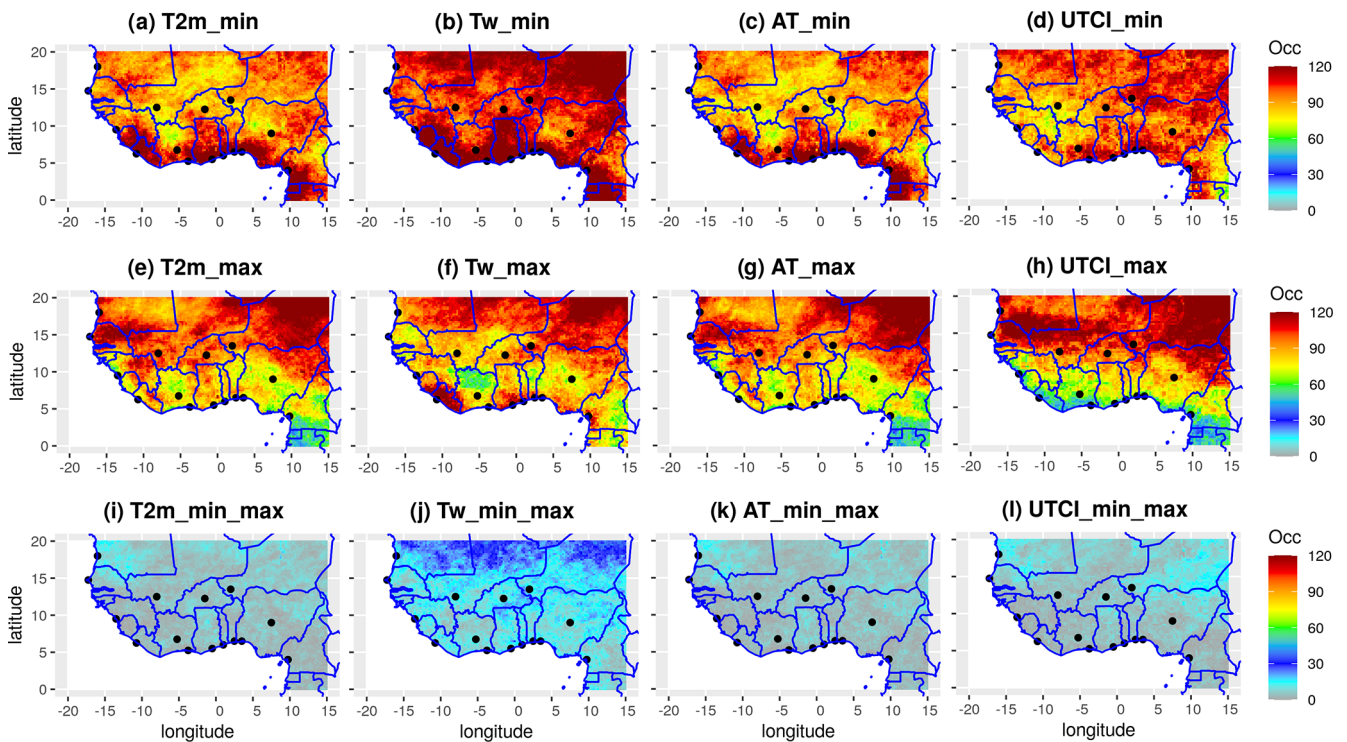


Figure 5. Climatological state of heat wave occurrence over West Africa during the period 1993–2020 using four different indicators (T_{2m} , T_w , AT, UTCI). The detection of heat waves is based on the definition adopted: (a–d) minimum values of indicators, (e–h) maximum values of indicators, and (i–l) minimum and maximum values of indicators. The detection of heat waves was processed using ERA5 reanalysis and the climatological daily 90th percentile over the period as a threshold. The x and y axes represent the longitude and latitude in degrees respectively. The colour bar shows the frequency of heat waves per region.




Figure 6. Sensitivity analysis of heat wave characteristics to the datasets, indicators and methodologies used in the CONT region. The characteristics investigated here are the duration and intensity. The circles and stars in the figure represent ERA5 and MERRA reanalyses respectively. The blue/red colour represents minimum/maximum values of the indicators. “ $T_{2m,max}$ ” from ERA5 is the reference variable used for this analysis. The x and y axes show the standardized variation in intensity and duration from the reference (no unit) respectively. The variations in duration and intensity have been computed using max daily T_{2m} in ERA5 as reference. The detection of heat waves is done using the climatological daily 90th percentile over the period as a threshold.

tics from 1993 to 2020. For each region, the characteristics of heat waves were calculated as the ratio of the sum of the characteristics of all the cities belonging to a region divided by the number of cities. We identified some particularly hot years with a high frequency of nighttime, daytime and concomitant heat waves: 1998, 2005, 2010, 2016, 2019 and 2020 in the three regions for all the indicators (see Figs. 7, S12 and S13). These peak heat wave years are addressed in Sect. 4. The GU region appears to have experienced more heat waves over the last decade than the CONT and ATL regions (see Fig. S12 for daytime events and Fig. S13 for nighttime). The mean duration of heat waves detected in the three regions is in the same range of values with some specific persistent events at the end of the period in the ATL and GU regions (not shown). Stronger and more persistent heat waves are found in the CONT region. From a statistical point of view, this is due to less variability in the signal of indicators in the region, which favours the detection of consecutive days with indicator values above the threshold. The highest occurrences of heat waves in the three regions are associated with T_w for daytime and nighttime events (see Figs. S12 and S13 respectively). Conversely, high-intensity heat waves are associated with AT (not shown) in the three regions. We can infer from this result that AT presents a more stable signal in the regions compared to T_{2m} and T_w . Concomitant high-intensity events are found in the CONT and ATL regions (see Fig. S15).

We also investigate the seasonal distribution of heat wave occurrence in the three regions. We find an increase in the

frequency of daytime and nighttime heat waves at the beginning of the season and during the retreat period of the West Africa monsoon (starting in September; see Fig. S14a–c). A decrease in heat wave frequency is observed during the active phase of the monsoon in the three regions; this is consistent because the monsoon flow brings rainfall into the region, resulting in a cooling effect. The concomitant heat waves show a seasonal cycle with strong fluctuations (Fig. S16). This is due to the fact that concomitant events are conditioned by daytime and nighttime heat waves, which are two distinct processes.

The seasonal cycle of the duration and intensity of heat waves follows the same distribution as the heat wave occurrence (see Fig. 8a–c and d–f respectively). Persistent and strong-intensity heat waves (nighttime, daytime) occur at the beginning and the end of the season, while short-duration and low-intensity events occur during the monsoon phase (Fig. 8a–c, d–f). This is verified for all the three indicators despite some discrepancies. The period 1993–2020 is then divided into 3 decades – 1993–2001, 2002–2011 and 2012–2020 – and we evaluate the contribution of each decade to the heat wave characteristics over the whole period (see Fig. 9 for heat wave duration). Results are similar when analysing the intensity of heat waves (not shown). The percentiles used for the detection of heat waves in each decade are computed over the whole period 1993–2020. It is clearly shown with ERA5 that the major contribution to heat wave characteristics over the period comes from the last decade (Fig. 9g–i). We notice a progressive increase in frequency, duration and inten-

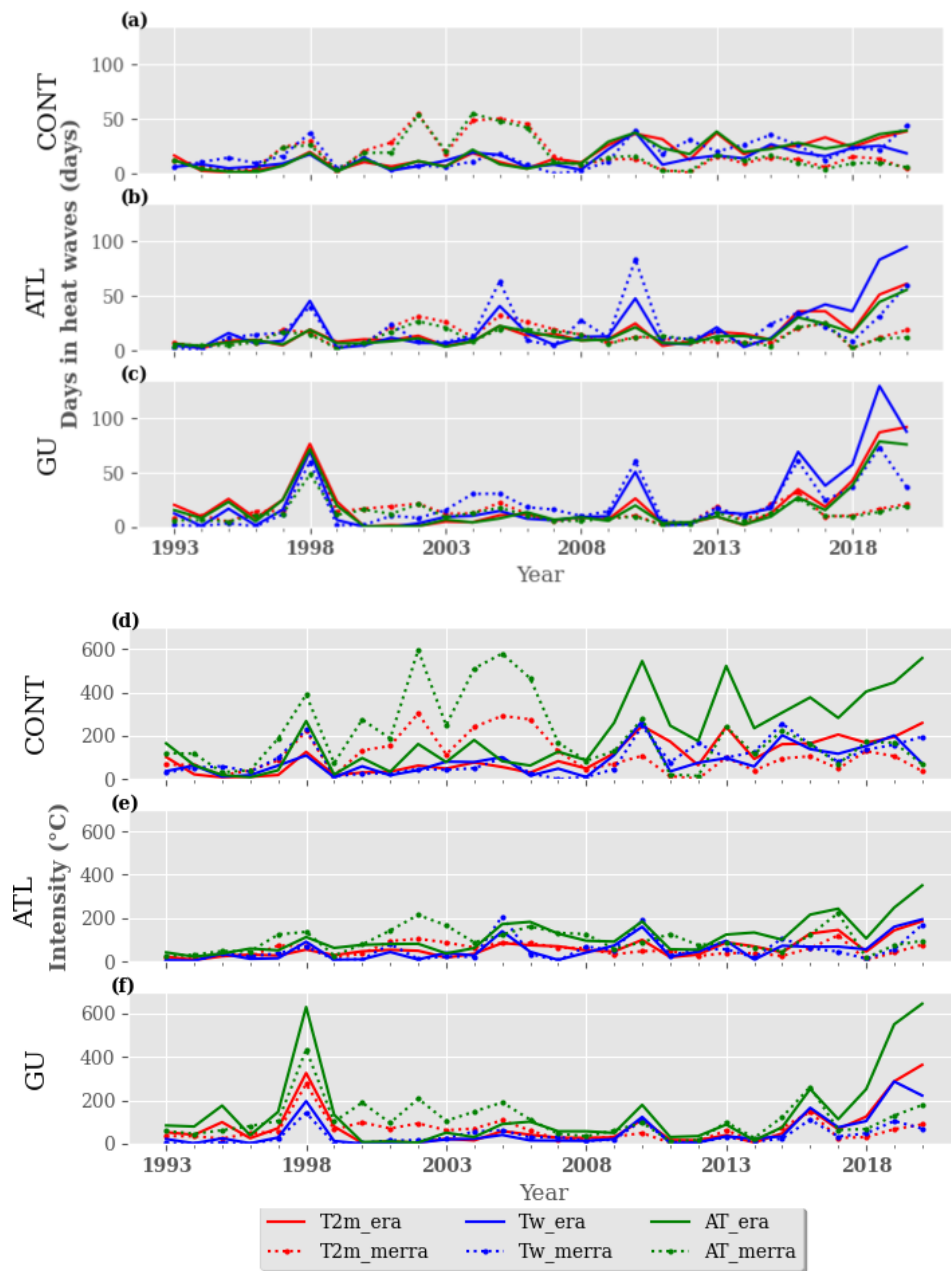


Figure 7. Interannual variability of heat wave characteristics using maximum values of T_{2m} , T_w and AT for (a–c) duration and (d–f) intensity. The detection of heat waves is done using the climatological daily 90th percentile as a threshold over the period, and the characteristics of heat waves are computed in the three regions: (a, d) CONT, (b, e) ATL and (c, f) GU. The solid and dashed red/blue/green lines represent the evolution of heat wave characteristics using $T_{2m}/T_w/AT$ from ERA5 and MERRA respectively. The x and y axes represent the duration and intensity of heat waves and the time in year respectively.

sity of all the heat waves (daytime, nighttime and concomitant) from the first to the last decade in the three regions (see Figs. S14j–l and S16j–l); this is true for all the indicators. Using ERA5 reanalysis, we found the last decade (2012–2020) shows a major contribution to around 50 % of heat wave characteristics over the period 1993–2010, while the first and second decades contribute up to 22.4 % and 27.6 %

respectively. This contribution of the last decade over the total period is not effective in MERRA reanalysis, where the different decades appear to have a similar contribution. This is the result of the uncertainties highlighted earlier in both reanalyses. The reinforcement of extreme events such as heat waves during the last decade in ERA5 is possibly linked to global warming. This result is consistent with other studies

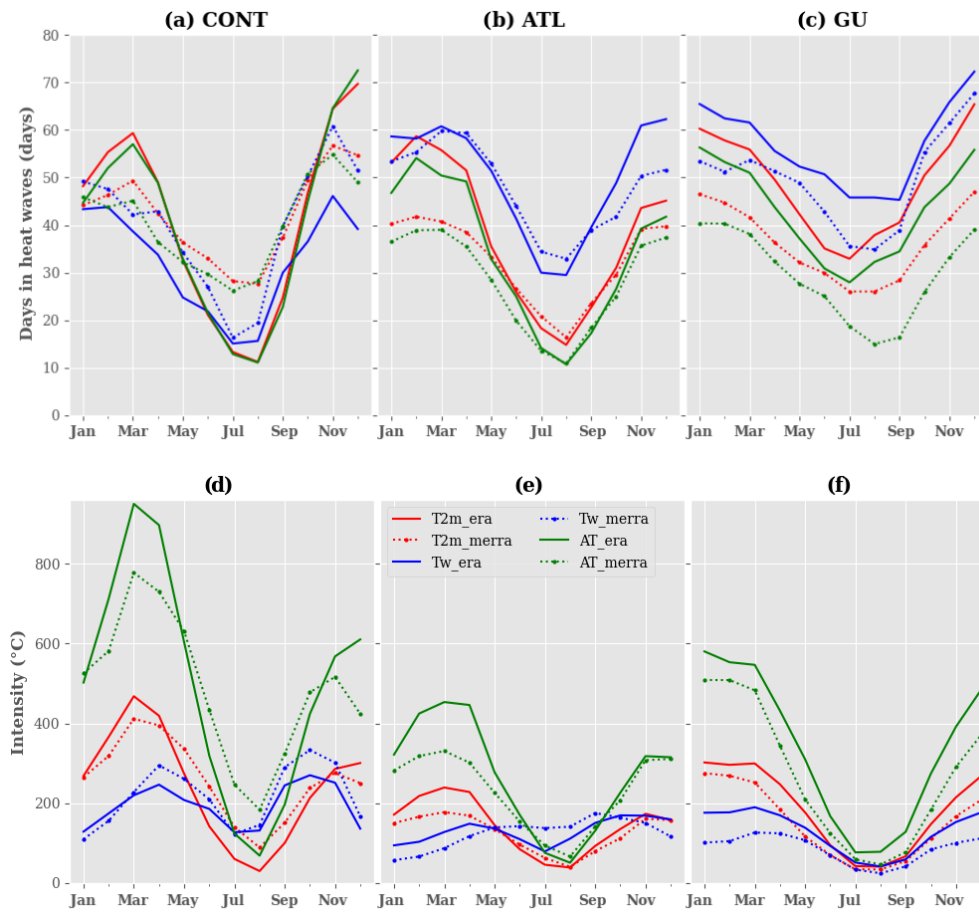


Figure 8. Seasonal variability of heat wave characteristics using maximum values of T_{2m} , T_w and AT for (a–c) duration and (d–f) intensity respectively. We compute a 3-month running mean to smooth the seasonal cycle. The detection of heat waves is done using the climatological daily 90th percentile as a threshold in the different regions: (a–d) CONT, (b–e) ATL and (c–f) GU. The solid and dashed red/blue/green lines represent the evolution of heat wave characteristics using $T_{2m}/T_w/AT$ from ERA5 and MERRA respectively. The y and x axes represent the duration and intensity of heat waves and the time in months respectively.

that show an increase in heat wave frequency and characteristics under climate change (e.g. Dosio, 2017; Dosio et al., 2018; Murari and Ghosh, 2019; Lorenzo et al., 2021; Engdaw et al., 2022). When analysing the severity of heat waves over the previous 3 decades using the mean duration and intensity (see Fig. S17 and S18), we do not find a significant increase in heat wave characteristics.

After the evaluation of the temporal evolution of heat waves over the three regions, we analyse their persistence based on their duration using ERA5 and MERRA reanalyses and maximum values of the indicators (see Figs. 10 and S19 respectively). We defined five types of event as described in Table 3. We observed that approximately 75 % of daytime heat waves have a duration of 3–6 d with at least 40 % of events belonging to C1 (Fig. 10). Very persistent daytime heat waves contribute to at least 9 %–13 % of the events registered. Severe and very severe daytime events are extremely rare in the region, and they contribute up to 12 % of the total number of heat waves. The classification is not too sensitive

Table 3. Classification of heat waves based on the duration.

Classes	Duration (days)	Degree of persistence
C1	3	normal
C2	4–6	persistent
C3	7–9	very persistent
C4	10–12	severe
C5	13+	very severe

to indicators and regions. We obtained a similar classification with nighttime heat waves (not shown).

4 Discussion on the uncertainties found in reanalyses and the impacts of the SST in the Atlantic

We analyse the evolution of heat wave occurrence and characteristics over a variety of climatic regions in West Africa.

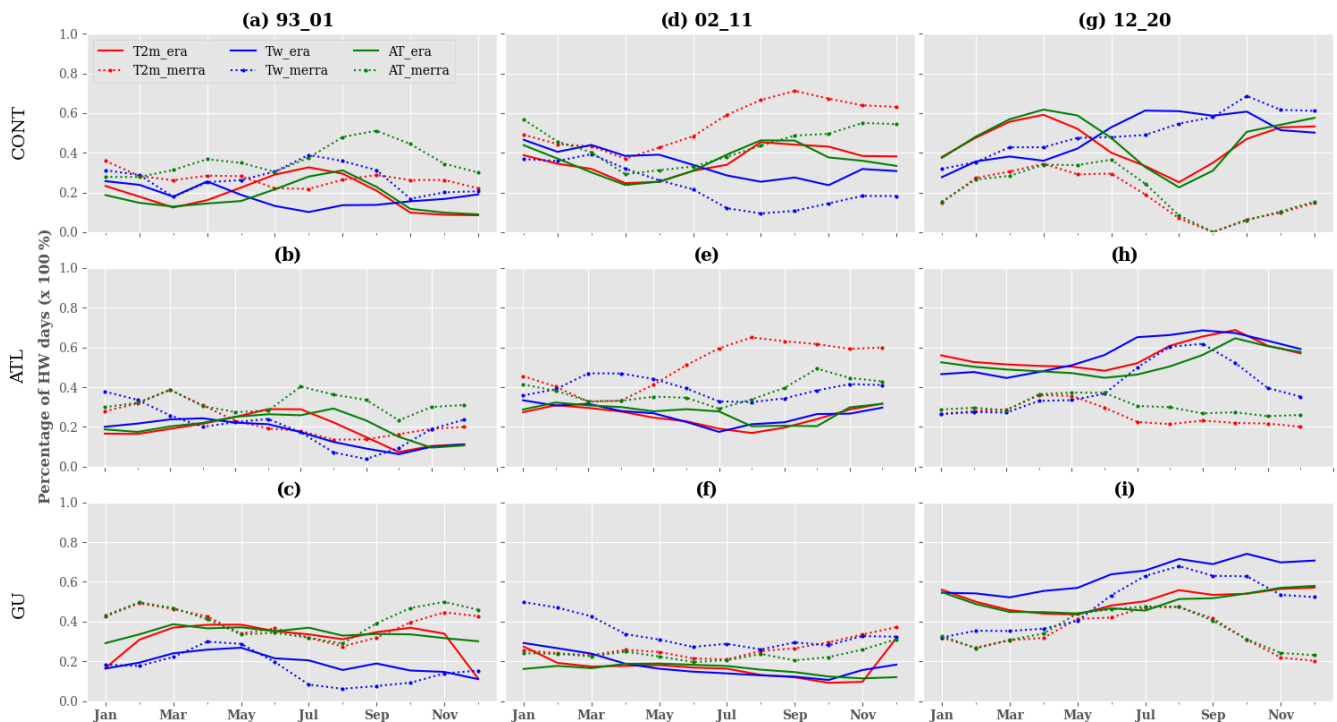


Figure 9. Contribution in percent of the different decades to heat wave duration using maximum values of T_{2m} , T_w and AT over the whole period for (a–c) 1993–2001, (d–f) 2002–2011 and (g–i) 2012–2020. We compute a 3-month running mean to smooth the seasonal cycle. The detection of heat waves is done using the 90th percentile as a threshold over the period in the different regions: (a, d, g) CONT, (b, e, h) ATL and (c, f, i) GU. The solid and dashed red/blue/green lines represent the evolution of heat wave duration using $T_{2m}/T_w/AT$ from ERA5 and MERRA respectively. The y and x axes represent the percentage of heat wave days and the time in months respectively.

The spatial variability of heat wave indicators (T_{2m} and T_w) over West Africa during the seasons (winter, spring, summer and autumn) was investigated. This is done through the computation of the interannual daily standard deviation over the period 1993–2020. We find the lowest values of standard deviation over the three regions of interest (CONT, ATL and GU) during the summer and autumn when we use minimum values of T_{2m} ($T_{2m,min}$) (see Fig. S20). This shows low variability in the signal of $T_{2m,min}$, which indicates favourable conditions for the occurrence of persistent heat waves in these regions during this period. With T_w , there is low variability in the signal during the summer for both minimum and maximum values, indicating persistent events. We find some discrepancies in the reanalysis products ERA5 and MERRA. The results show that ERA5 appears to be hotter than MERRA over the Sahel region. The source of these discrepancies in the reanalyses is very complex and may result from different factors such as the data assimilation techniques (4D-Var and Bonavita et al., 2016, for ERA5; 3D-Var and Courtier et al., 1998, for MERRA), atmospheric models, convective schemes, bias correction methods, spatial resolution and model parameterization. Another major difference between ERA5 and MERRA is in the vertical resolution of the profiles of the atmospheric variables between 0 and 2 km; ERA5 has more atmospheric vertical levels than MERRA

below 2 km, which leads to a more accurate representation of processes in the boundary layer (Taszarek et al., 2021). Many studies have highlighted these differences in the two reanalysis products (e.g. Olauson, 2018; Graham et al., 2019; Taszarek et al., 2021); some authors (e.g. Gensini et al., 2014; Tippet et al., 2014; Allen et al., 2015; Taszarek et al., 2018; King and Kennedy, 2019) have identified model parameterization and the data assimilation technique as possible causes of biases in reanalyses for low-level thermodynamic fields. A more detailed study of the source of these uncertainties is beyond the scope of this paper.

An assessment of the origins of heat waves in the coastal regions of West Africa is discussed. One driver of heat waves over the globe highlighted by many studies is the “blocking high” (e.g. Charney and DeVore, 1979; Coughlan, 1983; Perkins, 2015). This situation occurs when a high system pressure remains in the same region for a longer period of time than is usually expected. The consequence of this phenomenon is the compression of the air mass at the surface, which leads to an increase in temperatures in the region. Perkins (2015) also identified soil moisture–atmosphere interactions and large-scale climate dynamics as other drivers of heat waves.

To address the origin of heat waves in the coastal region, we firstly analysed the interannual variability in the sea sur-




Figure 10. Classification of heat waves using ERA5 reanalysis based on their persistence over the period 1993–2020: (a) T_{2m} , (b) T_w and (c) AT. The detection of heat waves is done using maximum values of the indicators and the climatological daily 90th percentile. Heat wave detection is firstly carried out, and then their duration is computed. Clusters of heat waves based on their duration (3, 4–6, 7–9, 10–12, 13+ d) are created, and finally, we quantify each class of heat waves as a proportion of the total number of events detected. The y and x axes represent the percentage of the heat waves per class and the duration in days respectively. The red/blue/green bars represent the percentage of heat waves detected over CONT/ATL/GU regions (see the “Region of interest” section for more details). The sum of the contribution of heat waves in different clusters is equal to 1 for each region.

face temperature (SST) over the period 1993–2020 using the ERA5 reanalysis. We computed the mean anomalies of SST with respect to the climatology (Fig. S21). Warming over the north-eastern and south-eastern tropical Atlantic Ocean is observed in some years: 1998, 2005, 2008, 2010, 2016, 2019 and 2020. This warming over the tropical Atlantic Ocean affects the whole western African coastal region. In comparison to the interannual variability of heat wave occurrence in the coastal region (see Fig. S12), we noticed that the years of high heat wave frequency correspond to years in which ocean warming was observed: 1998, 2005, 2010, 2016, 2019 and 2020 for instance. These years also correspond to the occurrence of El Niño events. The link between the SST and heat waves has been investigated in more detail in the following. We computed the yearly mean SST anomalies with

respect to heat waves days using the formula below:

$$\text{Ano_SST_year} = \sum_{i=1}^{12} \alpha_i \cdot \text{Ano}_i = \alpha_1 \cdot \text{Ano}_1 + \alpha_2 \cdot \text{Ano}_2 + \alpha_3 \cdot \text{Ano}_3 + \dots + \alpha_{12} \cdot \text{Ano}_{12}, \quad (15)$$

where α_i represents the total number of days in heat waves per month for each year; if there is no event detected, then $\alpha_i = 0$.

For this analysis, we focused on the years with high peaks of heat waves identified previously (1998, 2005, 2008, 2010, 2016, 2019 and 2020) using T_{2m} as an indicator for heat wave detection. We noticed that most of the heat waves are associated with a warming of the tropical Atlantic Ocean except for in some specific years such as 2016 and 2019 in the GU and ATL regions respectively (Fig. 11a, b). In the CONT region, heat waves are influenced by both the west–east airflow coming from the tropical northern Atlantic Ocean and the south–north airflow coming from the tropical southern Atlantic Ocean (Fig. 11c, d). Some years in which a considerable number of heat waves have been detected are not associated with positive anomalies of SST. These heat waves occur during a cold phase of the tropical Atlantic Ocean. There are no major changes observed in the analysis when using AT and T_w as indicators for heat wave detection (not shown). We can suggest from this result that heat waves in the coastal region have many drivers, and one of them at a local scale could be the oceanic forcings through the SST. Large-scale (El Niño, atmospheric circulation) and local-scale (soil–moisture interactions) processes may also contribute to the occurrence of heat waves in the region. This result is in agreement with Russo et al. (2016) and Moron et al. (2016), who identified links between heat waves and El Niño events. The investigation of the physical processes driving heat waves in the coastal region required more in-depth knowledge of local- and large-scale forcings, which is beyond the scope of this paper.

5 Conclusions

The present work assesses the potential uncertainties associated with heat wave detection using reanalysis data (ERA5, MERRA). It also looks into the recent evolution of heat waves in different parts of the West African region.

The first uncertainty highlighted in this study comes from the ERA5 and MERRA reanalyses. We found biases in the reanalysis products; MERRA shows a cold bias compared to ERA5 over the Sahel region and the Guinean region except over some countries (Guinea-Bissau, Sierra Leone, Liberia). Weak correlations between ERA5 and MERRA were found over the Guinea coast using minimum/maximum values of T_{2m} and AT indicators. The representation of extreme values in the reanalyses was analysed, showing that the coherence between the two products is very low, around 0.25, in

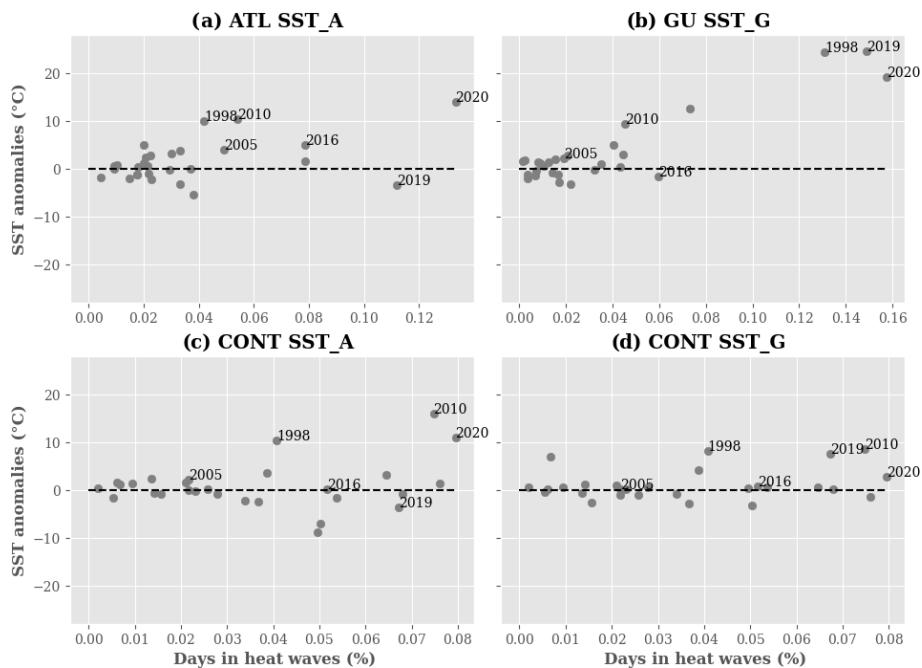


Figure 11. Analysis of the link between SST anomalies and heat waves days over the period 1993–2020 using ERA5 reanalysis and maximum values of T_{2m} in the different regions: (a) ATL, (b) GU, (c–d) CONT. SST_A and SST_G represent the boxes used to compute the SST mean anomalies for the ATL and CONT regions respectively (see Fig. 1). The anomalies are computed as the difference between monthly SST and the monthly climatological values of the SST over the whole period. For each year, the yearly anomalies of SST are computed with respect to the heat waves days. The x and y axes represent the frequency of heat waves days and the SST anomalies respectively. The grey dots represent the years over the period 1993–2020.

the southern Sahel and the Guinean region. This low agreement between the two reanalyses results in discrepancies in the frequency of heat waves associated with each product. Even though the reanalyses present large discrepancies over the southern Sahel and Guinea coast, they are able to preserve the relationship between the variables used for heat wave detection (AT, T_{2m}). Temperatures estimated from local station in Dakar and Abidjan show slightly better correlation with ERA5 than with MERRA. The second uncertainty found here is the sensitivity of the spatial variability of heat waves to the threshold values used to process the monitoring of events. Heat waves detected using low threshold values of the indicators T_{2m} and T_w are very persistent and last for several days, while the duration of heat waves related to the high threshold values is considerably reduced. We notice some discrepancies in the sensitivity to the threshold values of heat waves detected with T_w and T_{2m} . Nighttime and daytime heat waves are in the same range of occurrence, while concomitant events are extremely rare because they are more restrictive. This shows that daytime and nighttime heat waves are distinct phenomena. The climatological state of heat wave occurrence shows large differences between the indicators. Nighttime heat waves associated with T_w are more frequent than those detected with AT, T_{2m} and UTCI. This shows that humidity plays an important role in nighttime events and tends to reinforce concomitant events over the northern Sa-

hel. The spatial variability of daytime heat waves is more consistent for all indicators over the Sahel. The interannual variability of heat waves in the coastal region of West Africa shows for the three indicators (AT, T_{2m} , T_w) some particularly hot years with a high frequency of events: 1998, 2005, 2010, 2016, 2019 and 2020 linked to El Niño events. The GU region is more affected by heat waves during the last decade (2012–2020) than the CONT and ATL regions. The CONT region experienced more persistent and higher-intensity heat waves than the GU region. The seasonal cycle of heat waves shows an increase in the frequency of the events at the beginning of the season and during the retreat phase of the West African monsoon. Conversely, a decrease in heat wave occurrence is observed during the monsoon activity period in the three regions. We observed a reinforcement in the frequency, duration and intensity of heat waves during the last decade (2012–2020). This is a consequence of global warming acting on extreme events. No significant changes in the severity of heat waves have been found in the regions during the 3 decades. Most of the events detected in the regions (75 %) have a duration of around 3–6 d. The most dangerous events, lasting at least 10 d, accounted for up to 12 % of the total number of events. We noticed strong links between SST and heat waves during some specific peak event years, but this was not the case for 2016 and 2019 in the GU and ATL regions respectively. We can infer from this result that there

is a contribution of oceanic forcings in the reinforcement of heat waves in the coastal region among many other drivers. In a future work, we will investigate in more detail the influence of large-scale forcings on heat wave occurrence in this region. In the present study, we detected different types of heat wave based on the methodology and indicator used; this will be very important to investigate their potential impacts on human health and activities.

Code availability. The codes to perform heat wave detection, data interpolation and the rest of the analyses are available on request; please feel free to contact us. The codes were implemented using CDO, R (heatwaveR) and Python libraries.

Data availability. The data used in this study are mostly open access. Data from the ERA5 and MERRA reanalyses are available online at the Climate Data Store (CDS: <https://doi.org/10.24381/cds.adbb2d47>, Hersbach et al., 2023) and on the NASA (<https://doi.org/10.5067/VJAFPLIICSIV>, GMAO, 2015) website respectively. Local station data are not freely available; feel free to write to us if you need them.

Supplement. The supplement related to this article is available online at: <https://doi.org/10.5194/nhess-23-1313-2023-supplement>.

Author contributions. This study was conducted with the collaboration of different researchers, who played an important role at each step. CGNL performed the analyses and the interpretation of the results; CL supervised the work and made some good remarks; MV brought his expertise in statistical interpolation. CGNL, CL, CF and MV discussed the results and wrote the paper. CF and MV provided advice and insightful comments before submission.

Competing interests. The contact author has declared that none of the authors has any competing interests.

Disclaimer. Publisher's note: Copernicus Publications remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Acknowledgements. This work is supported by the French National Research Agency in the framework of the STEWARD project under grant ANR-19-CE03-0012 (2020–2024).

Financial support. This research has been supported by the Agence Nationale de la Recherche (STEWARD; grant no. ANR-19-CE03-0012).

Review statement. This paper was edited by Maria-Carmen Llasat and reviewed by two anonymous referees.

References

- Alduchov, O. A. and Eskridge, R. E.: Improved Magnus form approximation of saturation vapor pressure, *J. Appl. Meteorol. Clim.*, 35, 601–609, 1996.
- Allen, J. T., Tippett, M. K., and Sobel, A. H.: An empirical model relating US monthly hail occurrence to large-scale meteorological environment, *J. Adv. Model. Earth Sy.*, 7, 226–243, 2015.
- Anderson, B. G. and Bell, M. L.: Weather-Related Mortality, *Epidemiology*, 20, 205–213, <https://doi.org/10.1097/EDE.0b013e318190ee08>, 2009.
- August, E. F.: Ueber die Berechnung der Expansivkraft des Wasserdunstes, *Ann. Phys.*, 89, 122–137, <https://doi.org/10.1002/andp.18280890511>, 1828.
- Barbier, J., Guichard, F., Bouniol, D., Couvreur, F., and Roehrig, R.: Detection of Intraseasonal Large-Scale Heat Waves: Characteristics and Historical Trends during the Sahelian Spring, *J. Climate*, 31, 61–80, <https://doi.org/10.1175/JCLI-D-17-0244.1>, 2018.
- Batté, L., Ardilouze, C., and Déqué, M.: Forecasting West African Heat Waves at Subseasonal and Seasonal Time Scales, *Mon. Weather Rev.*, 146, 889–907, <https://doi.org/10.1175/MWR-D-17-0211.1>, 2018.
- Beniston, M., Stoffel, M., and Guillet, S.: Comparing observed and hypothetical climates as a means of communicating to the public and policymakers: The case of European heatwaves, *Environ. Sci. Policy*, 67, 27–34, <https://doi.org/10.1016/j.envsci.2016.11.008>, 2017.
- Bonavita, M., Hólm, E., Isaksen, L., and Fisher, M.: The evolution of the ECMWF hybrid data assimilation system, *Q. J. Roy. Meteor. Soc.*, 142, 287–303, <https://doi.org/10.1002/qj.2652>, 2016.
- Braga, A. L. F., Zanobetti, A., and Schwartz, J.: The effect of weather on respiratory and cardiovascular deaths in 12 U.S. cities, *Environ. Health Persp.*, 110, 859–863, <https://doi.org/10.1289/ehp.02110859>, 2002.
- Buck, A. L.: New equations for computing vapor pressure and enhancement factor, *J. Appl. Meteorol. Clim.*, 20, 1527–1532, 1981.
- Ceccherini, G., Russo, S., Ametztoy, I., Marchese, A. F., and Carmona-Moreno, C.: Heat waves in Africa 1981–2015, observations and reanalysis, *Nat. Hazards Earth Syst. Sci.*, 17, 115–125, <https://doi.org/10.5194/nhess-17-115-2017>, 2017.
- Charney, J. G. and DeVore, J. G.: Multiple flow equilibria in the atmosphere and blocking, *J. Atmos. Sci.*, 36, 1205–1216, 1979.
- Coughlan, M.: A comparative climatology of blocking action in the two hemispheres, *Aust. Meteorol. Mag.*, 31, 3–13, 1983.
- Courtier, P., Andersson, E., Heckley, W., Vasiljevic, D., Hamrud, M., Hollingsworth, A., Rabier, F., Fisher, M., and Pailleux, J.: The ECMWF implementation of three-dimensional variational assimilation (3D-Var). I: Formulation, *Q. J. Roy. Meteor. Soc.*, 124, 1783–1807, <https://doi.org/10.1002/qj.49712455002>, 1998.
- Déqué, M., Calmanti, S., Christensen, O. B., Aquila, A. D., Maule, C. F., Haensler, A., Nikulin, G., and Teichmann, C.: A multi-model climate response over tropical Africa at +2 °C, *Climate Services*, 7, 87–95, 2017.

- Di Napoli, C., Barnard, C., Prudhomme, C., Cloke, H. L., and Papenberger, F.: ERA5-HEAT: A global gridded historical dataset of human thermal comfort indices from climate reanalysis, *Geosci. Data J.*, 8, 2–10, <https://doi.org/10.1002/gdj3.102>, 2021.
- Dosio, A.: Projection of temperature and heat waves for Africa with an ensemble of CORDEX Regional Climate Models, *Clim. Dynam.*, 49, 493–519, <https://doi.org/10.1007/s00382-016-3355-5>, 2017.
- Dosio, A., Mentaschi, L., Fischer, E. M., and Wyser, K.: Extreme heat waves under 1.5 °C and 2 °C global warming, *Environ. Res. Lett.*, 13, 054006, <https://doi.org/10.1088/1748-9326/aab827>, 2018.
- Engdaw, M. M., Ballinger, A. P., Hegerl, G. C., and Steiner, A. K.: Changes in temperature and heat waves over Africa using observational and reanalysis data sets, *Int. J. Climatol.*, 42, 1165–1180, 2022.
- Eyring, V., Gillett, N. P., Achutarao, K., Barimalala, R., Barreiro Parrillo, M., Bellouin, N., Cassou, C., Durack, P., Kosaka, Y., McGregor, S., Min, S., Morgenstern, O., and Sun, Y.: Human Influence on the Climate System, in: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, IPCC Sixth Assessment Report*, edited by: Masson-Delmotte, V., Zhai, V., Pirani, A., Connors, S. L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M. I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J. B. R., Maycock, T. K., Waterfield, T., Yelekçi, O., Yu, R., and Zhou, B., Cambridge University Press, <https://elib.dlr.de/144265/> (last access: 4 April 2023), 2021.
- Fischer, E. M. and Schär, C.: Consistent geographical patterns of changes in high-impact European heatwaves, *Nat. Geosci.*, 3, 398–403, 2010.
- Fontaine, B., Janicot, S., and Monerie, P.-A.: Recent changes in air temperature, heat waves occurrences, and atmospheric circulation in Northern Africa, *J. Geophys. Res.-Atmos.*, 118, 8536–8552, <https://doi.org/10.1002/jgrd.50667>, 2013.
- Fouillet, A., Rey, G., Laurent, F., Pavillon, G., Bellec, S., Guihenneuc-Jouyau, C., Clavel, J., Jouglu, E., and Hémon, D.: Excess mortality related to the August 2003 heat wave in France, *Int. Arch. Occ. Env. Hea.*, 80, 16–24, <https://doi.org/10.1007/s00420-006-0089-4>, 2006.
- Gasparrini, A. and Armstrong, B.: The impact of heat waves on mortality, *Epidemiology*, 22, 68–73, <https://doi.org/10.1097/EDE.0b013e3181fdcd99>, 2011.
- Gelaro, R., McCarty, W., Suárez, M. J., Todling, R., Molod, A., Takacs, L., Randles, C. A., Darmenov, A., Bosilovich, M. G., Reichle, R., Wargan, K., Coy, L., Cullather, R., Draper, C., Akella, S., Buchard, V., Conaty, A., da Silva, A. M., Gu, W., Kim, G.-K., Koster, R., Lucchesi, R., Merkova, D., Nielsen, J. E., Parityka, G., Pawson, S., Putman, W., Rienecker, M., Schubert, S. D., Sienkiewicz, M., and Zhao, B.: The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2), *J. Climate*, 30, 5419–5454, <https://doi.org/10.1175/JCLI-D-16-0758.1>, 2017.
- Gensini, V. A., Mote, T. L., and Brooks, H. E.: Severe-thunderstorm reanalysis environments and collocated radiosonde observations, *J. Appl. Meteorol. Clim.*, 53, 742–751, 2014.
- Gleixner, S., Demissie, T., and Diro, G. T.: Did ERA5 improve temperature and precipitation reanalysis over East Africa?, *Atmosphere*, 11, 996, <https://doi.org/10.3390/atmos11090996>, 2020.
- Global Modeling and Assimilation Office (GMAO): MERRA-2 tavg1_2d_slv_Nx: 2d,1-Hourly,Time-Averaged,Single-Level,Assimilation,Single-Level Diagnostics V5.12.4, Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC) [data set], <https://doi.org/10.5067/VJAFPL1CSIV>, 2015.
- Graham, R. M., Hudson, S. R., and Maturilli, M.: Improved performance of ERA5 in Arctic gateway relative to four global atmospheric reanalyses, *Geophys. Res. Lett.*, 46, 6138–6147, 2019.
- Guigma, K. H., Todd, M., and Wang, Y.: Characteristics and thermodynamics of Sahelian heatwaves analysed using various thermal indices, *Clim. Dynam.*, 55, 3151–3175, <https://doi.org/10.1007/s00382-020-05438-5>, 2020.
- Hajat, S., Kovats, R. S., and Lachowycz, K.: Heat-related and cold-related deaths in England and Wales: who is at risk?, *Occup. Environ. Med.*, 64, 93–100, <https://doi.org/10.1136/oem.2006.029017>, 2007.
- Hartmann, D. L., Tank, A. M. K., Rusticucci, M., Alexander, L. V., Brönnimann, S., Charabi, Y. A. R., Dentener, F. J., Dlugokencky, E. J., Easterling, D. R., Kaplan, A., Soden, B. J., Thorne, P. W., Wild, M., and Zhai, P. M.: Observations: atmosphere and surface, in: *Climate change 2013 the physical science basis: Working group I contribution to the fifth assessment report of the intergovernmental panel on climate change*, edited by: Stocker, T. F., Qin, D., Plattner, G.-K., Tignor, M., Allen, S. K., Boschung, J., Nauels, A., Xia, Y., Bex, V., and Midgley, P. M., Cambridge University Press, 159–254, 2013.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., De Chiara, G., Dahlgren, P., Dee, D., Diamantakis, M., Dragani, R., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, R. J., Hólm, E., Janisková, M., Keeley, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., de Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., and Thépaut, J.-N.: The ERA5 global reanalysis, *Q. J. Roy. Meteor. Soc.*, 146, 1999–2049, <https://doi.org/10.1002/qj.3803>, 2020.
- Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., and Thépaut, J.-N.: ERA5 hourly data on single levels from 1940 to present, Copernicus Climate Change Service (C3S) Climate Data Store (CDS) [data set], <https://doi.org/10.24381/cds.adbb2d47>, 2023.
- Huynen, M. M., Martens, P., Schram, D., Weijenberg, M. P., and Kunst, A. E.: The impact of heat waves and cold spells on mortality rates in the Dutch population, *Environ. Health Persp.*, 109, 463–470, <https://doi.org/10.1289/ehp.01109463>, 2001.
- King, A. T. and Kennedy, A. D.: North American supercell environments in atmospheric reanalyses and RUC-2, *J. Appl. Meteorol. Clim.*, 58, 71–92, 2019.
- Kovats, R. S. and Hajat, S.: Heat Stress and Public Health: A Critical Review, *Annu. Rev. Publ. Health*, 29, 41–55, <https://doi.org/10.1146/annurev.publhealth.29.020907.090843>, 2008.

- Largerion, Y., Guichard, F., Roehrig, R., Couvreur, F., and Barbier, J.: The April 2010 North African heatwave: when the water vapor greenhouse effect drives nighttime temperatures, *Clim. Dynam.*, 54, 3879–3905, <https://doi.org/10.1007/s00382-020-05204-7>, 2020.
- Lavaysse, C., Cammalleri, C., Dosio, A., van der Schrier, G., Toreti, A., and Vogt, J.: Towards a monitoring system of temperature extremes in Europe, *Nat. Hazards Earth Syst. Sci.*, 18, 91–104, <https://doi.org/10.5194/nhess-18-91-2018>, 2018.
- Lorenzo, N., Díaz-Poso, A., and Royé, D.: Heatwave intensity on the Iberian Peninsula: Future climate projections, *Atmos. Res.*, 258, 105655, <https://doi.org/10.1016/j.atmosres.2021.105655>, 2021.
- Loughnan, M.: Heatwaves are silent killers, *Geodate*, 27, 7–10, 2014.
- Magnus, G.: Versuche über die Spannkraft des Wasserdampfes, *Annalen der Physik*, 137, 225–247, <https://doi.org/10.1002/andp.18441370202>, 1844.
- McGregor, G. R., Bessmoulin, P., Ebi, K., and Menne, B.: Heatwaves and health: guidance on warning-system development, WMO and WHO, WMO-No. 1142, 114 pp., ISBN 978-92-63-11142-5, 2015.
- Moron, V., Oueslati, B., Pohl, B., Rome, S., and Janicot, S.: Trends of mean temperatures and warm extremes in northern tropical Africa (1961–2014) from observed and PPCA-reconstructed time series, *J. Geophys. Res.-Atmos.*, 121, 5298–5319, 2016.
- Murari, K. K. and Ghosh, S.: Future Heat Wave Projections and Impacts, in: *Climate Change Signals and Response: A Strategic Knowledge Compendium for India*, edited by: Venkataraman, C., Mishra, T., Ghosh, S., and Karmakar, S., Springer, 91–107, https://doi.org/10.1007/978-981-13-0280-0_6, 2019.
- Mutiibwa, D., Vavrus, S. J., McAfee, S. A., and Albright, T. P.: Recent spatiotemporal patterns in temperature extremes across conterminous United States, *J. Geophys. Res.-Atmos.*, 120, 7378–7392, 2015.
- Ngoungue Langue, C. G., Lavaysse, C., Vrac, M., Peyrillé, P., and Flamant, C.: Seasonal forecasts of the Saharan heat low characteristics: a multi-model assessment, *Weather Clim. Dynam.*, 2, 893–912, <https://doi.org/10.5194/wcd-2-893-2021>, 2021.
- Olauson, J.: ERA5: The new champion of wind power modelling?, *Renew. Energ.*, 126, 322–331, 2018.
- Oueslati, B., Pohl, B., Moron, V., Rome, S., and Janicot, S.: Characterization of Heat Waves in the Sahel and Associated Physical Mechanisms, *J. Climate*, 30, 3095–3115, <https://doi.org/10.1175/JCLI-D-16-0432.1>, 2017.
- Pandis, N.: The chi-square test, *Am. J. Orthod. Dentofac.*, 150, 898–899, 2016.
- Perkins, S. E.: A review on the scientific understanding of heatwaves—Their measurement, driving mechanisms, and changes at the global scale, *Atmos. Res.*, 164–165, 242–267, <https://doi.org/10.1016/j.atmosres.2015.05.014>, 2015.
- Perkins, S. E. and Alexander, L. V.: On the Measurement of Heat Waves, *J. Climate*, 26, 4500–4517, <https://doi.org/10.1175/JCLI-D-12-00383.1>, 2013.
- Perkins, S. E., Alexander, L. V., and Nairn, J. R.: Increasing frequency, intensity and duration of observed global heatwaves and warm spells, *Geophys. Res. Lett.*, 39, L20714, <https://doi.org/10.1029/2012GL053361>, 2012.
- Ramon, J., Lledó, L., Torralba, V., Soret, A., and Doblás-Reyes, F. J.: What global reanalysis best represents near-surface winds?, *Q. J. Roy. Meteor. Society*, 145, 3236–3251, 2019.
- Robinson, P. J.: On the Definition of a Heat Wave, *J. Appl. Meteorol. Clim.*, 40, 762–775, [https://doi.org/10.1175/1520-0450\(2001\)040<0762:OTDOAH>2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<0762:OTDOAH>2.0.CO;2), 2001.
- Rocklöv, J., Forsberg, B., Ebi, K., and Bellander, T.: Susceptibility to mortality related to temperature and heat and cold wave duration in the population of Stockholm County, Sweden, *Global Health Action*, 7, 22737, <https://doi.org/10.3402/gha.v7.22737>, 2014.
- Russo, S., Marchese, A. F., Sillmann, J., and Immé, G.: When will unusual heat waves become normal in a warming Africa?, *Environ. Res. Lett.*, 11, 054016, <https://doi.org/10.1088/1748-9326/11/5/054016>, 2016.
- Shafei Shiva, J., Chandler, D. G., and Kunkel, K. E.: Localized Changes in Heat Wave Properties Across the United States, *Earth's Future*, 7, 300–319, <https://doi.org/10.1029/2018EF001085>, 2019.
- Shaposhnikov, D., Revich, B., Bellander, T., Bedada, G. B., Bottai, M., Kharkova, T., Kvasha, E., Lezina, E., Lind, T., Semutnikova, E., and Pershagen, G.: Mortality Related to Air Pollution with the Moscow Heat Wave and Wildfire of 2010, *Epidemiology*, 25, 359–364, <https://doi.org/10.1097/EDE.000000000000090>, 2014.
- Smith, T. T., Zaitchik, B. F., and Gohlke, J. M.: Heat waves in the United States: definitions, patterns and trends, *Climatic Change*, 118, 811–825, <https://doi.org/10.1007/s10584-012-0659-2>, 2013.
- Steadman, R. G.: The Assessment of Sultriness. Part I: A Temperature-Humidity Index Based on Human Physiology and Clothing Science, *J. Appl. Meteorol. Clim.*, 18, 861–873, [https://doi.org/10.1175/1520-0450\(1979\)018<0861:TAOSPI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1979)018<0861:TAOSPI>2.0.CO;2), 1979a.
- Steadman, R. G.: The assessment of sultriness. Part II: effects of wind, extra radiation and barometric pressure on apparent temperature, *J. Appl. Meteorol.*, 18, 874–885, 1979b.
- Steadman, R. G.: A universal scale of apparent temperature, *J. Appl. Meteorol. Clim.*, 23, 1674–1687, 1984.
- Stefanon, M., D'Andrea, F., and Drobinski, P.: Heatwave classification over Europe and the Mediterranean region, *Environ. Res. Lett.*, 7, 014023, <https://doi.org/10.1088/1748-9326/7/1/014023>, 2012.
- Stull, R.: Wet-Bulb Temperature from Relative Humidity and Air Temperature, *J. Appl. Meteorol. Clim.*, 50, 2267–2269, <https://doi.org/10.1175/JAMC-D-11-0143.1>, 2011.
- Tan, J., Zheng, Y., Tang, X., Guo, C., Li, L., Song, G., Zhen, X., Yuan, D., Kalkstein, A. J., Li, F., and Chen, H.: The urban heat island and its impact on heat waves and human health in Shanghai, *Int. J. Biometeorol.*, 54, 75–84, <https://doi.org/10.1007/s00484-009-0256-x>, 2010.
- Taszarek, M., Brooks, H. E., Czernecki, B., Szuster, P., and Fortuniak, K.: Climatological aspects of convective parameters over Europe: A comparison of ERA-Interim and sounding data, *J. Climate*, 31, 4281–4308, 2018.
- Taszarek, M., Pilguy, N., Allen, J. T., Gensini, V., Brooks, H. E., and Szuster, P.: Comparison of convective parameters derived from ERA5 and MERRA-2 with rawinsonde data over Europe and North America, *J. Climate*, 34, 3211–3237, 2021.

- Tippett, M. K., Sobel, A. H., Camargo, S. J., and Allen, J. T.: An empirical relation between US tornado activity and monthly environmental parameters, *J. Climate*, 27, 2983–2999, 2014.
- Wang, P., Tang, J., Sun, X., Liu, J., and Juan, F.: Spatiotemporal characteristics of heat waves over China in regional climate simulations within the CORDEX-EA project, *Clim. Dynam.*, 52, 799–818, <https://doi.org/10.1007/s00382-018-4167-6>, 2019.
- Wehner, M., Castillo, F., and Stone, D.: The impact of moisture and temperature on human health in heat waves, in: *Oxford Research Encyclopedia of Natural Hazard Science*, Oxford University Press, <https://doi.org/10.1093/acrefore/9780199389407.013.58>, 2017.
- Wu, W.-S., Purser, R. J., and Parrish, D. F.: Three-dimensional variational analysis with spatially inhomogeneous covariances, *Mon. Weather Rev.*, 130, 2905–2916, 2002.
- Yu, S., Tett, S. F. B., Freychet, N., and Yan, Z.: Changes in regional wet heatwave in Eurasia during summer (1979–2017), *Environ. Res. Lett.*, 16, 064094, <https://doi.org/10.1088/1748-9326/ac0745>, 2021.

4.4 Discussion sur l'origine des vagues de chaleur en zone côtière

Le monitoring des vagues de chaleur dans les trois régions climatiques a permis de mettre en évidence des années de pics de fréquence, intensité et durée d'événements notamment : 1998, 2005, 2010, 2016, 2019 et 2020. Les années 1998, 2005, 2010, 2016 correspondent aux années durant lesquelles l'on a enregistré des événements El Niño [Fig.4.2] qui se caractérisent principalement par un réchauffement anormal de la température de la surface de la mer (SST). Ce constat nous amène à nous interroger sur le lien entre les vagues de chaleur en zone côtière et le phénomène El Niño déjà souligné dans certaines études antérieures (Russo et al., 2016b; Moron et al., 2016). Dans cette perspective, nous avons investigué l'évolution de la SST sur la période d'étude (1993-2020) avec un intérêt particulier pour les années citées ci-dessus. On observe clairement un réchauffement de l'océan Atlantique tropical durant les années de pics de vague de chaleur [Fig.4.3], mais il est important de noter quelques différences entre l'évolution des biais de la SST en zone côtière. Durant les années 1998, 2008, 2010 et 2020, on note un biais chaud de l'océan Atlantique nord qui recouvre toute la zone côtière Atlantique et Guinéenne. Par contre, durant les années 1997 et 2005, on observe un dipôle caractérisé par un réchauffement dans l'océan Atlantique nord et un refroidissement dans la partie sud. Il en est de même durant les années 2018 et 2019 mais cette fois avec un dipôle inversé par rapport au précédent. Cette évolution de la SST laisse en suspens pas mal d'interrogations sur leur lien avec les vagues de chaleur dans la région. De fait, une analyse plus détaillée a été effectuée à travers le calcul de l'anomalie annuelle de la SST durant les jours de vague de chaleur à partir de la formule suivante :

$$\text{Ano_SST_year} = \sum_{i=1}^{12} \alpha_i * \text{Ano}_i = \alpha_1 * \text{Ano}_1 + \alpha_2 * \text{Ano}_2 + \alpha_3 * \text{Ano}_3 + \dots + \alpha_{12} * \text{Ano}_{12} \quad (4.2)$$

α_i désigne le nombre total de jours dans les vagues de chaleur par mois pour chaque année, si aucun événement n'est détecté $\alpha_i = 0$.

Cette analyse est effectuée principalement pour les années avec des pics de vagues de chaleur (1998, 2005, 2010, 2016, 2019 et 2020) en utilisant T^2m, Tw et AT comme indicateurs pour la détection de ces dernières dans les trois régions climatiques (ATL, CONT, GU). En général, on remarque que les vagues de chaleur se produisant en zone côtière durant nos années cibles sont associées pour la grande majorité à un réchauffement de l'océan Atlantique tropical, à l'exception de quelques années spécifiques telles que 2016 et 2019 respectivement dans les régions GU et ATL [Fig.4.4 (a,b)]. On remarque aussi dans ces deux régions, une certaine cohérence dans l'évolution saisonnière des vagues de chaleur et les anomalies de SST [Fig.4.5 (a,b)]. Dans la région CONT, les vagues de chaleur sont influencées à la fois par le flux d'air ouest-est provenant de l'océan Atlantique tropical nord et par le flux d'air sud-nord provenant de l'océan Atlantique tropical sud [Fig.4.4 (c,d)]. Nous pouvons donc suggérer à partir de ces résultats que les vagues de chaleur en région côtière ont plusieurs origines, et l'une d'entre elle à l'échelle locale serait le forçage océanique par l'intermédiaire de la SST. Des processus de grande échelle (El Niño, circulation atmosphérique (blocage anti-cyclonique)) et à l'échelle locale (interactions sol-humidité) pourraient également contribuer à l'occurrence des vagues de chaleur dans la région.


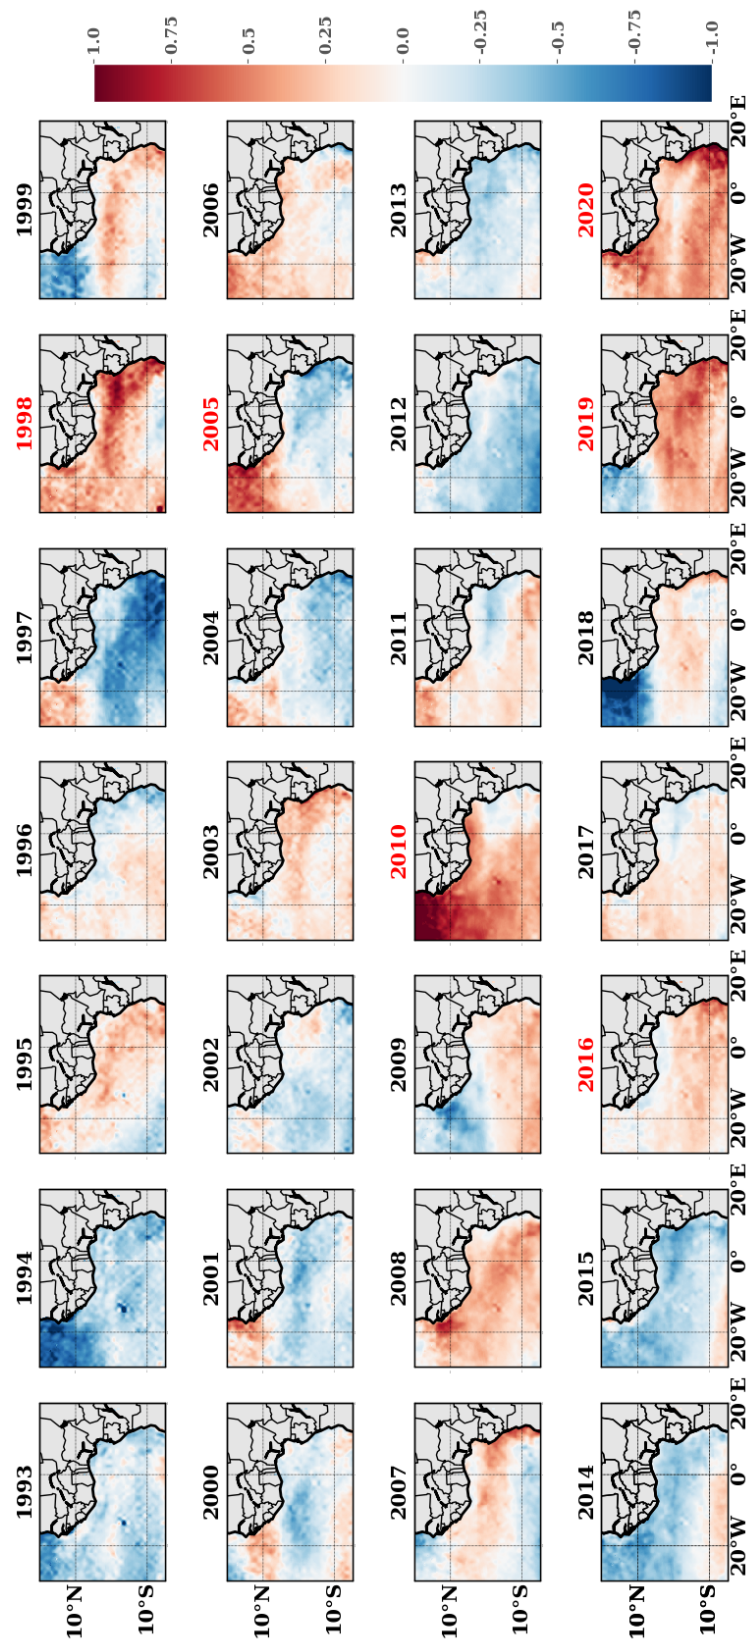


Figure 4.2 – Chronologie des événements El Niño [<http://www.bom.gov.au/climate/history/enso/>]

Figure 4.3 – Évolution interannuelle des anomalies de SST sur la période 1993-2020. Les anomalies annuelles de la SST sont calculées par rapport à la moyenne de la SST sur la période. Les années en rouge sont des années de pics de vague de chaleur enregistrées dans les 3 régions.



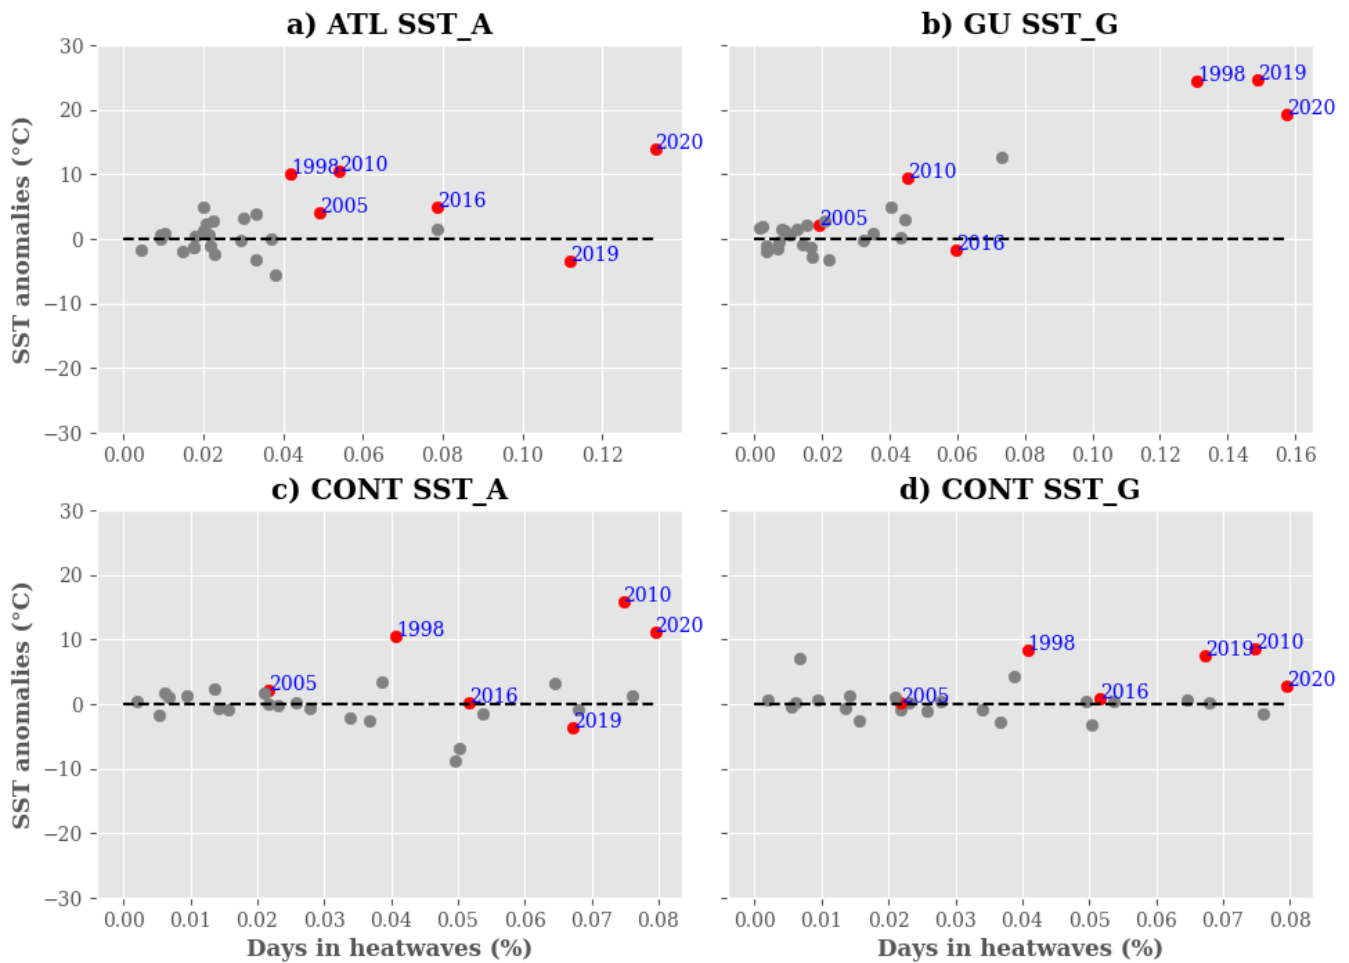


Figure 4.4 – Analyse du lien entre les anomalies de SST et les jours de vague de chaleur sur la période 1993-2020 en utilisant la réanalyse ERA5 et les valeurs maximales de T_{2m} dans les différentes régions : **a) ATL, b) GU, c-d) CONT.** "SST_A" et "SST_G" représentent les blocs utilisés pour calculer les anomalies moyennes de SST respectivement pour les régions ATL et CONT (voir [Fig.3.3.1]). Les anomalies sont calculées comme la différence entre la SST mensuelle et les valeurs climatologiques mensuelles de SST sur l'ensemble de la période. Pour chaque année, les anomalies annuelles de SST sont calculées en fonction des jours de vague de chaleur. Les axes X et Y représentent respectivement la fréquence des jours de canicule et les anomalies de SST. Les points gris représentent les années de la période 1993-2020.




Figure 4.5 – Évolution saisonnière des anomalies de SST et les jours de vague de chaleur sur la période 1993-2020 en utilisant la réanalyse ERA5 et les valeurs maximales de T_{2m} dans les différentes régions : **a) ATL, b) GU, c-d) CONT.** "SST_A" et "SST_G" représentent les blocs utilisés pour calculer les anomalies moyennes de SST respectivement pour les régions ATL et CONT (voir [Fig.3.3.1]). Les anomalies sont calculées comme la différence entre la SST mensuelle et les valeurs climatologiques mensuelles de SST sur l'ensemble de la période. Pour chaque année, les anomalies annuelles de SST sont calculées en fonction des jours de vague de chaleur. Les axes X et Y représentent respectivement les mois de l'année et la fréquence mensuelle des anomalies de SST (et les jours de vague de chaleur) sur toute la période. Les courbes bleues et grises représentent respectivement l'évolution saisonnière des anomalies de SST et des jours dans les vagues de chaleur.

4.5 Conclusion et perspectives

Dans cette partie, il était question de déterminer les potentielles sources d'incertitude rencontrées lors de la détection des vagues de chaleur d'une part, et d'autre part, analyser l'évolution de la fréquence et des caractéristiques de ces dernières au cours de la période 1993-2020 dans les grandes villes ouest-Africaines. Face à la faible couverture spatiale des données d'observation dans les villes Africaines, cette étude utilise principalement les données de réanalyse. La première source d'incertitude mise en évidence dans cette étude provient des données utilisées : les réanalyses ERA5 et MERRA. Nous avons trouvé d'importants biais dans les produits de réanalyse ; MERRA présente un biais froid par rapport à ERA5 sur la région du Sahel et la région Guinéenne sauf sur certains pays (Guinée Bissau, Sierra Leone, Libéria). La concordance entre les deux réanalyse dans la représentation des températures extrêmes reste très faible dans ces deux régions. Ces différences observées entre les deux réanalyses impacteront sans aucun doute sur la fréquence des événements détectés dans chaque produit. Toutefois les réanalyses préservent les relations entre les variables utilisées pour la détection des vagues de chaleur (AT, T2m). Les températures estimées à partir des stations locales de Dakar et d'Abidjan présentent une meilleure corrélation avec ERA5 par rapport à MERRA. La deuxième source d'incertitude repose sur le choix du seuil utilisé pour la définition d'une vague de chaleur. Nous avons pu observer une forte sensibilité de la distribution spatiale des vagues de chaleur en fonction des valeurs seuils choisies pour la détection des événements. Les vagues de chaleur détectées à partir des seuils faibles (Q_{75} , Q_{80}) des indicateurs T_{2m} et T_w sont très persistantes et durent plusieurs jours, alors que la durée des vagues de chaleur associées aux seuils élevés (Q_{85} , Q_{90}) est considérablement réduite. La méthodologie utilisée pour le monitoring d'une vague de chaleur constitue la troisième source d'incertitude. Elle repose sur deux aspects : l'indicateur utilisé et ses valeurs (valeurs minimale, maximale et moyenne). En se référant aux valeurs des indicateurs utilisés, trois types de vagues de chaleur ont été analysées : les vagues de chaleur nocturnes, diurnes et celles se produisant concomitamment la nuit et le jour. Les vagues de chaleur nocturnes et diurnes se situent dans la même fourchette d'occurrence, tandis que les événements concomitants sont ex-

trêmement rares parce qu'ils sont plus restrictifs. Ce résultat montre que les vagues de chaleur diurnes et nocturnes sont des phénomènes complètement distincts. L'évolution climatologique de l'occurrence des vagues de chaleur montre de grandes différences entre les indicateurs. Les vagues de chaleur nocturnes associées à T_w sont plus fréquentes que celles détectées avec AT , T_{2m} , $UTCI$. Ceci montre que l'humidité joue un rôle important dans l'occurrence des vagues de chaleur nocturnes et tend à renforcer les événements concomitants sur le nord du Sahel. Ce résultat est en accord avec [Largerion et al. \(2020\)](#) qui ont mis en évidence le rôle de la vapeur d'eau sur les vagues de chaleur nocturnes au Sahel. L'analyse de la variabilité inter-annuelle des vagues de chaleur dans la région côtière a permis de mettre en évidence pour les 3 indicateurs (AT , T_{2m} , T_w) des années particulièrement chaudes avec une fréquence élevée d'événements : 1998, 2005, 2010, 2016, 2019 et 2020. La région GU est plus touchée par les vagues de chaleur au cours de la dernière décennie (2012-2020) que les régions CONT et ATL. Toutefois, les vagues de chaleur les plus persistantes et les plus intenses se produisent dans la région CONT. Le cycle saisonnier des vagues de chaleur montre une augmentation de la fréquence des événements en début de saison et pendant la phase de retrait de la mousson ouest-Africaine. A l'inverse, une diminution de l'occurrence des vagues de chaleur est observée pendant la période d'activité de la mousson dans les 3 régions. L'on note durant la dernière décennie (2012-2020) un renforcement de la fréquence, de la durée et de l'intensité des vagues de chaleur. Il s'agirait d'une conséquence du réchauffement climatique sur les événements extrêmes. Néanmoins, aucun changement significatif sur la sévérité des vagues de chaleur n'a été observé dans les régions au cours des trois décennies. Les vagues de chaleur détectées dans les trois régions pour la grande majorité (75%) ont une durée d'environ 3 à 6 jours. Les événements les plus dangereux, qui durent au moins 10 jours, représentent jusqu'à 12% du nombre total d'événements. Les années de pics de vague de chaleur identifiées correspondent pour la plupart aux années El Niño. L'analyse de l'évolution inter-annuelle de la TSM a permis de mettre en évidence un réchauffement de l'océan Atlantique tropical durant ces années, à l'exception des années 2016 et 2019 respectivement dans les régions GU et ATL. Nous pouvons déduire de ce résultat qu'il existe une contribution des forçages océaniques dans le renforcement des vagues de chaleur dans la région côtière parmi de nombreux

autres facteurs de grande échelle tels que le blocage anticyclonique, et à l'échelle locale (les interactions sol-humidité). Ce résultat est en parfait accord avec les études antérieures ([Moron et al., 2016](#); [Russo et al., 2016b](#)).

En perspective pour ce travail, il serait important de s'intéresser aux processus à l'origine des pics de vague de chaleur en région côtière durant les phases de refroidissement de l'océan Atlantique tropical (le cas des années 2016 et 2019 respectivement dans les régions GU et ATL). Des questions restent encore en suspens sur l'origine de ces événements : seraient-ils engendrés par des processus locaux? processus de grande échelle? La présente étude s'inscrivant dans le cadre du projet STEWARD qui vise à développer un système d'alertes précoces multi-aléas, il serait nécessaire d'étudier les impacts sur la santé et les activités humaines des différents types de vague de chaleur détectées.

Chapitre 5

Prévisibilité des vagues de chaleur dans les villes ouest-Africaines à l'échelle intra-saisonnière

5.1 Introduction

L'impact des vagues de chaleur sur différents secteurs, notamment l'économie et la santé, en fait l'un des risques climatiques les plus dangereux à l'échelle mondiale (Perkins, 2015). Les vagues de chaleur constituent une menace importante pour la santé humaine, car elles provoquent un malaise et un stress thermique dans la régulation de la température corporelle. L'augmentation de la teneur en humidité de l'air peut exacerber le stress thermique et entraîner des décès de suite d'hyperthermie, en particulier chez les populations les plus vulnérables telles que les enfants et les personnes âgées. Les projections climatiques indiquent une augmentation de la fréquence, de l'intensité et de la durée des températures extrêmes au cours du prochain siècle et au-delà (Kharin et al., 2007; Fischer and Schär, 2010; Perkins et al., 2012). Sous ces conditions de réchauffement, les événements extrêmes tels que les vagues de chaleur deviendront plus récurrents. Au regard des conséquences des vagues de chaleur sur les activités humaines et la santé, il est nécessaire de disposer de prévisions climatiques précises et fiables à l'échelle intra-

saisonnaire afin d'anticiper les risques et de développer des solutions appropriées (Lowe et al., 2016). À cet effet, les systèmes d'alerte précoce sont d'une importance cruciale pour fournir des informations sur l'occurrence de tels événements. Ces systèmes d'alerte utilisent généralement des prévisions saisonnières leur permettant d'accéder à des informations sur la tendance (durée et fréquence) des vagues de chaleur au cours de la saison. Toutefois, en se référant sur leur expérience d'utilisation des produits de prévision, les services climatiques suggèrent que l'échelle intra-saisonnaire est également très pertinente pour développer des actions visant à atténuer les conséquences humaines et sanitaires des températures extrêmes et des vagues de chaleur (White et al., 2017). Les prévisions intra-saisonniers à saisonnières sont lancées pour une période comprise entre 2 semaines et 2 mois. Les prévisions intra-saisonniers à saisonnières (S2S) sont d'une grande importance pour les services humanitaires afin de mettre en place un concept d'alerte précoce "**Ready-Set-Go**" qui permet d'agir rapidement avant l'occurrence d'une potentielle catastrophe naturelle. Dans le dernier rapport du Groupe d'Experts Intergouvernemental sur l'évolution du climat (Rapport 2023 du GIEC), les auteurs montrent que les régions équatoriales seront plus affectées par le changement climatique que les régions situées aux latitudes moyennes. Dans certaines régions équatoriales, comme l'Afrique sub-saharienne, la prévisibilité des vagues de chaleur reste un secteur encore très peu exploré. Face à la vulnérabilité des populations Africaines à ces événements, il est primordial de se pencher sur cette question afin de développer des systèmes d'alerte fiables. C'est dans cette perspective, que nous apportons notre contribution à travers ce travail qui est à notre connaissance, l'une des premières de ce type dans la région.

Dans le cadre de cette étude, nous évaluons la prédictibilité des vagues de chaleur dans les grandes villes ouest-Africaines réparties en trois zones climatiques (AT, CONT, GU voir [Fig.3.3.1]), les mêmes que dans le chapitre précédent. À cette fin, deux modèles de prévision intra-saisonnaire faisant partie du projet S2S (Sub-seasonal to seasonal, (Vitart et al., 2017)) : le modèle du Centre Européen de Prévisions Météorologiques à Moyen Terme (CEPMMT) et UKMO du centre météorologique Britannique ont été utilisés sur la période 2001-2020. Les modèles du CEPMMT et UKMO ont été choisis parce qu'ils couvrent toute la période d'étude. L'évaluation des modèles

est effectuée à partir de deux réanalyses les plus utilisées en Afrique : ERA5 du centre Européen et MERRA-2 de la NASA. En se référant à l'étude menée au chapitre 3, nous avons défini une vague de chaleur comme une période minimale de trois jours durant laquelle les valeurs journalières de l'indicateur utilisé sont au dessus de la valeur climatologique journalière du quantile 90. En fonction des données disponibles dans les sorties des modèles, deux indicateurs ont pu être déduits : la température à 2-m (T_{2m}) et la température du thermomètre mouillé (T_w) afin d'étudier la prévisibilité des vagues de chaleur sèche et humide. Les modèles de prévision intra-saisonnière sont des modèles probabilistes, afin d'optimiser la détection des vagues de chaleur dans ces derniers, nous avons transformé les prévisions ensemblistes en des prévisions déterministes en adaptant l'approche développée par (Lavaysse et al., 2019). Cette approche consiste à optimiser les prévisions probabilistes en utilisant des valeurs seuils basés sur le nombre de membres du système ensembliste. Dans le cas de cette étude, nous avons montré qu'un seuil de 20% présentait de meilleurs scores pour la détection des jours dans les vagues de chaleur. Ainsi donc, un jour sera considéré comme faisant partie d'une vague de chaleur si au moins 20% des membres le prévoit. La prévisibilité des vagues de chaleur dans les modèles est évaluée à partir des scores dichotomiques issus de la table de contingence basés sur la cohérence entre les réanalyses et les prévisions [Table.5.1].

		Event observed	
		YES	NO
Event forecast	YES	hits	false alarms
	NO	misses	correct negative

Table 5.1 – Table de contingence

À partir de cette table de contingence, trois métriques statistiques ont été calculées : le hit-rate, le False Alarm Ratio (FAR) et le Gilbert Skill Score (GSS). Le hit-rate renseigne sur le pourcentage de vagues de chaleur observées qui ont été correctement prédites. Le FAR, quant à lui, indique le pourcentage d'événements prédits qui ne sont pas observés sur l'ensemble des événements prédits. Le GSS mesure la fraction des événements observés qui ont été correctement prédits en prenant les événements prédits de façon aléatoire. Le GSS est calculé à partir de la formule suivante :

$$\text{GSS} = \frac{\text{hits} - \text{CH}}{\text{hits} + \text{false_alarms} + \text{misses} - \text{CH}} \quad (5.1)$$

Where CH is given by :

$$\text{CH} = \frac{(\text{hits} + \text{false_alarms})(\text{hits} + \text{misses})}{\text{hits} + \text{false_alarms} + \text{misses} + \text{correct_rejections}} \quad (5.2)$$

L'évaluation de la prévisibilité des vagues de chaleur dans le modèle reste une tâche très complexe. Pour répondre à cette préoccupation, certaines études antérieures ([Batté et al., 2018](#); [Vitart and Robertson, 2018](#); [Katsafados et al., 2014](#)) utilisent les anomalies de $T2m$ et les variables atmosphériques de grande échelle telle que le géopotential à 500 hPa par exemple, pour prédire l'occurrence des vagues de chaleur quelques jours à l'avance. Cette approche, bien que permettant de détecter l'occurrence de la vague de chaleur, ne renseigne pas suffisamment sur la durée de l'événement. Nous proposons une approche beaucoup plus réaliste basée sur les événements prédits par les modèles. Cette méthodologie est inspirée des travaux de [Lavaysse et al. \(2019\)](#) portant sur la prédictibilité des vagues de chaleur et de froid en Europe. Nous distinguons les deux approches ci-dessous :

- La première approche consiste à déterminer la prévisibilité des jours de vague de chaleur dans les prévisions par rapport aux réanalyses. Pour ce faire, des scores dichotomiques ont été calculés pour chaque jour à différentes échéances, à partir desquels le hit-rate, le FAR et le GSS ont été déduits. Les scores sont calculés indépendamment pour chaque semaine et chaque région. Ce type d'information est utile pour les systèmes d'alerte précoce tels que pensés dans le cadre du projet ANR STEWARD.
- La deuxième approche se concentre sur la prévisibilité de l'ensemble de la vague de chaleur plutôt que sur les jours chauds de la vague de chaleur. Par conséquent, une vague de chaleur observée dans les réanalyses est considérée comme prédite par les modèles si au moins un jour durant l'événement est correctement prédit. Pour faciliter l'évaluation, des scores dichotomiques sont maintenant calculés pour chaque semaine, et le hit-rate, le FAR et le GSS sont calculés. Par exemple, si une vague de chaleur est observée dans les réana-

lyses au cours de la première semaine, et qu'un jour au sein de cette vague de chaleur est correctement prévu par le modèle, alors la vague de chaleur est considérée comme prédite et le "hit" (nombre d'événements détectés) est égal à 1 et le "misses" (nombre d'événements manqués) est égale à 0. Nous répétons le processus sur toutes les semaines pour chaque région et calculons le hit-rate.

5.2 Résumé de l'article Article sur la prévisibilité des vagues de chaleur

Les vagues de chaleur constituent l'un des aléas climatiques les plus dangereux pour la santé humaine et les écosystèmes dans le monde entier. Des prévisions fiables de ces événements dramatiques sont utiles aux décideurs politiques et aux services climatiques pour anticiper les risques et élaborer des réponses appropriées. Les prévisions intra-saisonnières à saisonnières (S2S) sont d'une grande importance pour les actions visant à atténuer les conséquences humaines et sanitaires des températures extrêmes. Dans cette perspective, la présente étude traite de la prévisibilité des vagues de chaleur de l'échelle intra-saisonnière dans les villes ouest-Africaines sur la période 2001-2020. Deux types de vagues de chaleur ont été analysées : les vagues de chaleur sèche et humide en utilisant respectivement la température à 2-m (T^2m) et la température du thermomètre mouillé (T^w). Deux modèles faisant partie du projet de prévision S2S, à savoir les modèles du Centre européen pour les prévisions météorologiques à moyen terme (CEPMMT) et du centre de météorologie Britannique (UKMO), ont été évalués à l'aide de deux produits de réanalyse de pointe, à savoir la réanalyse de cinquième génération du CEPMMT (ERA5) et la seconde version de la réanalyse MERRA de la NASA. La capacité des modèles à détecter les événements extrêmes chauds est évaluée à l'aide du score de Brier score. Les modèles présentent des performances significatives dans la détection des extrêmes chauds à la fois pour les prévisions à court et à long terme (respectivement 2 et 5 semaines à l'avance). La prévisibilité des vagues de chaleur dans les modèles de prévision est évaluée en calculant des scores dichotomiques tels que le hit-rate, le Gilbert skill score et le false alarm ratio (FAR). Les modèles de prévision pré-

sentent de meilleures performances par rapport à une climatologie de référence, principalement pour les prévisions à court terme (deux semaines à l'avance) dans les trois régions. Toutefois, les valeurs du hit-rate sont en moyenne inférieures à 50%. Nous constatons que les vagues de chaleur nocturnes sont plus prévisibles que les vagues de chaleur diurnes. En moyenne, le taux de fausses alarmes (FAR) est excessivement élevé et tend à augmenter avec l'échéance de la prévision; seulement 15 à 30 % des jours de vague de chaleur prédits sont effectivement observés respectivement pour les semaines 5 et 2. Ceci suggère que les modèles surestiment la durée des vagues de chaleur par rapport à la réanalyse ERA5. Les modèles présentent des performances similaires pour la prévision des vagues de chaleur sèche et humide. Bien que les modèles démontrent des performances pour la détection des vagues de chaleur par rapport à une climatologie de référence, leur capacité à prédire l'intensité des événements reste limitée même pour des courtes échéances.

5.3 Article sur la prévisibilité des vagues de chaleur dans les villes ouest-Africaines à l'échelle intra-saisonnière

Soumis au journal Weather and Climate Dynamics [HTTPS://EDITOR.COPERNICUS.ORG/WCD/MS-RECORDS/WCD-2023-13](https://editor.copernicus.org/wcd/ms-records/wcd-2023-13)

Subseasonal-to-seasonal forecasts of Heat waves in West African cities

Cedric G. Ngoungue Langué^{1,2}, Christophe Lavaysse^{2,3}, and Cyrille Flamant¹

¹Laboratoire Atmosphères, Milieux, Observations Spatiales (LATMOS) - UMR 8190 CNRS/Sorbonne Université/UVSQ, 78280 Guyancourt, France.

²Université Grenoble Alpes, CNRS, IRD, G-INP, IGE, 38000 Grenoble, France

³European Commission, Joint Research Centre (JRC), 21027 Ispra, VA, Italy

Correspondence: Ngoungue Langué Cedric Gacial (cedric-gacial.ngoungue-langué@latmos.ipsl.fr)

Abstract. Heat waves are one of the most dangerous climatic hazards for human and ecosystem health worldwide. Accurate forecasts of these dramatic events are useful for policy makers and climate services to anticipate risks and develop appropriate responses. Sub-seasonal to seasonal forecasts are of great importance for actions to mitigate the human and health consequences of extreme heat. In this perspective, the present study addresses the predictability of heat waves at sub-seasonal to seasonal time scale in West African cities over the period 2001-2020. Two types of heat waves were analyzed : dry and wet heat waves using 2-meter temperature (T_{2m}) and wet bulb temperature (T_w) respectively. Two models that are part of the S2S forecasting project, namely the European Centre for Medium-Range Weather Forecasts (ECMWF) and the UK Met Office models, were evaluated using two state-of-the-art reanalysis products, namely the fifth generation ECMWF reanalysis (ERA5) and the Modern-Era Retrospective analysis for Research and Application. The skill of the models to detect hot extreme events is evaluated using the Brier score. The models show significant skills in detecting hot days both for short- and long-term forecasts (2- and 5-week lead times, respectively). The predictability of heat waves in the forecast models is assessed by calculating categorical metrics such as the hit-rate, the Gilbert score and the false alarm ratio (FAR). The forecast models show significant skills in predicting heat wave days compared to a baseline climatology, mainly for short-term forecasts (two weeks lead time) in three climatic regions in West Africa, but the hit-rate values remain below 50% on average. We find that nighttime heat waves are more predictable than daytime heat waves. On average, the False Alarm Ratio (FAR) is excessively high and tends to increase with the lead time. Only approximately 15% to 30% of the predicted heat wave days are actually observed for Week 5 and Week 2, respectively. This suggests that the models overestimate the duration of the heat waves with respect to ERA5. The skill of the models in forecasting dry and hot heat waves are very close. Although the models demonstrate skills on heat wave detection compared to a baseline climatology, they fail in predicting the intensity of heat waves.

20 1 Introduction

The impact of heat waves on different sectors, in particular the economy and health, makes them one of the most dangerous climate hazards globally (Perkins, 2015). Heat waves pose a significant threat to human health, as they cause discomfort and stress to body temperature regulation. Increased atmospheric humidity can exacerbate heat stress and lead to deaths, particularly

among vulnerable populations such as children and the elderly. Climatic projections show an increase in the frequency, intensity
25 and duration of extreme temperatures over the next century and beyond [e.g. Kharin et al. (2007); Fischer and Schär (2010);
Perkins et al. (2012)]. Under these warming conditions, the frequency of extreme events such as heat waves will increase. In
the latest Intergovernmental Panel on Climate Change report (IPCC report 2023), the authors show that equatorial regions will
be more affected by climate change than mid- and high- latitudes. In some equatorial regions such as sub-Saharan Africa, the
predictability of heat waves remains poorly documented.

30 Heat waves are often associated with extreme daytime and/or night-time temperatures. Most often, heat waves are defined
as a period of at least three consecutive days with daily temperatures above a threshold [e.g. Perkins and Alexander (2013);
Déqué et al. (2017); Barbier et al. (2018); Batté et al. (2018); Ngoungue Langue et al. (2023)]. Many factors can affect the
definition of a heat wave, including the end-user sectors (human health, infrastructures, transport, agriculture) and also the
climatic conditions of the regions (Perkins and Alexander, 2013). Therefore, there is no standard definition of a heat wave
35 [e.g. Perkins (2015); Oueslati et al. (2017); Shafiei Shiva et al. (2019)]. Different thresholds, duration and indicators contribute
to the divergence in the definition of heat waves (Smith et al., 2013). Heat waves can be defined from daily meteorological
variables such as daily raw temperature [e.g. Fontaine et al. (2013); Beniston et al. (2017); Ceccherini et al. (2017); Déqué et al.
(2017); Batté et al. (2018); Barbier et al. (2018); Lavaysse et al. (2018); Engdaw et al. (2022); Ngoungue Langue et al. (2023)],
min, min or max daily wet bulb temperature [e.g. Yu et al. (2021); Ngoungue Langue et al. (2023)] or heat stress indices [e.g.
40 Robinson (2001); Fischer and Schär (2010); Perkins et al. (2012); Guigma et al. (2020); Ngoungue Langue et al. (2023)] using
relative or absolute thresholds. Some other authors use the daily anomalies of temperature to define heat waves [e.g. Stefanon
et al. (2012); Barbier et al. (2018)].

The impact of heat waves on human activities and health increases the need for skillful and reliable climate forecasts on sub-
seasonal to seasonal time scales in order to anticipate risks and develop appropriate responses (Lowe et al., 2016). Therefore,
45 early warning systems are of crucial importance to provide information on the occurrence of such events. This is usually done
using seasonal weather forecast models. Those forecasts can provide early indications of the frequency and duration of severe
heat waves, but some studies on the use of climate forecasts by service providers suggest that the sub-seasonal range is also
highly relevant for actions aimed at mitigating the human and health consequences of extreme heat (White et al., 2017). Sub-
seasonal to seasonal forecasts (S2S) are of great importance for humanitarian services in order to build up a "Ready-Set-Go"
50 early warning concept that allows early action to be taken before a potential disaster.

Vitart and Robertson (2018), as part of the Subseasonal-to-Seasonal Prediction Project ([S2Sproject,https://www.ecmwf.int/en/research/projects/s2s](https://www.ecmwf.int/en/research/projects/s2s)), analyzed the predictability of extreme events across the globe, with a particular focus on the Russian
heat wave of 2010. They show that S2S forecasts have the potential to predict the onset, evolution and decay of some large-scale
extreme events several weeks in advance. The time that elapses between the initialization of the forecast and the occurrence
55 of the target event is called the lead time. To assess the predictability of the 2010 Russian heat wave, their approach was
based on the predictability of 2-meter temperature (T2m) anomalies a few weeks before the onset of the event. They found
that the S2S models were able to predict extreme T2m anomalies over Russia up to three weeks lead time. Katsafados et al.
(2014) also assessed the predictability of the 2010 Russian heat wave at seasonal time scale using the National Center for

Atmospheric Research Community Atmosphere Model version 3 (NCAR CAM3) and the latest ECMWF operational forecasts
60 for validation. Their forecasting approach is based on the predictability of atmospheric blocking using temperature at 850 hPa
and the geopotential height at 500 hPa. They found that only a few members reproduced the main features of the blocking
system three months in advance. Most of the members predicted the blocking system in the wrong location and underestimated
its duration. In West Africa, few studies have been conducted on heat wave predictability. Batté et al. (2018) evaluated heat wave
forecasting at sub-seasonal and seasonal time scales using the Météo-France model in the S2S project and the Météo-France
65 seasonal forecasting System 5 (MF5) respectively. To assess the skills of the models at seasonal time scale, they defined two
indices from the Expert Team on Climate Change Detection and Indices (ETCCDI) database, namely, the heat wave duration
index (HWDI) and the number of heat waves per season (HWPP) using the apparent temperature and 2-meter temperature. At
the sub-seasonal time scale, they used the apparent temperature and T2m anomalies instead of the HWDI and HWPP. They
found that at the seasonal time scale, the skills of MF5 to reproduce inter-annual anomalies of heat wave duration is limited
70 at the grid point level because of the high spatial variability in the region, but it is significant when taking the average over
the Sahel region [10°N-20°N, 10°W-20°E]. At sub-seasonal time, the skills of the model decrease beyond one week. Guigma
et al. (2020) assessed the predictability of Sahelian heat waves at sub-seasonal time scale using the ECMWF extended long-
range forecast system (ENS-ext), ERA5 and BEST gridded data for the evaluation. Their approach is based on forecasting the
probability of occurrence of heat waves. They show that ENS-ext is able to forecast Sahelian heat waves with significant skill
75 up to 2 weeks ahead; and with increasing lead time, nighttime heat waves are more predictable than daytime events.

Most previous studies assess heat wave predictability using T2m anomalies and large-scale predictors such as temperature at
850 hPa and geopotential height at 500 hPa [e.g. Vitart and Robertson (2018); Katsafados et al. (2014)]. While this approach is
adequate for obtaining information about the weather situation for the future days, it cannot provide useful information about
the onset and duration of heat waves. In this study, we will adapt the method proposed by Lavaysse et al. (2019) when assessing
80 the predictability of heat waves over Europe. This method is more robust and takes into account the occurrence and duration
of events.

The present study assesses the predictability of heat wave frequency and characteristics in West African cities over the period
1993 to 2020 using two sub-seasonal to seasonal (S2S) models namely, ECMWF and UKMO. To the author's knowledge, this
work is the first of its kind in the region and represents a first assessment of heat wave predictability at subseasonal to seasonal
85 time scale in West Africa. To carry out this study, we first analyze the representation of T2m and wet bulb temperature (Tw) in
the forecast models with respect to the reanalysis data used as references (see Section 2). Secondly, we evaluate the models on
the representation of extreme heat events. Finally, the predictive skill of the models in forecasting heat waves is assessed.

The remainder of this article is organized as follows: in section2, we present the region of study and the data used for
this work; the description of the methodology is also provided. Section3 contains the main results of this study following the
90 methodology presented in section 2.

2 Region, Data and Methods

2.1 Region of interest

This work is carried out in West Africa, covering an area between 5-20°N and 15°W-10°E, extending from the Atlantic coast to Chad and from the Gulf of Guinea to the southern fringes of the Sahara desert [Fig.1]. The climate of West Africa is mainly influenced by the West African monsoon, which regulates the rainy season and therefore affects agriculture. The West African climate is characterized by a short wet season followed by a long dry season. West Africa exhibits high climate variability at regional- and local- scale. The present study focuses on major cities in the coastal and continental parts of West Africa. The cities were grouped in three regions based on their location, climate variability and the evolution of heat waves characteristics in each region Moron et al. (2016); Ngoungue Langue et al. (2023). The regions are structured as follows :

- Continental region (CO hereafter) englobes the cities of Bamako, Ouagadougou and Niger [Fig.1];
- Coastal atlantic region (AT hereafter) englobes the cities of Dakar, Nouakchott, Monrovia and Conakry [Fig.1];
- Coastal Guinean region (GU hereafter) englobes the cities of Yamoussoukro, Abidjan, Lomé, Abuja, Lagos, Accra, Cotonou and Douala [Fig.1].

2.2 Reanalysis products

African cities suffer from a critical lack of weather observation stations; and the few available are not well distributed in the regions. Therefore, reanalysis data appear as good candidates to overcome this issue. Reanalyses provide a numerical description of the recent climate by combining models with observations and are invaluable to numerous users around the world (Hersbach, 2016). In this work, we use two state-of-the art reanalysis products namely the fifth-generation European Center for Medium-Range Weather Forecasts reanalysis (ERA5, (Hersbach et al., 2020)) and the Modern-Era Retrospective analysis for Research and Applications, version 2 (MERRA-2, (Gelaro et al., 2017)) from the National Oceanic Atmospheric Administration (NOAA); (in the following, we will use "MERRA" to refer to MERRA-2) as our references for the evaluation of the forecast models. ERA5 and MERRA are part of the most reliable reanalyses used in Africa regions especially on the monitoring of heat waves [e.g. Barbier et al. (2018); Ngoungue Langue et al. (2021); Engdaw et al. (2022)]. Since ERA5 is used to initialize the atmospheric component of the ECMWF model which is one of the forecast models used here, one could argue that the evaluation of the skills of the forecast models using only ERA5 as reference is circular. Therefore, we also included MERRA as a second reference. It also allows for estimating the uncertainties of the reanalyses.

2.2.1 ERA5

The ERA5 reanalysis provides hourly estimates of various climate variables for the entire globe using 137 hybrid sigma levels up to 80 km above the surface (Hersbach et al., 2020). The original spatial resolution is 0.28125 degrees, interpolated to a regular 0.25°x 0.25° grid. ERA5 outputs are generated by the CY41r2 model cycle of the Integrated Forecast system (IFS) of

ECMWF, which uses a ten-member ensemble of 4D variational data assimilation. The set of atmospheric variables used within the ERA5 database are the hourly 2-meter temperature (T2m) and hourly 2-meter dew point temperature (d2m) covering the period from 1 January 2001 to 9 February 2021. From these variables, daily T2m (max, min, mean) and wet bulb temperature (Tw) are derived. The dataset is accessed through the Climserv database of the Institut Pierre Simon Laplace (IPSL) server or the Copernicus Climate Data Store (CDS). The land-sea mask used in this study is obtained from the ERA5 reanalysis and is available on the CDS.

2.2.2 MERRA

MERRA, unlike ERA5, has a spatial resolution of 0.625°x0.5° and provides data on 42 standard pressure levels. It uses an upgraded version of the Goddard Earth Observing System Model, Version 5 (GEOS-5) data assimilation system and the Global Statistical Interpolation (GSI) analysis scheme of Wu et al. (2002). To ensure consistency in our analysis, we converted the MERRA data to a spatial resolution of 0.25°x0.25°, similar to ERA5 using a conservative first-order interpolation. In the MERRA database, we use the hourly T2m, hourly 2-meter specific humidity and the pressure field at the surface from 1 January 2001 to 9 February 2021 to calculate daily T2m(max,min,mean) and Tw. The MERRA dataset was also accessed through the Climserv database on the Institut Pierre Simon Laplace (IPSL) server.

The assessment of dry and wet heat waves is done using T2m and Tw respectively. The computation of Tw is given by the following formula:

$$Tw = T * \operatorname{atan} \left[A(Rh + B) \frac{1}{2} \right] + \operatorname{atan} [T + Rh] - \operatorname{atan} [Rh - C] + D * (Rh) \frac{3}{2} * \left[\operatorname{atan}(E * Rh) \right] - F \quad (1)$$

(Stull, 2011), (Rh is used in percentage, for example 40 for Rh=40%).

The computation of relative humidity (RH) varies depending on the available variables in the products. The first formula is applied for ERA5, and the second for MERRA.

$$Rh = 100 * \frac{\exp \left(\frac{a * T_d}{b + T_d} \right)}{\exp \left(\frac{a * T}{b + T} \right)} \quad (2)$$

(August, 1828; Magnus, 1844; Alduchov and Eskridge, 1996)

$$Rh = 0.263 * p * q * \left[\exp \left(\frac{17.67 * (T - T_0)}{T - 29.65} \right) \right]^{-1} \quad (3)$$

<https://earthscience.stackexchange.com/questions/2360/how-do-i-convert-specific-humidity-to-relative-humidity>

$a = 17.625, b = 243.04, A = 0.151977, B = 8.313659, C = 1.676331, D = 0.00391838, E = 0.023101, F = 4.686035, T_0 = 273.16K$

Where $T(^{\circ}\text{C})$, $T_d(^{\circ}\text{C})$, $T_0(\text{K})$, $p(\text{hPa})$ and q are respectively the ambient temperature, dew-point temperature, reference temperature, pressure and specific humidity.

2.3 Forecasts products

150 To bridge the gap between medium range weather forecasts and seasonal forecasts, in 2013 the World Weather Research program (WWRP) and the World Climate Research program (WCRP) jointly launched a 5-year research initiative called the Subseasonal to Seasonal (S2S) project (Vitart et al., 2017) which aims to improve forecast skill and understanding on the sub-seasonal to seasonal timescale with special emphasis on high-impact weather events. The S2S project focuses on the risk of extreme weather conditions, including tropical cyclones, droughts, floods, heat waves and monsoonal rainfall (see
155 <http://www.s2sprediction.net/>). In order to obtain more robust statistical results, we conducted our study over a 20-year period, specifically using hindcast data from 2001 to 2020. Among the twelve models involved in the S2S project, we evaluated the ECMWF and UKMO (United Kingdom Met Office) models because they are both available throughout the study period.

2.3.1 ECMWF forecasts

The extended ECMWF ENS model runs on the Integrated Forecast System (IFS) cycle CY41r2. The native spatial resolution
160 of the ECMWF model is Tco639 (about 16 km) up to day 15 and Tco319 (about 32 km) after day 15, but the downloaded data are interpolated to a regular $0.25^{\circ} \times 0.25^{\circ}$ latitude/longitude grid. It contains 91 sigma levels from the surface to 80 km. ECMWF provides two types of outputs for the S2S program: real-time forecasts and reforecasts called "hindcasts". Real-time forecasts are forecasts for the coming days, while hindcasts refer to forecasts over historical periods that are used to calibrate a new version of a forecast model. ECMWF real-time forecasts are run with 51 ensemble members (50 perturbed
165 and 1 unperturbed), while hindcasts are run with 11 members. In this study, we focus on hindcasts only. ECMWF ENS hindcasts are produced twice a week, on Monday and Thursday at 00Z. We only analyzed the hindcasts for Thursday, as a first investigation revealed that some models had been initialized on the same date, but we realized after that those models were not available for the whole period. This means that each week a new set of hindcasts is produced to calibrate the real-time ensemble forecasts for Monday and Thursday of the following week using the latest version of the IFS. The 11-member
170 ensemble hindcasts start on the same day and month as the real-time forecast (Monday and Thursday), but covering the last 20 years. In our case, the forecast year is 2021 and we focus on the previous 20 years from that date, and the hindcasts run for 6 weeks. The variables of interest in the ECMWF S2S are T2m(max,min) over the last 6 hours, daily average T2m and d2m from which the daily average Tw was derived. The data are open access and available on the S2S project website (<https://apps.ecmwf.int/datasets/data/s2s-realttime-instantaneous-accum-ecmf/levtype=sfc/type=cf/>).

175 2.3.2 UKMO forecasts

The UKMO model runs on the HadGEM3 GC2.0 model which simulates the uncertainties of the initial conditions using a lagged initialisation and the uncertainties of the model using a stochastic scheme. The native spatial resolution of the UKMO

model is N216: $0.83^{\circ} \times 0.56^{\circ}$ (about 60 km at mid-latitudes). It contains 85 vertical levels from the surface to 85 km and 4 soil levels: level 1 (0 - 0.1 m), level 2 (0.1 - 0.35 m), level 3 (0.35 - 1 m) and level 4 (1- 3 m). Similar to ECMWF, UKMO provides
 180 to the S2S program real-time forecasts and hindcasts. The UKMO real-time forecast consists of a set of 4 members run daily for a period of 60 days (3 perturbed members and 1 control member). The UKMO hindcasts are produced 4 times per month, on the 1st, 9th, 17th and 25th, and cover a 24-year period from 1993 to 2016. We are aware that these init dates are not the same as those of ECMWF, but we are interested in this work on the predictability of heat waves in a global perspective, not on specific events. The ensemble hindcasts are composed of 7 members per cycle (from the 25 March 2017 hindcasts, prior to that
 185 3 members per cycle). Our target period is going from January 2001 to February 2021, and as mentioned earlier, the UKMO hindcasts are not available after the year 2016. To solve this problem and get more robust statistical results, we recombine the products to obtain a new composite that covers the whole target period. The process applied is described in the following expression:

$$\text{UKMO}_{2001-2021} = \text{Concatenation} \left[\text{UKMO}_{\text{hindcast}2001-2016}, \text{UKMO}_{\text{realtimeforecast}2017-2021} \right] \quad (4)$$

190 The concatenation operator is applied to the time dimension. The real time forecasts were extracted for the same days as the hindcasts initialization. The number of ensemble members in the hindcasts is set to 4 (1-control member and 3-perturbed members) to be consistent with the number of ensemble members in the real time forecasts. We selected the three first perturbed members in the hindcasts over the 7 available. The UKMO forecasts analyzed in this work are launched for a 6-week duration. The variables extracted from the UKMO database are the same as those in ECMWF.

195 2.4 Metrics

2.4.1 Estimation of temperatures at the city scale

Weather forecasts provide the evolution of atmospheric variables on a global scale, which implies the need to have data from local stations to access information on a local scale. This is a major problem in areas where there is a lack of weather stations to collect data, as is the case in African cities. To address this issue, downscaling methods can be employed. However, in this
 200 study, we study phenomena at the city scale, and the spatial resolution of the reanalyses (ERA5, MERRA) is too coarse for this purpose. Although the reanalysis scale is more representative of the spatial variability of a heat wave occurring in a city than an isolated local station, a validation analysis is needed on test stations in order to determine the best interpolation technique for estimating local temperature from reanalyses. Following the same approach as developed in Ngoungue Langue et al. (2023), local temperatures over the cities were derived from the reanalysis using the reanalysis grid point closest to the station that
 205 satisfies a land-sea mask (lsm) of at least 0.5 ([Table 1] shows the lsm values of all cities considered in this study). The same technique was used for the forecasts.

2.4.2 Heat wave detection

The detection of heat waves is carried out using 2-meter daily minimum temperature (T2m_min), 2-meter daily maximum temperature (T2m_max) and the average wet bulb temperature (Tw) as indicators. T2m_min and T2m_max are used to investigate the evolution of nighttime and daytime heat waves respectively. The most lethal heat waves are due not only to high temperatures but also to the effect of humidity (Steadman, 1979a, b). We therefore used Tw to assess the evolution of wet heat waves. This restriction to T2m_min, T2m_max and Tw is related to the atmospheric variables available on S2S outputs preventing us from computing more elaborated indices as in Ngoungue Langué et al. (2023). We defined a heat wave as a consecutive period of at least 3 days during which the daily temperatures exceeds the calendar 90th percentile threshold computed over the entire period for T2m_min, T2m_max or Tw respectively [Fig.2]. The 90th percentile is calculated for each calendar day of the year. The choice of a relative threshold is more appropriate as it is easily replicable in other regions. When two heat wave events are separated by one day with an indicator value below the daily 90th percentile, they are pooled together to form a single event [Fig.2].

2.4.3 Heat wave characteristics

After the detection of a heat wave, some important characteristics are deduced, namely the duration and the intensity. They are useful to investigate the severity of an event. The predictability of heat waves is assessed for occurrence, duration and intensity. To determine the occurrence and duration of heat waves, we create boolean files from T2m_min, T2m_max and Tw time series at each grid point following the steps below :

- proceed to heat wave detection at each grid point;
- for each grid point, we define a zero vector with the length of T2m_min or T2m_max time series containing only zeros;
- for days in T2m_min, T2m_max or Tw time series, if days are hot days, we replace in our zero vector the values corresponding to those days by 1. Hot days are days with T2m_min, T2m_max or Tw above the 90th percentile daily thresholds. In order to assess the characteristics of heat waves, only hot days belonging to heat wave sequences are kept. This is applied for all grid points and we obtain boolean files containing 0 or 1 (Ngoungue et al. 2023). These boolean files will be processed both for the reanalyses and the forecasts to assess the representation of heat waves occurrence and duration.

The intensity of heat waves was defined as the cumulative sum of the daily exceedances of daily values of indicators to the climatological daily threshold in a sequence of hot days (see Ngoungue Langué et al. (2023) for more details). This study is in the framework of the project Agence National de la Recherche STEWARD (STatistical Early WArning systems of weather-related Risks from probabilistic forecasts, over cities in West Africa) project which focuses on the human impacts of climate extremes. Therefore, the climatological daily threshold is chosen to be constant over the whole period; and it is defined as the minimum of the daily climatology thresholds over the study period. This approach allows us to properly assess the severity of a heat wave and its potential human impacts.

2.4.4 From probabilistic to deterministic forecast

240 Ensemble forecasting is a tool used for making probabilistic weather forecasts. It is both an alternative and an indispensable complement to deterministic weather forecasts. Ensemble forecasting is of major interest because it provides different scenarios of the evolution of the state of the atmosphere. The particularity of ensemble forecasting is that, unlike deterministic forecasting, many trajectories are simulated in order to take into account uncertainties in the physical component of the model. Although ensemble forecasting has many advantages over deterministic forecasting, the evaluation of the performance of an ensemble
 245 forecasting model remains quite complex due to the amount of information available. Statistical analyses can be performed by considering only the mean of the members, the median member, the warmest and coldest members, the 1st and 3rd quartiles. In order to extract deterministic information from a probabilistic system for the calculation of prediction scores, we defined an approach based on member thresholds inspired by Lavaysse et al. (2019). Three threshold values were tested (see [Table2]) to optimize the ensemble forecast system based on results found in Lavaysse et al. (2019).

250 2.4.5 Skill scores

The skill of the probabilistic models in forecasting the evolution of T2m, Tw and extreme events are assessed using several adapted scores. The forecast of T2m and Tw in the models is done using the Continuous Rank Probability Score (CRPS). The CRPS is a quadratic measure of the difference between the forecast and reanalysis cumulative distribution functions (CDFs); it quantifies the relative error between forecasts and observations. The values of the CRPS range from [0 to 1], the closer it is
 255 from 0, the better the forecast. The CRPS is calculated using the following formula:

$$\text{CRPS} = \int_{-\infty}^{+\infty} (\mathbf{P}_f(x) - \mathbf{P}_o)^2 dx \quad (5)$$

$\mathbf{P}_f, \mathbf{P}_o$ represent the forecast and reanalysis CDFs respectively.

The representation of hot days in the forecasts is addressed using the Brier score. The Brier Score (BS) is similar to the CRPS with the only difference that it focuses on specific events. It measures the difference between the probability of a forecast and
 260 the outcomes; it is a good metric to quantify the accuracy of a forecast system. The BS is given by :

$$\text{BS} = \frac{1}{N} \sum_{i=1}^N (\mathbf{P}_i - \mathbf{O}_i)^2 \quad (6)$$

$\mathbf{P}_i, \mathbf{O}_i$ are respectively the forecast probability and observed outcome (1 if the event occurs and 0 if not). N is the length of the forecasts or observations time series.

The predictability of heat waves in the forecast models is evaluated using dichotomous scores based on the coherence
 265 between reanalysis and forecasts such as hits, false alarms, misses and correct rejections. Let consider a 2x2 contingency table [Table3] from which 3 metrics have been computed : hit-rate, FAR ratio and GSS. The hit-rate indicates the percentage of

observed heat waves that have been correctly forecasted. The False Alarm Ratio (FAR) gives the percentage of forecasted events that did not occur. The Gilbert Skill Score (GSS) measures the fraction of observed events that are correctly predicted, adjusted for hits associated with random chance (close to the climatology). Chance hits (CH) are given as the event frequency multiplied by the number of event forecasts. The GSS takes in account the hits, misses, false alarms and neglects the correct rejections that would artificially improve the score. The values of the GSS range from $[-\frac{1}{3}$ to 1]; a GSS=0 indicates no skill while a GSS=1 perfect skill. The GSS is calculated using the following formula:

$$\text{GSS} = \frac{\text{hits} - \text{CH}}{\text{hits} + \text{false_alarms} + \text{misses} - \text{CH}} \quad (7)$$

Where CH is given by:

$$\text{CH} = \frac{(\text{hits} + \text{false_alarms})(\text{hits} + \text{misses})}{\text{hits} + \text{false_alarms} + \text{misses} + \text{correct_rejections}} \quad (8)$$

2.4.6 Heat waves forecast strategy

The assessment of heat wave predictability in the forecast models is a very difficult task. To address this concern, previous studies [e.g. Vitart and Robertson (2018); Batté et al. (2018)] have used T2m anomalies and large-scale atmospheric variables such as the geopotential at 500hPa for example, to predict their occurrence a few days in advance. In this study, we adapted the methodology developed by Lavaysse et al. (2019) to evaluate the predictability of heat waves in the forecasts. This assessment is done in two steps:

- The first approach is to determine the predictability of heat wave days in the forecasts with respect to the reanalyses. To do this, dichotomous scores (hits, false alarms, misses and correct rejection) have been calculated for each day at different lead times from which the hit-rate, FAR and GSS have been derived. The scores are calculated independently for each week and each city. This type of information is useful for early warning systems such as the STEWARD project.
- The second approach focuses on the predictability of the whole heat wave rather than hot days in the heat wave. Therefore, a heat wave occurring in the reanalyses is considered as predicted by the forecast models if at least one hot day of the event is correctly predicted. To facilitate the evaluation, dichotomous scores are now calculated for each week, and the hit-rate, FAR, GSS are derived. For example, if a heat wave is detected in the reanalysis during the first week, and a hot day within this heat wave is correctly predicted by the forecast model, then the heat wave is considered as predicted and the hit=1 and miss=0. We repeat the process over all weeks and calculate the hit-rate.

3 Results

3.1 Climatology evolution of some atmospheric variables (T2m and Tw) in the forecasts and reanalyses

295 The first assessment focuses on the representation of the climatological evolution of two key variables for this study, T2m and Tw in the forecasts compared to the reanalyses. To do so, the seasonal climatological bias between the forecasts and the reanalyses is computed over the 20-year period. The bias is computed for each couple of models (ECMWF/UKMO) and reanalysis (ERA5/MERRA) using T2m(min,max) and Tw values [Fig.3] and [Fig.4] respectively). First, we analysed the bias between the forecast models and the ERA5 reanalysis using T2m_min values. Both models show a cold bias over the Sahel region which is more pronounced with UKMO [Fig.3_a]. We observed in UKMO, a progressive shift of this strong cold bias over the northern Sahel during the season from winter to summer [Fig.3_a (e-g)]. UKMO exhibits a hot bias with respect to ERA5 over the Atlantic Ocean that decreases considerably in summer. The cold bias found in ECMWF over the Sahel region is consistent with previous global studies [e.g. Johnson et al. (2019); Haiden et al. (2021)]. The results obtained with T2m_max values are similar to those found with the T2m_min for both models. We notice especially a strong hot bias over the Atlantic coast during the winter and spring [Fig.3_b (a-b),(e-f)]. The evaluation of the representation of Tw in the forecasts shows strong cold bias with respect to the reanalyses over the whole Sahel region [Fig.4]. Compared to the results found with T2m, this strong cold bias can be related mainly to the underestimation of humidity in the models in this region. The assessment of the bias between the forecast models and MERRA on the evolution of T2m highlights significant discrepancies with the results obtained using ERA5 as a reference. Using T2m_min, we observed a warm bias in ECMWF with respect to MERRA over the Sahel and Guinea region during winter and autumn which tends to decrease during spring and summer. These results highlight the uncertainties between the two reanalyses already discussed in Ngoungue Langue et al. (2023). It can be deduced from these results using T2m_min that ERA5 has a warmer trend than MERRA over the Sahel region, while being cooler than MERRA over the Atlantic Ocean (see [Fig.S1] in supplement material). The spatial distribution of T2m in the forecast models shows significant biases with respect to the reanalyses. In order to determine whether these biases change over time, we analyze the spatio-temporal evolution of T2m and Tw. To do this, we calculate the daily climatological biases between forecasts and reanalyses over the CO, AT and GU regions at different lead times from week1 to week6. We observed a high spatial variability of the biases in the three regions. The models show smaller biases in the AT region in spring, of the order of +/- 0.25 K and larger biases, of the order of +/- 2 K are found in the CO region with T2m_min [Fig.S2]. These significant biases observed in the CO region are considerably reduced in summer. The results obtained with T2m_max are quite similar to those obtained with T2m_min (not shown). As observed in the previous results with Tw [Fig.4], the models show lower cold biases in the CO region in winter ([Fig.S3] in supplement). The range of biases associated with Tw spans from -14 K to 0 K. We do not observe any systematic increase in these biases from Week1 to Week6 ([Fig.S2 and [Fig.S3] in supplement). This first assessment of the evolution of T2m and Tw in the models compared to the reanalyses reveals significant biases in the models which may lead to poor predictive skills.

325 3.2 Assessment of the predictive skills of T2m and Tw forecasts

In this section, we carry out a global assessment of the predictive skills of the models on the representation of T2m and Tw at different time scales. To do this, we analyzed the interannual variability of the CRPS calculated between forecasts and reanalyses over the 3 regions for T2m_min, T2m_max and Tw. The forecasts used in this work are launched for a 6-week duration; for each week, the median CRPS was calculated from 2001-2020 using ERA5 and MERRA. The CRPS results are similar for the first two weeks (Week1,Week2), the two intermediate weeks (Week3,Week4) and the last two weeks (Week5,Week6). According to these findings, we have chosen to organize our results into medium-range forecasts (Week2) and long-range forecasts (Week5). Week 5 was chosen for the long-term forecasts instead of week 6 because from week 5 onwards, the models generally reach the predictability horizon and are closer to the climatology. This organization of the results applies to the rest of the study. Firstly, the results of the CRPS obtained using ERA5 as reference [Fig.5] are analyzed. We have noticed that the skill of the models does not improve necessarily with decreasing lead time. This could be related to systematic biases (the representation of atmospheric circulation, local scale processes) in the forecast models. The CRPS score shows a high spatial variability in the 3 regions, indicating a high dependence of the skill of the models with the region. The forecast models show better predictive skills in the AT region during all the seasons and lead times with T2m_min except for UKMO during summer. The CRPS associated with T2m_max indicates that ECMWF is more skillful in the GU region (it is also the case with UKMO except during Autumn when the AT region seems to be more predictable). In general, the models present more skills for T2m_min than T2m_max over the AT region. ECMWF generally shows more skill than UKMO. The evolution of the CRPS calculated using MERRA as a reference is similar to that found using ERA5 (not shown). As we previously observed a significant cold bias in the Sahel region with Tw, we expect high values of CRPS in the different regions. This is indeed the case, with CRPS values ranging from 4 to 13, i.e. 6 times higher than those obtained with T2_min or T2m_max. The CRPS values are drastically reduced in the CO region in winter, which is consistent with the previous results in section 3.1 (see [Fig.S4] in supplement). The models show more predictive skill on the representation of T2m than Tw. This is not surprising, given that Tw combines T2m and humidity, which is very difficult to predict.

3.3 Extreme temperature values and heat waves in the models and reanalyses

3.3.1 Extreme temperatures

350 After the evaluation of the forecast models on the representation of T2m and Tw, we focus now on the extreme heat events referred here as hot days (see section 2.4.3). This is done through the calculation of the Brier score between the forecasts and reanalyses (ERA5, MERRA). In order to compute the Brier score, the raw forecasts and reanalyses are converted to boolean data, where a value of 1 represents a hot day and a value of 0 indicates no hot days. This approach based on a relative threshold (see section 2.4.3) will contribute to partially correct the biases previously found in the models. We firstly evaluated the Brier score between the forecasts and ERA5 for T2m and Tw. The range of values for the Brier score is between 0.05 to 0.175, indicating that the models are able to detect hot days in agreement with the reanalyses over the three regions for short and long term forecasts (Week2,Week5) ([Fig.6] and [Fig.S5] in supplement material). We found with T2m that in spring the models are

more skillful and present less spatial variability compared to other seasons. In winter and autumn, for the short term lead time (Week2), the forecast models perform better for T2m_max than T2m_min. Over all lead times, regions and seasons, ECMWF performs better than UKMO on the detection of hot days except for Tw in the GU region in summer. Using MERRA reanalysis as reference, we also found that ECMWF has more skills than UKMO, except over the CO region during winter (see [Fig.S6] in supplement material) and the Brier score is in the same range of values as the Brier score computed using ERA5 for T2m and Tw. The results show a good performance of the models in predicting hot days for short and long term forecasts.

3.3.2 Spatial variability of heat wave characteristics

After assessing the skill of the models in predicting hot days, we study the spatial variability of heat waves in the forecast models versus the reanalyses. Heat waves are defined as a period of at least three consecutive hot days. The frequency and characteristics of heat waves were calculated using T2m and Tw. The mean duration (resp. mean intensity) of heat waves was calculated for each grid point as the sum of heat wave duration (resp. intensity) divided by the number of years affected by a heat wave during the period from 2001 to 2020. A first assessment of the representation of heat waves in the forecast models is made by calculating the bias between the models and the reanalyses for heat wave frequency, duration and intensity. The spatial distribution of the heat wave frequency bias between the forecast models (ECMWF, UKMO) and ERA5 reanalysis shows similar evolution for T2m_min and T2m_max [Fig.7]. The models overestimate the frequency of heat waves in spring and summer over the Sahel for ECMWF, and from the Sahel to the Guinean region for UKMO. This overestimation in heat wave frequency is well marked in UKMO, indicating the inaccurate representation of the daily variability of T2m in the model. The Sahel and Guinean regions exhibit a strong convective activity during spring and summer which is very complex to take into account in the models. Some discrepancies are observed in the spatial evolution of heat waves frequency when using Tw over the Guinea coast [Fig.8]; we noticed an underestimation in heat waves frequency over the Sahel and Guinea region in autumn. In a second step, we assess the evolution of the number of heat wave days in the models versus ERA5 reanalysis. We observed a north-south gradient well established over West Africa and an overestimation of the number of heat wave days over the Guinea region for both T2m_min and T2m_max [Fig.9]. The north-south gradient is well marked in UKMO. This north-south gradient observed in UKMO with T2m is also found in Tw and tends to strengthen from spring to autumn ([Fig.S7] in supplement material). The main differences between T2m and Tw on the representation of heat wave days are found with ECMWF. In a third step, the spatial evolution of heat waves intensity is evaluated. ECMWF generally tends to underestimate the intensity of heat waves over the Sahel region, while UKMO overestimates the intensity of events from the Sahel to the Guinean coast for T2m_min (see [Fig.S8] in supplement). This overestimation of heat wave intensity in UKMO with T2m_min is considerably reduced when using T2m_max. The evolution of heat wave intensity with Tw is similar to that observed with T2m_min, except in summer for the ECMWF (see [Fig.S9] in supplement). We found very similar patterns when calculating the bias of intensity using MERRA reanalysis as reference for T2m_min, T2m_max and Tw (not shown). The bias of heat wave duration using MERRA as reference shows some differences with the results obtained with ERA5 reanalysis for T2m_min and T2m_max. ECMWF shows mostly an underestimation of heat wave days from the Sahel to the Guinean region in spring and summer for T2m_min and T2m_max (see [Fig.S10] in supplemental material). In summer, UKMO shows a large

negative bias over Senegal, Guinea, Mali and Cameroon which tends to extend over the east of Sahel in autumn for T2m_min (see [Fig.S10_a]) in supplement). We do not find significant differences when using MERRA as reference for the evaluation of heat waves duration with Tw (not shown).

395 3.4 Predictability of the heat waves in extended forecasts

In the previous section, we analyzed the spatial variability of heat wave characteristics in the forecast models versus the reanalyses. We are now assessing the skills of the models to detect heat waves in the three regions. This is done by calculating the following probabilistic scores described in Section 2: the hit-rate, GSS and FAR ratio (see Section 2). The scores are calculated for T2m_min, T2m_max and Tw at daily and weekly time scales using the optimized forecasts (see Section 2) and ERA5 reanalysis chosen as reference. The evaluation of the forecast models at daily and weekly time scales provides useful insights for policy makers and climate services. Daily information is relevant for the accurate prediction of heat waves and early warning alert systems. The calculated metrics are then compared to a baseline climatology defined as the probability of having a heat wave in the ERA5 reanalysis over the period 2001-2020. The results presented below are obtained using a 20% threshold value to optimize the ensemble forecast system (see Section methods) [Fig.10]. The hit-rate and GSS values of the optimized forecasts using 40% and 60% percentile threshold values are lower than those obtained with the 20% threshold. The hit-rate values show a weak spatial variability in the 3 regions, which indicates that the skills of the models are not too sensitive to the geographical and climatic characteristics of the three regions. We also noticed a gradual loss of predictability in the models from winter to autumn, with high hit-rate values in winter. The forecast models show skills above the reference both for short- and long- term forecasts (Week2, Week5) but the hit-rate values are below 0.5 indicating misses in the forecasts. The hit-rate values are slightly better for short-term forecasts. ECMWF presents more skills than UKMO for short-term forecasts in winter. UKMO, for instance, is better for long-range forecasts, mainly for T2m_min [Fig.10(a-d)]. We also noticed that the predictability of heat waves is slightly better for heat waves associated with T2m_min than for T2m_max. We can infer from this result that nighttime heat waves are more predictable than daytime heat waves. The models show more skills in the AT and CO regions in winter and spring for T2m_min values for short-term forecasts. The analysis of the inter-day variability of T2m is assessed by calculating the standard deviation (std) for each region using ERA5 reanalysis. We found small std values in the AT and GU regions, indicating low variability of daily T2m in these regions [Table4]. Conversely, high variability of daily T2m is observed in the CO region. The low inter-day variability of T2m in the AT region indicates a more stable signal which will lead to favorable conditions for heat wave detection in the models based on a statistical perspective. The skills of the models previously highlighted in the AT region could be partly explained by this low variability of daily T2m. The hit-rate values obtained with Tw are very close to those associated with T2m in the different regions and seasons; but we also noticed with Tw, that UKMO is more skillful than ECMWF for short- and long-range forecasts (see [Fig.S11(a-d)] in supplement material).

The second metric calculated for the evaluation of the models is the GSS. The GSS follows the same evolution as the hit-rate with much lower values between 0 and 0.2 both for T2m_min, T2m_max and Tw ([Fig.10(i-l)] and [Fig.S11(i-l)] in supplement). This suggests that the skills of the models to predict heat waves are considerably reduced when random hits

(chance hits) are removed from the total hits. We found that the GSS values are significantly decreasing with lead time and season; the highest values are observed in winter. In winter, the atmospheric circulation in West Africa regions is mainly governed by the harmattan flow which results in low convective activity in the regions and therefore an improvement of the predictive skills of the models compared to summer. The GSS values are greater than 0, indicating that the forecast models perform better than a random forecast mainly for short-term forecasts (Week2) [Fig.10(i-l)]. Similar results of the GSS are found with Tw (see [Fig.S11(i-l)] in supplement). An important aspect of the evaluation of a forecasting system is to assess its ability to predict events that do not occur in the observations: the so-called "false alarms". This is done by the calculation of the FAR ratio between the forecast models and ERA5 reanalysis for T2m_min [Fig.10(e-h)], Tw [Fig.S11(e-h)] and T2m_max (not shown). The FAR values are too high on average, about 0.7 and 0.85 for the short and long term forecasts, respectively for all the three indicators. This suggests that the models tend to overestimate the number of heat days with respect to ERA5. The FAR ratio increases with the lead time; ECMWF makes fewer false alarms than UKMO for short-term forecasts. The FAR ratio is considerably reduced when we increase the threshold values used to optimize the ensemble forecasting systems (see [Fig.S12] in supplement for T2m_min). This is highlighted more clearly in ECMWF than UKMO over all seasons and regions. This result is consistent with the fact that the prediction of an event will be more robust as a large number of model members have predicted the event. However, we found that this is not the case for the hit-rate and GSS for which high values are obtained with lowest threshold (20%)(see [Fig.S13 and Fig.S14] in supplemental material). Thus, according to the context of the study, a compromise must be found in order to obtain a good balance between hit-rate and false alarms. The skill of the models in detecting heat waves is also assessed on a weekly time scale. As expected, we found an overall increase in the values of hit-rate and GSS for T2m_min, T2m_max and Tw (see [Fig.S15] for T2m_min in supplement). The forecast models show skills at weekly time scale compared to the baseline climatology. To be consistent with the previous analyses, the predictability of heat wave intensity in the models is also assessed for short- and long-range forecasts (Week2 and Week5) using ERA5 reanalysis. We found a large spatial variability in heat wave intensity across regions. The strongest heat waves are found in the CO region (as shown in Ngoungue Langue et al. (2023)) and low intensity heat waves in the GU region except for Tw in summer for all the three indicators. Although the models demonstrate consistency in forecasting the spatial distribution of heatwave intensity, they fail in accurately predicting the specific intensity values. The models underestimate the intensity of heat waves (see [Fig.11] for T2m_min, the results are very similar for T2m_max and Tw (not shown)). The forecast of heat wave intensity in the models remains a difficult task, even though the models show skills in heat wave detection.

4 Discussion

The behavior of the forecast models varies across different climatic regions. The question that arises is : Why do these differences exist?

In order to tackle this question, we analyze some key factors in the models such as the physical parameterizations, the data assimilation technique and the spatial resolution of the atmospheric component. First of all, the physical parameterizations used to simulate atmospheric processes such as convection, turbulence, interactions surface-ocean, surface-radiation and cloud

microphysics are different for the two models. For example, for the representation of the convective activity, ECMWF is using the Tiedtke scheme (Tiedtke, 1989) and UKMO, the Met Office convective scheme (Hagelin et al., 2017). The models used the same data assimilation methods (4D-Var) for control analyses but the data and initial conditions are completely different. These differences may influence the representation of surface-ocean interactions in the models. The differences observed in the representation of T2m_min over the Atlantic ocean [Fig.3] can result from these types configurations. Another important factor is the spatial resolution of the atmospheric component of the two models : ECMWF has a higher spatial resolution than UKMO (0.16°x0.16° Vs 0.83°x0.56°), which means that it can capture local-scale variability or atmospheric processes and provide more accurate forecasts for specific regions. This may explain why the ECMWF performs better than the UKMO in certain regions, for example in the case of extreme temperatures over AT and GU [Fig.6]. A more detailed analysis of these differences between the models is beyond the scope of this study.

5 Conclusions

This study is a first assessment of the predictability of heat waves in West African cities on a sub-seasonal to seasonal time scale. Two models that are part of the S2S prediction project, namely: ECMWF and UKMO, were evaluated using two state-of-the-art reanalysis data : ERA5 and MERRA over the period 2001-2020. To carry out this study, we first analyzed the representation of T2m and Tw in the forecast models with respect to the reanalyses. We found that the models are cooler than ERA5 in the Sahel region, and hotter than MERRA in the Sahel and Guinea region. These uncertainties between the 2 reanalyses have also been highlighted in Ngoungue Languet et al. (2023). Secondly, we investigate the representation of hot days and heat wave characteristics in the models with respect to the reanalyses. The Brier score exhibits small values for T2m and Tw, indicating that the models are able to detect extreme heat events up to 5 weeks lead time. Over all lead times, seasons and regions, ECMWF performs better than UKMO in detecting hot days when compared to both ERA5 and MERRA. The models face some issues in reproducing properly the spatial evolution of heat wave characteristics. We found an overestimation of the frequency of heat waves in spring and summer over the Sahel for ECMWF, and from the Sahel to the Guinean region for UKMO when using T2m. With Tw, we noticed an underestimation of heat waves frequency over the Sahel and Guinea region in autumn. Thirdly, we assessed predictive skills of the models using the hit-rate, GSS and FAR. The models perform well against a baseline climatology, but the hit-rate values remain below 50%, indicating missed events in the forecasts. The hit-rate values are slightly better for short-term forecasts (up to two weeks lead time). We found that nighttime heat waves are more predictable than daytime heat waves. This result is consistent with Guigma et al. (2021). On average, the False Alarm Ratio (FAR) is excessively high and tends to increase with the lead time. Only approximately 15% to 30% of the predicted heat wave days are actually observed for Week 5 and Week 2, respectively. This suggests that the models overestimate the duration of the heat waves with respect to ERA5. ECMWF issues fewer false alarms than UKMO for short-term forecasts. The prediction of dry heat waves is slightly better with ECMWF for short-term forecasts, while it is better with UKMO for long-term forecasts. For wet heat waves, UKMO outperforms ECMWF for both short- and long-term forecasts. Although the models demonstrate

skills on heat wave detection compared to a baseline climatology, they fail in predicting the intensity of heat waves; the accurate forecast of heat waves intensity remains a challenging task for the models.

495 In future work, we will investigate in more detail the origins of the differences observed in the two forecast models over the different regions. It has been shown recently in some studies that machine learning techniques can be useful to extend the predictability range of weather forecasts [e.g. Salcedo-Sanz et al. (2016); Anjali et al. (2019); Azari et al. (2022); van Straaten et al. (2023)]. Based on these findings, it would be interesting to investigate the potential of machine learning algorithms on heat waves forecasting.

Competing interests. The contact author has declared that none of the authors has any competing interests

500 References

- Alduchov, O. A. and Eskridge, R. E.: Improved Magnus Form Approximation of Saturation Vapor Pressure, 35, 601–609, [https://doi.org/10.1175/1520-0450\(1996\)035<0601:IMFAOS>2.0.CO;2](https://doi.org/10.1175/1520-0450(1996)035<0601:IMFAOS>2.0.CO;2), publisher: American Meteorological Society Section: Journal of Applied Meteorology and Climatology, 1996.
- Anjali, T., Chandini, K., Anoop, K., and Lajish, V.: Temperature prediction using machine learning approaches, in: 2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT), vol. 1, pp. 1264–1268, IEEE, 2019.
- 505 August, E. F.: Ueber die Berechnung der Expansivkraft des Wasserdunstes, 89, 122–137, <https://doi.org/10.1002/andp.18280890511>, _eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/andp.18280890511>, 1828.
- Azari, B., Hassan, K., Pierce, J., and Ebrahimi, S.: Evaluation of machine learning methods application in temperature prediction, *Environ Eng*, 8, 1–12, 2022.
- 510 Barbier, J., Guichard, F., Bouniol, D., Couvreur, F., and Roehrig, R.: Detection of Intraseasonal Large-Scale Heat Waves: Characteristics and Historical Trends during the Sahelian Spring, 31, 61–80, <https://doi.org/10.1175/JCLI-D-17-0244.1>, publisher: American Meteorological Society Section: Journal of Climate, 2018.
- Batté, L., Ardilouze, C., and Déqué, M.: Forecasting West African Heat Waves at Subseasonal and Seasonal Time Scales, 146, 889–907, <https://doi.org/10.1175/MWR-D-17-0211.1>, publisher: American Meteorological Society Section: Monthly Weather Review, 2018.
- 515 Beniston, M., Stoffel, M., and Guillet, S.: Comparing observed and hypothetical climates as a means of communicating to the public and policymakers: The case of European heatwaves, 67, 27–34, <https://doi.org/10.1016/j.envsci.2016.11.008>, 2017.
- Ceccherini, G., Russo, S., Ametoy, I., Marchese, A. F., and Carmona-Moreno, C.: Heat waves in Africa 1981–2015, observations and reanalysis, 17, 115–125, <https://doi.org/10.5194/nhess-17-115-2017>, 2017.
- Déqué, M., Calmanti, S., Christensen, O. B., Aquila, A. D., Maule, C. F., Haensler, A., Nikulin, G., and Teichmann, C.: A multi-model climate response over tropical Africa at + 2° C, *Climate Services*, 7, 87–95, 2017.
- 520 Engdaw, M. M., Ballinger, A. P., Hegerl, G. C., and Steiner, A. K.: Changes in temperature and heat waves over Africa using observational and reanalysis data sets, *International Journal of Climatology*, 42, 1165–1180, 2022.
- Fischer, E. M. and Schär, C.: Consistent geographical patterns of changes in high-impact European heatwaves, *Nature geoscience*, 3, 398–403, 2010.
- 525 Fontaine, B., Janicot, S., and Monerie, P.-A.: Recent changes in air temperature, heat waves occurrences, and atmospheric circulation in Northern Africa, 118, 8536–8552, <https://doi.org/10.1002/jgrd.50667>, _eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/jgrd.50667>, 2013.
- Gelaro, R., McCarty, W., Suárez, M. J., Todling, R., Molod, A., Takacs, L., Randles, C. A., Darmenov, A., Bosilovich, M. G., Reichle, R., Wang, K., Coy, L., Cullather, R., Draper, C., Akella, S., Buchard, V., Conaty, A., Silva, A. M. d., Gu, W., Kim, G.-K., Koster, R., Lucchesi, R., Merkova, D., Nielsen, J. E., Partyka, G., Pawson, S., Putman, W., Rienecker, M., Schubert, S. D., Sienkiewicz, M., and Zhao, B.: The Modern-Era Retrospective Analysis for Research and Applications, Version 2 (MERRA-2), 30, 5419–5454, <https://doi.org/10.1175/JCLI-D-16-0758.1>, publisher: American Meteorological Society Section: Journal of Climate, 2017.
- 530 Guigma, K. H., Todd, M., and Wang, Y.: Characteristics and thermodynamics of Sahelian heatwaves analysed using various thermal indices, 55, 3151–3175, <https://doi.org/10.1007/s00382-020-05438-5>, 2020.
- 535 Guigma, K. H., MacLeod, D., Todd, M., and Wang, Y.: Prediction skill of Sahelian heatwaves out to subseasonal lead times and importance of atmospheric tropical modes of variability, *Climate Dynamics*, 57, 537–556, 2021.

- Hagelin, S., Son, J., Swinbank, R., McCabe, A., Roberts, N., and Tennant, W.: The Met Office convective-scale ensemble, MOGREPS-UK, *Quarterly Journal of the Royal Meteorological Society*, 143, 2846–2861, 2017.
- Haiden, T., Janousek, M., Vitart, F., Ben-Bouallegue, Z., Ferranti, L., Prates, C., and Richardson, D.: Evaluation of ECMWF forecasts, including the 2020 upgrade, ECMWF, 2021.
- Hersbach, H.: The ERA5 Atmospheric Reanalysis., in: AGU Fall Meeting Abstracts, vol. 2016, pp. NG33D–01, 2016.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., De Chiara, G., Dahlgren, P., Dee, D., Diamantakis, M., Dragani, R., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, R. J., Hólm, E., Janisková, M., Keeley, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., de Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., and Thépaut, J.-N.: The ERA5 global reanalysis, 146, 1999–2049, <https://doi.org/10.1002/qj.3803>, [_eprint: https://onlinelibrary.wiley.com/doi/pdf/10.1002/qj.3803](https://onlinelibrary.wiley.com/doi/pdf/10.1002/qj.3803), 2020.
- Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., Tietsche, S., Decremmer, D., Weisheimer, A., Balsamo, G., et al.: SEAS5: the new ECMWF seasonal forecast system, *Geoscientific Model Development*, 12, 1087–1117, 2019.
- Katsafados, P., Papadopoulos, A., Varlas, G., Papadopoulou, E., and Mavromatidis, E.: Seasonal predictability of the 2010 Russian heat wave, *Natural Hazards and Earth System Sciences*, 14, 1531–1542, 2014.
- Khari, V. V., Zwiers, F. W., Zhang, X., and Hegerl, G. C.: Changes in temperature and precipitation extremes in the IPCC ensemble of global coupled model simulations, *Journal of Climate*, 20, 1419–1444, 2007.
- Lavaysse, C., Cammalleri, C., Dosio, A., van der Schrier, G., Toreti, A., and Vogt, J.: Towards a monitoring system of temperature extremes in Europe, 18, 91–104, <https://doi.org/10.5194/nhess-18-91-2018>, publisher: Copernicus GmbH, 2018.
- Lavaysse, C., Naumann, G., Alfieri, L., Salamon, P., and Vogt, J.: Predictability of the European heat and cold waves, *Climate Dynamics*, 52, 2481–2495, 2019.
- Lowe, R., García-Díez, M., Ballester, J., Creswick, J., Robine, J.-M., Herrmann, F. R., and Rodó, X.: Evaluation of an early-warning system for heat wave-related mortality in Europe: Implications for sub-seasonal to seasonal forecasting and climate services, *International journal of environmental research and public health*, 13, 206, 2016.
- Magnus, G.: Versuche über die Spannkraft des Wasserdampfs, 137, 225–247, <https://doi.org/10.1002/andp.18441370202>, [_eprint: https://onlinelibrary.wiley.com/doi/pdf/10.1002/andp.18441370202](https://onlinelibrary.wiley.com/doi/pdf/10.1002/andp.18441370202), 1844.
- Moron, V., Oueslati, B., Pohl, B., Rome, S., and Janicot, S.: Trends of mean temperatures and warm extremes in northern tropical Africa (1961–2014) from observed and PPCA-reconstructed time series, *Journal of Geophysical Research: Atmospheres*, 121, 5298–5319, 2016.
- Ngoungue Langué, C. G., Lavaysse, C., Vrac, M., Peyrille, P., and Flamant, C.: Seasonal forecasts of the Saharan Heat Low characteristics: A multi-model assessment, *Weather and Climate Dynamics*, 2, 893–912, 2021.
- Ngoungue Langué, C. G., Lavaysse, C., Vrac, M., and Flamant, C.: Heat wave monitoring over West African cities: uncertainties, characterization and recent trends, *Natural Hazards and Earth System Sciences*, 23, 1313–1333, 2023.
- Oueslati, B., Pohl, B., Moron, V., Rome, S., and Janicot, S.: Characterization of Heat Waves in the Sahel and Associated Physical Mechanisms, 30, 3095–3115, <https://doi.org/10.1175/JCLI-D-16-0432.1>, publisher: American Meteorological Society Section: *Journal of Climate*, 2017.
- Perkins, S. E.: A review on the scientific understanding of heatwaves—Their measurement, driving mechanisms, and changes at the global scale, 164–165, 242–267, <https://doi.org/10.1016/j.atmosres.2015.05.014>, 2015.

- Perkins, S. E. and Alexander, L. V.: On the Measurement of Heat Waves, 26, 4500–4517, <https://doi.org/10.1175/JCLI-D-12-00383.1>, publisher: American Meteorological Society Section: Journal of Climate, 2013.
- Perkins, S. E., Alexander, L. V., and Nairn, J. R.: Increasing frequency, intensity and duration of observed global heatwaves and warm spells, 39, <https://doi.org/10.1029/2012GL053361>, eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1029/2012GL053361>, 2012.
- Robinson, P. J.: On the Definition of a Heat Wave, 40, 762–775, [https://doi.org/10.1175/1520-0450\(2001\)040<0762:OTDOAH>2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<0762:OTDOAH>2.0.CO;2), publisher: American Meteorological Society Section: Journal of Applied Meteorology and Climatology, 2001.
- Salcedo-Sanz, S., Deo, R., Carro-Calvo, L., and Saavedra-Moreno, B.: Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms, *Theoretical and applied climatology*, 125, 13–25, 2016.
- Shafiei Shiva, J., Chandler, D. G., and Kunkel, K. E.: Localized Changes in Heat Wave Properties Across the United States, 7, 300–319, <https://doi.org/10.1029/2018EF001085>, eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1029/2018EF001085>, 2019.
- Smith, T. T., Zaitchik, B. F., and Gohlke, J. M.: Heat waves in the United States: definitions, patterns and trends, 118, 811–825, <https://doi.org/10.1007/s10584-012-0659-2>, 2013.
- Steadman, R. G.: The Assessment of Sultriness. Part I: A Temperature-Humidity Index Based on Human Physiology and Clothing Science, 18, 861–873, [https://doi.org/10.1175/1520-0450\(1979\)018<0861:TAOSPI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1979)018<0861:TAOSPI>2.0.CO;2), publisher: American Meteorological Society Section: Journal of Applied Meteorology and Climatology, 1979a.
- Steadman, R. G.: The Assessment of Sultriness. Part II: Effects of Wind, Extra Radiation and Barometric Pressure on Apparent Temperature, 18, 874–885, <https://www.jstor.org/stable/26179217>, publisher: American Meteorological Society, 1979b.
- Stefanon, M., D’Andrea, F., and Drobinski, P.: Heatwave classification over Europe and the Mediterranean region, 7, 014 023, <https://doi.org/10.1088/1748-9326/7/1/014023>, publisher: IOP Publishing, 2012.
- Stull, R.: Wet-Bulb Temperature from Relative Humidity and Air Temperature, 50, 2267–2269, <https://doi.org/10.1175/JAMC-D-11-0143.1>, publisher: American Meteorological Society Section: Journal of Applied Meteorology and Climatology, 2011.
- Tiedtke, M.: A comprehensive mass flux scheme for cumulus parameterization in large-scale models, *Monthly weather review*, 117, 1779–1800, 1989.
- van Straaten, C., Whan, K., Coumou, D., van den Hurk, B., and Schmeits, M.: Correcting sub-seasonal forecast errors with an explainable ANN to understand misrepresented sources of predictability of European summer temperatures, *Artificial Intelligence for the Earth Systems*, pp. 1–49, 2023.
- Vitart, F. and Robertson, A. W.: The sub-seasonal to seasonal prediction project (S2S) and the prediction of extreme events, *Npj Climate and Atmospheric Science*, 1, 3, 2018.
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., Déqué, M., Ferranti, L., Fucile, E., Fuentes, M., et al.: The subseasonal to seasonal (S2S) prediction project database, *Bulletin of the American Meteorological Society*, 98, 163–173, 2017.
- White, C. J., Carlsen, H., Robertson, A. W., Klein, R. J., Lazo, J. K., Kumar, A., Vitart, F., Coughlan de Perez, E., Ray, A. J., Murray, V., et al.: Potential applications of subseasonal-to-seasonal (S2S) predictions, *Meteorological applications*, 24, 315–325, 2017.
- Yu, S., Tett, S. F. B., Freychet, N., and Yan, Z.: Changes in regional wet heatwave in Eurasia during summer (1979–2017), 16, 064 094, <https://doi.org/10.1088/1748-9326/ac0745>, publisher: IOP Publishing, 2021.

Tables

Table 1. Land sea mask (lsm) of west African towns used in this study

Towns	latitude	longitude	lsm
DAKAR	14.75	-17.25	0.6
ABIDJAN	5.25	-3.75	0.5
NOUAKCHOTT	18	-16	continent
CONAKRY	9.5	-13.5	0.5
MONROVIA	6.25	-10.75	0.6
BAMAKO	12.5	-8	continent
YAMOISSOUKRO	6.75	-5.25	continent
OUAGADOUGOU	12.25	-1.5	continent
ACCRA	5.5	-0.5	0.8
LOMÉ	6	1	0.5
NIAMEY	13.5	2	continent
COTONOU	6.5	2.5	0.7
LAGOS	6.5	3.5	0.5
ABUJA	9	7.5	continent
DOUALA	4	9.75	0.9

Table 2. Description of the threshold values.

Threshold values	Description
20%	20% of the ensemble members are associated to a hot day
40%	40% of the ensemble members are associated to a hot day
60%	60% of the ensemble members are associated to a hot day

Table 3. Contingency table.

2X2 Contingency table		Event Observed	
		YES	NO
Event forecast	YES	hits	false alarms
	NO	misses	correct rejections

Table 4. Inter-daily variability of 2-meter temperature over the period 2001-2020 using ERA5 reanalysis during the seasons for T2m_min and T2m_max.

	AT				GU				CO			
	Win	Spri	Sum	Aut	Win	Spri	Sum	Aut	Win	Spri	Sum	Aut
T2m_min	0.5	0.5	0.43	0.77	0.57	0.36	0.44	0.44	1.64	1.74	1.08	1.69
T2m_max	0.38	0.35	0.43	0.58	0.39	0.69	0.76	1	1.71	0.81	2.04	1.66

Figures

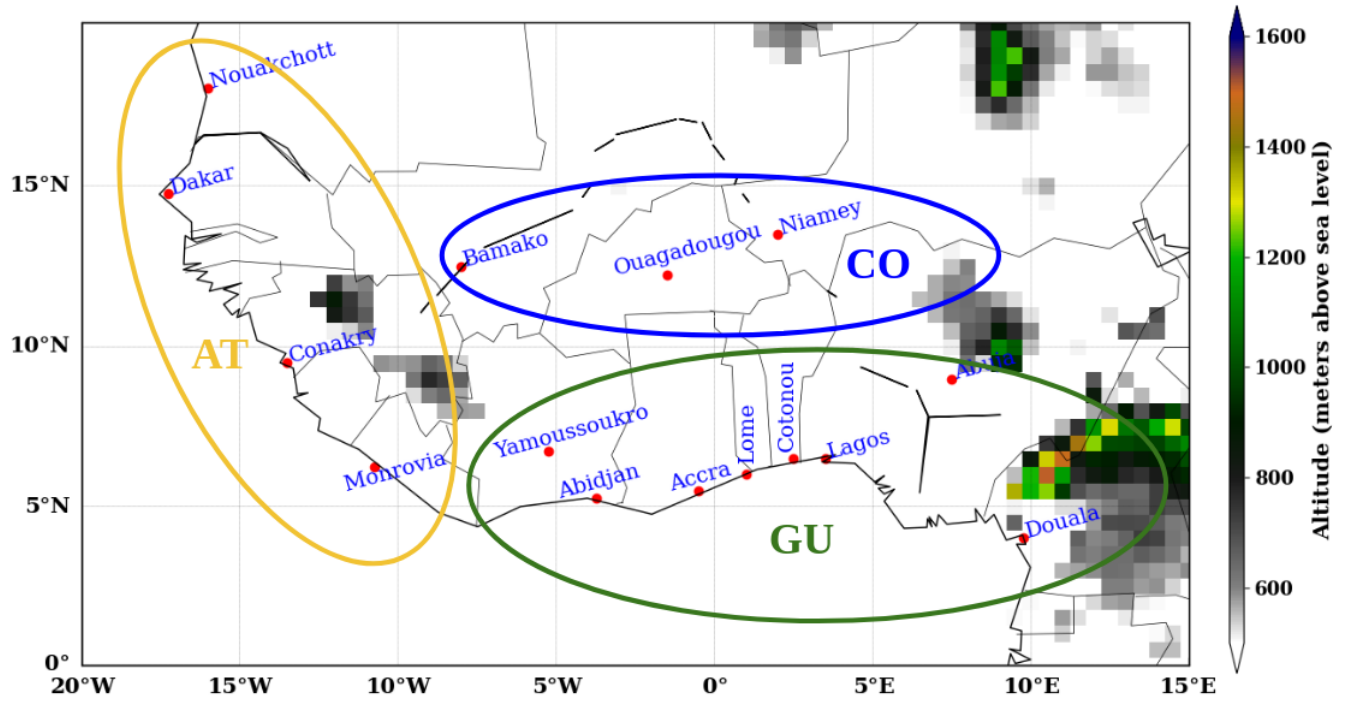


Figure 1. Topographic map of West Africa using ERA5 elevation data. The circles on the map represent the different climatic zones: AT (Coastal Atlantic zone), CO (Continental zone) and GU (Coastal Guinean zone). The y and x axes represent the latitude and longitude respectively. The color bar shows the elevation in meters over the region.




Figure 2. Detection process of heat wave: HW1/HW2 represent events associated respectively to maxima/minima temperature. The red/blue lines with circles are max/min daily temperatures. Red/blue solid lines are respectively max/min thresholds. X- and Y- axis represent the time in days and the temperature in degrees celsius. 'With pool' refers to the pooling of two (or more) events separated by a day characterized by the value of a given indicator below the daily XX^{th} percentile. This figure is a 'theoretical/schematic' illustration of the different types of heat waves investigated in this work.

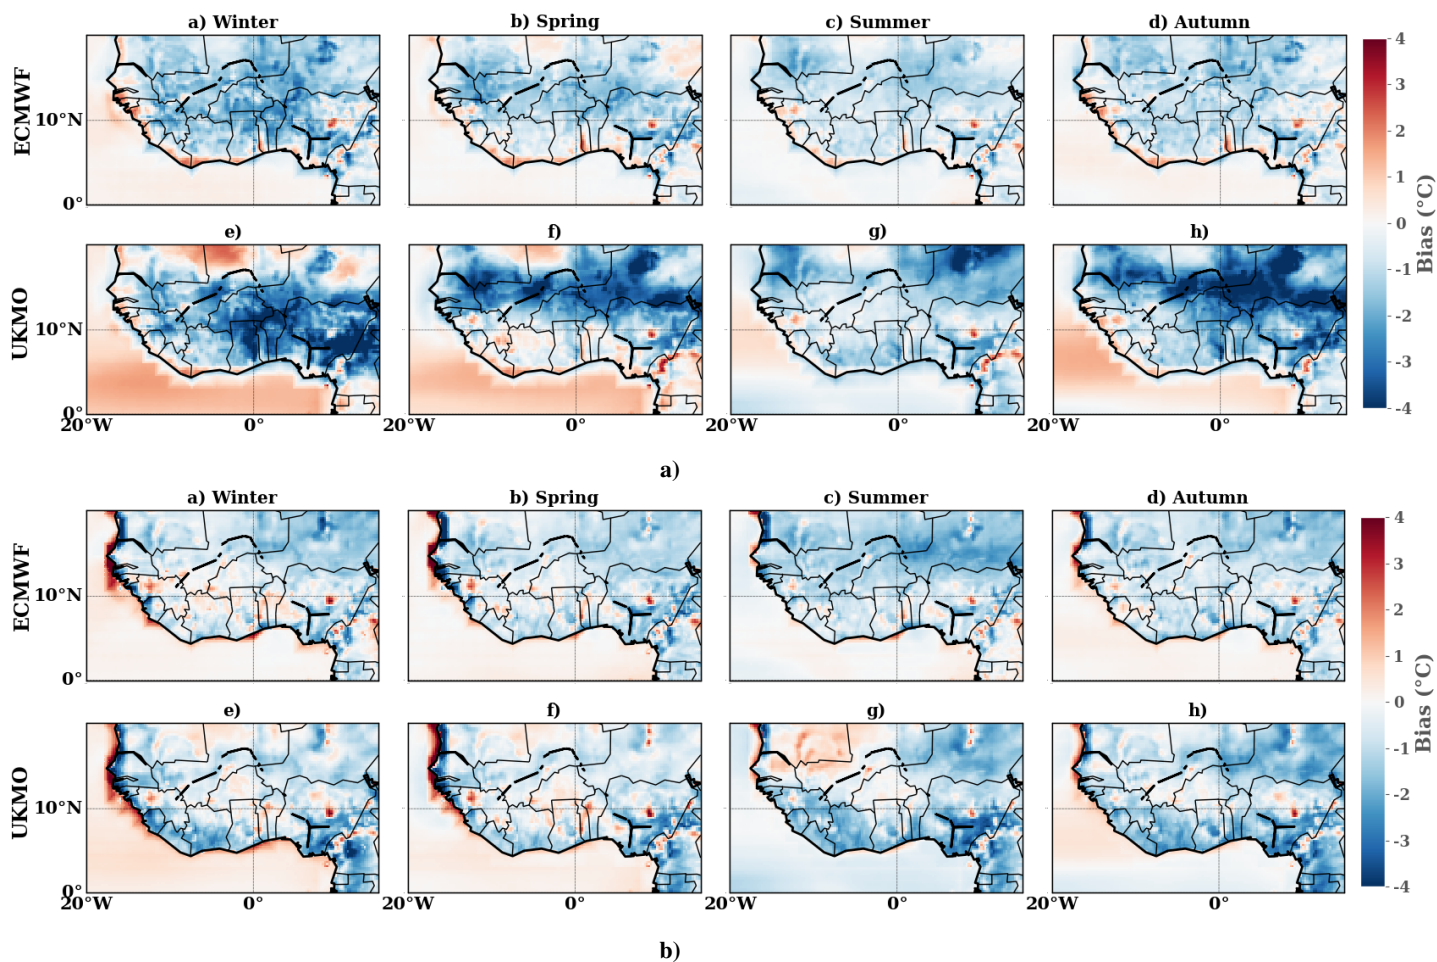


Figure 3. Spatial variability of the climatological bias between the forecast models ensemble mean and ERA5 reanalysis over the period 2001-2020 for : **(a)** T2m_min and **(b)** T2m_max, during the seasons : (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is computed as the difference between the forecast models and ERA5. The color indicates the bias values in degrees Celsius. The X and Y axes represent the longitude and latitude respectively.

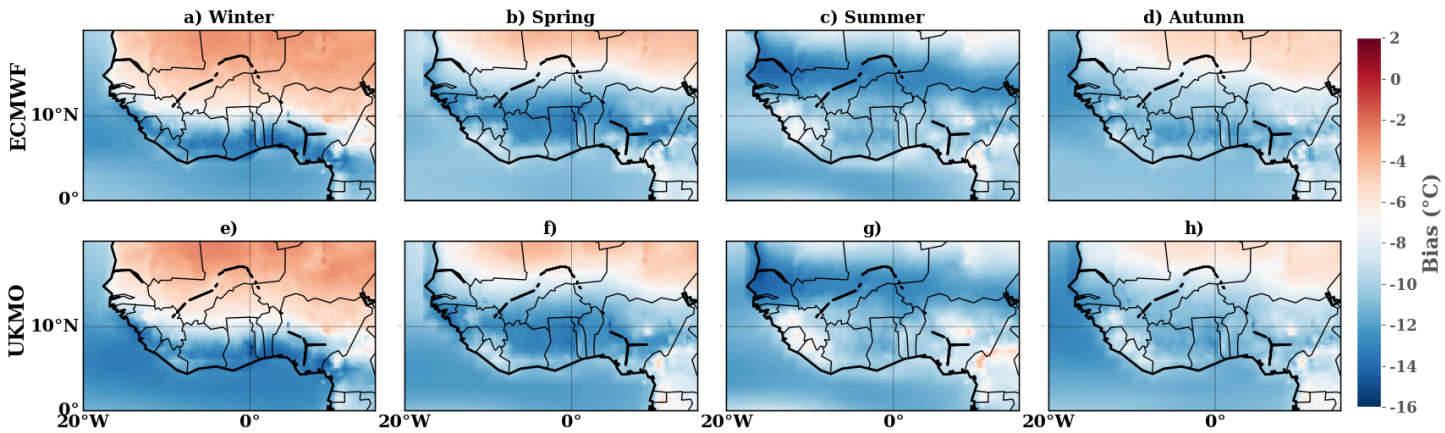


Figure 4. Spatial variability of the climatological bias between the forecast models ensemble mean and ERA5 reanalysis over the period 2001-2020 for Tw during the seasons : (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is computed as the difference between the forecast models and ERA5. The color indicates the bias values in degrees Celsius. The X and Y axes represent the longitude and latitude respectively.

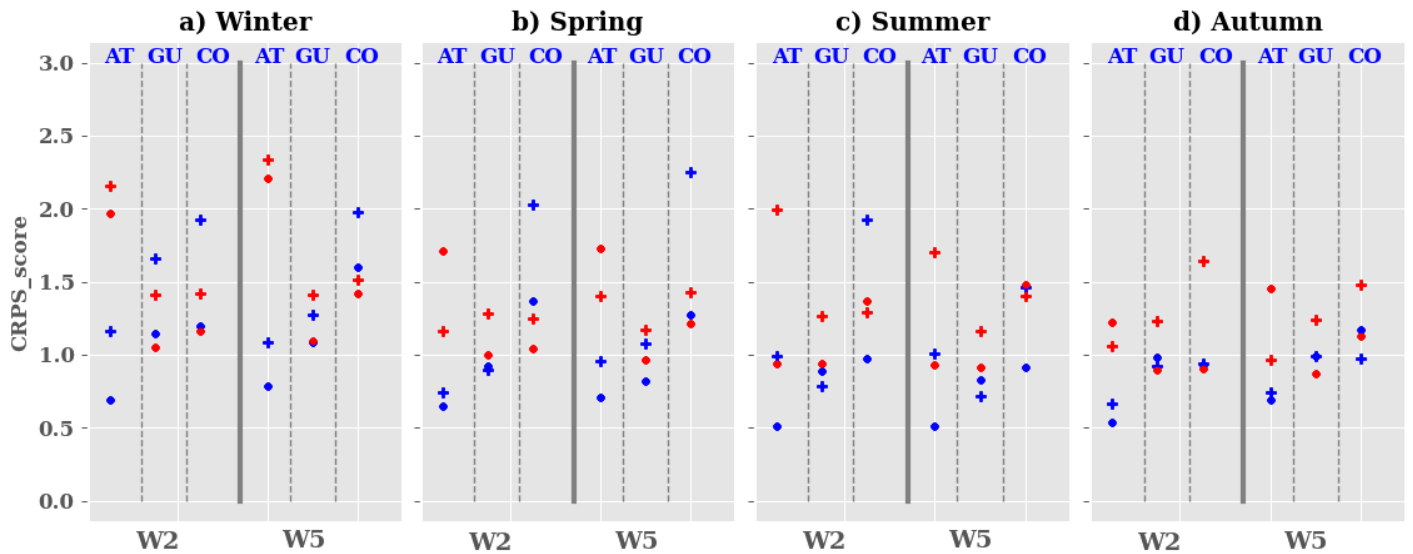


Figure 5. Evolution of the CRPS score between the forecast models and ERA5 reanalysis over the period 2001-2020 during the seasons : (a) winter, (b) spring, (c) summer and (d) autumn. The blue and red colors represent the CRPS score calculated using T2m_min and T2m_max respectively. The dot and cross symbols indicate the CRPS score obtained with ECMWF and UKMO respectively. The Y and X axes show the CRPS values and the lead times (W2: week2 and W5: week5) respectively.

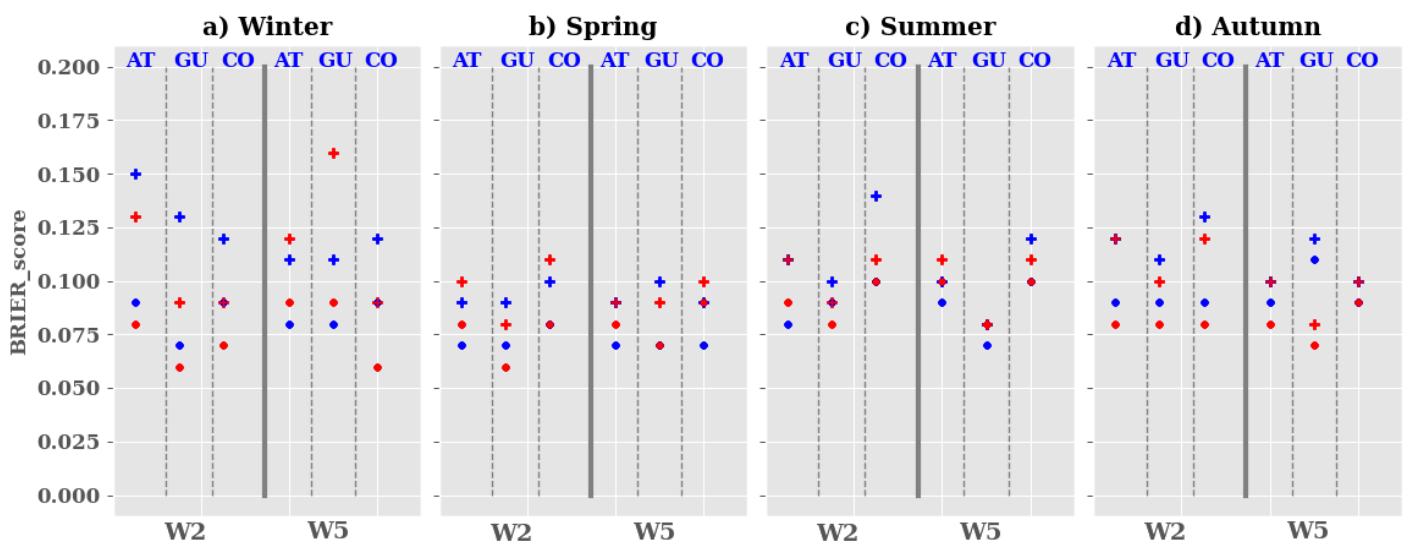


Figure 6. Evolution of the Brier score between the models and ERA5 reanalysis over the period 2011-2020 during the seasons : (a) winter, (b) spring, (c) summer and (d) autumn. The blue and red colors represent the Brier score calculated using T2m_min and T2m_max values respectively. The dot and cross symbols indicate the Brier score obtained with ECMWF and UKMO respectively. The Y and X axes show the CRPS values and the lead times (W2: week2 and W5: week5) respectively.

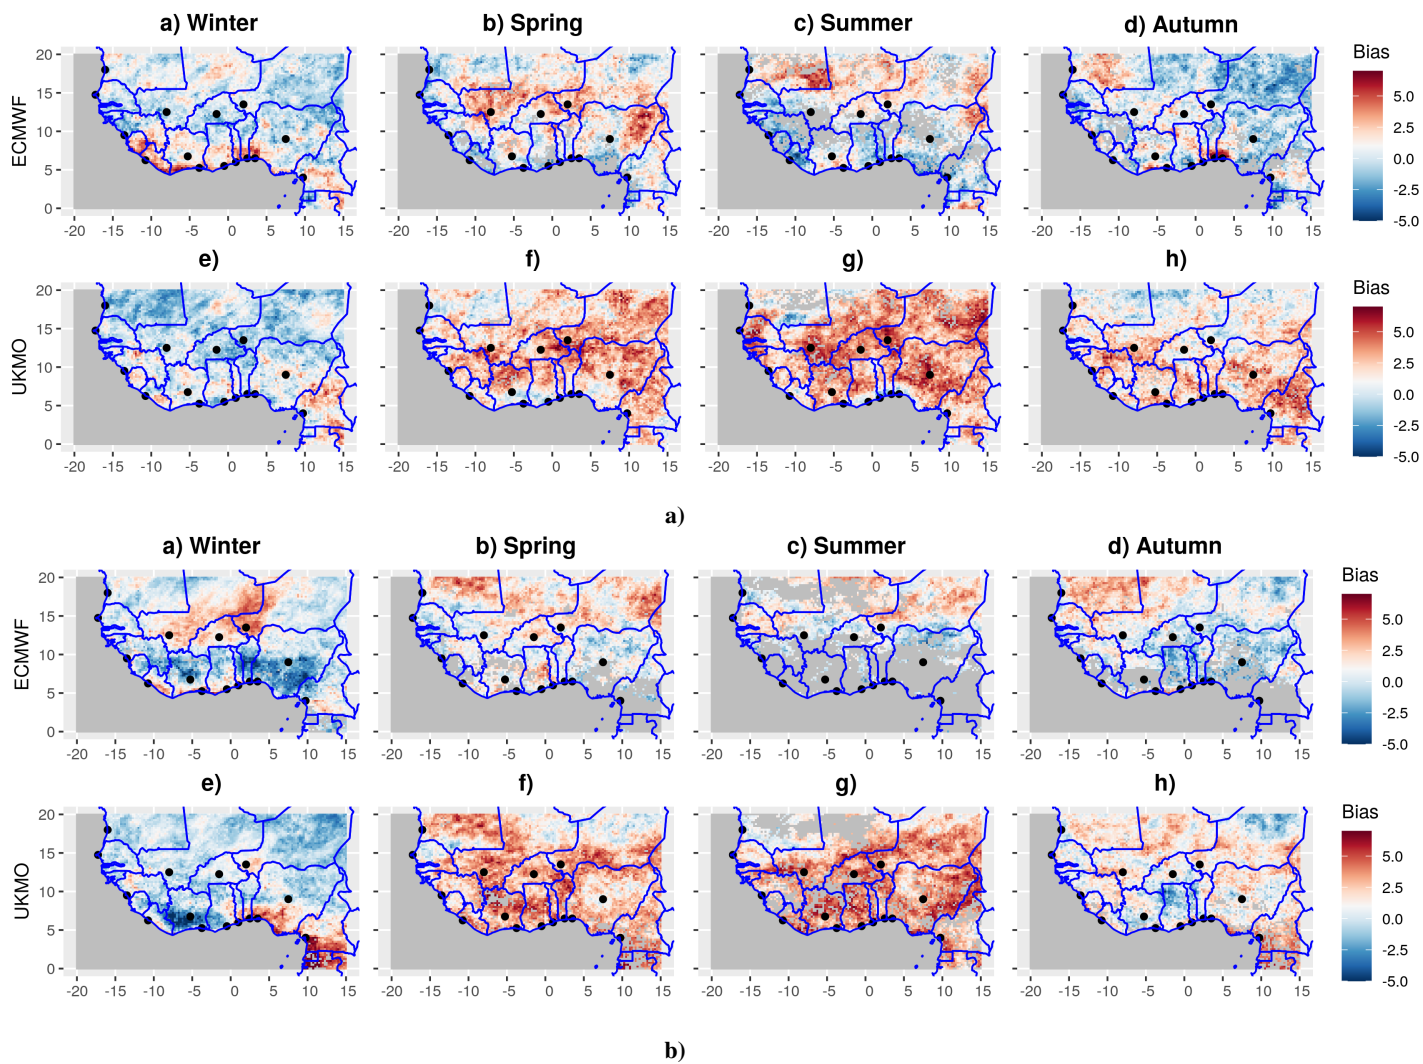


Figure 7. Spatial variability of heat wave frequency bias between forecast models and ERA5 over West Africa from 2001 to 2020 for:(a) T2m_min values and (b) T2m_max values, during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave frequency between the forecast models and ERA5. This analysis is performed using the unperturbed member of the models. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively. The solid blue lines indicate the borders between countries; the black dots represent the cities of interest for this study (this applies to the rest of the paper).

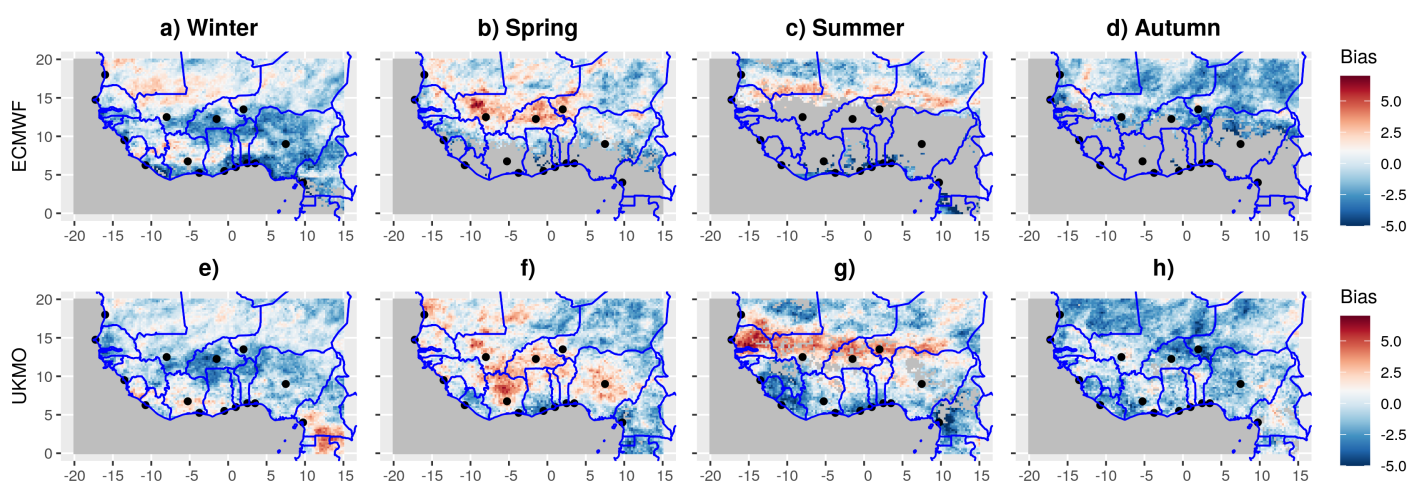


Figure 8. Spatial variability of heat wave frequency bias between forecast models and ERA5 over West Africa from 2001 to 2020 using T_w during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave frequency between the forecast models and ERA5. This analysis is performed using the unperturbed member of the models. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

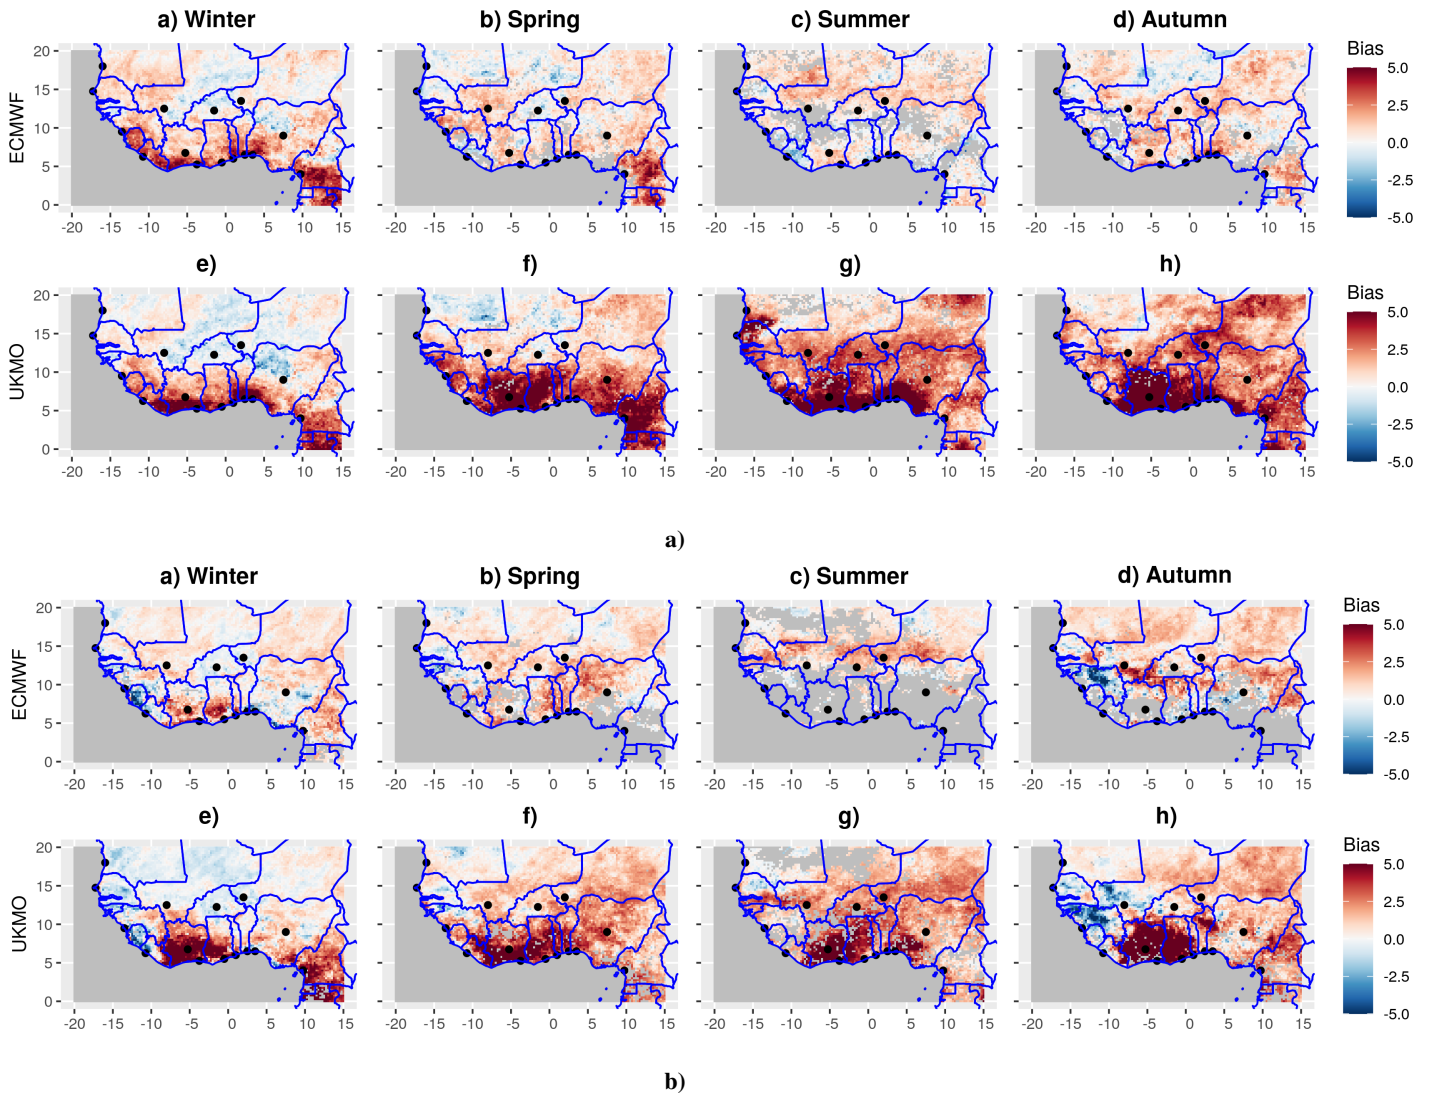


Figure 9. Spatial variability of heat wave duration bias between the forecast models and ERA5 over West Africa from 2001 to 2020 for: **(a)** T2m_min values and **(b)**, during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave duration between the forecast models and ERA5. This analysis is performed using the unperturbed member of the models over years where heat waves were detected. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

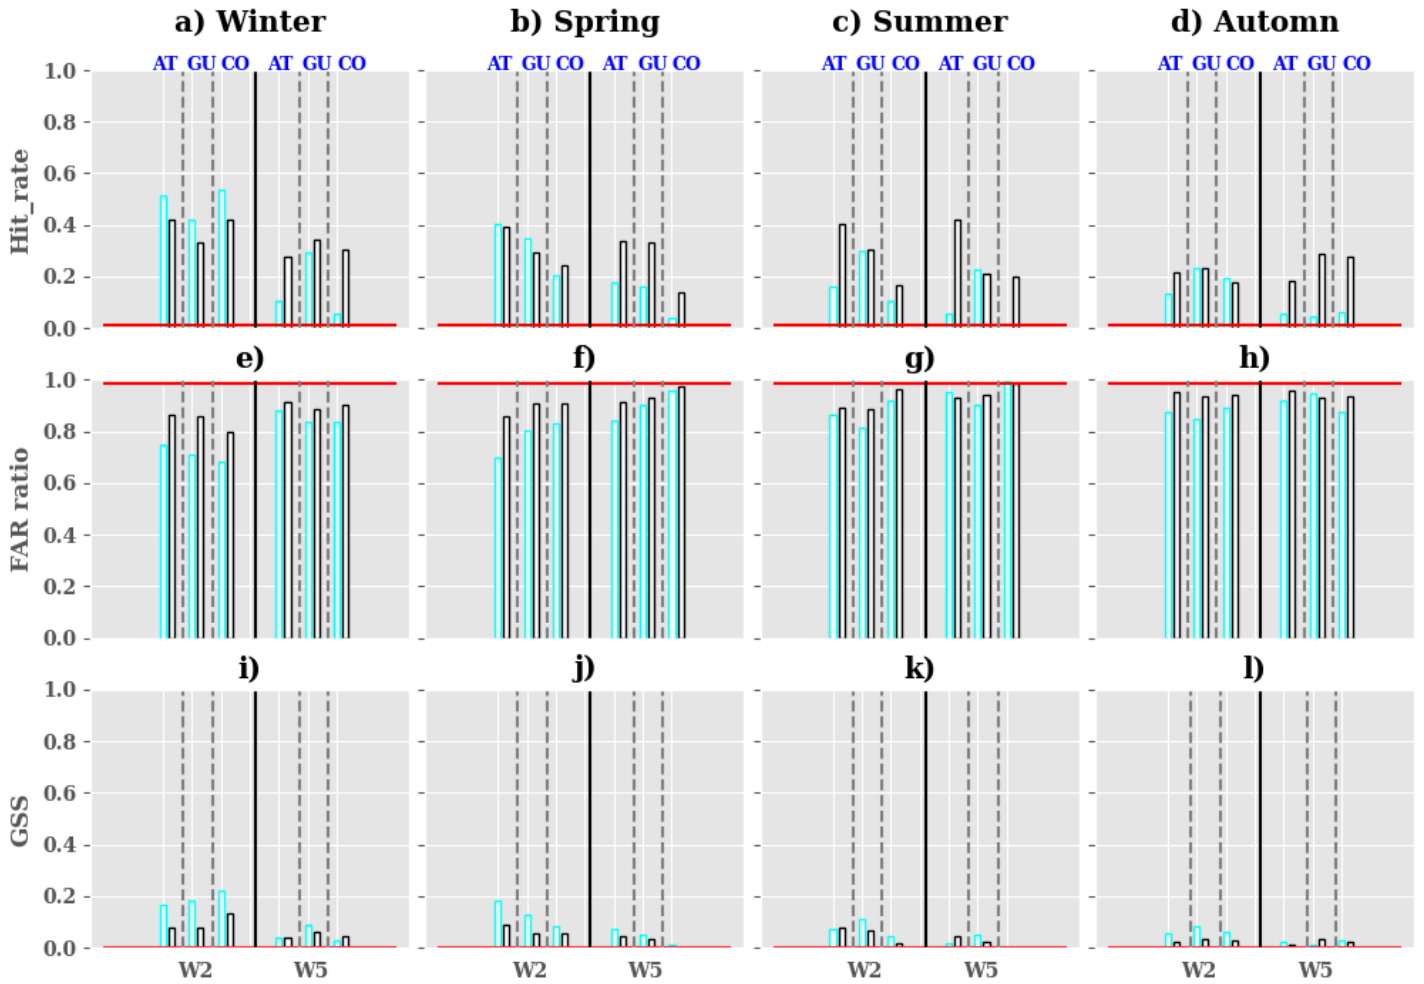


Figure 10. Evaluation of heat waves detection in the forecast models with respect to ERA5 at daily time scale over the period 2001-2020 using T2m_min values for : (a-d) hit-rate, (e-h) FAR ratio and (i-l) GSS. The metrics were computed using the optimized forecasts (see section Methods for the optimisation of the ensemble forecasts). The metrics were calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the metrics obtained when using ECMWF and UKMO respectively. The Y and X axes show the metrics values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.




Figure 11. Evaluation of the intensity of heat waves in the forecast models and ERA5 over the period 2001-2020 during the seasons : (a,e) winter; (b,f) spring; (c,g) summer; (d,h) autumn using T2m_min values. Yellow, green, blue colors represent the values of intensity in the AT, GU, CO regions respectively. The dot and cross symbols represent the intensity of heat waves during week 2 (W2) and week5 (W5) respectively. The Y and X axes represent the forecasted and observed intensities in ERA5 reanalysis respectively.

5.4 Discussion sur le comportement des modèles

Les résultats obtenus dans cette étude révèlent des différences entre les deux modèles dans les trois régions climatiques. Il serait intéressant d'investiguer l'origine des différences observées entre les modèles. À cette fin, nous analysons certains facteurs clés dans l'implémentation des modèles tels que la paramétrisation physique, la technique d'assimilation de données et la résolution spatiale de la composante atmosphérique du système. Les paramétrisations physiques utilisées pour simuler les processus atmosphériques tels que la convection, la turbulence, les interactions surface-océan, le rayonnement de surface et la microphysique des nuages sont différentes pour les deux modèles. Pour la représentation de l'activité convective par exemple, le modèle du CEPMMT utilise le schéma de Tiedtke (Tiedtke, 1989) et UKMO, le schéma convectif du Met Office (Hagelin et al., 2017). Les paramètres utilisés dans les deux schémas convectifs diffèrent également. Le schéma de Tiedtke utilise des paramètres tels que la hauteur de l'enveloppe convective, la température de l'enveloppe et la masse d'air convective, tandis que le schéma convectif du Met Office utilise des paramètres tels que l'indice de stabilité convective, la vitesse verticale ascendante et la fraction de précipitations convectives. Le schéma de Tiedtke est couramment utilisé dans les modèles de circulation générale (GCM) tandis que le schéma du Met Office est utilisé dans les modèles régionaux. Les deux modèles utilisent les mêmes techniques d'assimilation de données (4D-Var, (Fisher and Andersson, 2001)) pour les prévisions déterministes, mais les données et les conditions initiales sont complètement différentes. Ces différences peuvent influencer sur la représentation des interactions surface-océan dans les modèles. Les différences observées dans la représentation de T_{2m} sur l'océan Atlantique [voir **Fig.3** dans l'article] peuvent résulter de ce type de configurations. Un autre facteur important est la résolution spatiale de la composante atmosphérique des deux modèles : le modèle du CEPMMT a une résolution spatiale plus élevée que UKMO ($0,16^\circ \times 0,16^\circ$ contre $0,83^\circ \times 0,56^\circ$), ce qui signifie qu'il peut capturer la variabilité à l'échelle locale ou les processus atmosphériques et fournir des prévisions plus précises pour des régions spécifiques. Cela peut expliquer pourquoi le modèle du CEPMMT est plus performant que l'UKMO dans certaines régions, par exemple dans le cas des tempéra-

tures extrêmes sur les régions *AT* et *GU* [Voir **Fig.6** dans l'article]. Une étude plus approfondie des différences entre les modèles va au-delà de la portée de cette étude.

5.5 Conclusion et perspectives

Cette partie portait sur l'évaluation de la prévisibilité des vagues de chaleur dans les villes d'Afrique de l'Ouest à des échelle intra-saisonnière. À notre connaissance, cette étude est une première de ce type dans la région. Deux modèles prenant part au projet S2S, à savoir : le modèle du CEPMMT et UKMO, ont été évalués en utilisant deux réanalyses fréquemment utilisées dans la région : ERA5 et MERRA sur la période 2001-2020. Nous étudions tout à tour la représentation des températures extrêmes et l'évolution des caractéristiques des vagues de chaleur dans les modèles par rapport aux réanalyses. Les modèles présentent de faibles valeurs de Brier score pour T_{2m} et T_w pour les semaines 2 et 5, ce qui indique leur capacité à prévoir les événements de chaleur extrême jusqu'à 5 semaines à l'avance. Le modèle du CEPMMT se montre plus performant que UKMO pour détecter les journées chaudes par rapport à aux réanalyses (ERA5, MERRA) indépendamment de l'échéance de prévision, des saisons et des régions. Les modèles présentent des difficultés à reproduire correctement l'évolution spatiale des caractéristiques des vagues de chaleur. Nous avons constaté avec T_{2m} une surestimation de la fréquence des vagues de chaleur au printemps et en été dans la région du Sahel pour le modèle du CEPMMT, et du Sahel à la région Guinéenne pour UKMO. En utilisant T_w cette fois, nous avons noté une sous-estimation de la fréquence des vagues de chaleur sur le Sahel et la région Guinéenne en automne. La prévisibilité des vagues de chaleur dans les modèles a été évaluée à partir des métriques telles que le hit-rate, le GSS et le FAR utilisant la réanalyse ERA5 comme référence. Les modèles de prévision présentent de meilleures performances par rapport à une climatologie de référence, principalement pour les prévisions à court terme (deux semaines à l'avance) dans les trois régions. Toutefois, les valeurs du hit-rate sont en moyenne inférieures à 50%, ce qui indique des événements manqués dans les prévisions. Nous constatons que les vagues de chaleur nocturnes sont plus prévisibles que les vagues de chaleur diurnes. Ce résultat est en accord avec l'étude de [Guigma et al. \(2021b\)](#). Le taux de fausses alarmes (FAR) est excessivement élevé en moyenne, et a tendance à augmenter avec l'échéance de la prévision. Seulement 15 à 30 % des jours de vague de chaleur prédits sont effectivement observés, respectivement pour les semaines 5 et

2. Cela suggère que les modèles surestiment la durée des vagues de chaleur par rapport à la réanalyse ERA5. Le modèle du CEPMMT émet moins de fausses alertes que UKMO pour les prévisions à court terme. La prévision des vagues de chaleur sèche est meilleure avec le modèle du CEPMMT pour les prévisions à court terme, tandis que pour les prévisions à long terme, UKMO l'emporte sur le modèle du CEPMMT. En ce qui concerne les vagues de chaleur humide, UKMO est plus performant que le modèle du CEPMMT pour les prévisions à court et à long terme. Bien que les modèles démontrent des performances en matière de détection des vagues de chaleur par rapport à une climatologie de référence, leur capacité à prédire l'intensité des événements reste limitée. La prévision de l'intensité des vagues de chaleur reste une tâche difficile pour les modèles.

En guise de perspective, nous étudierons plus en détails les origines des différences observées dans les deux modèles de prévision dans les différentes régions. La méthode d'optimisation utilisée dans cette étude pourrait être élargie à d'autres indicateurs comme les quantiles 25, 75, 90, la médiane et la moyenne afin d'obtenir une information déterministe la plus optimale. De récentes études ont démontré que les méthodes d'apprentissage automatique peuvent s'avérer utiles pour étendre l'horizon de prédictibilité des prévisions météorologiques [[Salcedo-Sanz et al. \(2016\)](#); [Anjali et al. \(2019\)](#); [Azari et al. \(2022\)](#); [van Straaten et al. \(2023\)](#)]. Sur la base de ces résultats, il serait intéressant d'étudier le potentiel des algorithmes d'apprentissage automatique pour la prévision des vagues de chaleur.

Chapitre 6

Utilisation des méthodes d'apprentissage automatique pour l'optimisation de la prévision des vagues de chaleur dans les modèles de prévision intra-saisonnière

6.1 Introduction

Dans le chapitre précédent, nous avons évalué la prédictibilité des vagues de chaleur dans les modèles de prévision intra-saisonnière. Les modèles présentent de meilleures performances par rapport à une climatologie de référence. Toutefois, les valeurs de score tels que le hit-rate restent faibles en dessous de 50% et le taux de fausses alarmes est très élevé, et ceci même pour de courtes échéances de prévision. La prévision des extrêmes climatiques tels que les vagues reste un véritable challenge pour les modèles de prévision ([Zhu and Li, 2018](#)). Dans le but d'améliorer la qualité des prévisions, nous utilisons les méthodes d'apprentissage automatique comme outils de débiaisage des modèles de prévision.

Les vagues de chaleur représentant un potentiel danger pour les populations, il serait important de développer des outils permettant de fournir des prévisions fiables sur l'occurrence

de ces événements afin de déployer des stratégies d'adaptation adéquates. Plusieurs modèles d'apprentissage automatique ont été développés pour prédire la température et les événements de température extrême. [Naing and Htike \(2015\)](#) ont utilisé la méthode de forêt aléatoire "Random Forest (RF)" pour la prévision des variations de températures mensuelles dans la région de Kuala Lumpur. La méthode de forêt aléatoire a été comparée avec d'autres méthodes telles que le "K-nearest neighbours (KNN)", "Radial Basic Function (RBF) network" et les perceptrons multi-couches. La méthode de forêt aléatoire réalise de meilleures performances par rapport aux autres méthodes. [Khan et al. \(2019\)](#) ont utilisé une variante de forêt aléatoire appelée "Quantile Random Forest (QRF)" pour la détection des vagues de chaleur au Pakistan à partir de la prédiction de la température maximale journalière. Le modèle QRF a pu prédire quelques dates de déclenchement des vagues de chaleur en Mai, Juin et Juillet avec des incertitudes de +/- 5 jours. Dans la même lancée, [Khan et al. \(2021\)](#) utilisent un autre algorithme d'apprentissage automatique le "Support Vector Machine (SVM)" pour la détection des vagues de chaleur au Pakistan cette fois à partir du nombre de jours associés aux vagues de chaleur en période estivale. Les résultats obtenus ont démontré le potentiel de la méthode SVM à réaliser des prévisions fiables des vagues de chaleur. [Giamalaki et al. \(2022\)](#) ont étudié la prédictibilité des vagues de chaleur marines en utilisant un modèle de forêt aléatoire. Le modèle de forêt aléatoire a été capable de prévoir des températures extrêmes de surface de la mer à des échéances de quelques semaines. Dans cette étude, notre objectif principal est d'explorer le potentiel des méthodes d'apprentissage automatique en vue de l'optimisation des prévisions probabilistes des jours dans les vagues de chaleur réalisées par les modèles de prévision intra-saisonnière. Sur la base des travaux antérieurs utilisant les méthodes d'apprentissage automatique pour la prévision des vagues de chaleur, nous avons identifié trois méthodes d'apprentissage automatique : RF, SVM et une variante de la forêt aléatoire appelée "Balanced Random Forest (BRF)". Ces méthodes d'apprentissage sont appliquées comme outil de débiaisage aux prévisions des modèles, et par la suite nous comparons les prévisions corrigées aux prévisions brutes des modèles (CEPMMT, UKMO).

6.2 Région

6.2.1 Région d'étude

La présente étude est réalisée en Afrique de l'ouest, couvrant une zone comprise entre 5-20°N et 15°W-10°E, s'étendant de la côte atlantique au Tchad et du golfe de Guinée au désert du Sahara [Fig.6.1]. Le climat de l'Afrique de l'ouest est principalement influencé par la mousson ouest-africaine, qui régule la saison des pluies et impacte en conséquence l'activité agricole. Le climat de l'Afrique de l'ouest se caractérise par une courte saison humide suivie d'une longue saison sèche. L'Afrique de l'ouest présente une grande variabilité climatique à l'échelle régionale et locale. Ce travail se focalise sur les principales villes des régions côtières et continentales d'Afrique de l'ouest. Les villes ont été regroupées en trois régions en fonction de leur emplacement, de la variabilité climatique et de l'évolution des caractéristiques des vagues de chaleur dans chaque région (Moron et al., 2016; Ngoungue Langue et al., 2023). Les régions sont structurées comme suit :

- la région continentale (CO ci-après) englobe les villes de Bamako, Ouagadougou et Niamey [Fig.6.1];
- Région côtière atlantique (AT ci-après) englobe les villes de Dakar, Nouakchott, Monrovia et Conakry [Fig.6.1];
- La région côtière Guinéenne (GU ci-après) englobe les villes de Yamoussoukro, Abidjan, Lomé, Accra, Cotonou, Lagos, Abuja et Douala [Fig.6.1].

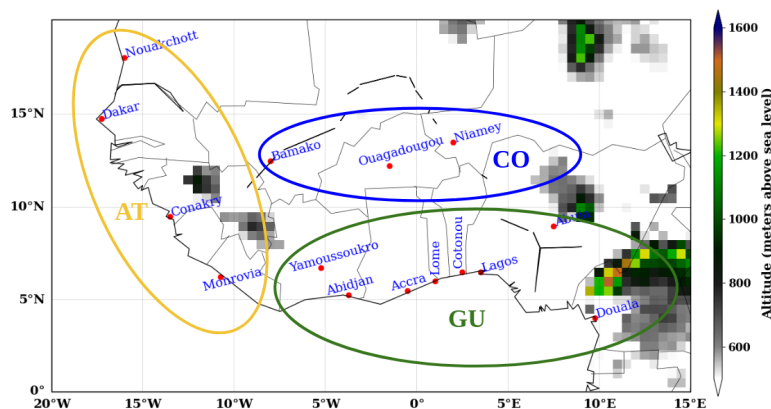


Figure 6.1 – Région d'étude

6.3 Données utilisées

Nous utilisons dans le cadre de ce travail, les prévisions passées ("hindcasts") des modèles de prévisions intra-saisonnières et la réanalyse ERA5 comme référence d'après les précédentes études réalisées dans la région (Guigma et al., 2020b; Ngoungue Langue et al., 2021).

6.3.1 Réanalyse ERA5

La réanalyse ERA5 est produite par le CEPMMT et fournit des données horaires de diverses variables atmosphériques pour l'ensemble du globe (Hersbach et al., 2020). La résolution spatiale originale de ERA5 est de 0.28125° , et par la suite les données sont interpolées sur une grille régulière de $0.25^\circ \times 0.25^\circ$. Quant à la résolution verticale, ERA5 utilise 137 niveaux hybrides appelés "niveaux sigma" jusqu'à 80 km au-dessus de la surface. Les analyses sont faites en utilisant la température horaire à 2 mètres (T2m) à partir de laquelle les valeurs minimale et maximale ont été déduites (Tmin, Tmax). Les données couvrent la période allant du 1^{er} Janvier 2001 au 9 Février 2021, et sont accessibles via la base de données Climserv du serveur de l'Institut Pierre Simon Laplace (IPSL) ou encore le site du Copernicus Climate Data Store (CDS).

6.3.2 Modèles de prévision intra-saisonnière

Les prévisions intra-saisonnières sont d'un intérêt capital afin de combler le gap entre les prévisions météorologiques à moyen terme et les prévisions saisonnières. Lancé en 2013 par le programme mondial de recherche météorologique (WWRP) et le programme mondial de recherche sur le climat (WCRP), le projet S2S (Subseasonal to seasonal forecasts) vise à améliorer la qualité et la compréhension des prévisions à l'échelle sub-saisonnière et saisonnière, en mettant l'accent sur les phénomènes météorologiques à fort impact (voir <http://www.s2sprediction.net/>). Cette étude est réalisée sur une période de 20 ans (2001 à 2020) afin d'obtenir des résultats statistiquement robustes. De fait, parmi les 12 modèles impliqués dans le projet S2S, nous avons évalué 2 modèles à savoir : CEPMMT et UKMO car ils sont tous deux disponibles tout au long de la période d'étude. Ces deux modèles sont décrits dans l'article sur la prévisibilité des vagues de

chaleur au chapitre 4. Toutefois, dans un souci de cohérence et également pour faciliter la compréhension des travaux réalisés dans ce chapitre, nous avons décidé de décrire une nouvelle fois les modèles dans cette partie.

6.3.2.1 Modèle du CEPMMT

Le modèle étendu du CEPMMT "ENS" fonctionne à partir du système de prévision intégré (IFS cycle CY41r2). La résolution spatiale native du modèle du CEPMMT est d'environ 16km jusqu'au 15^{eme}, puis environ 32km après le 15^{eme} jour mais les données téléchargées sur le site sont interpolées sur une grille régulière de 0.25° x 0.25°. Le modèle comprend 91 niveaux sigma allant de la surface jusqu'à 80km d'altitude. Le modèle du CEPMMT réalise deux types de prévision : les prévisions en temps réel et les prévisions passées ("hindcasts"). Les prévisions en temps réel sont des prévisions pour les jours à venir, tandis que les hindcasts font référence aux prévisions sur des périodes historiques utilisées pour calibrer une nouvelle version du modèle. Les prévisions en temps réel du modèle du CEPMMT sont réalisées avec 51 membres d'ensemble (50 perturbés et 1 non perturbé), tandis que les hindcasts sont réalisées avec 11 membres. Dans cette étude, nous nous concentrons uniquement sur les hindcasts. Les hindcasts du modèle du CEPMMT sont produites deux fois par semaine, le Lundi et le Jeudi à 00Z. Nous avons uniquement analysé les hindcasts du jeudi, car une première investigation a révélé que certains modèles avaient été initialisés à la même date, mais nous avons réalisé par la suite que ces modèles n'étaient pas disponibles sur toute la période. Chaque semaine un nouvel ensemble de hindcasts est produit pour calibrer les prévisions en temps réel pour le Lundi et le Jeudi de la semaine suivante. Dans notre cas, l'année de prévision est l'année 2021 et nous nous intéressons sur les 20 années précédentes à partir de cette date. Les hindcasts sont produites pour une durée de 6 semaines. Les variables d'intérêt dans le cadre du projet S2S sont Tmin et Tmax sur les 6 dernières heures. Les données sont accessibles sur le site du projet S2S.

6.3.2.2 Modèle UKMO

Le modèle UKMO fonctionne à partir du modèle HadGEM3 GC2.0, qui simule les incertitudes des conditions initiales et les incertitudes du modèle à l'aide d'un schéma stochastique. La résolution spatiale native du modèle UKMO est $0.83^\circ \times 0.56^\circ$ (environ 60 km aux latitudes moyennes). Il comprend 85 niveaux verticaux de la surface à 85 km et 4 niveaux au sol : niveau 1 (0 - 0.1m), niveau 2 (0.1 - 0.35m), niveau 3 (0.35 - 1m) et niveau 4 (1 - 3m). Tout comme le modèle du CEPMMT, UKMO fournit au programme S2S des prévisions en temps réel et des hindcasts. Les prévisions en temps réel de UKMO sont constituées d'un ensemble de 4 membres exécutés quotidiennement sur une période de 60 jours (3 membres perturbés et 1 membre non perturbé). Les hindcasts de UKMO sont produits 4 fois par mois : les 1^{er}, 9, 17 et 25, et couvrent une période de 24 ans, de 1993 à 2016. Nous sommes conscients que ces dates initiales ne correspondent pas à celles du CEPMMT, mais notre intérêt dans cette étude porte sur la prévisibilité des vagues de chaleur dans une perspective globale, et non sur des événements spécifiques. Les hindcasts sont composées de 7 membres (à partir des hindcasts du 25 mars 2017, avant cela c'était 3 membres). Notre période cible s'étend de janvier 2001 à février 2021, et comme mentionné précédemment, les hindcasts de UKMO ne sont pas disponibles après l'année 2016. Pour résoudre ce problème et obtenir des résultats statistiques plus robustes, nous recomposons les produits afin d'obtenir un nouveau composite qui couvre toute la période d'étude. Le processus appliqué est décrit par l'expression suivante :

$$\text{UKMO}_{2001-2021} = \text{Concatenation} \left[\text{UKMO}_{\text{hindcast}2001-2016}, \text{UKMO}_{\text{realtimeforecast}2017-2021} \right] \quad (6.1)$$

L'opérateur concaténation est appliqué à la dimension temporelle. Les prévisions en temps réel ont été extraites pour les mêmes jours que l'initialisation des "hindcasts". Le nombre de membres d'ensemble dans les "hindcasts" est fixé à 4 (1 membre de contrôle et 3 membres perturbés) pour être cohérent avec le nombre de membres d'ensemble dans les prévisions en temps réel. Nous avons sélectionné les trois premiers membres perturbés parmi les 7 disponibles dans

les hindcasts. Les prévisions UKMO analysées dans cette étude sont lancées pour une durée de 6 semaines. Les variables extraites de la base de données UKMO sont les mêmes que celles du modèle du CEPMMT.

6.4 Méthodes

D'après les études antérieures portant sur l'utilisation des méthodes d'apprentissage pour la prévision des vagues de chaleur ([Chen et al., 2004](#); [Naing and Htike, 2015](#); [Khan et al., 2019, 2021](#)), nous avons identifié pour ce travail, trois méthodes d'apprentissage automatique les plus utilisées. La philosophie derrière le choix des méthodes étant de monter progressivement en complexité en évaluant les algorithmes les plus simples et faciles à optimiser. Ces méthodes d'apprentissage vont être appliqués aux prévisions des modèles (CEPMMT, UKMO) comme outil de correction de biais.

6.4.1 Random Forest (Forêt aléatoire) "RF" + Synthetic Minority Oversampling Technique (SMOTE)

Le RF est un algorithme d'apprentissage supervisé très répandu qui peut être appliqué pour des tâches de classification et de régression. C'est une méthode d'apprentissage d'ensemble développée par [Breiman \(2001\)](#), elle est constituée de plusieurs arbres de décision d'où l'appellation de "forêt aléatoire" [Fig.6.2]. Ces arbres de décision sont créés à partir d'échantillons issus du bootstrap des données d'entraînement, en utilisant une sélection aléatoire des prédicteurs lors de la création de l'arbre. Le bootstrap est une technique de ré-échantillonnage qui consiste à tirer à plusieurs reprises des échantillons dans un jeu de données avec remise dans le but d'améliorer la capacité de généralisation d'un modèle de machine learning. Le RF présente de meilleures performances par rapport aux classificateurs à un seul arbre tels que les arbres de décision (arbres de classification et de régression) ([Chen et al., 2004](#); [Singh and Gupta, 2014](#)). Le RF réduit le risque de sur-apprentissage sur les données d'entraînement et fournit une meilleure capacité de généralisation en comparaison aux arbres de décision. On parle de sur-apprentissage

quand le modèle de très bonnes performances sur les données d'entraînement tandis que ses performances sur les données de test, ne sont pas dans le même ordre de grandeur.

L'apprentissage d'un modèle RF s'effectue en deux étapes :

1. le "tree baging" qui consiste à tirer des échantillons à partir des données d'entraînement en utilisant le bootstrap;
2. le "feature sampling", pour chacun des échantillons bootstrap de l'étape 1, un arbre de classification ou de régression est généré en définissant à chaque nœud le nombre de prédicteurs à utiliser. Le choix de nombre de prédicteurs par nœud se fait techniquement à travers le paramètre "mtry" dans la librairie scikit-learn destinée à l'implémentation des algorithmes d'apprentissage automatique en Python. Le paramètre "mtry" permet de fixer le valeur du nombre de prédicteurs à utiliser pour chaque nœud pendant la phase d'entraînement.

La prédiction par le RF est faite en agrégeant les prédictions de l'ensemble des arbres de décision en utilisant :

- le vote majoritaire dans le cas de la classification;
- la moyenne dans le cas de la régression.

Dans notre cas, nous réalisons un classification des jours en jours normaux ou jours de vague de chaleur à partir des caractéristiques de l'évolution de la température fournies par les modèles de prévision.

La méthode RF possède trois paramètres clés pouvant impacter considérablement sur les performances du modèle. Il s'agit entre autres du nombre d'arbres de décision constituant la forêt aléatoire, de la taille des arbres (nombre de noeuds) et le nombre de prédicteurs à considérer à chaque noeud. Ces hyper-paramètres sont optimisés par une technique appelée "gridsearch", consistant à évaluer les performances du modèle pour chaque combinaison d'hyper-paramètres afin de trouver la combinaison d'hyper-paramètres qui optimise les performances du modèle.

Comme la plupart des méthodes de classification, le RF peut également rencontrer des difficultés dans l'apprentissage à partir d'un ensemble de données d'entraînement extrêmement

déséquilibré : le cas des vagues. Comme il est conçu pour minimiser le taux d'erreur global, il aura tendance à se concentrer davantage sur la prédiction de la classe majoritaire, ce qui se traduirait par de mauvaises prédictions pour la classe minoritaire (Chen et al., 2004). Pour surmonter ce problème, deux solutions sont utilisées : Balanced Random Forest (BRF) et un RF classique appliqué aux données rééquilibrées. L'opération de rééquilibrage de données est effectuée en utilisant une technique de sur-échantillonnage des données de la classe minoritaire appelée "Synthetic Minority Oversampling Technique (SMOTE)".

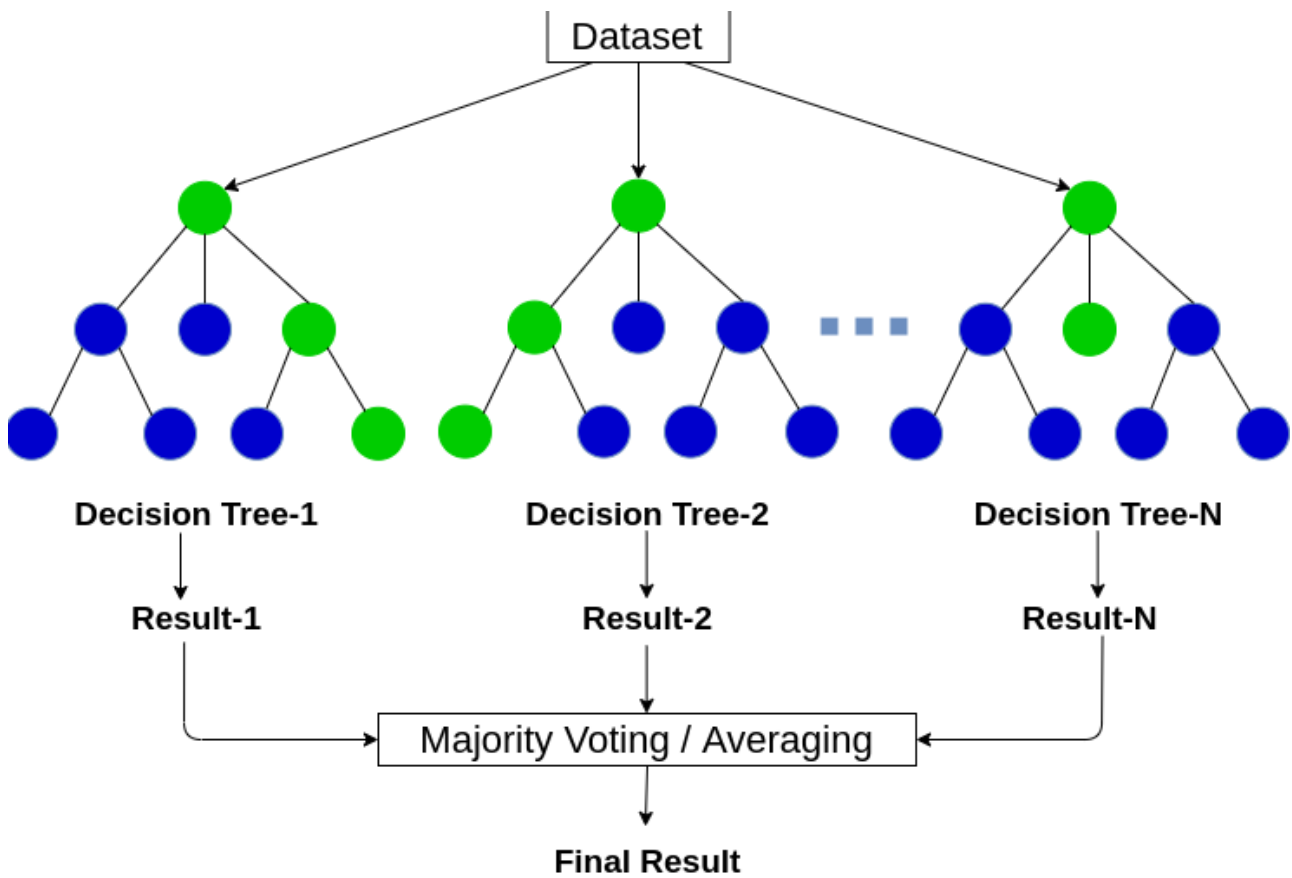


Figure 6.2 – Illustration de la méthode random Forest (Forêt aléatoire)

Le SMOTE est l'une des techniques de sur-échantillonnage utilisant la classe minoritaire pour générer des échantillons synthétiques (Chawla et al., 2002). Il permet de résoudre le problème de sur-apprentissage rencontré dans le sur-échantillonnage aléatoire des données. La technique SMOTE procède en générant des individus de la classe minoritaire qui ressemblent aux autres, sans être strictement identiques. Cela permet de densifier de façon plus homogène la population d'individus minoritaires. La méthode sélectionne aléatoirement une instance de la classe minori-

taire et trouve son plus proche voisin. Ces nouvelles données synthétiques seront utilisées pour l'entraînement du modèle RF. La création d'individu synthétique par la méthode SMOTE passe par les étapes suivantes [Fig.6.3] :

1. la sélection de façon aléatoire d'une observation de la classe minoritaire initiale;
2. l'identification de ses k plus proches voisins parmi les observations minoritaires (où k est un paramètre défini par l'utilisateur);
3. le choix de façon aléatoire d'un des k plus proches voisins;
4. le choix d'un coefficient aléatoirement entre 0 et 1 ($0 < \alpha < 1$);
5. la création d'un nouvel individu ("individu synthétique") entre l'observation initiale choisie à l'étape 1 et le plus proche voisin choisi à l'étape 3, selon la valeur du coefficient. Par exemple, si $\alpha = 0.5$, le nouvel individu sera positionné à mi-chemin entre l'observation et le plus proche voisin choisi.




Figure 6.3 – Illustration de la méthode SMOTE sur les données minoritaires. Le petit rond rouge est l'observation minoritaire initiale.

6.4.2 Balanced Random Forest (Forêt aléatoire équilibrée) - BRF

En se référant à [Breiman \(2001\)](#), la forêt aléatoire génère chaque arbre à partir d'un échantillon de données issu du bootstrap des données d'entraînement. Lors de l'apprentissage sur des données extrêmement déséquilibrées, il existe une forte probabilité qu'un échantillon bootstrap contienne peu, voire pas du tout des observations de la classe minoritaire. De fait, cet arbre réalisera de mauvaises prédictions de la classe minoritaire. Une approche basique pour résoudre ce problème consiste à utiliser un bootstrap stratifié, c'est-à-dire à échantillonner avec remplacement à l'intérieur de chaque classe. Mais cela ne résout pas entièrement le problème du déséquilibre des données. Les études antérieures ([Kubat et al., 1997](#); [Ling and Li, 1998](#); [Drummond et al., 2003](#)) montrent que l'utilisation des techniques artificielles pour rééquilibrer les classes, soit par un sous-échantillonnage de la classe majoritaire, soit par un sur-échantillonnage de la classe minoritaire, est généralement plus efficace pour l'amélioration des performances du modèle. Et aussi, les techniques de sous-échantillonnage semblent être plus avantageuses que les techniques de sur-échantillonnage. Toutefois, le sous-échantillonnage de la classe majoritaire peut entraîner une perte d'informations, car une grande partie des données de la classe majoritaire n'est pas utilisée. La forêt aléatoire équilibrée (BRF) est une variante de la méthode RF dans laquelle chaque échantillon de données issu du bootstrap est rééquilibré en réduisant les observations de la classe majoritaire.

6.4.3 Support Vector Machine - SVM

Le SVM fait partie des méthodes d'apprentissage supervisé utilisé pour la classification, la régression ou encore la détection des valeurs aberrantes ([Hearst et al., 1998](#); [Noble, 2006](#); [Suthaharan and Suthaharan, 2016](#)). L'objectif de la méthode SVM est de trouver un hyperplan dans un espace à N dimension ($N > 1$, représentant le nombre de prédicteurs), qui divise au mieux un jeu de données en deux classes distinctes. Les SVM sont des séparateurs linéaires, c'est-à-dire que la frontière séparant les classes est une droite. Il existe une multitude de d'hyperplans pour séparer les données d'observation en deux classes [Fig.6.4.a)]. C'est à ce niveau qu'intervient la

notion de "marge maximale", le but ici étant de déterminer l'hyperplan qui maximise la distance entre les deux classes [Fig.6.4.b)]. Les points situés de part et d'autre de l'hyperplan sont attribués à des classes différentes; l'hyperplan constitue ainsi la séparation entre les deux classes. Plus grande est la distance entre les deux classes, plus précises seront les prédictions pour chacune des classes. La dimension de l'hyperplan dépend du nombre de prédicteurs. Si $N=\{2, 3\}$ alors l'hyperplan est respectivement une droite, un plan. Au-delà de 3, il devient difficile de visualiser l'hyperplan. Les points les plus proches de l'hyperplan sont appelés vecteurs support et influencent considérablement la position et l'orientation de ce dernier. Ils sont donc le support que le SVM utilise pour construire la frontière d'où vient le nom Support Vector Machine. Les SVM ont fait l'objet d'études approfondies et ont connu un succès remarquable dans de nombreuses applications. Toutefois, le succès des SVM est très limité lorsqu'elles sont appliquées au problème de l'apprentissage sur des données déséquilibrés (Akbari et al., 2004). Nous avons ajusté certains paramètres de cet algorithme tels que le poids accordé à chaque classe, afin de rééquilibrer le jeu de données durant l'apprentissage. Les hyper-paramètres les plus importants pour cette méthode sont le facteur régularisation, la fonction noyau et le coefficient associé à la fonction noyau ("gamma"). Les hyper-paramètres optimaux sont obtenus à partir d'une technique de gridsearch sur un ensemble de valeurs pour chacun des paramètres. Les SVM sont très efficaces en dimension élevée, très peu sensibles au bruit dans les données d'apprentissage car utilisent uniquement une partie de données pour déterminer l'hyperplan optimal (vecteurs support).

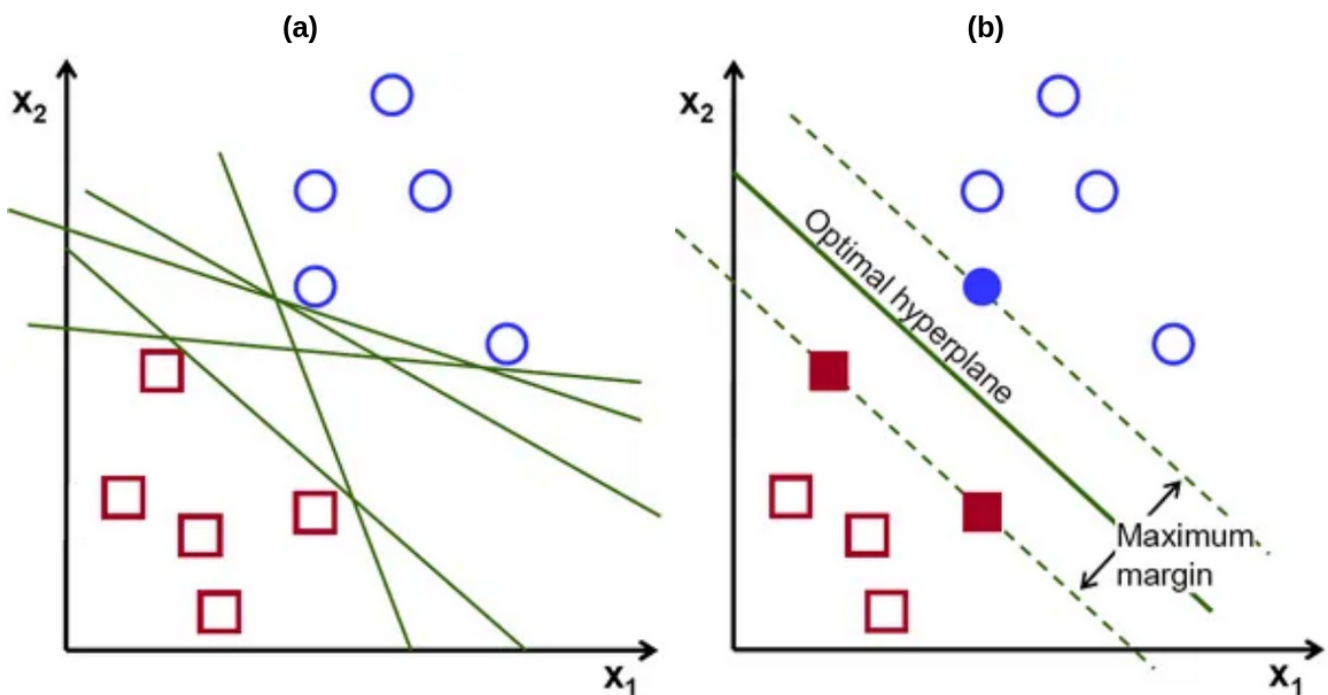


Figure 6.4 - Illustration de la méthode SVM

6.4.4 Métrique d'évaluation des méthodes d'apprentissage automatique : F1-score

Dans le cas de cette étude nous avons évalué trois algorithmes d'apprentissage supervisé à savoir : le RF classique, le BRF et le SVM. Il existe diverses métriques statistiques pour l'évaluation des modèles de machine learning. Toutefois, en fonction du contexte et de l'application de l'étude, certaines métriques peuvent être plus indiquées que d'autres. Dans notre cas, nous cherchons à prédire les jours dans les vagues de chaleur. De fait, une métrique comme le taux de bonnes prédictions ("accuracy") ne serait pas un bon choix car elle présentera des valeurs élevées même si le modèle ne classe pas correctement les jours dans les vagues de chaleur. L'accuracy prend en compte toutes les bonnes prédictions effectuées par le modèle. Par contre, des métriques comme la "Précision" et le "Rappel" peuvent être intéressantes pour notre problème. La précision représente la proportion des événements positifs correctement prédits par rapport à l'ensemble des événements prédits "positif" par le modèle. Le rappel représente quant à lui la proportion d'événements positifs correctement prédits par rapport aux événe-

ments positifs observés en réalité. Ces deux métriques peuvent être déterminées à partir d'une table de contingence [Tab.6.1].

		modèle	
		0	1
observation	0	TN	FP
	1	FN	TP

Table 6.1 – Table de contingence

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (6.2)$$

$$\text{Rappel} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6.3)$$

Toutefois, il convient de trouver un équilibre entre précision et rappel pour l'optimisation des performances du modèle. La précision aura tendance à optimiser le hit (occurrence des événements positifs) tandis que le rappel se focalisera sur les misses (événements manqués par le modèle). De fait, le F1-score apparaît comme un bon compromis entre les deux précédentes métriques.

Le F1-score est une métrique utilisée pour évaluer les performances des modèles de classification à 2 classes ou plus ([Chicco and Jurman, 2020](#)). Il est particulièrement utilisé pour les problèmes utilisant des données déséquilibrées comme la détection de fraudes ou la prédiction d'incidents graves. Il est donné par la formulation suivante :

$$\text{F1_score} = \frac{2 * \text{Precision} * \text{Rappel}}{\text{Precision} + \text{Rappel}} \quad (6.4)$$

Il peut être directement obtenu à partir de la table de contingence comme suit :

$$\text{F1_score} = \frac{\text{TP}}{\text{TP} + \frac{\text{FN} + \text{FP}}{2}} \quad (6.5)$$

Cette dernière formule montre que le F1-score compare les prédictions positives correctes

(TP) aux erreurs (FN+FP) faites par le modèle. Un F1-score de 50% équivaut à $TP = \frac{1}{2}(FN + FP)$ et s'interprète donc de la façon suivante : pour une prédiction positive correcte, le modèle fait deux erreurs (faux négatif ou faux positif). Les valeurs du F1-score sont comprises entre [0-1], plus élevées sont les valeurs du F1-score, meilleur est le modèle.

6.4.5 Implémentation des modèles de Machine learning

Le but de cette étude étant d'améliorer la qualité des prévisions des vagues de chaleur réalisées par les modèles S2S (CEPMMT,UKMO). À cet effet, nous utilisons comme prédicteurs les prévisions de température à 2-m sur les 6 jours précédents le jour à prédire (nous l'appelons "le jour j" par la suite). Ceci permet au modèle d'apprentissage automatique de prendre en compte l'évolution de la température quelques jours avant le déclenchement d'une vague de chaleur. Les prévisions utilisées sont initialisées au début de chaque mois. Les températures absolues présentent une forte saisonnalité pouvant impacter sur les performances du modèle d'apprentissage. Afin de réduire le bruit dans les données d'entraînement, nous utilisons les anomalies de température calculées sur la période 2001-2021. Les modèles CEPMMT et UKMO étant des modèles d'ensemble, nous avons défini quelques indicateurs afin d'extraire des informations robustes de ces systèmes [Table.6.2] :

- le membre non perturbé;
- le minimum journalier de tous les membres;
- la moyenne journalière de tous les membres;
- le maximum journalier de tous les membres;
- l'écart type journalière entre les membres.

Les prédicteurs désignant les variables à prédire, sont les jours dans les vagues de chaleur détectés à partir de la réanalyse ERA5. Il s'agit d'un vecteur booléen contenant "1" si on est dans une période de vague de chaleur et "0" sinon. Les données sont ensuite subdivisées en données d'entraînement soit 15 années et données de test soit 4 années (2003, 2008, 2012, 2019). Les années de test ont été choisies en prenant en compte l'effet du changement climatique sur la période 2001-

2021, une année par bloc de 5 années. Plusieurs approches peuvent être utilisées pour le choix des années de test, celles-ci pourraient être explorées dans les perspectives de ce travail. Compte tenu du temps de calcul nécessaire pour l'apprentissage des modèles et du temps imparti pour la thèse, nous n'avons pas pu réaliser l'apprentissage sur plusieurs sous-ensembles du jeu de données. Les modèles sont entraînés séparément pour chaque ville et chaque semaine. En vue d'une application dans un contexte opérationnel, les modèles sont entraînés uniquement pour les semaines 2 à 6 car pour une prévision pour le "jour j", les modèles d'apprentissage utilisent les prévisions des modèles intra-saisonniers des 6 jours précédents. Les modèles d'apprentissage automatique évalués dans ce travail ont été développés en utilisant le langage de programmation "Python" et des bibliothèques telles que "scikit-learn".

Les grandes étapes de l'implémentation des algorithmes d'apprentissage sont décrites ci-dessous :

1. subdiviser les données en ensemble d'entraînement et de test;
2. déterminer les hyperparamètres pour chaque modèle en utilisant une approche de grid-search et la validation croisée;
3. procéder à l'entraînement des modèles en utilisant la combinaison d'hyperparamètres trouvée à l'étape 2;
4. réaliser des prédictions sur l'ensemble de test;
5. évaluer les performances des modèles sur l'ensemble de test en calculant le F1-score;
6. optimiser les valeurs de F1-score obtenues à l'étape 5, en évaluant plusieurs seuils de décision entre 0 et 1.

unpert_day6	prévision membre non perturbé 6 jours avant le jour j
unpert_day5	prévision membre non perturbé 5 jours avant le jour j
unpert_day4	prévision membre non perturbé 4 jours avant le jour j
unpert_day3	prévision membre non perturbé 3 jours avant le jour j
unpert_day2	prévision membre non perturbé 2 jours avant le jour j
unpert_day1	prévision membre non perturbé 1 jours avant le jour j
unpert_day0	prévision membre non perturbé le jour j
min_day0	minimum journalier des prévisions d'ensemble le jour j
mean_day0	moyenne journalière des prévisions d'ensemble le jour j
max_day0	maximum journalier des prévisions d'ensemble le jour j
std_day0	écart-type journalier des prévisions d'ensemble le jour j

Table 6.2 – Liste des prédicteurs utilisés.

6.5 Résultats

6.5.1 Évaluation des modèles d'apprentissage automatique

Les modèles d'apprentissage décrits ci-dessus ont été évalués sur leurs capacités à prédire les jours de vague de chaleur. Pour ce faire, nous calculons le F1-score entre les prévisions réalisées par chacun des modèles sur la période de test (2003,2008,2012,2019) et les observations ERA5 correspondantes en utilisant Tmin et Tmax. Le F1-score est évalué pour chaque semaine dans les différentes régions. Les résultats obtenus avec Tmin montrent une perte de prédictibilité dans les modèles d'apprentissage en fonction de l'échéance de prévision [Fig.6.5]. Cette perte de prédictibilité dans les modèles est assez flagrante dans les régions AT et GU [Fig.6.5a,c)]. Les valeurs du F1-score sont relativement faibles autour de 20% en moyenne spatiale dans les trois ré-

gions pour les deux premières semaines. Ainsi pour un événement correctement prédit par les modèles d'apprentissage automatique, 8 erreurs sont produites, soit des fausses alertes (faux positifs) ou alors des événements manqués (faux négatifs). En analysant les résultats obtenus à partir de T_{max} , on remarque que les valeurs de F1-score ne décroissent pas nécessairement en fonction de l'échéance de prévision et une forte variabilité spatiale des performances des méthodes d'apprentissage automatique [Fig.6.6]. De façon générale, la méthode BRF présente de meilleures performances par rapport aux méthodes RF et SVM lorsqu'elle est appliquée aux deux modèles de prévision intra-saisonnière CEPMMT et UKMO [Fig.6.5 et Fig.6.6]. De fait pour la suite des analyses, nous utiliserons le modèle BRF.




Figure 6.5 – Évaluation des prévisions des différentes méthodes d'apprentissage automatique en utilisant T_{min} sur la période de test dans les différentes régions : a) AT, b) CONT et c) GU. Les méthodes d'apprentissage ont été appliquées sur les différents modèles de prévision (CEPMMT et UKMO) chaque ville et semaine; et par la suite le F1-score a été calculé et regroupé par région. Les ronds de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant en entrée les prévisions du modèle CEPMMT. Les croix de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant cette fois en entrée les prévisions du modèle UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du F1-score.




Figure 6.6 – Évaluation des prévisions des différentes méthodes d'apprentissage automatique en utilisant Tmax sur la période de test dans les différentes régions : a) AT, b) CONT et c) GU. Les méthodes d'apprentissage ont été appliquées sur les différents modèles de prévision (CEPMMT et UKMO) chaque ville et semaine; et par la suite le F1-score a été calculé et regroupé par région. Les ronds de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant en entrée les prévisions du modèle CEPMMT. Les croix de couleur noire, bleue et rouge représentent respectivement le F1-score associé aux prévisions issues des différentes méthodes d'apprentissage : "SVM", "RF+SMOTE" et "BRF" en utilisant cette fois en entrée les prévisions du modèle UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du F1-score.

6.5.2 Inter-comparaison entre les modèles d'apprentissage automatique et les modèles de prévision intra-saisonnière

Une fois les différents modèles d'apprentissage automatique évalués entre eux, nous comparons le modèle d'apprentissage le plus performant (BRF) et les modèles de prévision S2S (CEPMMT,

UKMO) par rapport à la réanalyse ERA5 choisie comme référence. Pour ce faire, nous utilisons les mêmes métriques précédemment énoncées au Chapitre 4 à savoir : le hit-rate, le False Alarm Ratio (FAR) et le Gilbert skill score (GSS). Ces scores sont calculés en utilisant T_{min} et T_{max} pour chaque semaine sur la période de test dans chacune des trois régions (AT, GU, CONT). Pour calculer les scores dans les régions, nous agrégeons les prévisions réalisées pour les villes de chaque bloc de façon à obtenir un seul vecteur représentant la région en question, à partir duquel le score est estimé. Les prévisions des modèles S2S utilisées pour cette analyse ont été optimisées en utilisant un seuil de 20% (voir chapitre 4 section 2.4.4 dans l'article "Subseasonal to seasonal forecasts of heat waves over West African cities"). Nous analysons dans un premier temps le hit-rate et le GSS associés à T_{min}. On note une forte variabilité spatiale des performances des modèles de prévision et du modèle BRF dans les différentes régions [Fig.6.7]. Les modèles de prévision intra-saisonnière présentent des valeurs de hit-rate très faibles autour de 20% en moyenne spatiale sur les trois régions. Le modèle BRF quant à lui, présente des valeurs de hit-rate plus élevées en moyenne spatiale autour de 50% sur les 3 régions pour les différentes échéances de prévision. Le modèle BRF réalise de meilleures performances dans la région GU et les valeurs du hit-rate restent assez constantes dans la région [Fig.6.7.c]. Ceci pourrait être expliqué par une certaine homogénéité dans les conditions atmosphériques conduisant à l'occurrence des vagues de chaleur dans cette région. Nous remarquons également que le modèle BRF performe très bien durant la cinquième semaine sur toutes les régions. Les performances des modèles par rapport à la climatologie sont évaluées en calculant le GSS. Les valeurs de GSS obtenues sont relativement faibles par rapport aux valeurs de hit-rate pour les modèles de prévision et le modèle BRF. Le GSS associé au modèle BRF est élevé pour les courtes échéances de prévision jusqu'à deux semaines et tend à décroître avec le temps [Fig.6.8]. L'évolution du hit-rate et du GSS associés à T_{max} est quasi-similaire à celle obtenue avec T_{min}. Toutefois, le modèle BRF présente des valeurs de hit-rate plus élevées en région CONT avec T_{max} par rapport à celles obtenues avec T_{min} dans la même région (Voir [Fig.C.1] en annexe). Les valeurs de GSS sont plus élevées avec T_{max} que T_{min} dans les régions AT et GU (Voir [Fig.C.2] en annexe). En se basant sur le GSS, le modèle BRF est meilleur pour la détection des vagues de chaleur journalières que les

vagues de chaleur nocturnes dans les régions AT et GU. Le modèle BRF présente de fortes valeurs de hit-rate pour T_{min} et T_{max}, ce qui traduit une bonne cohérence entre les événements prédits et les événements observés dans ERA5. Toutefois, il est important d'évaluer le taux de fausses alertes réalisées par les modèles d'où le calcul du FAR. Les valeurs du FAR obtenues à partir de T_{min} sont très élevées pour les modèles de prévision et le modèle d'apprentissage BRF [Fig.6.9]. Le modèle BRF réalise moins de fausses alertes durant les deux premières semaines mais le nombre de fausses alertes tend à croître au cours du temps. Néanmoins, les valeurs de FAR avoisinent les 85% pour les courtes échéances jusqu'à deux semaines et 90% au-delà. De fait, sur dix jours de vagues de chaleur prédits par le modèle BRF, approximativement 2 jours sont observés dans ERA5 jusqu'à deux semaines d'échéance. En analysant l'évolution du FAR en utilisant T_{max}, nous remarquons que le modèle BRF réalise moins de fausses alertes dans la région GU (Voir [Fig.C.3] en annexe). L'évaluation des prévisions des méthodes d'apprentissage et des modèles intra-saisonniers sur chaque ville en utilisant T_{min} est illustrée en annexe (voir [Fig.C.4 - Fig.C.18]).




Figure 6.7 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmin dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de hit-rate associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du hit-rate.




Figure 6.8 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant T_{min} dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de GSS associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du GSS.




Figure 6.9 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant Tmin dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs du FAR associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du FAR.

6.6 Conclusion et perspectives

Dans cette étude préliminaire, il était question d'explorer le potentiel des méthodes d'apprentissage automatique en vue d'optimiser les prévisions des vagues de chaleur journalières et nocturnes dans les modèles de prévision intra-saisonnière du CEPMMT et UKMO. Les prévisions des modèles d'apprentissage sont évaluées par rapport à la réanalyse ERA5 choisie comme référence sur la base des études antérieures. Trois modèles d'apprentissage ont été explorés à savoir : RF+SMOTE, SVM et BRF. Dans un premier temps, nous avons procédé à une inter-comparaison des différentes méthodes d'apprentissage automatique en utilisant comme métrique d'évaluation le F1-score sur la période de test (2003,2008,2012,2019). Le F1-score est calculé entre les prévisions réalisées par chacun de ces algorithmes et ERA5. Les valeurs du F1-score sont très faibles autour de 20% en moyenne spatiale sur les différentes régions pour les deux premières semaines. Ces faibles valeurs de F1-score mettent en évidence des erreurs de prévision dans les différentes méthodes. Ainsi pour un événement correctement prédit, les modèles d'apprentissage réalisent 8 fausses prédictions pouvant être soit des fausses alertes soit des événements manqués, ce qui reste quand même assez important. Toutefois, la méthode BRF présente de meilleures performances par rapport aux deux autres (SVM et RF+SMOTE). Par la suite, les prévisions réalisées à partir de la méthode BRF sont comparées à celles des modèles de prévision intra-saisonnière en utilisant des métriques statistiques telles que le hit-rate, GSS et FAR. Le modèle BRF présente de meilleures performances dans la détection des vagues de chaleur par rapport aux modèles de prévision intra-saisonnière dans les trois régions. Toutefois, le modèle BRF réalise un taux élevé de fausses alertes autour de 85% pour les courtes échéances jusqu'à deux semaines et 90% au-delà. Le modèle BRF améliore considérablement la détection des vagues de chaleur dans les modèles de prévision, en contre partie, il génère un taux élevé de fausses alertes ([voir annexes](#)).

En guise de perspectives à cette étude préliminaire, il serait important d'explorer davantage le potentiel des méthodes d'apprentissage pour l'amélioration des modèles de prévision. Une première approche serait d'analyser d'autres prédicteurs de grande échelle pour les vagues de chaleur telles que l'anomalie de géopotential à 500hPa (Z500), l'humidité relative à la surface et le

vent à 10m ([Asadollah et al., 2021](#)). Ceci pourrait apporter plus d'informations aux modèles d'apprentissage et réduire les fausses alertes observées dans ces derniers. La seconde étape consisterait à l'utilisation des algorithmes d'apprentissage profond ("deep learning") tels que le "Long Short Term Memory (LSTM)" par exemple qui sont très utilisés pour la prévision des extrêmes météorologiques ([Chattopadhyay et al., 2020](#); [McGovern et al., 2017](#)).

Chapitre 7

Prévisibilité de potentiels prédicteurs aux vagues de chaleur en Afrique de l'Ouest

7.1 Introduction

La dépression thermique Saharienne (Saharan Heat Low (SHL)) est une zone de basse pression atmosphérique qui se forme au-dessus du Sahara en été boréal due aux températures élevées qui y règnent durant la saison et la forte insolation dans la région (Lavaysse et al., 2009). La SHL est une composante essentielle du système de mousson ouest Africaine à l'échelle synoptique (Sultan and Janicot, 2003; Parker et al., 2005; Peyrillé and Lafore, 2007; Lavaysse et al., 2009; Chauvin et al., 2010) et contribue fortement aux précipitations au Sahel (Lavaysse et al., 2010; Evan et al., 2015). La SHL joue un rôle important dans la circulation atmosphérique en Afrique de l'ouest et apporte de l'humidité provenant de l'océan Atlantique dans la région favorisant ainsi l'installation du flux de mousson. Les fortes intensités de la SHL sont atteintes en moyenne du 20 Juin au 17 Septembre (Lavaysse et al., 2009), ce qui correspond à la saison des pluies au Sahel. En plus d'être un élément clé du système de mousson ouest-Africaine, la SHL de par son activité, peut générer des conditions atmosphériques favorables à l'occurrence des vagues de chaleur au Sahel. Plusieurs cas de figure, peuvent se présenter :

- la circulation atmosphérique : La SHL influence les schémas de circulation atmosphérique

en Afrique de l'ouest. Elle crée un gradient de pression qui entraîne le déplacement des masses d'air chaud et sec du Sahara sur le flanc ouest de la SHL vers le golfe de Guinée et les régions environnantes. Cela peut entraîner l'advection d'air chaud et sec dans ces régions, et par la suite à une augmentation des températures contribuant ainsi au déclenchement des vagues de chaleur;

- les interactions avec le système de mousson : La SHL interagit fortement avec le système de mousson. Durant la période estivale, en raison de la forte activité de la SHL, un contraste thermique entre le continent très chaud et les eaux du golfe de Guinée plus froides se met en place. Ce contraste thermique contribue à intensifier le flux de mousson, ce qui entraîne un renforcement du transport d'humidité et de l'activité convective dans la région sur le flanc est de la SHL. La combinaison de la chaleur intense et de la forte teneur en humidité associée au flux de mousson peut entraîner des vagues de chaleur extrêmes pour la population.

De fait, la SHL apparaît comme un potentiel processus de grande échelle contribuant à l'occurrence des vagues de chaleur dans la région. Dans le chapitre 4, nous avons évalué la prédictibilité des vagues de chaleur à partir des variables de surface telles que la température à 2-m et la température du thermomètre mouillé dans les modèles de prévision. Les modèles ont démontré de meilleures performances dans la détection des vagues de chaleur par rapport à une climatologie de référence jusqu'à deux semaines à l'avance. Toutefois, les valeurs des métriques d'évaluation utilisées (hit-rate) restent relativement faibles, inférieures à 50%. Les études antérieures ont mis en évidence des liens entre les vagues de chaleur au Sahel et les modes d'oscillation tropicaux principalement l'oscillation Madden-Julian ([Guigma et al., 2021a](#)).

Ceci nous amène à nous interroger sur la prévisibilité des vagues de chaleur en Afrique de l'ouest à partir des processus de grande échelle tels que la SHL.

La prévisibilité des vagues de chaleur à partir de la SHL passe par deux étapes : l'investigation du lien entre la SHL et les vagues de chaleur, et l'évaluation des performances des modèles saisonniers à prédire la SHL par rapport aux vagues de chaleur. Dans un premier temps, nous

intéresserons à la représentation et la prévisibilité d'une des grandes composantes atmosphériques de la mousson Ouest-Africaine dans les modèles de prévision saisonnière. Une fois la représentation de la SHL dans les modèles évaluée, le lien avec les vagues de chaleur pourra être investigué. Ceci constitue une étude préliminaire dans le but de déterminer le potentiel de la SHL à améliorer la prévisibilité des vagues de chaleur à l'échelle saisonnière. C'est dans cette perspective que nous apportons notre contribution à travers ce travail.

Cette étude a été réalisée à partir de deux modèles de prévision saisonnière : SEAS5 (la cinquième version du modèle de prévision saisonnière du Centre Européen de Prévisions à Moyen Terme (CEPMMT)) et MF7 (la septième version du modèle de prévision saisonnière de Météo-France) sur la période 1993-2016. Les prévisions sont initialisées le 1^{er} de chaque mois pour une période 6 mois. L'évaluation des modèles est effectuée à partir d'une réanalyse couramment utilisée dans la région : ERA5 produite par le CEPMMT. Les études antérieures utilisent la température potentielle à 850 hPa (Roehrig et al., 2011) et l'épaisseur de la couche atmosphérique entre deux niveaux de pression 700 et 925hPa (Low Level Atmospheric Thickness (LLAT)) (Lavaysse et al., 2009). Comme mentionné ci-dessus, l'activité de la SHL atteint son maximum durant la période estivale de Juin à Septembre. De fait, nous analysons la représentation de l'évolution de la SHL dans les modèles en considérant les prévisions initialisées au maximum deux mois avant la période JJAS (Juin, Juillet, Août, Septembre) à savoir le 1^{er} Mai, 1^{er} Avril et 1^{er} Juin. Cette approche est nécessaire pour évaluer la sensibilité des modèles dans la représentation de la SHL à différentes échéances. Les pulsations Est-Ouest sont des caractéristiques importantes de la dynamique de la SHL. Afin d'analyser leur évolution dans les modèles, nous avons subdivisé la région d'étude en 4 sous-domaines [Fig.7.1] :

- le bloc Sahara ("*SAH*") compris entre [10°W - 20°E, 20°N - 30°N] [Fig.7.1];
- le bloc central SHL ("*CSHL*") compris entre [7°W - 5°E, 20°N - 30°N] est la position occupée par la SHL en été [Fig.7.1];
- le bloc ouest Sahara ("*WSHL*"), compris entre [10°W - 2°W, 20°N - 30°N] [Fig.7.1];
- le bloc est Sahara ("*ESHL*"), compris entre [0°E - 8°E, 20°N - 30°N] [Fig.7.1].

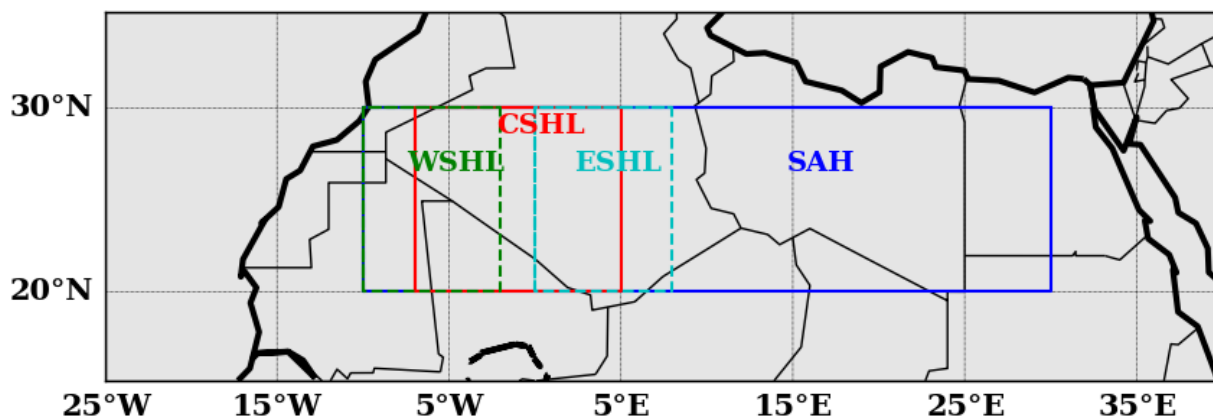


Figure 7.1 – Région d'étude et les différents blocs de SHL analysés.

Nous avons analysé les modes de variabilité de la SHL en utilisant la décomposition en ondelettes du signal de température à 850 hPa (T850) (Tang et al., 2010). La décomposition en ondelette est effectuée séparément pour les prévisions et les réanalyses suivant les différentes dates d'initialisation des modèles. La climatologie et la variabilité inter-annuelle des jours de forte pulsation de la SHL ont été évaluées.

La variabilité inter-annuelle de la SHL a été analysée en utilisant une fonction densité de probabilité paramétrique basée sur la loi "Genextreme" afin de représenter au mieux les extrêmes dans la distribution du signal. Les prévisions ont été débiaisées en utilisant deux techniques de correction de biais assez répandues : la méthode CDF-t (Cumulative Distribution Function transform, (Michelangeli et al., 2009b)) et la méthode QMAP (Quantile Mapping, (Dosio and Paruolo, 2011)). Les méthodes QMAP et CDF-t sont généralement utilisées pour des tâches de descente d'échelle dans un contexte de projection climatique. Dans cette étude, nous avons adapté l'application de ces méthodes à la correction des biais dans le contexte des prévisions saisonnières. Nous avons utilisé une approche "leave-one-out" pour la calibration des techniques CDF-t et QMAP. Cette méthode consiste à supprimer l'année cible (l'année que l'on souhaite corriger) de la période historique avant d'estimer la fonction de transfert permettant de passer de l'échelle globale aux l'échelle locale. Dans notre cas, la calibration a été réalisée en utilisant 23 des 24 années sur la période historique 1993-2016 pour la correction de chaque année. La correction de biais est effectuée différemment suivant les méthodes CDF-t et QMAP. Pour la méthode QMAP, nous

utilisons comme entrée l'année cible précédemment supprimée lors de la phase d'étalonnage. Avec la méthode CDF-t, nous avons construit un nouvel ensemble de données de 24 ans qui est la concaténation de l'ensemble de données utilisé pour la calibration et l'année cible de sorte que l'année à la fin du nouvel ensemble de données représente l'année cible. La valeur ajoutée de la correction de biais dans les modèles par rapport aux prévisions brutes, a été évaluée à travers le calcul du "Cramér-Von Misses" (Michelangeli et al., 2009b). Cette métrique indique le degré de similarité entre deux fonctions de distribution. Les prévisions saisonnières étant issues de modèles probabilistes, leur analyse reste très délicate en raison du nombre d'informations disponibles : faut-il utiliser le membre non perturbé, le membre moyen de l'ensemble, le membre médian de l'ensemble ou l'ensemble des membres? La méthode de correction de biais et le calcul du Cramér-Von Misses ont été effectués suivant les trois approches ci-dessous :

- "CORR_NO_MEAN", dans cette approche, la correction des biais est appliquée à l'ensemble des membres du modèle et le Cramér score est calculé par la suite;
- "CORR_MEAN", ici nous calculons d'abord la moyenne des résultats de la correction des biais sur l'ensemble des membres du modèle; et nous utilisons cette moyenne pour calculer le Cramer score;
- "MEAN_CORR", la méthode consiste à appliquer la correction de biais sur la moyenne des membres du modèle et le calcul de l'indice de Cramér-Von Misses est effectué directement en utilisant les résultats de la correction de biais.

L'évaluation des modèles par rapport aux réanalyses se fait par le calcul de scores probabilistes tels que le CRPS (Continuous rank Probabilitic Score). Le CRPS quantifie l'erreur entre les prévisions et les réanalyses, il est donné par la formule ci-dessous :

$$\text{CRPS} = \int_{-\infty}^{+\infty} (\mathbf{P}_F(\mathbf{x}) - \mathbf{P}_O(\mathbf{x}))^2 d\mathbf{x} \quad (7.1)$$

$P_F(x)$ et $P_O(x)$ représentent les fonctions de distribution cumulées respectivement associées

aux prévisions et réanalyses.

Étant donné qu'une forte activité de la SHL contribuera au renforcement du système de mousson sur le Sahel oriental et central, il serait important de s'intéresser à leur représentation dans les modèles. L'évolution des événements extrêmes de la SHL a été évaluée en considérant les extrêmes froids et chauds qui représentent respectivement les événements en-dessous du quantile 10% et au-delà du quantile 90%. L'une des caractéristiques de la SHL, c'est son oscillation d'est vers l'ouest durant la saison. De fait, les phases Est-Ouest de la SHL ont également été étudiées dans les modèles ([Lavaysse et al., 2010](#); [Roehrig, 2010](#); [Chauvin et al., 2010](#)).

7.2 Résumé de l'article sur la prévision de la dépression thermique Saharienne à l'échelle saisonnière

La dépression thermique Saharienne (SHL) est une composante clé du système de mousson ouest-africaine à l'échelle synoptique et un moteur des précipitations estivales dans la région du Sahel. De fait, les prévisions saisonnières des précipitations reposent en partie sur une représentation adéquate des caractéristiques de la SHL dans les modèles. Dans cette étude, nous utilisons deux modèles de prévision saisonnière, à savoir SEAS5 et MF7 respectivement du Centre européen pour les prévisions météorologiques à moyen terme (CEPMMT) et de Météo-France. Les caractéristiques de la SHL dans les modèles sont évaluées par rapport à la réanalyse ERA5 du CEPMMT sur la période 1993-2016. L'étude des modes de variabilité de la SHL révèle que les modèles ont du mal à reproduire correctement la temporalité et l'intensité des pulsations observées dans la réanalyse ERA5. Les modèles SEAS5 et MF7 présentent respectivement un biais froid centré sur le Sahara et un biais chaud situé à l'est du Sahara. Les deux modèles ont tendance à sous-estimer la variabilité inter-annuelle de la SHL. De grandes divergences sont observées dans la représentation des événements extrêmes de la SHL dans les modèles de prévision saisonnière. Ces résultats ne sont pas liés à notre choix de ERA5 comme référence car les réanalyses ERA5 et MERRA sont fortement corrélées. L'utilisation des techniques de correction de biais réduit significativement les biais dans les modèles et améliore la distribution inter-annuelle de la SHL par rapport à ERA5, et par conséquent les scores de prévision. Les résultats mettent en évidence la capacité des modèles à représenter les pulsations intra-saisonnières de la SHL (les phases Est-Ouest). Nous remarquons une surestimation de l'occurrence des phases Est de la SHL dans les modèles (SEAS5/MF7) tandis que les phases Ouest de la SHL sont mieux représentées dans MF7. Malgré une amélioration du score de prédiction, les modèles ont du mal à représenter certaines oscillations spécifiques de la SHL à des échéances supérieures à 1 mois nécessitant certaines adaptations. En outre, les prévisions des modèles sont meilleures à l'échelle intra-saisonnière pour des délais plus courts.

7.3 Article sur la prévision de la dépression thermique Saharienne à l'échelle saisonnière



Seasonal forecasts of the Saharan heat low characteristics: a multi-model assessment

Cedric G. Ngoungue Langue^{1,4}, Christophe Lavaysse^{4,5}, Mathieu Vrac², Philippe Peyrillé³, and Cyrille Flamant¹

¹Laboratoire Atmosphères, Milieux, Observations Spatiales (LATMOS) – UMR 8190 CNRS–Sorbonne Université–UVSQ, 78280 Guyancourt, France

²Laboratoire des Sciences du Climat et de l’Environnement, CEA Paris-Saclay l’Orme des Merisiers, UMR 8212 CEA–CNRS–UVSQ, Université Paris-Saclay & IPSL, 91191 Gif-sur-Yvette, France

³Centre National de Recherches Météorologiques (CNRM) – Université de Toulouse, Météo-France, CNRS, 31057 Toulouse CEDEX 1, France

⁴Université Grenoble Alpes, CNRS, IRD, G-INP, IGE, 38000 Grenoble, France

⁵European Commission, Joint Research Centre (JRC), 21027 Ispra, VA, Italy

Correspondence: Cedric G. Ngoungue Langue (cedric-gacial.ngoungue-langue@latmos.ipsl.fr)

Received: 14 April 2021 – Discussion started: 26 April 2021

Revised: 23 July 2021 – Accepted: 2 August 2021 – Published: 15 September 2021

Abstract. The Saharan heat low (SHL) is a key component of the West African Monsoon system at the synoptic scale and a driver of summertime precipitation over the Sahel region. Therefore, accurate seasonal precipitation forecasts rely in part on a proper representation of the SHL characteristics in seasonal forecast models. This is investigated using the latest versions of two seasonal forecast systems namely the SEAS5 and MF7 systems from the European Center of Medium-Range Weather Forecasts (ECMWF) and Météo-France respectively. The SHL characteristics in the seasonal forecast models are assessed based on a comparison with the fifth ECMWF Reanalysis (ERA5) for the period 1993–2016. The analysis of the modes of variability shows that the seasonal forecast models have issues with the timing and the intensity of the SHL pulsations when compared to ERA5. SEAS5 and MF7 show a cool bias centered on the Sahara and a warm bias located in the eastern part of the Sahara respectively. Both models tend to underestimate the interannual variability in the SHL. Large discrepancies are found in the representation of extremes SHL events in the seasonal forecast models. These results are not linked to our choice of ERA5 as a reference, for we show robust coherence and high correlation between ERA5 and the Modern-Era Retrospective analysis for Research and Applications (MERRA). The use of statistical bias correction methods significantly reduces the bias in the seasonal forecast models and improves the

yearly distribution of the SHL and the forecast scores. The results highlight the capacity of the models to represent the intraseasonal pulsations (the so-called east–west phases) of the SHL. We notice an overestimation of the occurrence of the SHL east phases in the models (SEAS5, MF7), while the SHL west phases are much better represented in MF7. In spite of an improvement in prediction score, the SHL-related forecast skills of the seasonal forecast models remain weak for specific variations for lead times beyond 1 month, requiring some adaptations. Moreover, the models show predictive skills at an intraseasonal timescale for shorter lead times.

1 Introduction

In the Sahel region, food security for populations depends on rainfed agriculture which is conditioned by seasonal rainfall (Durand, 1977; Bickle et al., 2020), characterized by a strong convective activity in the summer, associated with a large climatic variability (local- and large-scale forcings), generally leading to poor precipitation forecast skills at subseasonal and seasonal timescales in tropical North Africa (Vogel et al., 2018). Hence, climate models suffer from biases in the representation of West African Monsoon (WAM) processes and dynamics responsible for rainfall in West Africa (Roehrig et al., 2013; Martin et al., 2017). During the African

Monsoon Multidisciplinary Analysis (AMMA) project (Redelsperger et al., 2006), the Saharan heat low (SHL) has been used as a key component to assess the variability in the WAM system. In particular, forecasters and researchers have pointed out the need to document the SHL predictability and its link with Sahelian rainfall (Janicot et al., 2008b). Improving precipitation forecasts not only is crucial for agriculture and water supply in the region but also is of paramount importance for floods and disease prevention.

The SHL refers to the low-surface-pressure area that appears above the Sahara region in the boreal summer due to seasonal high temperatures and insolation (e.g., Lavaysse et al., 2009). The SHL is an essential component of the WAM system at the synoptic scale (Sultan and Janicot, 2003; Parker et al., 2005; Peyrillé and Lafore, 2007; Lavaysse et al., 2009; Chauvin et al., 2010) and a driver of precipitation over the Sahel region (Lavaysse et al., 2010a; Evan et al., 2015). It plays an important role in the atmospheric circulation over West Africa and brings moisture from the Atlantic Ocean to the region, thereby favoring the installation of the monsoon flow. In the lower atmospheric layers, the cyclonic circulation generated by a strong SHL tends to reinforce the monsoon flow around its eastern flank and the Harmattan flow along the western flank (Lavaysse, 2015). In the mid-layers, the anticyclonic circulation associated with the divergent flow at the top of the SHL contributes to maintaining the African Easterly Jet (AEJ) at around 700 hPa and modulates its intensity (Thorncroft and Blackburn, 1999). An intensification of the AEJ is observed during strong phases of SHL activity (Lavaysse et al., 2010b). According to Lavaysse et al. (2009), the SHL maximum activity over the Sahara occurs on average from 20 June to 17 September, and it is located 20–30° N, 7° W–5° E, covering much of northern Mauritania, Mali, Niger and southern Algeria (Fig. 1). The maximum of SHL activity happens during the rainfall season in the Sahel region (from June to September; Sultan and Janicot, 2003). The SHL is considered a reliable proxy for the regional- and large-scale forcings impacting the WAM (Lavaysse et al., 2010b).

Lavaysse et al. (2009) monitored the seasonal evolution of the West African heat low (WAHL) using ERA-40 reanalyses and brightness temperature from the Cloud Archive User Service (CLAUS). They found a northwestward migration of the WAHL from a position south of the Darfur mountains in the winter to a location over the Sahara between the Hoggar and the Atlas mountains during the summer. They also estimated the climatological onset of the SHL occurring around 20 June (from the period 1984–2001) some days before the climatological monsoon onset date. This highlights strong links between the SHL and the monsoon flux. Chauvin et al. (2010) assessed the intraseasonal variability in the SHL and its link with midlatitudes using National Centers for Environmental Prediction (NCEP-2) reanalysis data. They found a robust mode of variability in the SHL over North Africa and the Mediterranean which can be decom-

posed into two phases called east–west oscillations. The west phase corresponds to a maximum temperature over the coast of Morocco–Mauritania, propagating southwestward, and a minimum temperature between Libya and Sicily, propagating southeastward. The east phase corresponds to the opposite temperature structure which propagates as in the west phase. Roehrig et al. (2011) studied the link between the variability in convection in the Sahel region and the variability in the SHL at an intraseasonal timescale using NCEP-2 reanalysis data. They showed that the onset of the monsoon is associated with strong SHL activity when the northerlies coming from the Mediterranean (sometimes called ventilation) are weak. Conversely, they revealed that the formation of a strong cold air surge over Libya and Egypt and its propagation toward the Sahel lead to the decrease in the SHL, which inhibits the WAM onset.

As detailed above, previous work has evidenced the importance and the role of the SHL in the West African climate. These studies are based on a climatological view of the SHL using mostly reanalysis data. One may legitimately wonder how seasonal forecast models represent the SHL evolution.

The seasonal forecast is a long-term forecast which is very useful because it allows an anticipation of seasonal trends. The use of an ensemble forecast for seasonal forecasting provides a range of forecasts and gives information about the spread associated with the forecast of a specific variable. Ensemble forecast models lead to an improvement in the predictive skills of some atmospheric variables (Haiden et al., 2015; Lavaysse et al., 2019). The evaluation of the SHL behavior in seasonal forecast models has not been addressed yet. Roehrig et al. (2013) show that the mean temperature over the Sahara from July to September is well correlated with rainfall position over the Sahel region. Provided that the SHL characteristics (i.e., the east and west pulsations of the heat low, its intensity, and its interannual variability) are well captured in seasonal forecast models simulations, they can be used as predictors for rainfall in the Sahel area.

The goal of this article is (i) to investigate the representation and the forecast skills of the SHL in two seasonal forecast models and (ii) to evaluate the added value of bias correction techniques on raw seasonal forecasts. Bias issues are very frequent in seasonal forecast models; by correcting them with statistical methods, the predictive skills of the models can be improved in order to provide atmospheric variables that better fit the characteristics of the observation.

To reach this aim, we firstly study the SHL variability modes in seasonal forecast models and reanalyses; secondly we estimate the biases between the forecasts and reanalyses. Finally, we assess the recent evolution of the SHL and proceed with an evaluation of forecasts with respect to the reanalyses.

The remainder of this article is organized as follows: in Sect. 2, we present our region of interest and the data used for this work; the description of the methodology adopted is also provided. Section 3 contains the main results of this in-

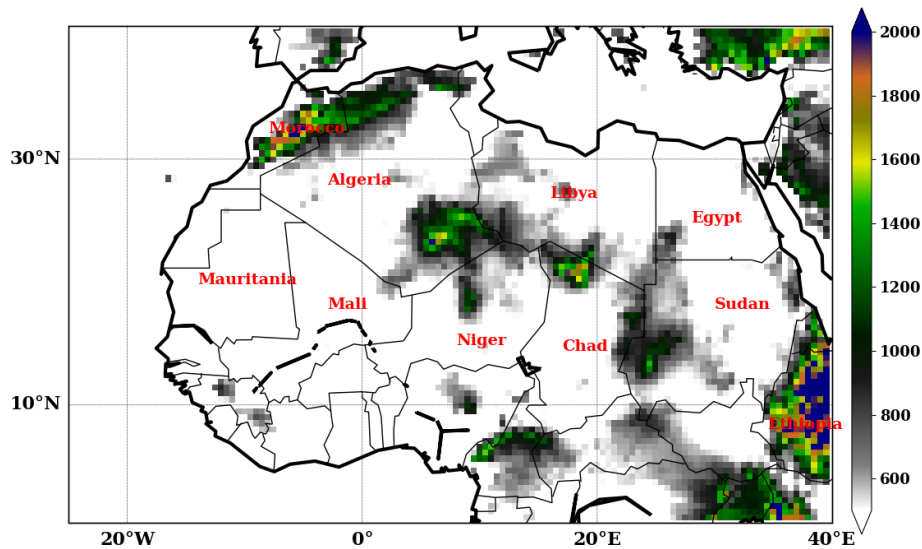


Figure 1. Topographic map of West Africa using ERA5 elevation data. The y axis and x axis represent the latitude and longitude respectively, in degrees over the domain. The color bar shows the elevation in meters over the region.

vestigation obtained by following the methodology described in Sect. 2. In Sect. 4, the predictive skills of the seasonal forecast models are discussed; and Sect. 5 provides a conclusion with some perspectives for future studies.

2 Data and methods

2.1 Saharan heat low evaluation metric

The location of the West African heat low has a strong seasonal variation: north–south owing to the seasonal cycle of insolation and east–west owing to orographic forcing (Lavaysse et al., 2009; Drobinski et al., 2005). It is termed SHL once it reaches its Saharan location generally within 20–30° N, 7° W–5° E, during the monsoon season, an area that is bounded by the Atlas mountains to the north, the Hogar mountains to the east, the Atlantic Ocean to the west and the northern extent of the WAM to the south (Evan et al., 2015). The SHL has been detected in previous studies using the low-level atmospheric thickness (LLAT) computed as a geopotential distance between two pressure levels, 700 and 925 hPa (Lavaysse et al., 2009). Because the LLAT is due to a thermal dilatation of the low troposphere and in order to simplify the detection process, the SHL can be monitored by using the 850 hPa temperature field. Lavaysse et al. (2016) using ERA-Interim reanalysis, showed that the 850 hPa temperature (T850) field is well correlated to the LLAT and can be used as a proxy for the monitoring of the SHL (detection and intensity). As ERA5 is an improvement in ERA-Interim, we assume that the correlation between T850 and the LLAT is preserved in ERA5. We suppose this is also true for the forecast models. Consequently in this study, we use T850 to analyze the SHL characteristics. Because fixed boxes

are used, the detection of the SHL is not needed, but strong (weak) phases of the SHL will be associated with high (low) T850.

2.2 Region of interest

The Sahara is located over 20–35° N, 25° W–40° E, and covers large parts of Algeria, Chad, Egypt, Libya, Mali, Mauritania, Morocco, Niger, Western Sahara, Sudan and Tunisia (see topographic map in Fig. 1). The climate is associated with very hot temperatures from May to September of around 30°C for mean temperatures and over 40°C for mean maximum temperatures, very low humidity close to the surface (with relative humidities of less than 10%), and a critical absence of rainfall.

It is also the region with the largest production of dust particles (Prospero et al., 2002). For this study, North Africa is subdivided in four regions (see Fig. 2) defined as follows:

- the Sahara area 20–30° N, 10° W–20° E, and extending from the south of Morocco to Egypt;
- the central SHL here denoted as CSHL, located 20–30° N, 7° W–5° E, and covering most of the north of Mauritania, Mali and the south of Algeria;
- the western SHL here denoted as WSHL, located 20–30° N, 10–2° W and including the north of Mauritania, Mali, the south of Morocco and Algeria;
- the eastern SHL denoted as ESHL, located 20–30° N, 0–8° E, and mostly in the south of Algeria.

The choice of the four regions is supported by previous studies: Lavaysse et al. (2009) highlight a maximum activity of the SHL in the CSHL location during summer (JJAS

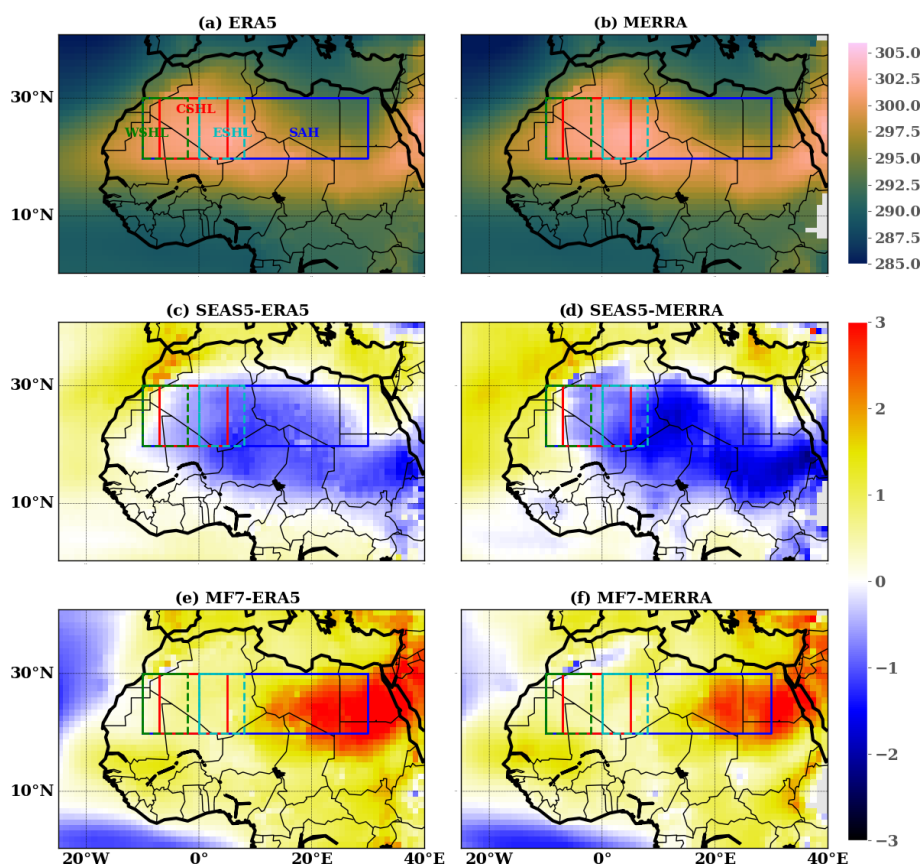


Figure 2. Climatology of the SHL during the JJAS period over 1993–2016 in the reanalysis data using T850, (a) ERA5 and (b) MERRA, and the anomalies of the climatologies of the SHL between (c) SEAS5 and ERA5, (e) SEAS5 and MERRA, (d) MF7 and ERA5, and (f) MF7 and MERRA. The rectangles indicate the boxes chosen for the computation of the average T850 and their corresponding name. WSHL: western SHL; CSHL: central SHL; ESHL: eastern SHL; SAH: the Saharan region. The color bars indicate T850 (a, b) and the anomalies of T850 (c–f) in kelvins. The computation was made using the ensemble mean member.

period, June–September); Roehrig et al. (2011) show that the SHL tends to migrate from the west to the east during the season, which explains the WSHL and ESHL locations. The Saharan location has been used in some climate studies (Lavaysse, 2015; Taylor et al., 2017).

2.3 Data

In this study, we used two types of data: reanalyses and seasonal forecast model outputs. We used outputs from the fifth-generation European Center for Medium-Range Weather Forecasts (ECMWF) Reanalysis (ERA5) (Hersbach et al., 2020). The ERA5 atmospheric variable studied here is daily T850 with a spatial resolution of $0.25^\circ \times 0.25^\circ$ downloaded on the climate data store website: <https://cds.climate.copernicus.eu/> (last access: 14 January 2020). The Modern-Era Retrospective analysis for Research and Applications (MERRA) dataset was also used. The MERRA data have a spatial resolution of $0.5^\circ \times 0.625^\circ$ with 42 vertical levels downloaded on the ClimServ database. As for ERA5 reanalysis, we used the MERRA T850 to carry out our analyses.

To be coherent with the model outputs, we consider only the daily temperature data at 00:00 and 12:00 UTC. We also transformed the spatial resolution of ERA5/MERRA (from $0.25^\circ \times 0.25^\circ/0.5^\circ \times 0.625^\circ$ to $1^\circ \times 1^\circ$) to match the one of the seasonal forecast models. The two forecast models analyzed here are the seasonal forecast SEAS5 from ECMWF and the seasonal forecast system MF7 from Météo-France. The seasonal forecast model SEAS5 replaces the previous seasonal system S4 (Johnson et al., 2019); it includes upgraded versions of the atmosphere and ocean models at higher resolutions. The SEAS5 model has a horizontal resolution of 36 km over the globe and contains 91 levels for the vertical resolution. The MF7 seasonal forecast system is based on the ARPEGE/IFS global forecast model (Déqué et al., 1994) which was jointly developed by Météo-France and ECMWF. MF7 uses the climate version of CNRM-CM6 (Voldoire et al., 2019) such that MF7 and SEAS5 only share a common radiation parameterization but the rest of the physical package is different. The horizontal resolution of the MF7 model is around 7.5 km over France and 37 km over the Antipodes; it contains 105 vertical levels. Both SEAS5 and MF7

model outputs used in this paper are based on the ensemble retrospective forecast (hindcast) which contains 25 members, meaning that for a given time, we have 25 re-forecasts from each model. The re-forecasts are released on the first day of every month for a period of 6 months for SEAS5. With MF7, one member of the model is initialized on the first of the month and the other members are launched on the last two Thursdays of the month. The atmospheric variable investigated in models is also daily temperature at 00:00 and 12:00 UTC with a spatial resolution of $1^\circ \times 1^\circ$. Our dataset covers the period going from 1 January 1993 to 31 December 2016.

2.4 Strategy for the analysis of forecast

As we analyze the representation of the SHL, we focus on the period going from June to September (denoted by JJAS in the rest of the study) because it corresponds approximately to the period of maximum heat low activity over the Sahara (Lavaysse et al., 2009). Seasonal forecast models usually fail to correctly forecast events a long time in advance for a given target period. Therefore, we are interested in a forecast launched at most 2 months in advance of the JJAS period. In order to do that, we consider re-forecasts initialized on 1 April, 1 May and 1 June, which corresponds to a June lead time of 2, 1 and 0 months respectively. This technique allows us to quantify the sensitivity of the models in representing the SHL at different lead times. The re-forecast validation process is made separately for the whole JJAS period and individual months (June, July, August and September) because June and September temperature values are in the same range.

2.5 Methods

This section describes in more detail the set of analyses carried out to achieve our goal. The methodology adopted is illustrated below.

2.5.1 Subseasonal modes of variability

A mode of variability represents a spatio-temporal structure highlighting the main characteristics of the evolution of atmospheric variables at a given timescale. There are several statistical methods for assessing the modes of variability that contribute to a raw signal. The one used here is the wavelet analysis of the temperature signal. The wavelet transform consists in applying a time–frequency analysis to a given signal. It is very useful for analyzing non-stationary signals in which phenomena occur at different scales. This method provides more information than the Fourier transform about the observed structures in the initial signal (starting and ending time and the duration of propagation (frequency)). With this type of analysis, we observe the distribution of the signal intensity in time and frequency. A wavelet function is defined

by a scale factor and a position factor (Büßow, 2007; Zhao et al., 2004).

Let $f(t)$ be a real function of a real variable; the wavelet transformation of this function denoted as $W(f)(a, b)$ is given by

$$W(f)(a, b) = \langle f, \psi_{a,b} \rangle = \int_{-\infty}^{+\infty} (f(t) \cdot \psi_{a,b}(t)) dt, \quad (1)$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \Psi\left(\frac{t-b}{a}\right). \quad (2)$$

The function Ψ is called the mother wavelet and must be of square integrable that means $\int_{-\infty}^{+\infty} (\Psi(t))^2 dt$ is finite and also verify the following property: $\int_{-\infty}^{+\infty} \Psi(t) dt = 0$. The parameter b is the position factor, and a is the scaling parameter greater than zero. For a given signal, a represents the frequency and b the time. There exist diverse types of mother wavelets; based on the literature review and its common use, we chose the Morlet wavelet (Tang et al., 2010). The Morlet wavelet is defined as the product of a complex sine wave and a Gaussian window (see Eq. 3) (Cohen, 2018). The wavelet analysis has been applied separately to the re-forecasts and the reanalyses for an initialization of the seasonal forecast models on 1 April, 1 May and 1 June for a 6-month period; but we extracted only the signal on the JJAS period to conduct our analyses on variability modes. We focused on signals with a period of up to 32 d.

$$\Psi(t) = \pi^{-1/4} \exp^{-t^2/2} \cos(\omega_0 t) \quad (3)$$

2.5.2 Bias correction

Seasonal forecast models provide a numerical representation of the Earth and the interactions between its different components: the atmosphere, the ocean and the continental surfaces. Those interactions are very complex and take place at different spatio-temporal scales. This can lead in certain cases to an over/underestimation of the evolution of atmospheric variables in the models. The cause of this behavior in the models is often the presence of biases. To overcome this bias issue, we use here two univariate bias correction methods: quantile mapping (QMAP) and cumulative distribution function transform (CDF-t).

QMAP

Quantile mapping aims to adjust climate model simulations with respect to reference data, in determining a transfer function to match the statistical distribution of simulated data to one of the reference values (e.g., Dosio and Paruolo, 2011). When reference data have a resolution similar to those of climate model simulations, this technique can be considered a bias adjustment method. On the other hand, when the observations are of a higher spatial resolution than those of climate

simulations, quantile mapping attempts to fill the scale shift and is then considered a downscaling method (Michelangeli et al., 2009). The QMAP method is based on the assumption that the transfer function calibrated over the past period remains valid in the future. Let $F_{o,h}$ and $F_{m,h}$ be the cumulative distribution functions (CDFs) of the observational (reference) data $X_{o,h}$ and modeled data $X_{m,h}$ respectively, in a historical period h . The transfer function for bias correction of $X_{m,p}(t)$ which represents a modeled value at time t within a projected period p is given by the following relation (e.g., Cannon et al., 2015; Dosio and Paruolo, 2011):

$$\hat{X}_{m,p}(t) = F_{o,h}^{-1}\{F_{m,h}[X_{m,p}(t)]\}, \quad (4)$$

where $F_{o,h}^{-1}$ is the inverse function of the CDF $F_{o,h}$.

CDF-t

CDF-t is a statistical downscaling method developed by Michelangeli et al. (2009). It can be considered a generalization of the quantile-mapping correction method. Hence, as with QMAP, CDF-t consists in finding a relationship between the CDF of a large-scale climate variable and the CDF of this same variable at the local scale. However, while the quantile-mapping method projects the simulated values at a large scale on the historical CDF to calculate quantiles, CDF-t takes explicitly into account the change in the large-scale CDF between the historical period and the future period. In the CDF-t approach, a mathematical transformation T is applied to the large-scale CDF to define a new CDF as close as possible to the CDF obtained from the station data (e.g., Vrac et al., 2012; Lavaysse et al., 2012).

Let $F_{m,h}$ and $F_{o,h}$ be the CDFs at a large and local scale respectively of the modeled data $X_{m,h}$ and the observational data $X_{o,h}$ over a historical period h and T the transformation allowing us to go from $F_{m,h}$ to $F_{o,h}$. We have the following relation (Vrac et al., 2012):

$$T(F_{m,h}(X_{m,h})) = F_{o,h}(X_{o,h}). \quad (5)$$

By applying this relation to the CDF $F_{m,f}$ of the modeled data $X_{m,f}$ in a future period f , it provides an estimation of the local CDF $F_{o,f}$ in the future period f :

$$\hat{F}_{o,f} = T(F_{m,f}(X_{m,f})). \quad (6)$$

Quantile mapping can then be performed between $F_{m,f}$ and $\hat{F}_{o,f}$ to obtain bias-corrected values of future simulations. More details about CDF-t can be found in Vrac et al. (2012). All the computations for the CDF-t method were done with the R package ‘‘CDFt’’.

After applying the bias correction methods to the model outputs, the added value of the bias correction compared

to the raw re-forecasts will be assessed by the computation of the Cramér–von Mises (hereafter Cramér) score (Henze and Meintanis, 2005; Michelangeli et al., 2009). The Cramér score measures the similarity between two distribution functions; the closer its value is to 0, the closer the distributions are.

Application of bias correction

QMAP and CDF-t are usually used for downscaling tasks in a climate projection context. In this study, we adapted the application of these methods for bias correction in a seasonal forecast context. We used a leave-one-out approach for the calibration process with CDF-t and QMAP. This method consists in removing the target year (the year we want to apply the correction to) in the historical period before the estimation of the transfer function which allows us to pass from the global scale to local-scale data. In our case the calibration process has been made using 23 of the 24 years in the historical period 1993–2016 for every year. The correction or projection process is made differently using CDF-t and QMAP. For QMAP, we use as input the target year removed previously during the calibration phase. With CDF-t, we built a new dataset of 24 years which is the concatenation of the dataset used for the calibration and the target year so that the year at the end of the new dataset represents the target year.

2.5.3 Ensemble forecast verification

Ensemble forecast verification is the process of assessing the quality of a forecast. The forecast is compared against a corresponding observation or a reference; the verification can be qualitative or quantitative. Forecast verification is important for monitoring forecast quality, improving forecast quality and comparing the quality of different forecast systems. There are many metrics or probability scores developed for ensemble forecast verification depending on the tasks performed. In our preliminary studies (not shown) on the skills of the forecast models, we used different scores (continuous ranked probability score – CRPS, Brier score, relative operating characteristic (ROC) area curve, rank histogram, reliability diagram), but in the present work, we will only focus on the CRPS (Hudson and Ebert, 2017), which is very similar to the Brier score. This choice is justified by the simplicity in data processing when computing the CRPS through some R packages like SpecsVerification (Siegert et al., 2017). The CRPS is a quadratic measure of the difference between the forecast CDF and observation CDF. It quantifies the relative error between the model forecasts and the observations; it is a measure of the precision of an ensemble forecast model. The closer the CRPS is to 0, the better it is.

Letting $P_F(x)$ and $P_O(x)$ be the cumulative distribution functions for the forecasts and observations respectively, the

CRPS is computed as follows:

$$\text{CRPS} = \int_{-\infty}^{+\infty} (P_F(x) - P_O(x))^2 dx \quad (7)$$

The root mean square error (RMSE), which is a measure of the differences between two samples (model predictions and observations), has also been used for the evaluation of the forecasts. Letting y_t be the forecast of the model at time t and O_t the corresponding observation at the same time, the RMSE is given by the following relation:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^N (y_t - O_t)^2}{N}}, \quad (8)$$

where N is the number of time steps.

3 Results

3.1 Climatology of the SHL

The climatology state of the SHL has been assessed from 1993 to 2016 during the JJAS period for ERA5, MERRA, SEAS5 and MF7 (see Fig. S2 in the Supplement). The seasonal forecast models tend to develop SHL's climatologies with very similar characteristics to those of the reanalyses. Strong SHL intensities are located over the CSHL location (Fig. S2) for all the products (reanalyses and forecast models); this is in agreement with Lavaysse et al. (2009). Another point discussed in this section is the uncertainty between the reanalyses (ERA5 and MERRA) (see Fig. 2). ERA5 and MERRA exhibit similar behaviors regarding the climatological bias of the SHL with respect to the seasonal forecast models (Fig. 2c–f): a cold bias with SEAS5 and a warm bias with MF7. The seasonal evolution of the climatological state of the SHL in ERA5 and MERRA (see Fig. 6) is almost similar over the CSHL location except for the Sahara, where a little shift of MERRA to high temperatures is observed but the patterns in the evolution remain very close to ERA5. The distribution of yearly T850 over the JJAS period (see Fig. 7a, b, g, h) in ERA5 and MERRA is quite similar, suggesting a good correlation between the two reanalyses. The uncertainties between the reanalyses (see Fig. S3 in the Supplement) are much smaller than the biases in the seasonal forecast models with respect to ERA5. We also found large correlation between ERA5 and MERRA (see Fig. S1 in the Supplement) of around 0.97/0.92 over the CSHL/Sahara location during the JJAS period. By considering all these results highlighting high similarities between ERA5 and MERRA, we decided to choose ERA5 as our reference dataset for the rest of the study.

3.2 Variability modes

Through a wavelet transformation, we compared the variability modes in the forecast products (SEAS5, MF7) with respect to ERA5 over the central SHL location and Sahara (boxes indicated in Fig. 2) (see Fig. S4 in the Supplement). Especially for the year 2016, three main frequency bands of activity of the SHL have been identified in ERA5: firstly, the SHL activity within the 4–8 d window with high intensity; secondly an intensification of events with strong intensity (spectral power > 16) is observed for periods of about 8–16 d. Finally, events at very high frequencies are observed, and the intensity associated is much higher (spectral power > 64) than in the previous ones. This shows the SHL activity becomes stronger at high frequencies. The models tend to reproduce the pulsations observed in the reanalysis signals quite differently; there is an issue regarding the temporality, frequency and intensity of the pulsations in the forecast models.

To assess the climatology of the variability modes (Fig. 3), we analyzed the distribution of days associated with spectral power greater than 1 (normalized value), here defined as significant days during the period 1993 to 2016. This threshold of 1 has been selected arbitrarily after applying a sensitivity test to several threshold values from 0.5 to 10 to focus on predominant events at different periods. We noticed globally a decrease in events occurrence with high threshold values of the spectral power. Note that the sensitivity to the threshold values does not significantly impact our results (not shown). We observe similar behavior in ERA5, SEAS5 and MF7 in terms of significant days with an increasing number of days with periods of up to 10 d followed by quite steady activity for longer periods. Over the Sahara area, there is a tendency for both models to reproduce SHL activity that is similar to ERA5 at too-short periods (~ 10 d). ERA5 shows little variation in the number of significant days with periods between 12–26 d and tends to be constant for high-frequency periods (greater than 27 d). SEAS5 overestimates the SHL activity around the 15 d period, while MF7 is shifted toward higher frequencies and underestimates the longer period. Over the central SHL box, there is a tendency of both the MF7 and the SEAS5 models to generate significant SHL activity at too-short periods ($\sim 4/10$ d) compared to ERA5. At longer timescales MF7 tends to overestimate the SHL activity within the 10–23 d period, while SEAS5 shows an underestimation of the SHL activity within the same window. The evolution of significant days over the central SHL location and Sahara highlighted three main pulsations based on the period (or frequency). The different pulsations identified are arbitrarily classified as follows: the class C1 = [0, 10] d for low-frequency, the class C2 = (10, 22] d for high-frequency and the class C3 = (22, 32] d for very high frequency pulsations. In the following, we investigate the interannual variability of significant days for those different classes of pulsation (Fig. 4). The result for ERA5 shows a high interannual

variability for pulsations in class C1 over both the central SHL box and the Sahara (Fig. 4a, d). This can be caused by the triggering of easterly waves and Kelvin equatorial waves which tend to reinforce the convection activity. Those two types of wave have a periodicity of between 1–6 d (Janicot et al., 2008a). The correlation between the seasonal forecast models and ERA5 is very low, less than 0.4. From this analysis, we can see that the seasonal forecast models tend to represent the climatological activity of the SHL at different frequencies even if some discrepancies are observed. However, the representation of the interannual variability in the SHL activity remains a big challenge for the seasonal forecast models.

3.3 Seasonal cycle

In this section, we are assessing the spatial representation of the SHL over the Sahara region. In order to do that, we evaluate the bias between the seasonal forecast models (SEAS5, MF7) and ERA5 (Fig. 5). The bias is defined here as the difference between the forecasts and the reanalyses; the mathematical expression of the bias is the following:

$$B_t = F_t - R_t, \quad (9)$$

where F_t and R_t are the forecasts and reanalyses respectively at time t .

The bias is computed for each month at lead time 0 during the season from January to December for the period 1993–2016. By extending the analysis window over the season, we are able to check if the biases in the seasonal forecast models are constant or specific to the JJAS period. When analyzing the SEAS5 model outputs (Fig. 5a), we notice an overestimation of temperature over the Atlantic Ocean and over the Mediterranean Sea. We observe a cold bias between SEAS5 and ERA5 which appears progressively during the first months (January to April) and tends to intensify during the monsoon phase over the Sahel region. This cold bias is centered over the Sahara between the north of Mali, Niger and the south of Algeria and tends to decrease in intensity during the retreat phase of the monsoon in October. SEAS5 is colder than ERA5 and underestimates the spatial evolution of the SHL over the Sahara. In fact, biases in the evolution of the coupled ocean–atmosphere system or in the continental sub-surface can play a role in these biases, but their investigation is beyond the scope of this paper. The analysis on MF7 shows a progressive appearance of a warm bias in comparison to ERA5 over the Sahel during January and February (Fig. 5b). This warm bias tends to develop from March to September and affects the whole Sahara. It is more intense during the monsoon phase and is located over the eastern part of the Sahara. The bias between MF7 and ERA5 tends to decrease in intensity during the retreat phase of the monsoon in October. MF7 is warmer than ERA5 and overestimates the spatial evolution of the SHL over the Sahara. The central SHL area is

less affected by this warming in MF7 compared to the rest of the Sahara. This behavior in the Sahara region, especially in the eastern part of the Sahara, could be related to an underestimation of air advection coming from the Mediterranean regarding the prevalence of the hot bias to the eastern part of the Sahara (Fig. 2b). This analysis shows that the two seasonal forecast models have two contrasted representations of the SHL compared to ERA5, with a colder SHL in SEAS5 and a warmer SHL in MF7, which is in agreement with previous global studies (e.g., Dixon et al., 2017; Johnson et al., 2019). The two seasonal forecast models share however a similar seasonal evolution of the bias (increasing bias during the monsoon season) and a large spatial scale of the bias that covers most of the Sahara. Without sensitivity experiments, it is impossible to clearly identify the reasons for these opposite behaviors between the two models. The investigation of the origins of these biases is well beyond the scope of this article. In a more general framework, various European research projects have shown the difficulty of attributing a specific bias to a specific parameterization over West Africa, including the SHL (Martin et al., 2017).

After the evaluation of the spatial evolution of the SHL in the seasonal forecast models, the representation of the temporal drift is assessed (Fig. 6). The method used here consists in computing the climatology of the daily T850 ensemble mean and ensemble spread for the two models (SEAS5 and MF7) and the daily climatology of T850 for ERA5 from 1993–2016. For the models, we consider only the reforecasts launched on 1 April, 1 May and 1 June for a period of 6 months (see Sect. 2.4 for more details). We can see that the climatology of ERA5 remains contained in the spread described by SEAS5 for all lead times over the central SHL location and Sahara; this spread in SEAS5 seems to be constant in time and does not increase with the lead time. We observe for the first forecast days a large spread with MF7 which is not present in SEAS5, likely associated with different perturbations and initialization techniques that are beyond the scope of this study. For all lead times, an overestimation of temperature is shown with MF7 over the Sahara around mid-June and later over the central SHL location (~ 10 d after 1 July). SEAS5 shows an underestimation of temperature occurring on 1 July over both the central SHL box and the Sahara at different lead times. The maximum intensities of the SHL activity in the two seasonal forecast models are reached during the period of strong activity of the monsoon flux in the Sahel region (July–August). Both models are very consistent at the beginning of the season (April–June) when the Sahara is gradually warming. In the extension of the previous analyses, we decided to check the temporal correlation of the models and ERA5 (Fig. S6). We observe a weak correlation between the evolution of the SHL in the seasonal forecast models and ERA5. The scatterplot analysis used for this evaluation highlights the over/underestimation of T850 in MF7/SEAS5 with respect to ERA5 as observed in the monthly bias analyses (Fig. S6c).




Figure 3. Climatology of significant days: significant days here refer to days with a spectral power signal greater than 1. Red, blue and black curves and bars represent the number of days and spread for SEAS5, MF7 and ERA5 respectively over the (a) central SHL box and (b) Sahara during the period 1993–2016. The computation was made just using the unperturbed member of the ensemble forecast models launched from 1 June for the JJAS period. The y axis represents significant days and x axis the duration of propagation in days.

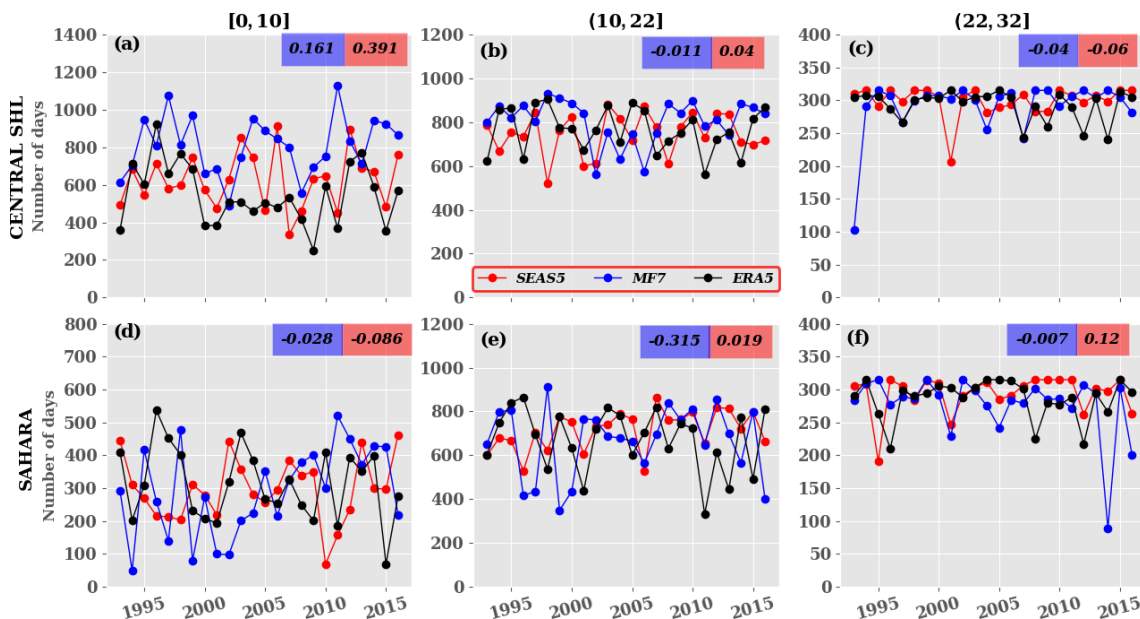


Figure 4. Interannual variability of significant days: significant days here refer to days with a spectral power signal greater than 1. Red, blue and black curves represent the number of days for SEAS5, MF7, ERA5 respectively over the (a–c) central SHL and (d–f) Sahara. The values in red and blue boxes refer to the correlation between SEAS5 and ERA5 and between MF7 and ERA5 respectively. The terms [0, 10], (10, 22] and (22, 32] are the different classes of days identified for the present study. The computation was made just using the unperturbed member of the ensemble forecast models launched from 1 June for the JJAS period. The y axis represents significant days and x axis the year.

An estimation of bias was carried out for the SEAS5 model data for (i) the full available period, running from 1981 to 2016 (denoted SEAS5₁), and (ii) the period common to MF7 and SEAS5, 1993–2016 (denoted SEAS5₂). The bias evolution is quite similar over the two periods (see Fig. 5a and Fig. S5 in the Supplement); but we notice in SEAS5₁ a

smaller cold bias compared to in SEAS5₂. This change in bias intensity can be explained by a warming in SEAS5 re-forecasts during the period 1981–1992 which attenuates the cooling effect in the model during the period 1993–2016.

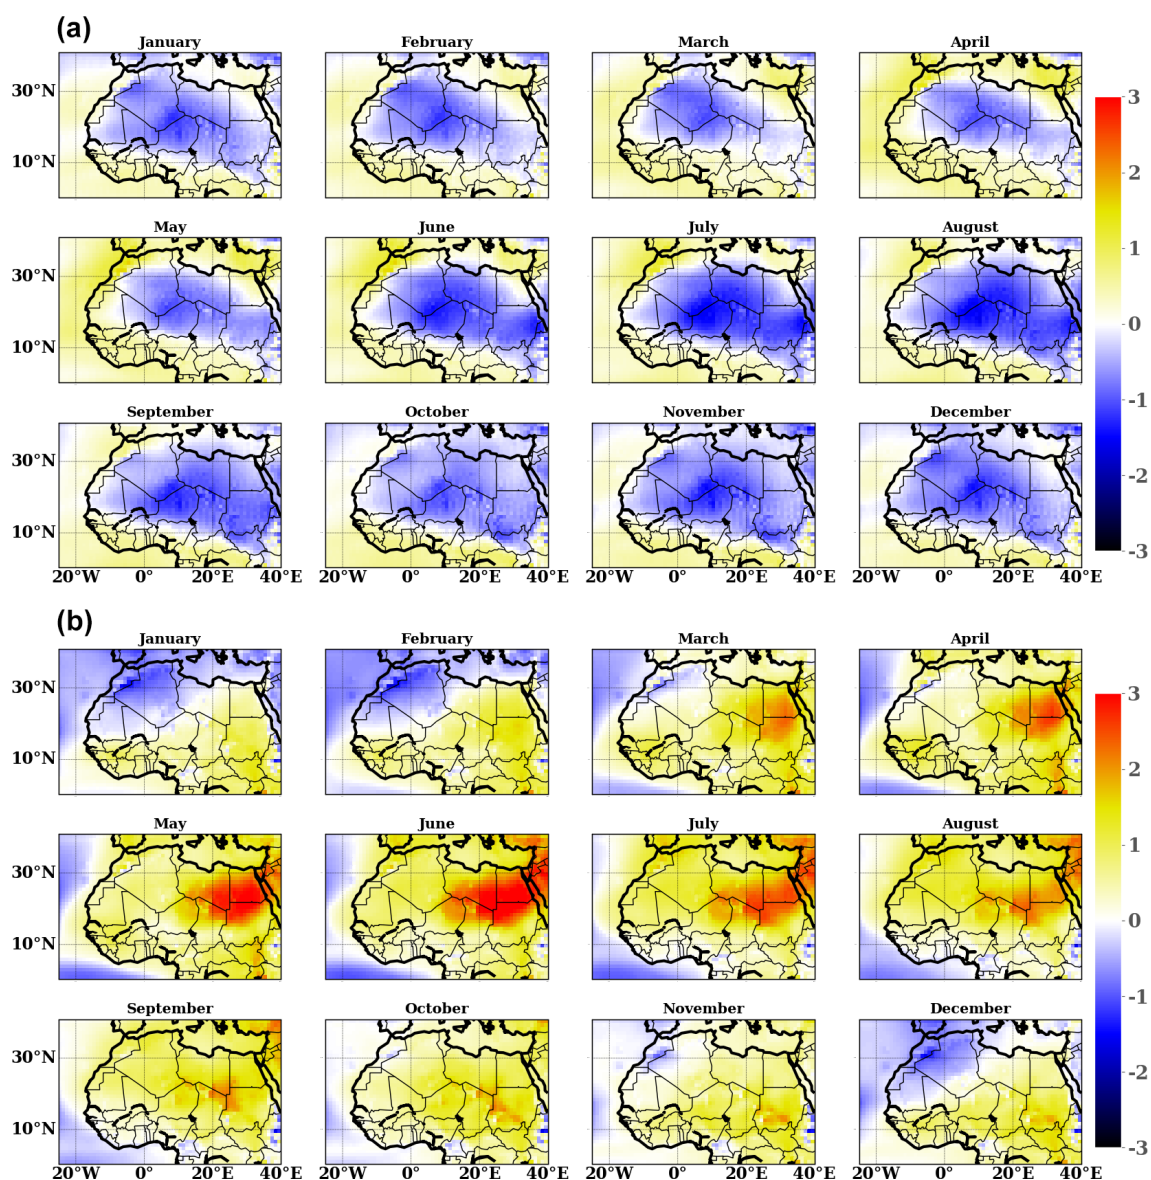


Figure 5. Climatology of monthly bias temperature over the Sahara region during 1993–2016 between (a) SEAS5 and ERA5 and (b) MF7 and ERA5. The bias is computed using daily temperature at 00:00 and 12:00 UTC. The computation was made using the ensemble mean for forecast models. The color bar indicates the bias value in kelvins. The y axis indicates the latitudes and x axis the longitudes of our domain.

3.4 Interannual distribution of the T850

The climatological trend of the distribution of SHL intensities has been analyzed using the seasonal probability distribution function (pdf) (Fig. 7a, f) of the SHL box-averaged T850 (used as the proxy for the SHL intensity) over the JJAS period at June lead time 0 (i.e., the initialization of the model was made on 1 June). The analysis of seasonal T850 shows a high variability in ERA5 and the presence of a decadal warming trend from 2005–2016 over both the central SHL location and the Sahara (Fig. 7a, g). The high interannual variability in the SHL seen in ERA5 is underestimated by SEAS5 and MF7. Using raw outputs of the seasonal forecast models,

SEAS5 tends to represent much better than MF7 the distribution the SHL intensities over the Sahara (Fig. 7a, c, d and g, i, j). Another specificity of MF7 is its slightly larger ensemble spread. SEAS5 seems to underestimate the warming trends present in ERA5 from 2005–2016, and an overestimation of this trend is observed with MF7 (Fig. S10); this behavior in the seasonal forecast models is present over both the central SHL box and the Sahara. By using this type of visualization (heatmap which is a graphical representation of data where values are depicted by color), it is possible to assess the intensity of the climatological trend with respect to the intraseasonal variability (Fig. 8). The interannual variability in the

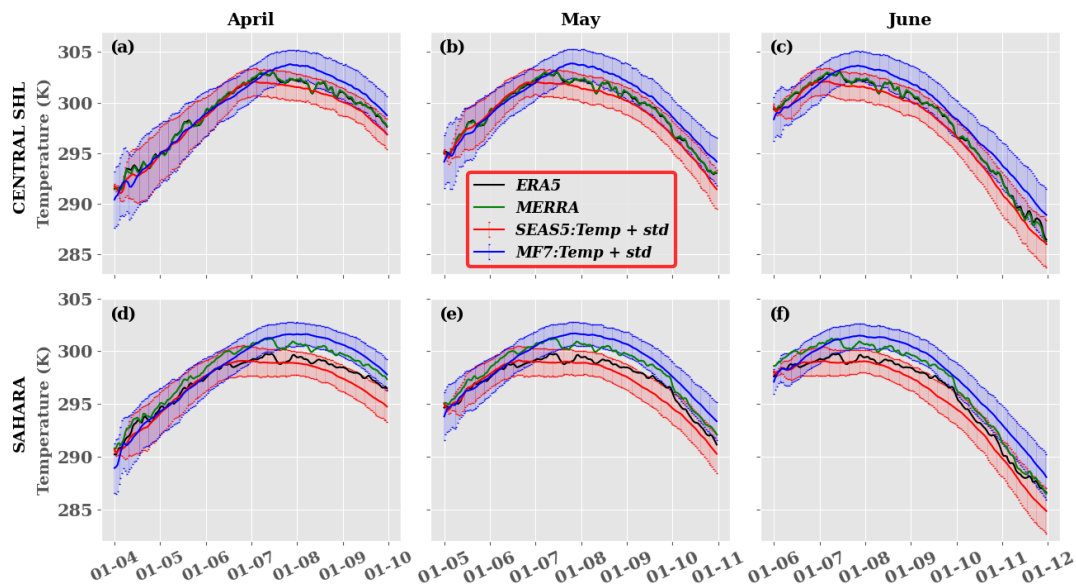


Figure 6. Climatology and spread of mean daily temperature during 1993–2016 at different initialization months for a 6-month forecast: (a, d) April, (b, e) May and (c, f) June for the (a–c) central SHL box and (d–f) Sahara. Bold black, green, red and blue curves refer to the mean T850 of ERA5, MERRA, SEAS5 and MF7 respectively; red and blue bars represent the inter-member spreads for SEAS5 and MF7 respectively. The computation was made using the ensemble mean of forecast models. The y axis indicates temperature in kelvins and x axis the time.

SHL anomalies distribution in the seasonal forecast models is too far from ERA5, but some characteristics are captured by the models (e.g., the increase in the frequency of anomalies in ERA5 during the 2000s). We observed high frequencies in the SHL anomalies distribution at an interannual timescale for MF7 and SEAS5 with more intense values over the Sahara (Fig. 8b, c, g, h). To focus more on the evolution of the tails of the distribution (i.e., the warmest and coldest T850), the anomaly of the pdf of temperature is provided in supplementary materials (Fig. S7). An increase in the occurrence of the warmest temperature is observed in SEAS5 and MF7 during the 2010s. MF7 tends to overestimate the interannual variability in the coldest and warmest temperature distribution, and SEAS5 exhibits an overall trend with some features close to ERA5. Despite the fact that seasonal models tend to capture some characteristics of the SHL variability, large differences are observed in comparison with ERA5. These differences can be explained by systematic biases present in models, as well as by approximations made during the models implementation (initial and boundary conditions, physical hypotheses, etc.). In order to improve the quality of the forecast, bias correction methods have been applied.

The above analyses revealed the presence of biases in the models; bias correction was applied over the JJAS period for June lead times 2, 1 and 0 (which represent the forecast of the JJAS period initialized in April, May and June respectively). The bias correction techniques used are CDF-t and QMAP (see Sect. 2.5.2 for more details on their application). The analysis of ensemble forecast models remains very delicate

because of the many possible ways to approach the bias correction; i.e., should we use the unperturbed member, mean ensemble member, median ensemble member or the whole ensemble member? In our case, the bias correction is first applied separately to the ensemble members in order to correct the re-forecasts of each of the 25 members of the seasonal forecast models (SEAS5 and MF7). A second methodology has been tested by applying a bias correction to the ensemble mean. To evaluate the sensitivity of the Cramér score to the ensemble forecast models, we defined three different approaches as follows:

- *CORR_NO_MEAN*. In this approach the bias correction is applied to the whole ensemble member and the Cramér score is computed using the outputs of the correction.
- *CORR_MEAN*. Here we compute first the mean over the outputs of the bias correction on the whole ensemble member; and we use this mean to compute the Cramér score;
- *MEAN_CORR*. The method consists of applying the bias correction to the ensemble mean, and the computation of the Cramér is performed directly using the outputs of the correction.

The Cramér score was calculated firstly using ERA5 and the raw forecast samples (SEAS5 and MF7) and secondly between ERA5 and the bias-corrected forecast samples (Fig. 9). We can observe that raw forecasts are not improved with




Figure 7. Distribution of yearly T850 over the JJAS period during 1993–2016 over the (a–f) central SHL box and (g–l) Sahara. ERA5, MERRA, SEAS5_BRUT and MF7_BRUT here correspond to the intensity of the SHL using ERA5 and MERRA for the reanalyses; SEAS5 and MF7 raw forecasts respectively. SEAS5_CDFT and MF7_CDFT refer to the intensity of the SHL using SEAS5 and MF7 seasonal forecasts respectively bias corrected using ERA5. The computation was made using the ensemble members of the forecast models. The y axis indicates time in years and x axis T850 in kelvins. The color bar indicates the probability of occurrence.

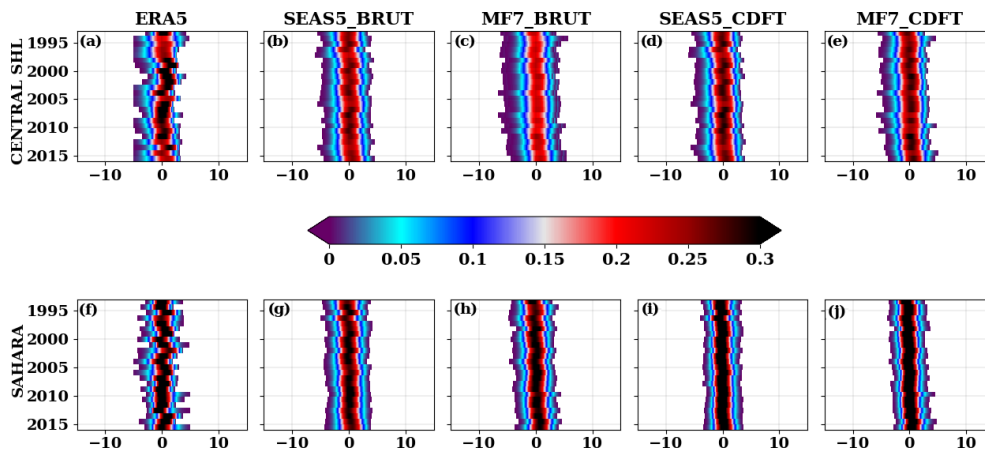


Figure 8. Same as Fig. 7 but for the yearly anomalies of temperature. The anomalies are computed by removing the daily climatology temperature for each year.

initialization months (April, May or June) while corrected forecasts show an improvement with decreasing lead times. This can be the result of systematic bias in seasonal forecast models. The MEAN_CORR method (Fig. 9c, f, i) is more efficient than the two other approaches CORR_MEAN and CORR_NO_MEAN, based on the Cramér score values. The CORR_MEAN approach tends to smooth the corrected forecasts due to the computation of the mean ensemble member after applying the correction. CDF-t and QMAP methods produce very similar results; an illustration of the corrected forecasts using both the methods is provided in supplementary materials (see Fig. S9). MF7 raw forecasts show relatively large correction over the Sahara (Fig. S8); this behavior in MF7 is related to the hot bias occurring over the eastern part of Sahara during the JJAS period as mentioned in Sect. 3.2 (Fig. 5b). We can see from these results that bias corrections are efficient and so important to apply to the

model outputs. Some illustrations of the corrected forecasts have been made with the CDF-t method. In Fig. 7e and j, we can notice a significant improvement in the distribution of SHL in MF7 over both the central SHL location and the Sahara. This improvement is also effective for SEAS5 (Fig. 7d, i). The corrected forecast distributions are closer to ERA5 than the raw forecast ones. The investigation of the correlation between the corrected forecasts and ERA5 (Fig. S6b, d) shows clearly that CDF-t corrects the cold/hot bias in SEAS5/MF7 by increasing/decreasing T850 values in order to match with ERA5 T850 values. CDF-t reduces a large part of the biases in SEAS5 and MF7, but the interannual correlation with ERA5 is not improved. Indeed, CDF-t is a quantile-based univariate bias adjustment method. As such, it preserves the ranks of the model simulations and thus preserves their rank (Spearman) correlations as well (e.g., Vrac, 2018; François et al., 2020).

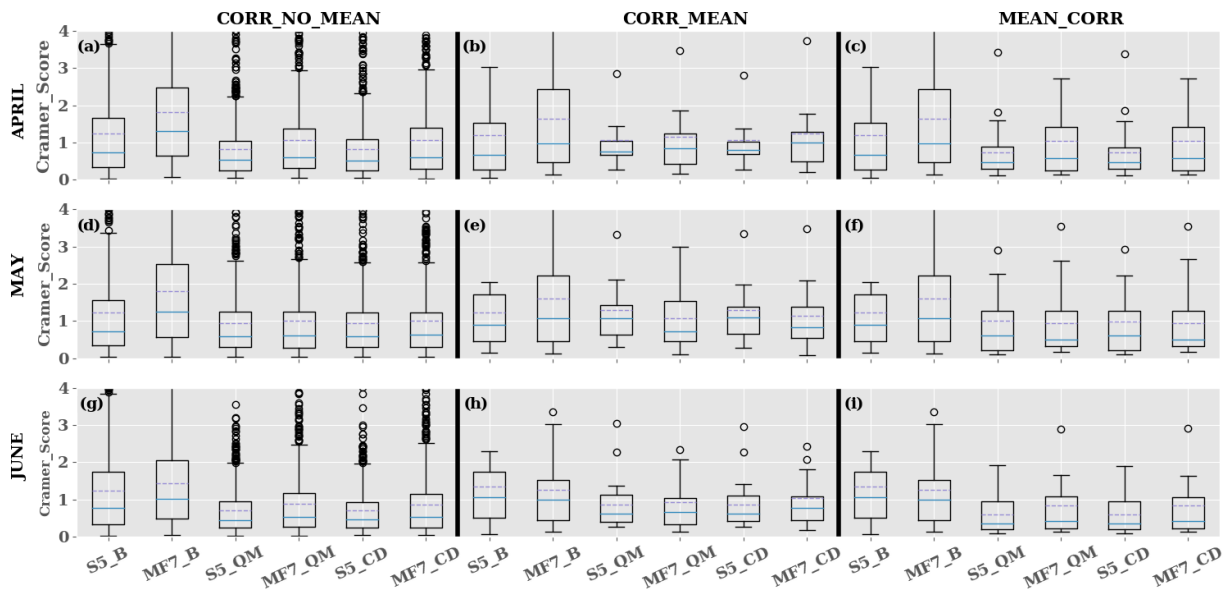


Figure 9. Bias correction evaluation using Cramér–von Mises score over the JJAS period during 1993–2016 on the central SHL box at different forecast initialization months: (a–c) April, (d–f) May and (g–i) June. The CORR_NO_MEAN, CORR_MEAN and MEAN_CORR methods are well described in Sect. 3.4. S5_B, S5_CD and S5_QM represent the Cramér score computed using the SEAS5 raw forecasts, SEAS5 corrected with CDF-t and QMAP methods respectively. The same applies to MF7_B, MF7_CD and MF7_QM with the MF7 model. The y axis indicates the Cramér score and x axis the different products used for the computation of the Cramér score.

3.5 Evolution of the extreme SHL events

Strong SHL activity contributes to the reinforcement of the monsoon flow over the Sahel along the eastern flank of the SHL. It also modulates the intensity of the AEJ and generates wind shear over the region. The resulting wind shear will generate more instabilities favoring convective activities over the West Africa region. Taylor et al. (2017) showed that strong SHL activity intensifies the convection within the meso-scale convective systems (MCSs). Fitzpatrick et al. (2020) suggest that stronger wind shear may be a key driver of decadal changes in storm intensity in the Sahel. This shows the importance of having a good representation of these SHL characteristics in the models. Therefore, we analyzed the variability in the SHL extremes using the raw and corrected forecasts obtained with CDF-t (Fig. 10). We distinguished cold and hot extremes which represent events under the quantile 10 % and above the quantile 90 % respectively. We observe an increase in the SHL hot extremes in the seasonal forecast models during the 2010s as well as a diminution of the SHL cold extremes which is in agreement with the evolution in ERA5. MF7 raw forecasts tend to overestimate the SHL hot extremes, while they seem to underestimate the SHL cold extremes over both the central SHL location and the Sahara. SEAS5 raw forecasts underestimate the SHL hot extremes and make an overestimation of the SHL cold extremes over the Sahara. We can see the efficiency of the bias correction (CDF-t) when analyzing the evolution of the SHL extremes from the corrected forecasts. Despite the

difference between ERA5 and the corrected forecasts being reduced compared to the raw forecasts, the observed gap remains significant.

3.6 East–west pulsation modes

The SHL has a typical timescale of 15 d associated with low-level horizontal advection of moist and cold air that modulates the surface temperature on the eastern part of the Sahara and makes the maximum surface temperature shift from a more eastern to a more western location of the Sahara (Chou et al., 2001; Roehrig et al., 2011), leading to so-called heat low east (HLE) events and heat low west (HLW) events respectively (Chauvin et al., 2010). Roehrig et al. (2011) and Lavaysse et al. (2011) highlighted interactions between SHL components and Sahelian rainfall events. In the present work, a simple method is proposed to capture the HLW and HLE oscillations. Our method consists in defining a dipole by computing the mean T850 difference between HLW and HLE boxes, here referred to as WSHL and ESHL respectively (see Sect. 2.2 for more details):

$$\text{Dipole} = \text{HLW} - \text{HLE} \quad (10)$$

A positive value of the dipole indicates an HLW occurrence, while a negative value corresponds to the HLE event. We evaluate the method using the LLAT approach and the automatic detection of the SHL barycenter (Lavaysse et al., 2009) used during the H2020 Dynamics–Aerosol–Chemistry–Cloud Interactions in West Africa (DACCIWA)

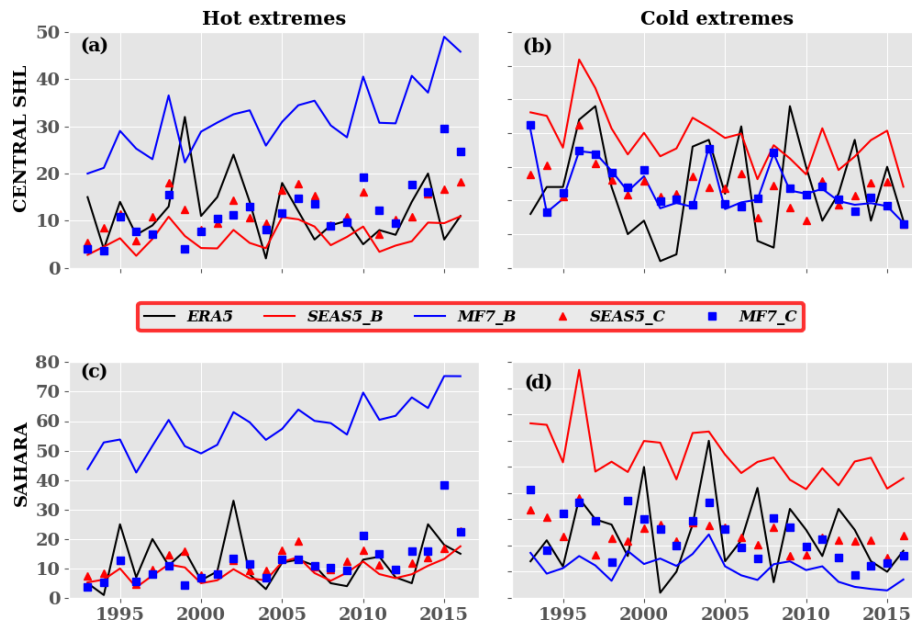


Figure 10. Interannual variability in the SHL extremes over the (a, b) central SHL and (c, d) Sahara during the JJAS period from 1993 to 2016. SEAS5_C and MF7_C refer to corrected forecasts with the CDF-t method, and SEAS5_B and MF7_B represent raw model forecasts. The x axis indicates the time (year) and y axis the number of extremes registered for each year. Hot extremes are events occurring above the 90th percentile, and cold extremes are associated with events below the 10th percentile.

project campaign (Knippertz et al., 2017), which aims to evaluate the seasonal location of the SHL with respect to its climatological position. An illustration of our method for the year 2005 is shown in Fig. S11 and confirms that there is a good agreement between the evolution of the dipole of T850 in ERA5 and the SHL barycenter computed in Knippertz et al. (2017). After the assessment of the detection method, we evaluate the representation of the SHL components in the seasonal forecasts and ERA5 data (Fig. 11a). As the corrected forecasts are unbiased compared to the raw forecasts, we use them for this analysis. The results show that ERA5 presents a bimodal regime; the first one is less accentuated and associated with the HLE events (negative dipole value), while the second regime is more representative and related to HLW events (positive dipole value). For MF7, we also noticed a bimodal regime and a large range in the distribution of the dipole compared to ERA5; the first regime is more frequent and associated with the HLE events. The second regime is less frequent and related to HLW events. With SEAS5, we also observed a bimodal regime and a reduced range compared to ERA5. The first regime is less important and associated with the HLE events, while the second one is more important and related to HLW events. From this analysis, we can notice that MF7 (SEAS5) tends to overestimate the HLE (HLW) phases (Fig. 11a). This behavior in the seasonal models is well highlighted when using the raw forecasts for the computation of the dipole (see Fig. S16a in the Supplement). MF7 and SEAS5 here again exhibit opposite behaviors in terms of frequencies and intensities of the

Table 1. Correlation between the dipole values derived from the seasonal models (SEAS5 and MF7) and the one derived from ERA5. The “Raw dipole” represents the dipole computed using raw forecasts and “Corrected dipole” that using the bias-corrected forecasts.

	SEAS5	MF7
Raw dipole	0.53	0.65
Corrected dipole	0.61	0.75

SHL components. The analysis of the correlation between the models and ERA5 shows that MF7 seems to be slightly better correlated with ERA5 than SEAS5 (see Table 1). We noticed a little and not significant improvement in the correlation with the corrected signal.

To better understand the reasons for these differences, a separate analysis of the SHL distribution in the two boxes is performed (Fig. 11b, c). First, it is worth noting that the east Sahara is climatologically hotter than the west Sahara in ERA5, SEAS5 and MF7. This is explained by the proximity of the west Sahara to the Atlantic Ocean and the advection of fresh air masses in that area (see Fig. 2 for the location of the west Sahara). Hence, there is a greater occurrence of the HLE events compared to the HLW phases in ERA5. The models (SEAS5/MF7) are able to reproduce this partitioning of the SHL phases observed in ERA5 with the same range of frequencies (~ 0.6/0.4) for HLE/HLW respectively. Both models overestimate the occurrence of the HLE events; MF7

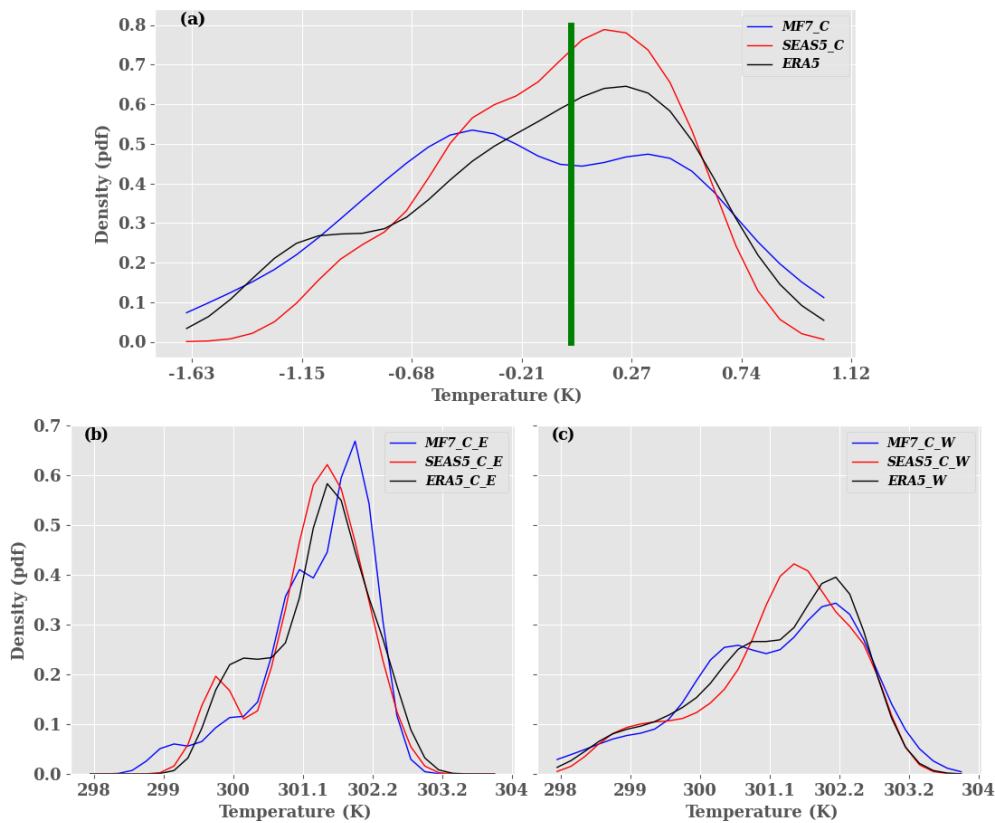


Figure 11. Distribution of the climatology over the period 20 June–17 September from 1993 to 2016 at June lead time 0 for (a) the dipole which represents the difference between heat low west and heat low east, (b) heat low east, and (c) heat low west. MF7_C and SEAS5_C refer to the MF7 and SEAS5 forecasts respectively corrected with the CDF-t method. ERA5_E, MF7_C_E and SEAS5_C_E refer to the HLE in the reanalyses and MF7 SEAS5 forecasts respectively corrected with the CDF-t method. “ERA5_W”, “MF7_C_W” and “SEAS5_C_W” refer to the HLW in the reanalyses and MF7 and SEAS5 forecasts respectively corrected with CDF-t method. The y axis indicates the probability of occurrence and x axis the temperature in kelvins. The vertical green bar represents the boundary between the HLE and HLW phases. The analysis was carried out using the unperturbed member.

tends to develop hot HLE events (Fig. 11b). The analysis of the HLW phases reveals an under/overestimation of the intensity/occurrence of these events in SEAS5. We notice, with MF7, a good representation of the intensity of the HLW events with sometimes an overestimation of the frequencies associated with these phases (Fig. 11c). The interactions between the east and west boxes are investigated through a correlation analysis using the outputs of both the seasonal models. The results obtained using raw and corrected forecasts are very similar (not shown), so in the following we present only the results related to the bias-corrected forecasts. High correlation would suggest an influence of the large-scale processes, whereas low correlation would indicate that smaller-scale processes and local impacts come into play. The correlation between HLE and HLW phases is about 0.45, 0.56 and 0.48 for ERA5, SEAS5 and MF7 respectively (see Table 2). SEAS5 shows a higher correlation between the two phases compared to ERA5 and MF7. To discriminate the effect of the intraseasonal and seasonal cycles, the correlations are computed between HLW and HLE by using the daily T850

anomalies relative to the daily climatology of T850 in the two boxes. As expected, the seasonal cycle has a strong impact and the correlation reduces from 0.45 to 0.30 for ERA5 compared to a reduction from 0.56 to 0.45 for SEAS5 and from 0.48 to 0.34 for MF7 (see Table 2). The correlation with SEAS5 remains high compared to MF7 and ERA5; this suggests that T850 over the Sahara in SEAS5 is more affected by large-scale drivers that provide wider temperature field anomalies. MF7 shows a partitioning of SHL variability between the SHL intraseasonal mode and the seasonal cycle that is more in agreement with ERA5. An investigation of the representation of the SHL phases in the models vs. ERA5 has been assessed using the corrected forecasts. The models are more correlated with ERA5 for the HLW phases (see Table S1). Despite the differences between seasonal models and ERA5, the models are able to capture the seasonal east–west migration of the SHL.

Table 2. Correlation between the HLW and HLE phases: values in bold (parentheses) indicate the correlation using the bias-corrected temperatures (anomalies of temperature) over the east and west SHL boxes.

	ERA5	SEAS5	MF7
Correlation	0.45 (0.30)	0.56 (0.45)	0.48 (0.34)

4 Discussion

Our results show that the two seasonal forecast models have the capability to capture some of the SHL main characteristics. There is a deficit in reproducing the intensity and the occurrence of events, such as east and west phases of the SHL, as they appear in the reference ERA5. The analysis of the bias in seasonal forecast models evidenced a hot bias in MF7 and a cold bias in SEAS5 which could be explained by large-scale processes and forcings occurring at different timescales in the Sahara region. The different behaviors observed in forecast models can be related to their sensitivity to the drivers and the physical processes involved in the SHL evolution.

A preliminary assessment of the quality of the forecasts with respect to the ERA5 reanalysis is discussed. This is performed through an evaluation of the skills of the seasonal forecast models to reproduce the interannual variability in the SHL. For this evaluation, we used two metrics: the CRPS and RMSE (see Sect. 2.5.3 for more details). A first analysis of the forecasts at an interannual timescale was conducted using monthly mean T850 and daily T850 respectively for the computation of the CRPS (Figs. 12 and S12) and the RMSE (Fig. S14) with initialization of the seasonal forecast models in April, May and June. The first period of evaluation is the seasonal timescale that provides a benchmark of the forecast for the rainy season (Fig. 12a, f, k; see also Fig. S14a, f, k in the Supplement). It gives a limited but significant improvement with respect to the climatology. The scores (CRPS, RMSE) are then decomposed by month (Fig. 12b–e, g–j, l–o) (see also Fig. S14a–e, g–j and l–o in the Supplement) to investigate the representation of the intraseasonal variability in the SHL. We noticed an increase in the CRPS and RMSE values with the lead times over the CSHL location, which leads to a loss of predictability in the seasonal forecast models. SEAS5 shows more predictive skills over the CSHL location for short-lead-time forecasting (0 to 1 months), and MF7 is a little better for long lead times (approximately 3 months). MF7 raw forecasts show very limited skills over the Sahara (see Figs. S12 and S13b in the Supplement); this behavior in MF7 can be related to hot biases evidenced in Sect. 3.2 (Fig. 5a). Bias correction improves considerably the predictive skills of the models. The effect of bias correction on the predictive skills of the seasonal models is more efficient over the Sahara (see Figs. S12 and S13b in the Supplement). This

can be explained by the fact that climate models usually take into account large-scale variability. As the Sahara is larger than the central SHL box, the forecast models will better represent the variability occurring over the Sahara; and the correction method will adjust the systematic bias present in the models. Models present lower predictive skills for the daily T850, and an improvement is seen at a monthly timescale for short lead times. However, the correlation found at a monthly timescale never exceeds 0.61 (see Fig. S15b in the Supplement); at a daily timescale, the correlation is less than 0.53 (see Fig. S15a in the Supplement) for all months at lead time 0. Correlations at different lead times have also been computed, but the resulting coefficients were even lower than those obtained at lead time 0 (not shown). An evaluation of the seasonal forecast models at a very short lead time has been performed for June, July, August and September at lead time 0 by computing the CRPS using daily T850 raw forecasts (see Fig. S14 in the Supplement); similar results have been found with the unbiased forecasts (not shown). We observed a progressive increase in the CRPS with time before reaching the predictability horizon at around 20 d. SEAS5 shows predictive skills at the first time steps of 1–3 d over the CSHL and 1–8 d over the Sahara location; and MF7 is more affected by the spin-up at the beginning of the prediction. This behavior in SEAS5 can be explained by the capacity of the model to represent large-scale variability occurring at the Sahara location. From these results, we observed some predictive skills in the seasonal forecast models at an intraseasonal timescale; however they remain weak for a long period and for lead times beyond 1 month. These results are in agreement with previous works which addressed the predictive skills of the ECMWF ensemble system (Haiden et al., 2015).

As seen previously, MF7 and SEAS5 present different characteristics in terms of bias, particularly regarding HLW and HLE event detection. This suggests that a multi-model ensemble approach may be a solution to improve the forecast skills of the seasonal models. Surprisingly, the multi-model shows a predictive skill comparable to the individual models (Fig. 12). This shows that the predictive skills of an ensemble model do not depend on the number of members in the models.

5 Conclusions

This work assessed the representation of the SHL in two seasonal forecast models (SEAS5 and MF7) using ERA5 reanalyses as reference. The choice of ERA5 as reference for this evaluation was supported by a sensitive study conducted between ERA5 and another reanalysis dataset, namely MERRA. Very high correlations have been found between the two reanalyses data, i.e., around 0.97 and 0.92 over the CSHL and the Sahara location respectively; robust similarities are also observed in the yearly distribution of

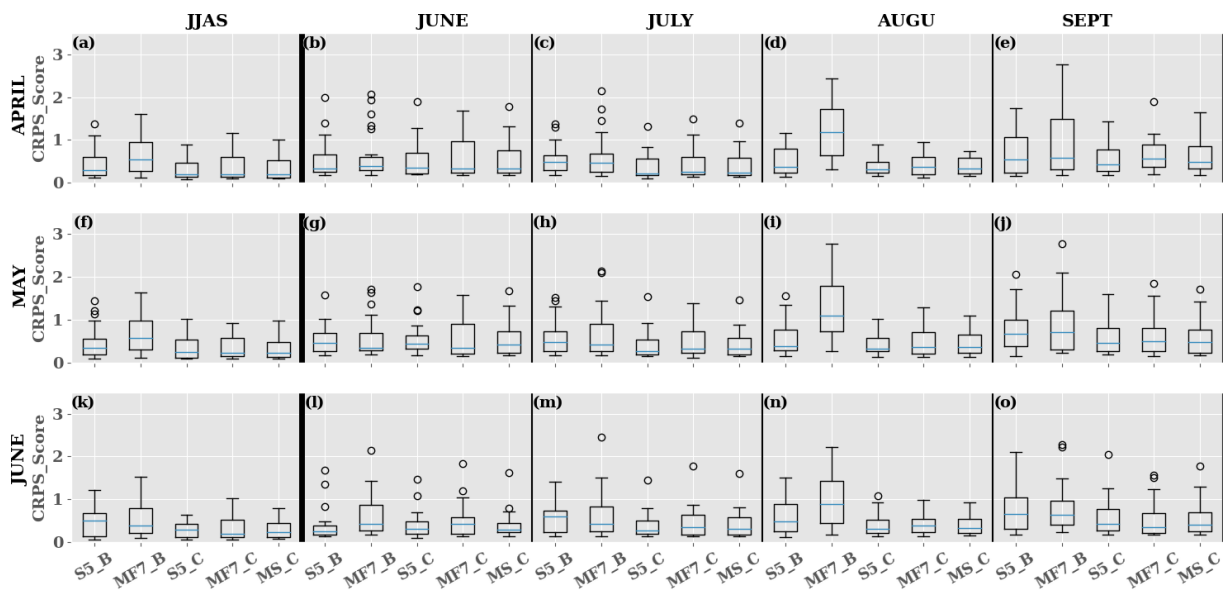


Figure 12. Evaluation of the interannual variability in the SHL over the JJAS period and separately in June, July, August and September during 1993–2016 using monthly mean T850 over the central SHL box at different initialization months: (a–e) April, (f–j) May and (k–o) June. S5_B and S5_C represent respectively the CRPS evaluated using the SEAS5 raw and corrected forecast respectively with the CDF-t method. The same applies for MF7_B and MF7_C with the MF7 model. MS_C represents the CRPS evaluated on the multi-model formed by SEAS5 and MF7 corrected forecasts with the CDF-t method. The computation was made using the ensemble member for both corrected and raw forecasts. The y axis indicates the CRPS values and x axis the data type used for the computation of the CRPS.

T850. The discrepancies between the reanalyses are much smaller than the biases in the seasonal forecast models with respect to ERA5. Through a set of analyses, we have found opposite biases in the seasonal forecast models compared to ERA5. MF7 has a warm bias and tends to overestimate the intensity of the SHL with respect to ERA5. SEAS5 develops a cold bias and tends to underestimate the intensity of the SHL over the Sahara. The models are able to represent the mean seasonal cycle of the SHL and capture some characteristics of its interannual variability like the warming trends observed during the 2010s. However, the good representation of this interannual variability remains challenging for the models. SEAS5 represents more realistically the climatic trend of the SHL than MF7. The bias correction methods CDF-t and QMAP are very efficient at reducing the systematic bias present in the seasonal models. By using bias correction tools, the results highlight the capacity of the models to represent the intraseasonal pulsations (the so-called east–west phases) of the SHL. We notice an overestimation of the occurrence of the HLE phases in the models (SEAS5 and MF7); the HLW phases are much better represented in MF7. This diagnosis is a first validation of the representation of the SHL in seasonal models. In spite of this, the correct timing of these pulsations is still a key challenge and the next step forward. Seasonal forecast models show predictive skills at an intraseasonal timescale for short periods. Bias correction contributes to improving the ensemble forecast score (CRPS), but the forecast skill remains weak

for a lead time beyond 1 month. The issue of the lack of correlation in models cannot be solved through a bias correction approach; only model improvements could provide better correlations between forecasts and observations. In a future study, we will investigate the relationship between the SHL and the extreme rainfall in the Sahel region at an intraseasonal timescale.

Code availability. The codes to perform the detection and the scores are available on demand; please feel free to contact us. The codes were implemented using CDO, R (CDFt, SpecsVerification, biwavelet packages) and Python (NumPy, pandas, SciPy libraries).

Data availability. The data used for this work are available and open access. ERA5 and MERRA reanalyses can be assessed through the ISPL (Institut Pierre Simon Laplace) server ClimServ or the Copernicus website (<https://cds.climate.copernicus.eu/#!/home>; Copernicus, 2021). MF7 seasonal forecasts can be found at the Météo-France service, and SEAS5 seasonal forecasts are accessible through the ECMWF website (<https://www.ecmwf.int/en/forecasts>; ECMWF, 2021).

Supplement. The supplement related to this article is available online at: <https://doi.org/10.5194/wcd-2-893-2021-supplement>.

Author contributions. This study was conducted with the collaboration of different researchers who played an important role at each step. CGNL performed the analysis with the collaboration of CL; MV brought his expertise in statistical bias correction methods; CGNL, CL, PP, CF and MV discussed the results and wrote the paper. CF and MV provided advice and insightful comments before submission.

Competing interests. The authors declare that they have no conflict of interest.

Disclaimer. Publisher's note: Copernicus Publications remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Acknowledgements. We thank LATMOS for providing infrastructures and the IPSL center for the access to the ClimServ server to download some of the data used in our study.

Financial support. This work is supported by the French National Research Agency in the framework of the “Investissement d’avenir” program (ANR-15-IDEX-02) with the project PREDISAH LIM (2019–2021) and under grant ANR-19-CE03-0012 with the project STEWARD (2020–2024).

Review statement. This paper was edited by Peter Knippertz and reviewed by two anonymous referees.

References

- Bickle, M. E., Marsham, J. H., Ross, A. N., Rowell, D. P., Parker, D. J., and Taylor, C. M.: Understanding mechanisms for trends in Sahelian squall lines: Roles of thermodynamics and shear, *147*, 983–1006, *Q. J. Roy. Meteor. Soc.*, 2020.
- Büßow, R.: An algorithm for the continuous Morlet wavelet transform, *Mech. Syst. Signal Pr.*, 21, 2970–2979, <https://doi.org/10.1016/j.ymsp.2007.06.001>, 2007.
- Cannon, A. J., Sobie, S. R., and Murdock, T. Q.: Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes?, *J. Climate*, 28, 6938–6959, 2015.
- Chauvin, F., Roehrig, R., and Lafore, J.-P.: Intraseasonal variability of the Saharan heat low and its link with midlatitudes, *J. Climate*, 23, 2544–2561, 2010.
- Chou, C., Neelin, J. D., and Su, H.: Ocean-atmosphere-land feedbacks in an idealized monsoon, *Q. J. Roy. Meteor. Soc.*, 127, 1869–1891, 2001.
- Cohen, M. X.: A better way to define and describe Morlet wavelets for time-frequency analysis, *bioRxiv*, Cold Spring Harbor Laboratory Section: New Results, Elsevier, 397182, <https://doi.org/10.1101/397182>, 2018.
- Copernicus: ERA5 and MERRA reanalyses, available at: <https://cds.climate.copernicus.eu#!/home>, last access: 8 September 2021.
- Déqué, M., Drevet, C., Braun, A., and Cariolle, D.: The ARPEGE/IFS atmosphere model: a contribution to the French community climate modelling, *Clim. Dynam.*, 10, 249–266, 1994.
- Dixon, R. D., Daloz, A. S., Vimont, D. J., and Biasutti, M.: Saharan heat low biases in CMIP5 models, *J. Climate*, 30, 2867–2884, 2017.
- Dosio, A. and Paruolo, P.: Bias correction of the ENSEMBLES high-resolution climate change projections for use by impact models: Evaluation on the present climate, *J. Geophys. Res.-Atmos.*, 116, 2011.
- Drobinski, P., Sultan, B., and Janicot, S.: Role of the Hoggar massif in the West African monsoon onset, *Geophys. Res. Lett.*, 32, 2005.
- Durand, J.-H.: A propos de la sécheresse et ses conséquences au Sahel, *Les cahiers d’outre-mer*, 30, 383–403, Presses Universitaires de Bordeaux, Persée-Portail des revues scientifiques en SHS, Bordeaux, 1977.
- ECMWF: Seasonal forecasts, available at: <https://www.ecmwf.int/en/forecasts>, last access 9 September 2021.
- Evan, A. T., Flamant, C., Lavaysse, C., Kocha, C., and Saci, A.: Water vapor–forced greenhouse warming over the Sahara Desert and the recent recovery from the Sahelian drought, *J. Climate*, 28, 108–123, 2015.
- Fitzpatrick, R. G., Parker, D. J., Marsham, J. H., Rowell, D. P., Guichard, F. M., Taylor, C. M., Cook, K. H., Vizy, E. K., Jackson, L. S., Finney, D., Crook, J., Stratton, R., and Tucker, S.: What drives the intensification of mesoscale convective systems over the West African Sahel under climate change?, *J. Climate*, 33, 3151–3172, 2020.
- François, B., Vrac, M., Cannon, A. J., Robin, Y., and Allard, D.: Multivariate bias corrections of climate simulations: which benefits for which losses?, *Earth Syst. Dynam.*, 11, 537–562, <https://doi.org/10.5194/esd-11-537-2020>, 2020.
- Haiden, T., Bidlot, J., Ferranti, L., Bauer, P., Dahoui, M., Janousek, M., Prates, F., Vitart, F., and Richardson, D.: Evaluation of ECMWF forecasts, including 2014–2015 upgrades, European Centre for Medium-Range Weather Forecasts, Shinfield Park, Reading, Berkshire RG2 9AX, England, 2015.
- Henze, N. and Meintanis, S. G.: Recent and classical tests for exponentiality: a partial review with comparisons, *Metrika*, 61, 29–45, Springer Verlag, Paris, France, 2005.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavatti, G., Bidlot, J., Bonavita, M., De Chiara, G., Per, D., Dee, D., Diamantakis, M., Dragani, R., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, J. R., Hólm, E., Janisková, M., Keely, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., De Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., and Thépaut, J.-N.: The ERA5 global reanalysis, *Q. J. Roy. Meteor. Soc.*, 146, 1999–2049, 2020.
- Hudson, D. and Ebert, B.: Ensemble Verification Metrics, in: Proceedings of the ECMWF Annual Seminar, Reading, UK, 11–14, 2017.

- Janicot, S., Mounier, F., and Diedhiou, A.: Les ondes atmosphériques d'échelle synoptique dans la mousson d'Afrique de l'Ouest et centrale : ondes d'est et ondes de Kelvin, *Science et changements planétaires / Sécheresse*, 19, 13–22, 2008a.
- Janicot, S., Thorncroft, C. D., Ali, A., Asencio, N., Berry, G., Bock, O., Bourles, B., Caniaux, G., Chauvin, F., Deme, A., Kergoat, L., Lafore, J.-P., Lavaysse, C., Lebel, T., Marticorena, B., Mounier, F., Nedelec, P., Redelsperger, J.-L., Ravegnani, F., Reeves, C. E., Roca, R., de Rosnay, P., Schlager, H., Sultan, B., Tomasini, M., Ulanovsky, A., and ACMAD forecasters team: Large-scale overview of the summer monsoon over West Africa during the AMMA field experiment in 2006, *Ann. Geophys.*, 26, 2569–2595, <https://doi.org/10.5194/angeo-26-2569-2008>, 2008b.
- Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., Tietsche, S., Decremier, D., Weisheimer, A., Balsamo, G., Keeley, S. P. E., Mogensen, K., Zuo, H., and Monge-Sanz, B. M.: SEAS5: the new ECMWF seasonal forecast system, *Geosci. Model Dev.*, 12, 1087–1117, <https://doi.org/10.5194/gmd-12-1087-2019>, 2019.
- Knippertz, P., Fink, A. H., Deroubaix, A., Morris, E., Tocquer, F., Evans, M. J., Flamant, C., Gaetani, M., Lavaysse, C., Mari, C., Marsham, J. H., Meynadier, R., Affo-Dogo, A., Bahaga, T., Brosse, F., Deetz, K., Guebsi, R., Latifou, I., Maranan, M., Rosenberg, P. D., and Schlueter, A.: A meteorological and chemical overview of the DACCIIWA field campaign in West Africa in June–July 2016, *Atmos. Chem. Phys.*, 17, 10893–10918, <https://doi.org/10.5194/acp-17-10893-2017>, 2017.
- Lavaysse, C.: Warming trends: Saharan desert warming, *Nat. Clim. Change*, 5, 807–808, 2015.
- Lavaysse, C., Flamant, C., Janicot, S., Parker, D. J., Lafore, J.-P., Sultan, B., and Pelon, J.: Seasonal evolution of the West African heat low: a climatological perspective, *Clim. Dynam.*, 33, 313–330, 2009.
- Lavaysse, C., Flamant, C., and Janicot, S.: Regional-scale convection patterns during strong and weak phases of the Saharan heat low, *Atmos. Sci. Lett.*, 11, 255–264, 2010a.
- Lavaysse, C., Flamant, C., Janicot, S., and Knippertz, P.: Links between African easterly waves, midlatitude circulation and intraseasonal pulsations of the West African heat low, *Q. J. Roy. Meteor. Soc.*, 136, 141–158, 2010b.
- Lavaysse, C., Chaboureaud, J.-P., and Flamant, C.: Dust impact on the West African heat low in summertime, *Q. J. Roy. Meteor. Soc.*, 137, 1227–1240, <https://doi.org/10.1002/qj.844>, 2011.
- Lavaysse, C., Vrac, M., Drobinski, P., Lengaigne, M., and Vischel, T.: Statistical downscaling of the French Mediterranean climate: assessment for present and projection in an anthropogenic scenario, *Nat. Hazards Earth Syst. Sci.*, 12, 651–670, <https://doi.org/10.5194/nhess-12-651-2012>, 2012.
- Lavaysse, C., Flamant, C., Evan, A., Janicot, S., and Gaetani, M.: Recent climatological trend of the Saharan heat low and its impact on the West African climate, *Clim. Dynam.*, 47, 3479–3498, 2016.
- Lavaysse, C., Naumann, G., Alfieri, L., Salamon, P., and Vogt, J.: Predictability of the European heat and cold waves, *Clim. Dynam.*, 52, 2481–2495, 2019.
- Martin, G. M., Peyrillé, P., Roehrig, R., Rio, C., Caian, M., Bellon, G., Codron, F., Lafore, J.-P., Poan, D. E., and Idelkadi, A.: Understanding the West African Monsoon from the analysis of diabatic heating distributions as simulated by climate models, *J. Adv. Model. Earth Sy.*, 9, 239–270, 2017.
- Michelangeli, P.-A., Vrac, M., and Loukos, H.: Probabilistic downscaling approaches: Application to wind cumulative distribution functions, *Geophys. Res. Lett.*, 36, 2009.
- Parker, D. J., Burton, R. R., Diongue-Niang, A., Ellis, R. J., Felton, M., Taylor, C. M., Thorncroft, C. D., Bessemoulin, P., and Tompkins, A. M.: The diurnal cycle of the West African monsoon circulation, *Q. J. Roy. Meteor. Soc.*, 131, 2839–2860, 2005.
- Peyrillé, P. and Lafore, J.-P.: An idealized two-dimensional framework to study the West African monsoon. Part II: Large-scale advection and the diurnal cycle, *J. Atmos. Sci.*, 64, 2783–2803, 2007.
- Prospero, J. M., Ginoux, P., Torres, O., Nicholson, S. E., and Gill, T. E.: Environmental characterization of global sources of atmospheric soil dust identified with the Nimbus 7 Total Ozone Mapping Spectrometer (TOMS) absorbing aerosol product, *Rev. Geophys.*, 40, 2–1, 2002.
- Redelsperger, J.-L., Thorncroft, C. D., Diedhiou, A., Lebel, T., Parker, D. J., and Polcher, J.: African Monsoon Multidisciplinary Analysis: An international research project and field campaign, *B. Am. Meteorol. Soc.*, 87, 1739–1746, 2006.
- Roehrig, R., Chauvin, F., and Lafore, J.-P.: 10–25-day intraseasonal variability of convection over the Sahel: A role of the Saharan heat low and midlatitudes, *J. Climate*, 24, 5863–5878, 2011.
- Roehrig, R., Bouniol, D., Guichard, F., Hourdin, F., and Redelsperger, J.-L.: The present and future of the West African monsoon: A process-oriented assessment of CMIP5 simulations along the AMMA transect, *J. Climate*, 26, 6471–6505, 2013.
- Siegert, S., Bhend, J., Kroener, I., and De Felice, M.: Package “SpecsVerification”, available at: <https://mran.microsoft.com/snapshot/2016-09-07/web/packages/SpecsVerification/SpecsVerification.pdf> (last access: 2 September 2021), 2017.
- Sultan, B. and Janicot, S.: The West African monsoon dynamics. Part II: The “preonset” and “onset” of the summer monsoon, *J. Climate*, 16, 3407–3427, 2003.
- Tang, B., Liu, W., and Song, T.: Wind turbine fault diagnosis based on Morlet wavelet transformation and Wigner-Ville distribution, *Renew. Energ.*, 35, 2862–2866, <https://doi.org/10.1016/j.renene.2010.05.012>, 2010.
- Taylor, C. M., Belušić, D., Guichard, F., Parker, D. J., Vischel, T., Bock, O., Harris, P. P., Janicot, S., Klein, C., and Panthou, G.: Frequency of extreme Sahelian storms tripled since 1982 in satellite observations, *Nature*, 544, 475–478, <https://doi.org/10.1038/nature22069>, 2017.
- Thorncroft, C. D. and Blackburn, M.: Maintenance of the African easterly jet, *Q. J. Roy. Meteor. Soc.*, 125, 763–786, 1999.
- Vogel, P., Knippertz, P., Fink, A. H., Schlueter, A., and Gneiting, T.: Skill of global raw and postprocessed ensemble predictions of rainfall over northern tropical Africa, *Weather Forecast.*, 33, 369–388, 2018.
- Voltaire, A., Saint-Martin, D., Sénési, S., Decharme, B., Alias, A., Chevallier, M., Colin, J., Guérémy, J.-F., Michou, M., Moine, M.-P., Nabat, P., Roehrig, R., Méliá, D. S. y., Séférian, R., Valcke, S., Beau, I., Belamari, S., Berthet, S., Cassou, C., Cattiaux, J., Deshayes, J., Douville, H., Ethé, C., Franchistéguy, L., Geoffroy, O., Lévy, C., Madec, G., Meurdesoif, Y., Msadek, R., Ribes, A., Sanchez-Gomez, E., Terray, L., and Waldman, R.: Evaluation of CMIP6 DECK Experiments

- With CNRM-CM6-1, *J. Adv. Model. Earth Sy.*, 11, 2177–2213, <https://doi.org/10.1029/2019MS001683>, 2019.
- Vrac, M.: Multivariate bias adjustment of high-dimensional climate simulations: the Rank Resampling for Distributions and Dependences (R^2D^2) bias correction, *Hydrol. Earth Syst. Sci.*, 22, 3175–3196, <https://doi.org/10.5194/hess-22-3175-2018>, 2018.
- Vrac, M., Drobinski, P., Merlo, A., Herrmann, M., Lavaysse, C., Li, L., and Somot, S.: Dynamical and statistical downscaling of the French Mediterranean climate: uncertainty assessment, *Nat. Hazards Earth Syst. Sci.*, 12, 2769–2784, <https://doi.org/10.5194/nhess-12-2769-2012>, 2012.
- Zhao, G., Jiang, D., Diao, J., and Qian, L.: Application of wavelet time-frequency analysis, 10, available at: http://perso.univ-lemans.fr/~jhthomas/28_zhao.pdf (last access: 2 September 2021), 2004.

7.4 Discussion

Les résultats obtenus montrent que les deux modèles de prévision saisonnière ont la capacité de reproduire certaines des caractéristiques principales de la SHL. Par contre, ils ont du mal avec la représentation de l'intensité et l'occurrence des événements tels que les phases Est-Ouest de la SHL en comparaison avec ERA5. La qualité des prévisions par rapport à la réanalyse ERA5 aux échelles de temps saisonnière et intra-saisonnière est discutée. Pour ce faire, nous évaluons la capacité des modèles de prévision saisonnière à reproduire la variabilité inter-annuelle de la SHL en utilisant des moyennes mensuelle et journalière de T850 à partir desquelles le CRPS et la RMSE ont été calculés respectivement [Fig.7.2, Fig.7.3] et [Fig.7.4]. La première échelle d'évaluation est l'échelle saisonnière qui fournit une référence pour les prévisions de la saison des pluies [Fig.7.2-a, f, k], (voir aussi [Fig.7.3a) -a),f),k])). Elle apporte une amélioration limitée mais significative par rapport à la climatologie. Les scores (CRPS, RMSE) sont ensuite décomposés par mois [Fig.7.2- b-e), g-j), l-o)] (voir aussi [Fig.7.3a) - b-e), g-j), l-o))), afin d'étudier la représentation de la variabilité intra-saisonnière de la SHL. Nous avons constaté une augmentation des valeurs de CRPS et RMSE avec l'échéance de prévision sur le domaine CSHL, ce qui entraîne une perte de prédictibilité dans les modèles. SEAS5 montre de meilleures performances sur le domaine CSHL pour les prévisions à court terme (0 à 1 mois) tandis que MF7 est plus adapté pour des échéances plus longues (environ 3 mois). Les prévisions brutes de MF7 montrent des performances très limitées sur le Sahara [Fig.7.3] et [Fig.7.4b)]; ce comportement de MF7 peut être lié à des biais chauds mis en évidence dans la section 3.2 (voir Fig.5 dans l'article). La correction des biais améliore considérablement les capacités prédictives des modèles. L'effet de la correction des biais sur les performances des modèles saisonniers est plus efficace sur le Sahara (voir [Fig.7.3] et [Fig.7.4b)] dans le matériel supplémentaire). Cela peut s'expliquer par le fait que les modèles climatiques prennent généralement en compte la variabilité à grande échelle. Comme le Sahara est plus grand que le domaine SHL central, les modèles de prévision représenteront mieux la variabilité qui se produit sur le Sahara; et la méthode de correction ajustera le biais systématique présent dans les modèles. Les modèles présentent des capacités de prévision plus faibles pour

les valeurs journalières de T850 et une amélioration est observée à l'échelle mensuelle pour les délais courts.

Une évaluation des modèles de prévision saisonnière à l'échelle intra-saisonnière a été réalisée pour les mois de Juin, Juillet, Août et Septembre en calculant le CRPS score à l'aide des prévisions brutes de T850 [Fig.7.5]. Les résultats similaires ont été trouvés avec les prévisions débiaisées. Nous avons observé une augmentation progressive du score CRPS au cours du temps avant d'atteindre l'horizon de prévisibilité autour de 20 jours. SEAS5 montre des performances durant les premiers jours (1-3) jours sur le CSHL et (1-8) jours sur le Sahara; et MF7 est plus affecté par le spin-up au début de la prévision. Ce comportement dans SEAS5 peut être expliqué par la capacité du modèle à représenter la variabilité à grande échelle se produisant sur le Sahara. Bien que les modèles présentent des performances à l'échelle intra-saisonnière, ces performances restent faibles pour des longues échéances au-delà d'un mois. Ces résultats sont en accord avec les travaux antérieurs qui ont été effectués sur l'évaluation des prévisions du système d'ensemble du CEPMMT ([Haiden et al., 2015](#)).

Comme nous l'avons vu précédemment, MF7 et SEAS5 présentent des caractéristiques différentes en termes de biais, en particulier en ce qui concerne la détection des événements HLW (Heat Low West) et HLE (Heat Low East). Cela suggère qu'une approche d'ensemble multi-modèle peut être une solution pour améliorer les capacités de prévision des modèles saisonniers. De manière surprenante, le multi-modèle montre une capacité de prévision comparable à celle des modèles individuels [Fig7.2]. Cela montre que les capacités de prévision d'un modèle d'ensemble ne dépendent pas du nombre de membres dans les modèles.

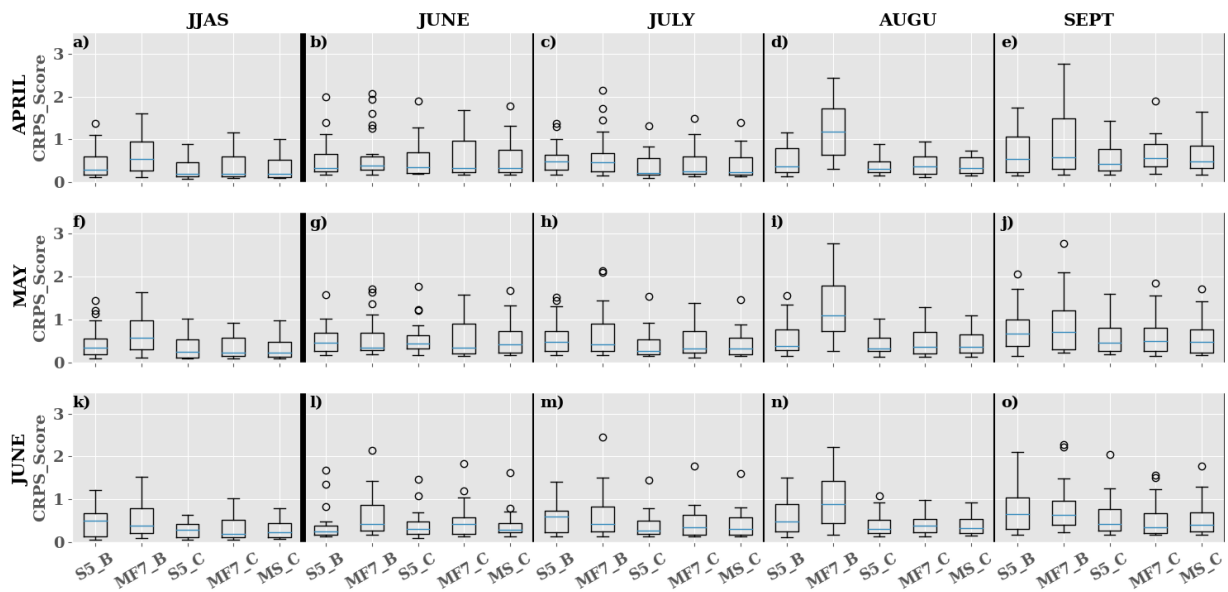


Figure 7.2 – Évaluation de la variabilité inter-annuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août et Septembre de 1993-2016 en utilisant la moyenne mensuelle de T850 sur le domaine SHL central à différents échéances : **a) - e)** Avril, **f) - j)** Mai et **k) - o)** Juin. "S5_B", "S5_C" représentent respectivement le CRPS évalué en utilisant respectivement les prévisions brutes et corrigées de SEAS5 avec la méthode CDF-t. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. "MS_C" représente le CRPS évalué à partir des prévisions du multi-modèle formé par les prévisions corrigées SEAS5 et MF7 avec la méthode CDF-t. Le calcul a été effectué en utilisant le membre de l'ensemble à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs du score CRPS et l'axe des abscisses, les produits utilisés pour le calcul du CRPS.

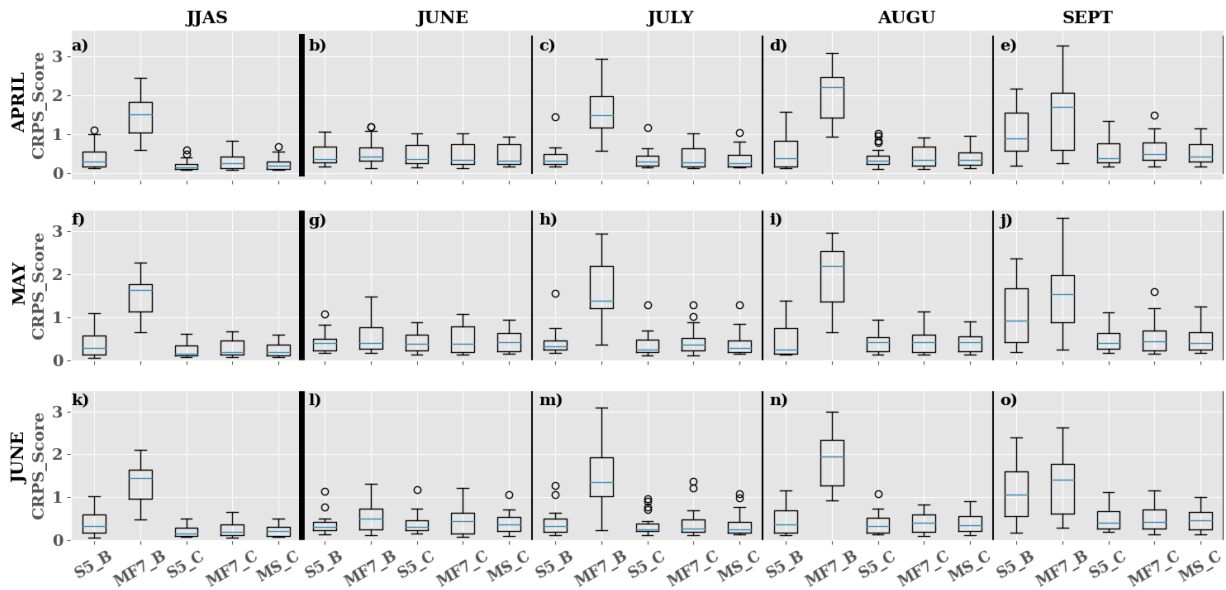


Figure 7.3 – Évaluation de la variabilité inter-annuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août, Septembre de 1993-2016 en utilisant la moyenne mensuelle de T850 sur le Sahara à différents échéances : **a) - e)** Avril, **f) - j)** Mai et **k) - o)** Juin. "S5_B", "SS5_C" représentent respectivement le CRPS évalué en utilisant les prévisions brutes/corrigées de SEAS5 avec la méthode CDF-t. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. "MS_C" représente le CRPS évalué à partir des prévisions du multi-modèle formé par les prévisions corrigées de SEAS5 et MF7 avec la méthode CDF-t. Le calcul a été effectué en utilisant l'ensemble des membres à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs du score CRPS et l'axe des abscisses, les produits utilisés pour le calcul du CRPS.


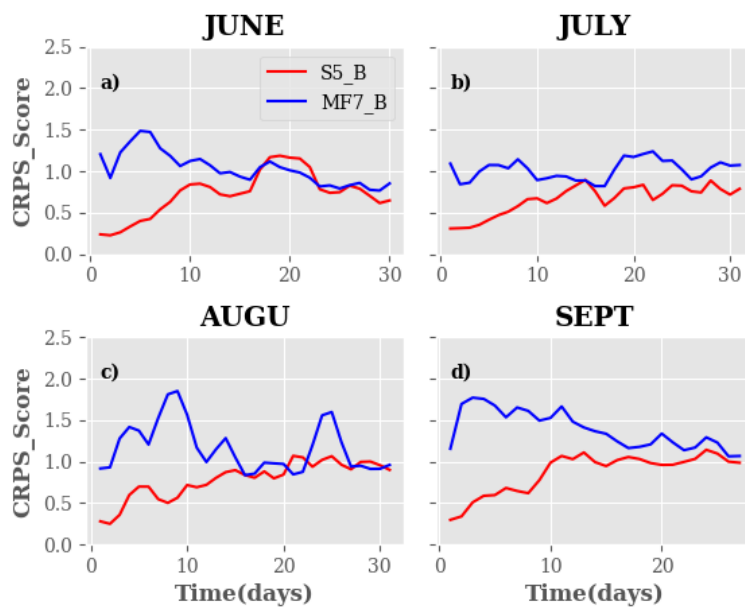
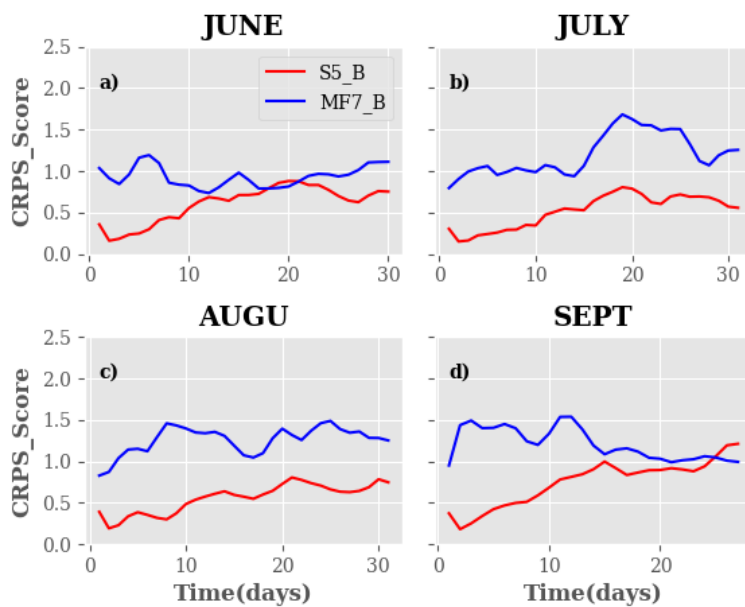


Figure 7.4 – Évaluation de la variabilité interannuelle de la SHL sur la période JJAS et séparément pour les mois de Juin, Juillet, Août, Septembre de 1993-2016 en utilisant T850 journalier sur : a) CSHL et b) le Sahara à différentes échéances : a) - e) Avril, f) - j) Mai et k) - o) Juin. "S5_B"/"SS5_C" représentent respectivement la métrique RMSE évaluée à l'aide des prévisions SEAS5 brutes/corrigées. Idem pour "MF7_B", "MF7_C" avec le modèle MF7. Le calcul a été effectué en utilisant le membre non perturbé à la fois pour les prévisions corrigées et brutes. L'axe des ordonnées indique les valeurs de la RMSE.



a)



b)

Figure 7.5 – Évaluation de la variabilité interannuelle de la SHL dans les modèles de prévision saisonnière (SEAS5, MF7) séparément pour les mois de Juin, Juillet, Août, Septembre au cours de la période 1993-2016 en utilisant le T850 journalier sur : a) CSHL et b) le Sahara. "S5_B" / "MF7_B" représentent respectivement les prévisions brutes SEAS5/MF7. Le calcul a été effectué en utilisant l'ensemble des membres des modèles. L'axe Y indique les valeurs du score CRPS et l'axe X, le temps en jours.

7.5 Conclusion et perspectives

Dans cette partie, il était question d'évaluer la représentation de la SHL dans deux modèles de prévision saisonnière (SEAS5 et MF7) en utilisant la réanalyse ERA5 comme référence. Le choix de ERA5 comme référence pour cette évaluation a été soutenu par une étude de corrélation menée entre ERA5 et une autre donnée de réanalyse, à savoir MERRA. Les deux réanalyses étant fortement corrélées, nous avons décidé de garder ERA5 comme référence pour la suite. L'étude de la variabilité spatiale de la SHL révèle un biais chaud dans MF7 et donc, une surestimation de l'intensité de la SHL par rapport à ERA5. SEAS5 développe un biais froid et tend à sous-estimer l'intensité de la SHL au Sahara. Les modèles sont capables de représenter le cycle saisonnier moyen de la SHL et de capturer certaines caractéristiques de sa variabilité inter-annuelle comme la tendance au réchauffement observée durant les années 2010. Cependant, la bonne représentation de cette variabilité inter-annuelle reste un véritable défi pour les modèles. SEAS5 représente de manière plus réaliste la tendance climatique de la SHL que MF7. Les méthodes de correction de biais CDF-t et QMAP sont très efficaces pour réduire le biais systématique présent dans les modèles saisonniers. En utilisant les outils de correction de biais, les résultats mettent en évidence la capacité des modèles à représenter les pulsations intra-saisonnières (les phases Est-Ouest) de la SHL. On note une surestimation de l'occurrence des phases HLE dans les modèles (SEAS5/MF7); les phases HLW sont beaucoup mieux représentées dans MF7. Ce diagnostic est une première validation de la représentation de la SHL dans les modèles saisonniers. Les modèles de prévision saisonnière montrent des performances à l'échelle intra-saisonnière pour une courte période. La correction des biais contribue à améliorer le score de la prévision d'ensemble (CRPS), mais les performances des modèles restent faibles pour une échéance supérieure à un mois. La représentation cohérente de la temporalité des pulsations de la SHL ne peut pas être résolue par une approche de correction de biais, seules des améliorations du modèle pourraient fournir de meilleures corrélations entre les prévisions et les observations.

Dans une étude future, il sera intéressant d'approfondir l'investigation sur les origines des biais observés dans les modèles concernant la représentation de l'activité de la SHL dans la région

du Sahara. Une autre analyse importante à réaliser serait l'étude de l'évolution de l'activité de la SHL au cours des années pour lesquelles une fréquence élevée de vagues de chaleur a été identifiée dans l'étude précédente (cf **Chapitre3**). Cela permettrait une meilleure compréhension du rôle de la SHL sur les vagues de chaleur dans la région de l'Afrique de l'Ouest.

Chapitre 8

Conclusions et perspectives

8.1 Conclusions

Ce projet de thèse s'inscrit dans le cadre du projet ANR STEWARD visant à développer des modèles d'alerte précoce multi-aléas dans les grandes villes ouest-Africaines, plus particulièrement dans le work package 2 et apporte la contribution de la partie vagues de chaleur au projet. Les études sur la partie précipitations ont été réalisées par les travaux de (Fall et al., 2021). Le présent travail est organisé autour de deux objectifs :

- le suivi des vagues de chaleur dans les grandes villes ouest-Africaines;
- la prédictibilité de ces dernières dans les modèles de prévision étendue.

La première partie de ce travail a été consacrée au monitoring des vagues de chaleur dans les villes ouest-Africaines. Ceci nous a amené tour à tour à investiguer les sources d'incertitudes rencontrées dans le processus de détection d'une vague de chaleur, analyser l'évolution de la fréquence et des caractéristiques de ces dernières sur la période 1993-2020. Face à la faible couverture spatiale des données d'observation dans la région, deux produits de réanalyse à l'état de l'art ont été utilisés à savoir : ERA5 et MERRA. À travers une méthode d'interpolation développée dans le cadre de ce travail, les variables météorologiques nécessaires à la caractérisation des vagues de chaleur dans les grandes villes d'Afrique de l'Ouest des trois régions représenta-

tives (Golfe de Guinée -GU, Atlantique -ATL et Continentale -CONT), ont pu être estimées à partir des données de réanalyse. La première source d'incertitude mise en évidence dans cette étude provient des données de réanalyse elles-mêmes. La deuxième source d'incertitude repose sur le choix du seuil utilisé pour la définition de la vague de chaleur. La méthodologie utilisée pour la détection de la vague de chaleur constitue la troisième source d'incertitude. Quatre indicateurs ont été utilisés : AT , T_{2m} , $UTCI$ et T_w dérivés à partir de la température à 2-m, le vent à 10-m, l'humidité relative et/ou une combinaison des 3 variables. Les vagues de chaleur nocturnes associées à T_w sont plus fréquentes que celles détectées avec AT , T_{2m} , $UTCI$. Ceci montre que l'humidité joue un rôle important dans l'occurrence des vagues de chaleur nocturnes, augmentant ainsi le nombre d'événements concomitants (jour et nuit consécutivement) sur le nord du Sahel. Ce résultat est en accord avec [Largeron et al. \(2020\)](#) qui ont mis en évidence le rôle de la vapeur d'eau sur les vagues de chaleur nocturnes au Sahel. La région GU est plus touchée par les vagues de chaleur au cours de la dernière décennie (2012-2020) que les régions CONT et ATL. Toutefois, les vagues de chaleur les plus persistantes et les plus intenses se produisent dans la région CONT. Un renforcement de la fréquence, de la durée et de l'intensité des vagues de chaleur est observé durant la dernière décennie (2012-2020). Il s'agirait d'une conséquence du réchauffement climatique sur les événements extrêmes. La variabilité inter-annuelle des vagues de chaleur dans les différentes régions a mis en évidence pour les 3 indicateurs (AT , T_{2m} , T_w) des années particulièrement chaudes avec une fréquence élevée d'événements : 1998, 2005, 2010, 2016, 2019 et 2020. Ces années correspondent pour la plupart aux années dites "El Niño". L'analyse de la variabilité inter-annuelle de la SST a mis en évidence un réchauffement de l'océan Atlantique tropical durant ces années, à l'exception des années 2016 et 2019 respectivement dans les régions GU et ATL.

Dans la deuxième partie de travail, nous nous sommes intéressés à l'aspect prédictibilité des vagues de chaleur. Une première étude de la prédictibilité des vagues de chaleur dans les modèles de prévision intra-saisonnière à saisonnière (CEPMMT, UKMO) a été conduite sur la période 2001-2020. Les modèles de prévision présentent de meilleures performances par rapport à une climatologie de référence, principalement pour les prévisions à court terme (deux semaines à

l'avance) dans les trois régions d'intérêt. Toutefois, les valeurs du hit-rate sont en moyenne inférieures à 50%, ce qui indique des événements manqués dans les prévisions. Les vagues de chaleur nocturnes sont plus prévisibles que les vagues de chaleur diurnes. Ce résultat est en accord avec l'étude de [Guigma et al. \(2021b\)](#). Seulement 15 à 30 % des jours de vague de chaleur prédits sont effectivement observés, respectivement pour les semaines 5 et 2. Cela suggère que les modèles surestiment la durée des vagues de chaleur par rapport à la réanalyse ERA5. Le modèle du CEPMMT émet moins de fausses alertes que UKMO pour les prévisions à court terme. La prévision des vagues de chaleur sèche est meilleure avec le modèle du CEPMMT pour les prévisions à moyen terme (semaine 2), tandis que pour les prévisions à long terme (semaine 5), UKMO l'emporte sur le modèle du CEPMMT. Cela suggère que le modèle du CEPMMT réalise une meilleure représentation de T2m sur du court terme tandis qu'avec UKMO, une meilleure représentation est observée sur des échéances plus longues. En ce qui concerne les vagues de chaleur humide, UKMO est plus performant que le modèle du CEPMMT pour les prévisions à court et à long terme. Ainsi donc l'humidité est mieux représentée dans UKMO par rapport au modèle du CEPMMT. Bien que les modèles démontrent des performances en matière de détection des vagues de chaleur par rapport à une climatologie de référence, leur capacité à prédire l'intensité des événements reste faible même pour les courtes échéances (semaine 2). De fait, la prévision de l'intensité des vagues de chaleur reste une tâche difficile pour les modèles de prévision numérique.

Une seconde étude cette fois préliminaire a été effectuée sur la prédictibilité des vagues de chaleur à partir des méthodes d'apprentissage automatique. Les résultats obtenus à partir de la prévision des vagues de chaleur par approche directe en utilisant les modèles de prévision intra-saisonnière montrent des performances de ces derniers limités à deux semaines d'échéance. A cet effet, nous avons exploré le potentiel des méthodes d'apprentissage en vue d'optimiser les performances des modèles de prévision intra-saisonnière. Les méthodes d'apprentissage ont été utilisées comme outils de débiaisage pour les prévisions des modèles. Les prévisions des modèles d'apprentissage sont évaluées par rapport à la réanalyse ERA5 choisie comme référence sur la base des études antérieures. Trois modèles d'apprentissage ont été analysés à savoir :

RF+SMOTE, SVM et BRF. Dans un premier temps, nous avons procédé à une inter-comparaison des différentes méthodes d'apprentissage automatique en utilisant comme métrique d'évaluation le F1-score sur la période de test (2003,2008,2012,2019). Le F1-score est calculé entre les prévisions réalisées par chacun de ces algorithmes et ERA5. Les valeurs du F1-score sont très faibles autour de 20% en moyenne spatiale sur les différentes régions pour les deux premières semaines. Ces faibles valeurs de F1-score mettent en évidence des erreurs de prévision dans les différentes méthodes. Ainsi pour un événement correctement prédit, les modèles d'apprentissage réalisent 8 fausses prédictions pouvant être soit des fausses alertes soit des événements manqués, ce qui reste quand même assez important. Toutefois, la méthode BRF présente de meilleures performances par rapport aux deux autres (SVM et RF+SMOTE). Par la suite, les prévisions réalisées à partir de la méthode BRF sont comparées à celles des modèles de prévision intra-saisonnière en utilisant des métriques statistiques telles que le hit-rate, GSS et FAR. Le modèle BRF présente de meilleures performances dans la détection des vagues de chaleur par rapport aux modèles de prévision intra-saisonnière dans les trois régions. Si le modèle BRF améliore considérablement la détection des vagues de chaleur dans les modèles de prévision avec des valeurs de hit-rate autour de 50% contre 15%, en contrepartie, il génère un taux élevé de fausses alertes, autour de 85% pour les courtes échéances jusqu'à deux semaines et 90% au-delà.

Une troisième étude de la prédictibilité des vagues de chaleur par méthode de prédicteurs de grande échelle tel que la dépression thermique Saharienne (SHL) à l'échelle saisonnière a été analysée. La prévisibilité des vagues de chaleur à partir de la SHL passe par deux étapes : l'investigation du lien entre la SHL et les vagues de chaleur, et l'évaluation des performances des modèles saisonniers à prédire la SHL par rapport aux vagues de chaleur. La présente étude a consisté à évaluer la représentation et la prévisibilité d'une des grandes composantes atmosphériques de la mousson Ouest-Africaine dans les modèles de prévision saisonnière. Ceci constitue une étude préliminaire dans le but de déterminer le potentiel de la SHL à améliorer la prévisibilité des vagues de chaleur à l'échelle saisonnière. Deux modèles de prévision saisonnière (SEAS5 et MF7) ont été utilisés. La variabilité spatiale de la SHL révèle un biais chaud dans MF7 et donc, une surestimation de l'intensité de la SHL par rapport à ERA5. SEAS5 développe un biais froid et

tend à sous-estimer l'intensité de la SHL au Sahara. Les modèles sont capables de représenter le cycle saisonnier moyen de la SHL et de capturer certaines caractéristiques de sa variabilité inter-annuelle comme la tendance au réchauffement observée durant les années 2010. SEAS5 représente de manière plus réaliste la tendance climatique de la SHL que MF7. En utilisant les outils de correction de biais, les résultats mettent en évidence la capacité des modèles à représenter les pulsations intra-saisonnières, notamment les phases dites 'Est' ou 'Ouest' de la SHL entre lesquelles cette dernière oscille lors de l'été austral, et qui pourraient avoir des impacts locaux importants dans la région du Sahel. La bonne prévision de ces phases est importante car celles-ci conditionnent en partie les précipitations sur différentes parties du Sahel. On note une surestimation de l'occurrence des phases dites 'Est' de la SHL dans les modèles (SEAS5/MF7); les phases dites 'Ouest' sont beaucoup mieux représentées dans MF7. Les modèles de prévision saisonnière montrent des performances à l'échelle intra-saisonnière pour une courte période. La correction des biais contribue à améliorer le score de la prévision d'ensemble (CRPS), mais les performances des modèles restent faibles pour une échéance supérieure à un mois.

8.2 Perspectives

Bien que les résultats obtenus dans le cadre de ce travail ont fait l'objet de publications dans les journaux scientifiques, plusieurs pistes restent encore à explorer dans la continuité de ce travail.

Les données utilisées comme référence pour le suivi et l'évaluation des vagues de chaleur dans les modèles de prévision sont des données de réanalyse de grande échelle. En utilisant une méthode d'interpolation basée sur le point de grille de la réanalyse le plus proche de la station météorologique avec un $LSM \geq 0.5$ développée dans le cadre de la thèse, les données de température à l'échelle locale ont pu être estimées. Cette méthode d'interpolation pourrait être améliorée afin d'obtenir des données interpolées présentant de meilleures corrélations avec les données stations. L'on pourrait penser par exemple à intégrer plus d'indicateurs de la dynamique atmosphérique dans cette approche. En prenant en compte la dynamique, l'on pourrait améliorer la représentation des processus influençant la température à l'échelle locale. Ceci reste une question ouverte qui fera l'objet de futures études.

Le monitoring des vagues de chaleur dans les villes ouest-Africaines a permis d'identifier des années avec des fréquences élevées en terme d'événements associées de caractéristiques (durée, intensité) aussi importantes dans les trois régions à savoir : 1998, 2005, 2010, 2016, 2019 et 2020. Ces années sont associées pour la plupart aux événements El Nio intenses notamment 1998, 2010, 2016 et 2019. L'analyse du lien entre les jours de vagues de chaleur et le phénomène El Nio à travers la SST a permis de mettre en évidence deux années de pics de vagues de chaleur 2016 et 2019 respectivement en régions GU et ATL associées à un refroidissement de l'océan atlantique tropical. Il convient donc de s'intéresser aux processus à l'origine des pics de vague de chaleur en région côtière durant les phases de refroidissement de l'océan Atlantique tropical. Des questions restent encore en suspens sur l'origine de ces événements : seraient-ils engendrés par des processus locaux? processus de grande échelle, atmosphériques seulement?

La prévisibilité des vagues de chaleur a été réalisée par méthode directe en utilisant les mo-

dèles de prévision intra-saisonnière dans un premier temps. Dans le but, d'optimiser les performances des modèles de prévision, les méthodes d'apprentissage automatique ont été utilisées comme outils de correction de biais des prévisions provenant des modèles. Les méthodes d'apprentissage améliorent considérablement la détection des vagues de chaleur dans les modèles de prévision mais réalisent beaucoup de fausses alertes même pour des courtes échéances. Les modèles d'apprentissage automatique ayant été entraînés uniquement en utilisant la température à 2m comme prédicteur, l'on pourrait penser à rajouter d'autres prédicteurs de grande échelle pour les vagues de chaleur telles que l'anomalie de géopotential à 500hPa (Z500), l'humidité relative à la surface et le vent à 10m (Asadollah et al., 2021). Ceci pourrait apporter plus d'informations aux modèles d'apprentissage et réduire les fausses alertes observées dans ces derniers. L'on pourrait également explorer le potentiel des méthodes basées sur des analogues pour la prévisibilité des vagues de chaleur en utilisant des champs de température, géopotential, pression et l'humidité relative. La prévisibilité des vagues de chaleur à partir des prédicteurs de grande échelle a également été abordée dans ce travail mais dans un contexte exploratoire. Dans une étude future, il serait important d'étudier le lien entre l'évolution des prédicteurs de grande échelle des vagues de chaleur (SHL, MJO) au cours des années pour lesquelles une fréquence élevée de vagues de chaleur a été observée dans l'étude précédente (cf **Chapitre 3**). Cela permettrait une meilleure compréhension du rôle de ces prédicteurs sur les vagues de chaleur dans la région de l'Afrique de l'Ouest.

Ce projet de thèse s'inscrivant dans le cadre du projet STEWARD qui vise à développer un système d'alertes précoces multi-aléas, il serait nécessaire d'étudier les impacts sur la santé et les activités humaines des différents types de vagues de chaleur détectées pour déterminer les plus dangereuses pour l'Homme et son environnement. Une analyse aussi importante serait d'étudier l'occurrence des événements concomitants dans la région, par exemple des épisodes de sécheresse qui déclencheront des vagues de chaleur, conduisant à leur tour aux feux de forêt ("**règle des trois 30**" : Lorsque le taux d'humidité dans l'air est inférieur à 30%, la température est supérieure à 30 °C et que la vitesse du vent dépasse 30 km/h en moyenne, une simple étincelle en incendie massif) entraînant ainsi la dégradation de la qualité de l'air.

Annexe A

Monitoring des vagues de chaleur dans les villes ouest-Africaines

Supplement of Nat. Hazards Earth Syst. Sci., 23, 1313–1333, 2023
<https://doi.org/10.5194/nhess-23-1313-2023-supplement>
© Author(s) 2023. CC BY 4.0 License.



Natural Hazards
and Earth System
Sciences Open Access 

Supplement of

Heat wave monitoring over West African cities: uncertainties, characterization and recent trends

Cedric Gacial Ngoungue Langue et al.

Correspondence to: Cedric Gacial Ngoungue Langue (cedric-gacial.ngoungue-langue@latmos.ipsl.fr)

The copyright of individual parts of the supplement might differ from the article licence.




Figure S1. Evaluation of the coherence in terms of heat wave frequency in the cities belonging to the ATL region over the period 1993-2020. The color legend represents the different cities. The X- and Y-axes represent the time in month, heat wave duration and intensity respectively.

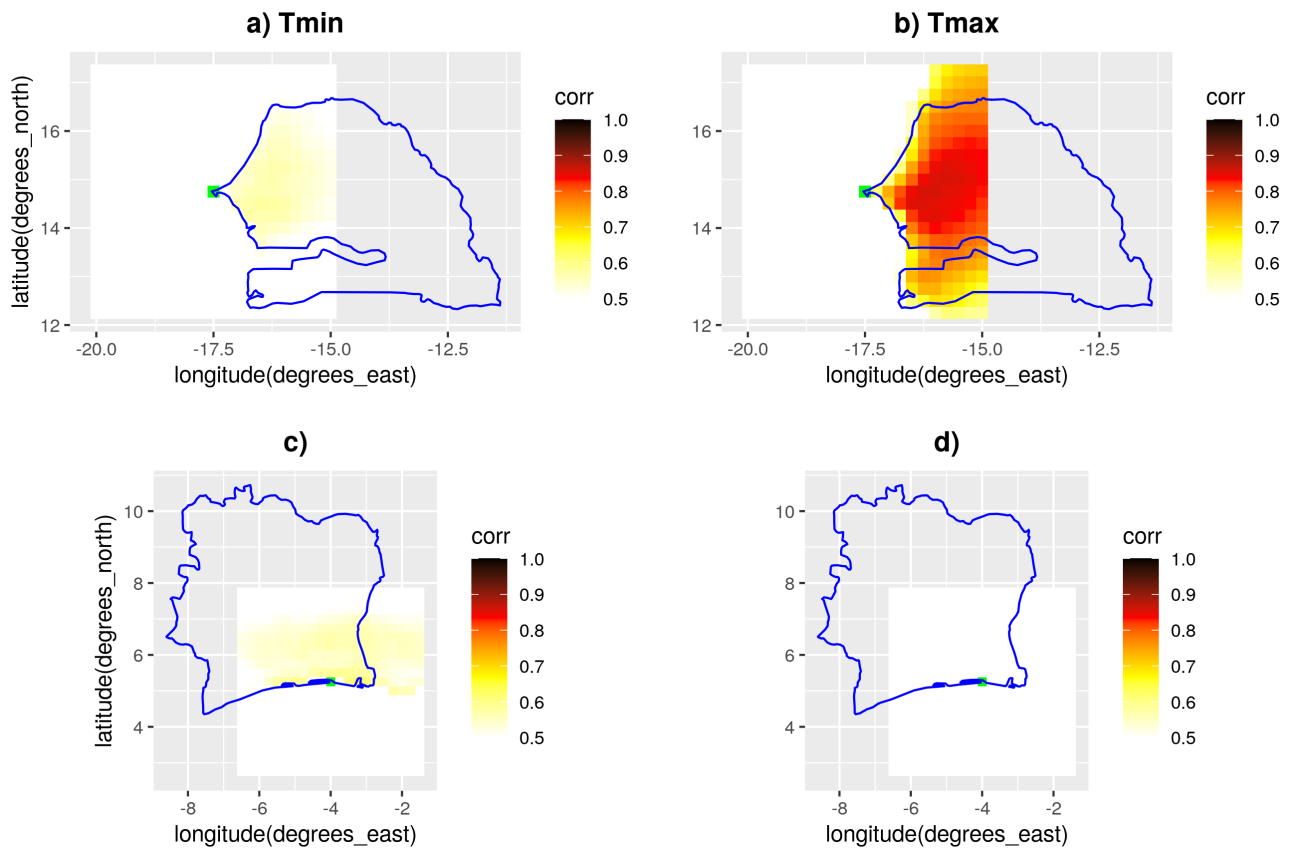


Figure S2. Analysis of the spatial variability of T2m in ERA5 reanalysis and the local station data. This is done by the computation of the anomaly of correlation coefficient between the station data and ERA5 reanalysis over Dakar: **a)** Tmin and **b)** Tmax and Abidjan : **c)** Tmin and **d)** Tmax. X- and Y- axis represent the longitude and latitude in degree respectively. The color bar shows the values of the correlation. The stations used for this analysis are located at Yoff in Senegal and Felix Houphouet Boigny airport in Ivory coast.

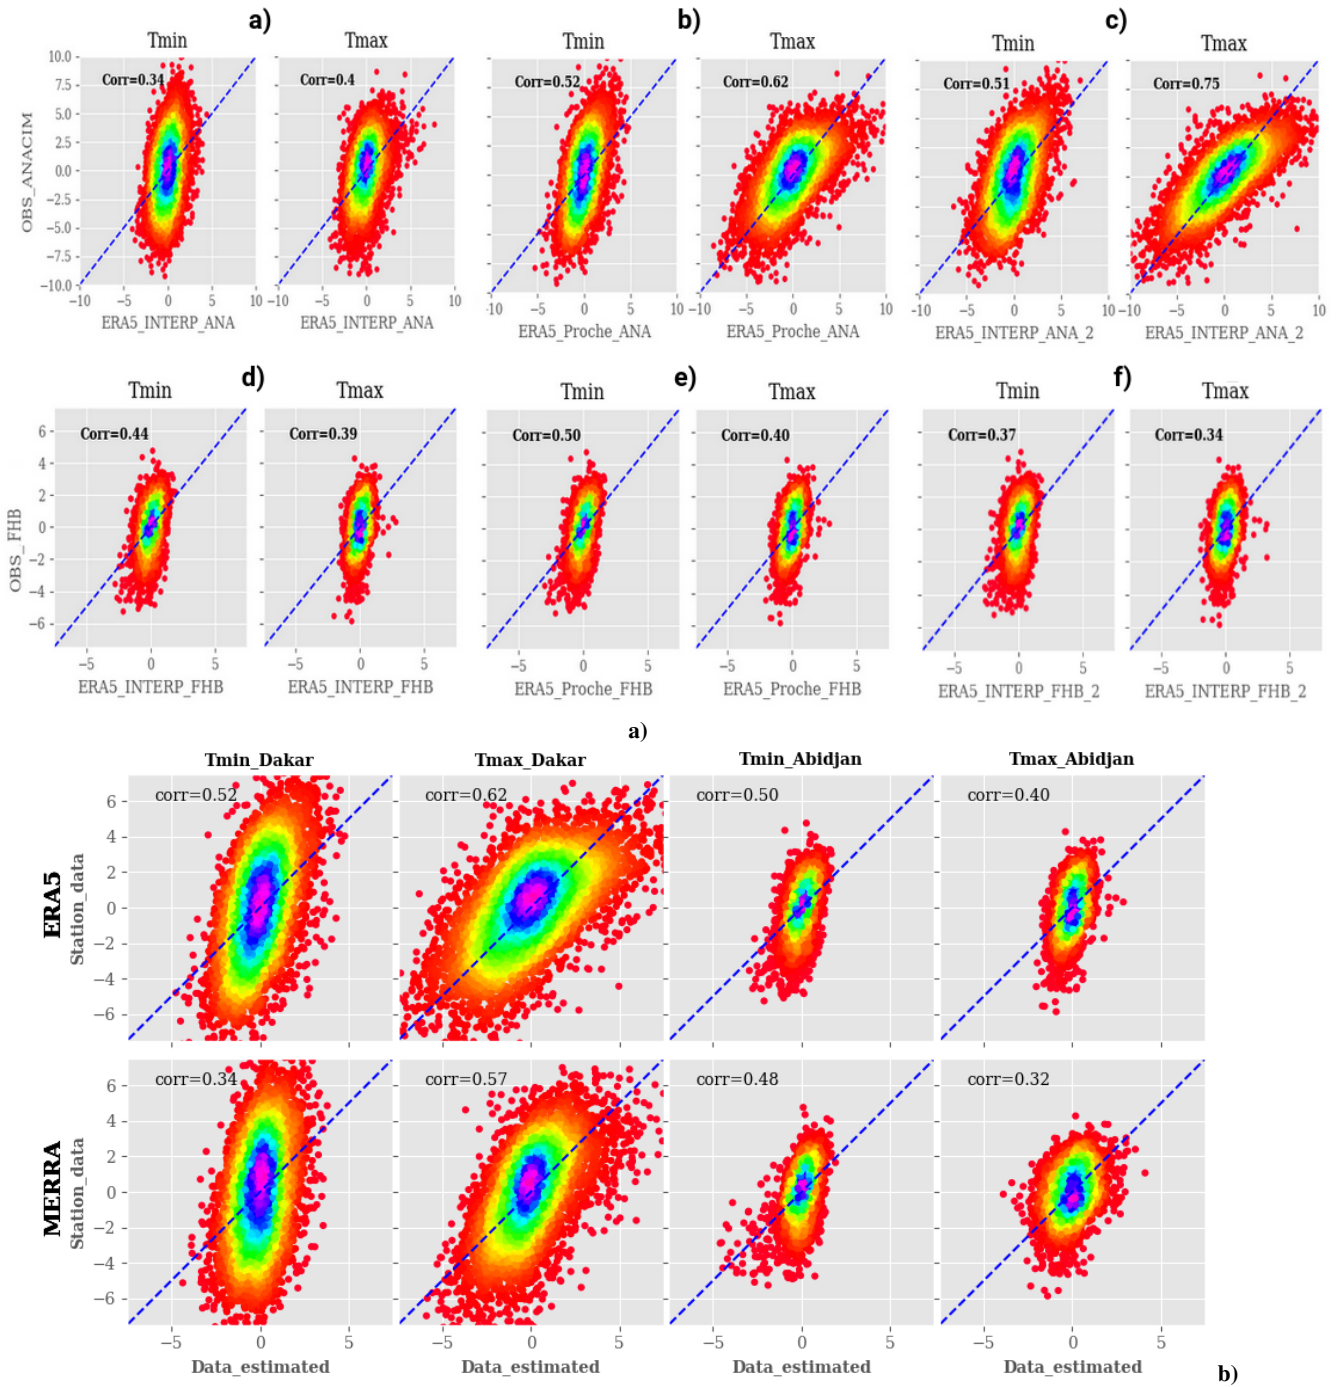


Figure S3. a) Evaluation of different interpolation techniques for the estimation of T2m at the scale of cities from ERA5 reanalysis for: **a-c)** Dakar-Yoff station and **d-f)** Aéroport FHB station. The 1st, 2nd, 3rd columns show the results obtained with the bilinear interpolation method (a,d), nearest neighbour method with $lsm \geq 0.5$ (b,e) and the linear gradient approach with a $lsm \geq 0.5$ (c,f) respectively. **b)** Evaluation of the coherence between reanalyses (ERA5, MERRA) and the local station data using the best interpolation method found previously. The blue dashed line represents the identity line which means perfect correlation between the two products. The X- and Y-axis represent the estimated T2m from ERA5 and MERRA and local T2m from the stations respectively.

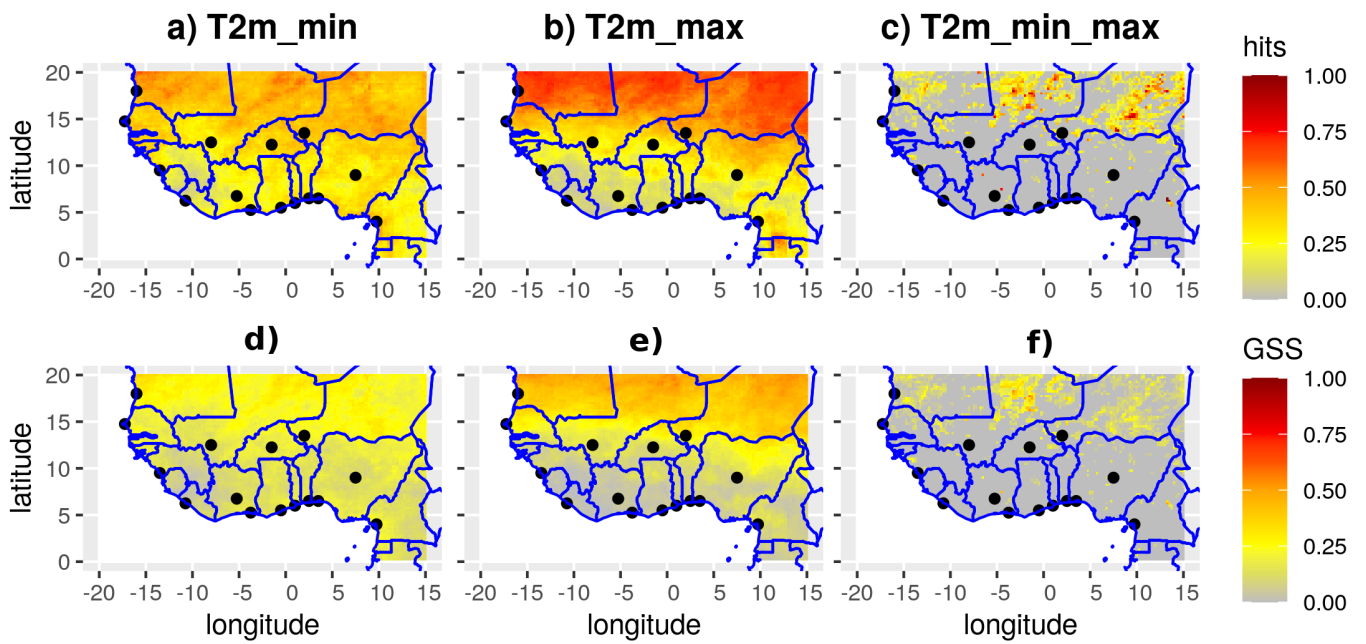


Figure S4. Evaluation of the consistency of reanalyses (ERA5, MERRA) on the representation of hot days in West African regions: The first/second row represents the hits rate (a-c) / Gilbert score (d-f). X- and Y-axis represent the longitude and latitude in degrees respectively. The color bar shows the values of the metrics. The threshold used for the computation of hot days is the climatological daily 90th percentile. Hot days are therefore defined as days above the threshold.

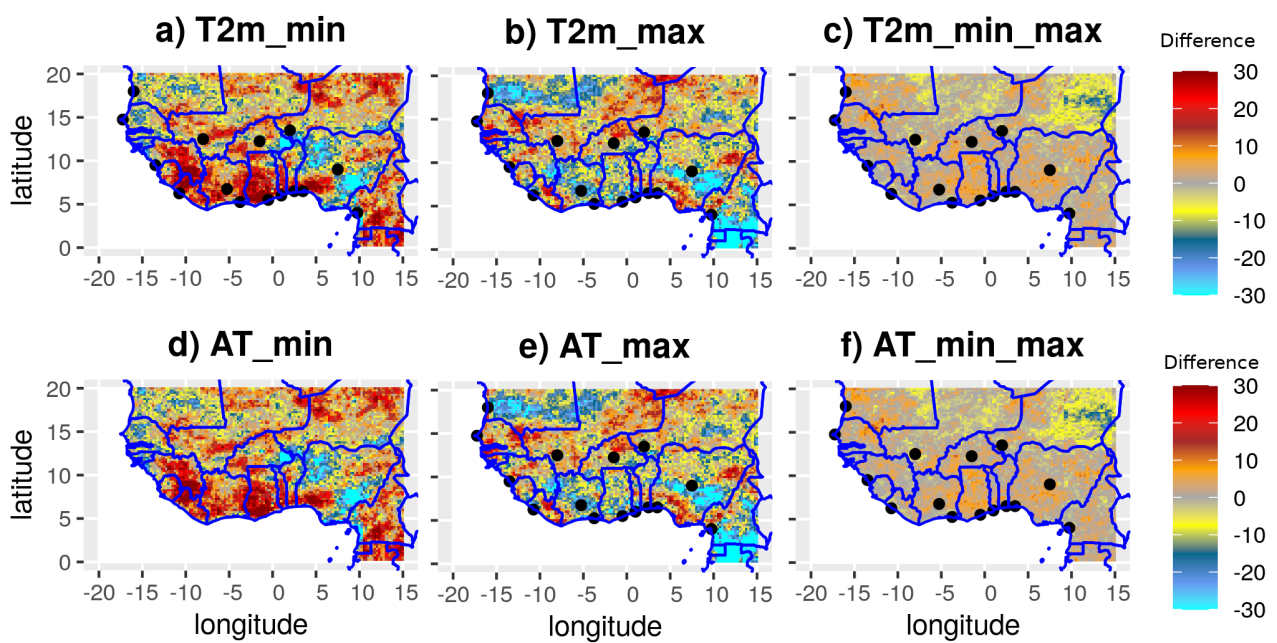


Figure S5. Evaluation of the uncertainties of the reanalyses (ERA5, MERRA) in terms of heat waves frequency. The uncertainty is defined as the difference between the heat wave frequency in ERA5 and MERRA. The X- and Y-axis represent the longitude and latitude in degree respectively. The threshold used for the computation of hot days is the climatological daily 90th percentile.

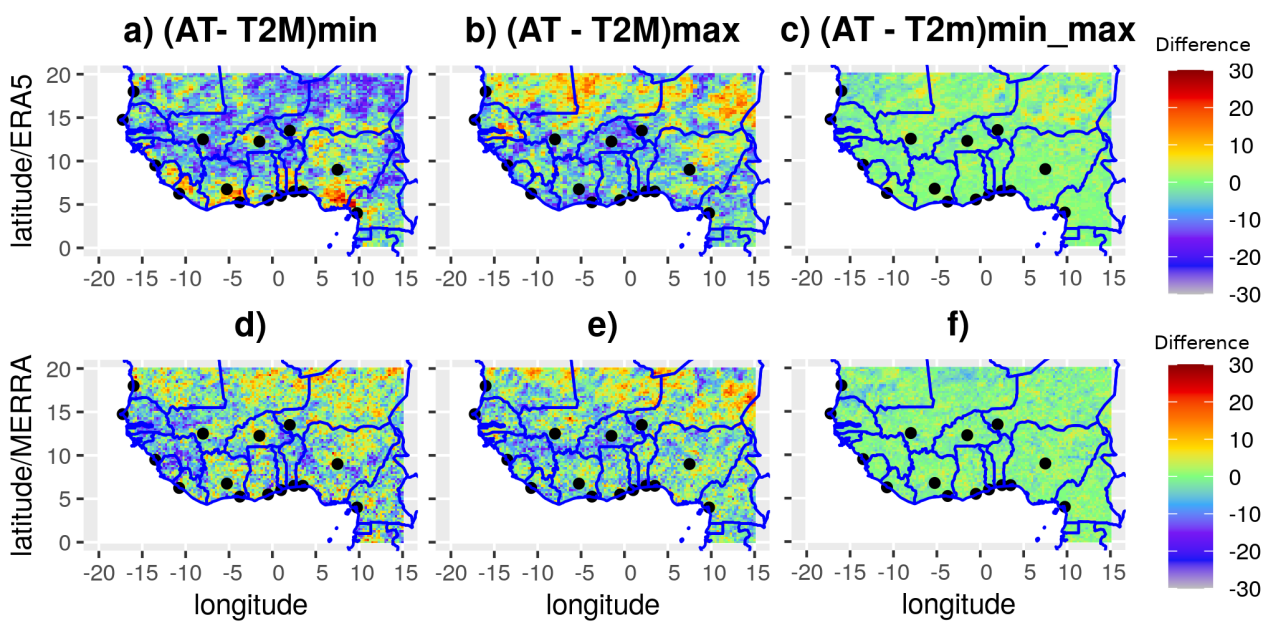


Figure S6. Evaluation of the uncertainties in terms of heat waves frequency between AT and T2m using min/max/min-max values: **a-c)** ERA5 and **d-f)** MERRA respectively. X- and Y-axis represent the longitude and latitude in degrees respectively. The color bar shows the difference of heat wave frequency. The threshold used for the computation of hot days is the climatological daily 90th percentile.

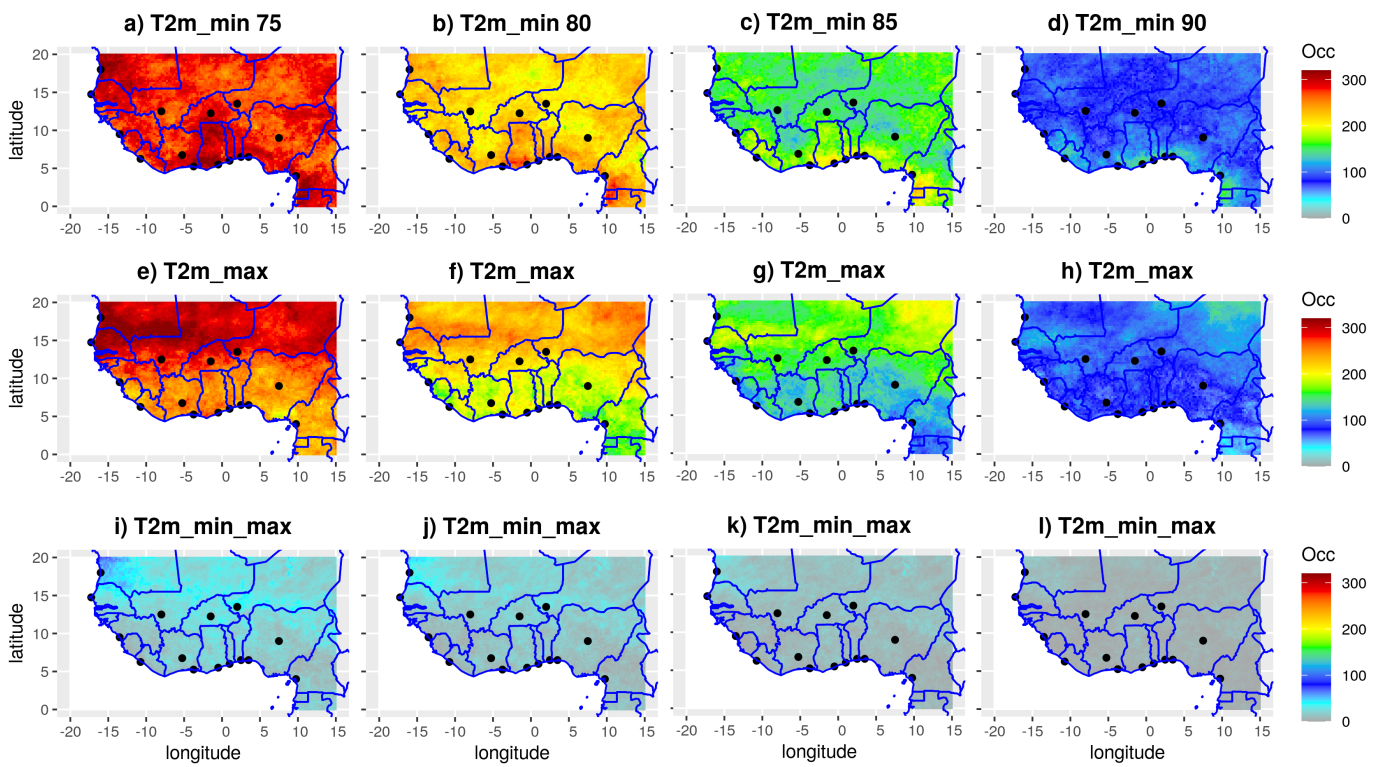


Figure S7. Spatial variability of heat waves frequency with respect to the threshold values using T2m as indicator and ERA5 reanalysis for : **a,e,i** 75th, **b,f,j** 80th, **c,g,k** 85th and **d,h,l** 90th respectively. X- and Y- axis represent the longitude and latitude in degrees respectively. The color bar shows the values of the frequency of heat waves. "Occ" stands for heat waves occurrence or frequency.

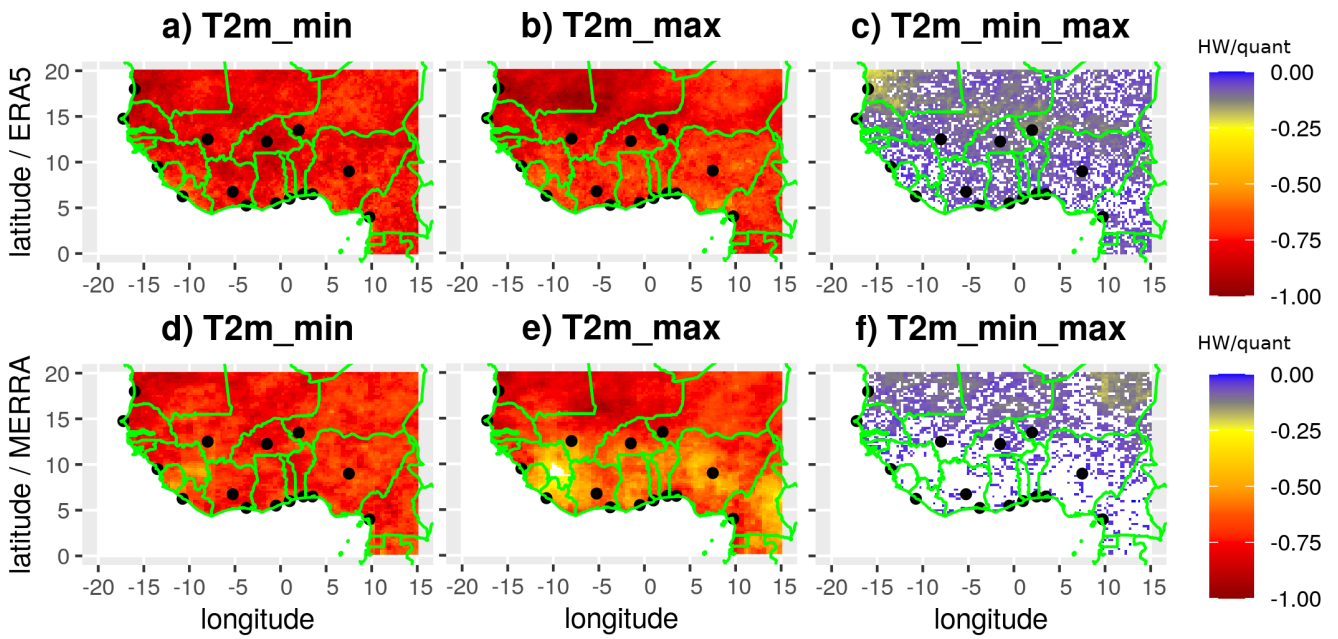


Figure S8. Evolution of the heat waves frequency with respect to the threshold values using T2m as indicator for : **a-c)** ERA5 and **d-f)** MERRA respectively. The figure shows the slope of the regression line in number of events per percentile which is computed by fitting a linear regression between the threshold values (Q_{75} , Q_{80} , Q_{85} , Q_{90}) and their corresponding heat waves frequency (N_{75} , N_{80} , N_{85} , N_{90}). X- and Y- axis represent the longitude and latitude in degrees respectively. The color bar shows the values of the slope. The white blanks indicate non significant changes in the heat waves frequency per percentile. The significance of the slope of the regression line has been computed using a two-sided Chi-square test.

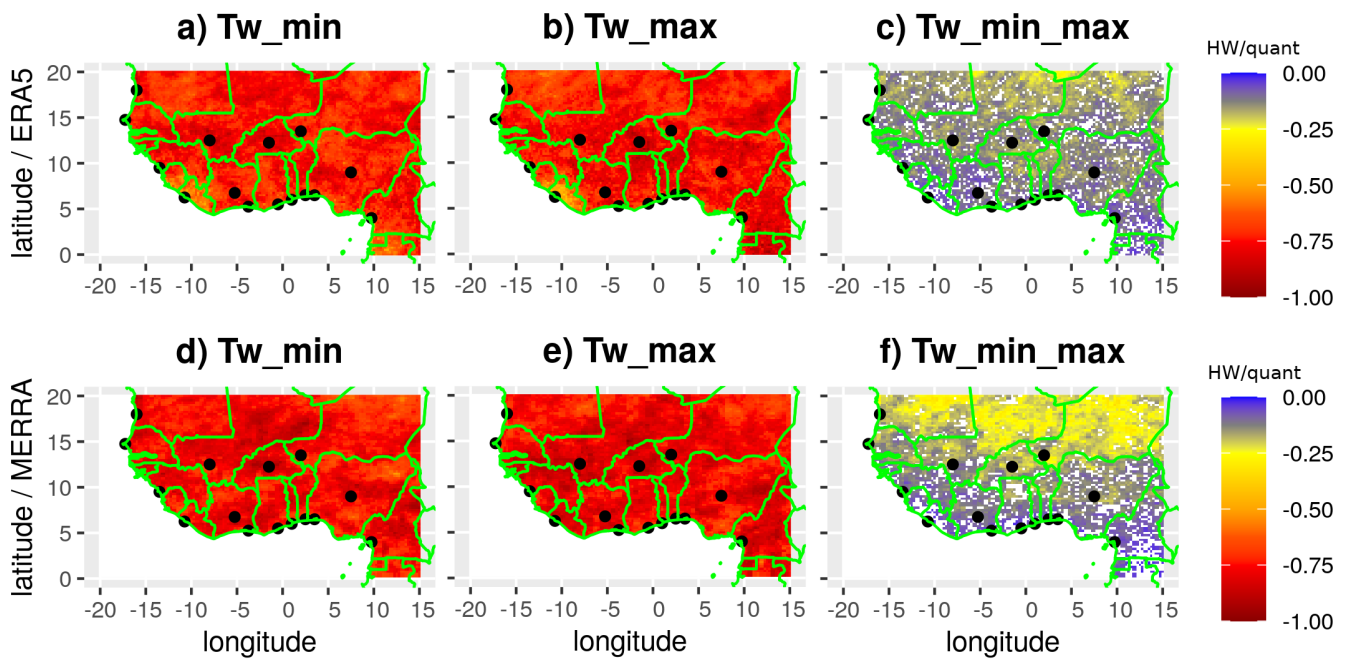


Figure S9. Evolution of the heat waves frequency with respect to the threshold values using Tw as indicator for : **a-c)** ERA5 and **d-f)** MERRA respectively. The figure shows the slope of the regression line in number of events per percentile which is computed by fitting a linear regression between the threshold values ($Q75, Q80, Q85, Q90$) and their corresponding heat waves frequency ($N_{75}, N_{80}, N_{85}, N_{90}$). X- and Y- axis represent the longitude and latitude in degrees respectively. The color bar shows the values of the slope. The white blanks indicate non significant changes in the heat waves frequency per percentile. The significance of the slope of the regression line has been computed using a two-sided Chi-square test.




Figure S10. Sensitivity analysis of heat waves characteristics to the datasets, indicators and methodology used in the ATL region. The characteristics investigated here are the duration and intensity. The circles and stars in the figure represent ERA5 and MERRA reanalyses respectively. The blue/red color represents minimum/maximum values of the indicators. "T2m_{max}" from ERA5 is the reference variable used for this analysis. The Y- and X- axis show the standardized variation of intensity and duration from the reference (no unit) respectively. The variation of duration and intensity have been computed using max daily T2m in ERA5 as reference. The detection of heat waves is done using the climatological daily 90th percentile over the period as threshold.




Figure S11. Sensitivity analysis of heat waves characteristics to the datasets, indicators and methodology used in the GU region. The characteristics investigated here are the duration and intensity. The circles and stars in the figure represent ERA5 and MERRA reanalyses respectively. The blue/red color represents minimum/maximum values of the indicators. "T2m_{max}" from ERA5 is the reference variable used for this analysis. The Y- and X- axis show the standardized variation of intensity and duration from the reference (no unit) respectively. The variation of duration and intensity have been computed using max daily T2m in ERA5 as reference. The detection of heat waves is done using the climatological daily 90th percentile over the period as threshold.




Figure S12. Interannual variability of heat waves frequency using reanalyses (ERA5, MERRA) and maximum values of the indicators $T2m$, Tw and AT over the period 1993-2020. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions : **a)** CONT, **b)** ATL, **c)** GU. The Red/blue/green strong and dashed lines represent the evolution of heat waves frequency using $T2m$, Tw , AT from ERA5 and MERRA respectively. The Y- and X- axis represent the frequency of heat waves and the time in year respectively.

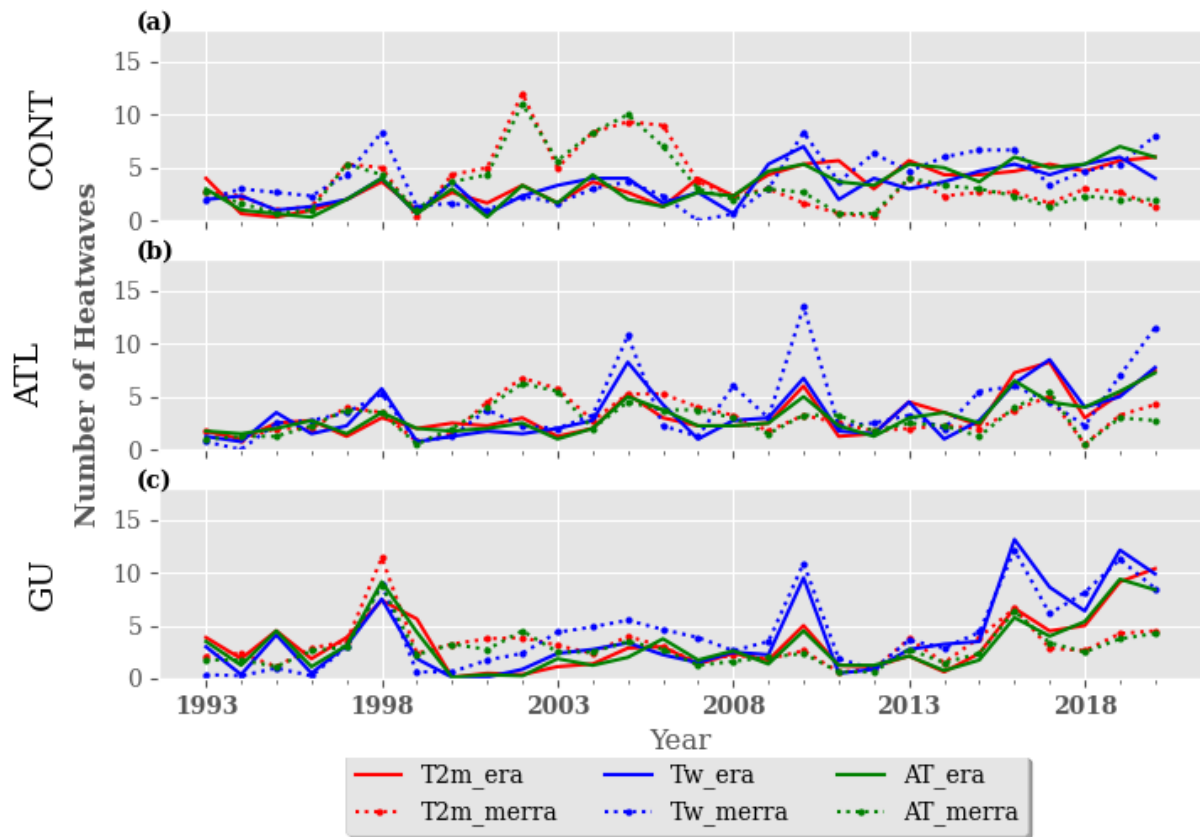


Figure S13. Interannual variability of heat waves frequency using reanalyses (ERA5, MERRA) and minimum values of the indicators $T2m$, Tw and AT over the period 1993-2020. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions : **a)** CONT, **b)** ATL, **c)** GU. The Red/blue/green strong and dashed lines represent the results using $T2m$, Tw , AT from ERA5 and MERRA respectively. The Y- and X- axis represent the frequency of heat waves and the time in year respectively.

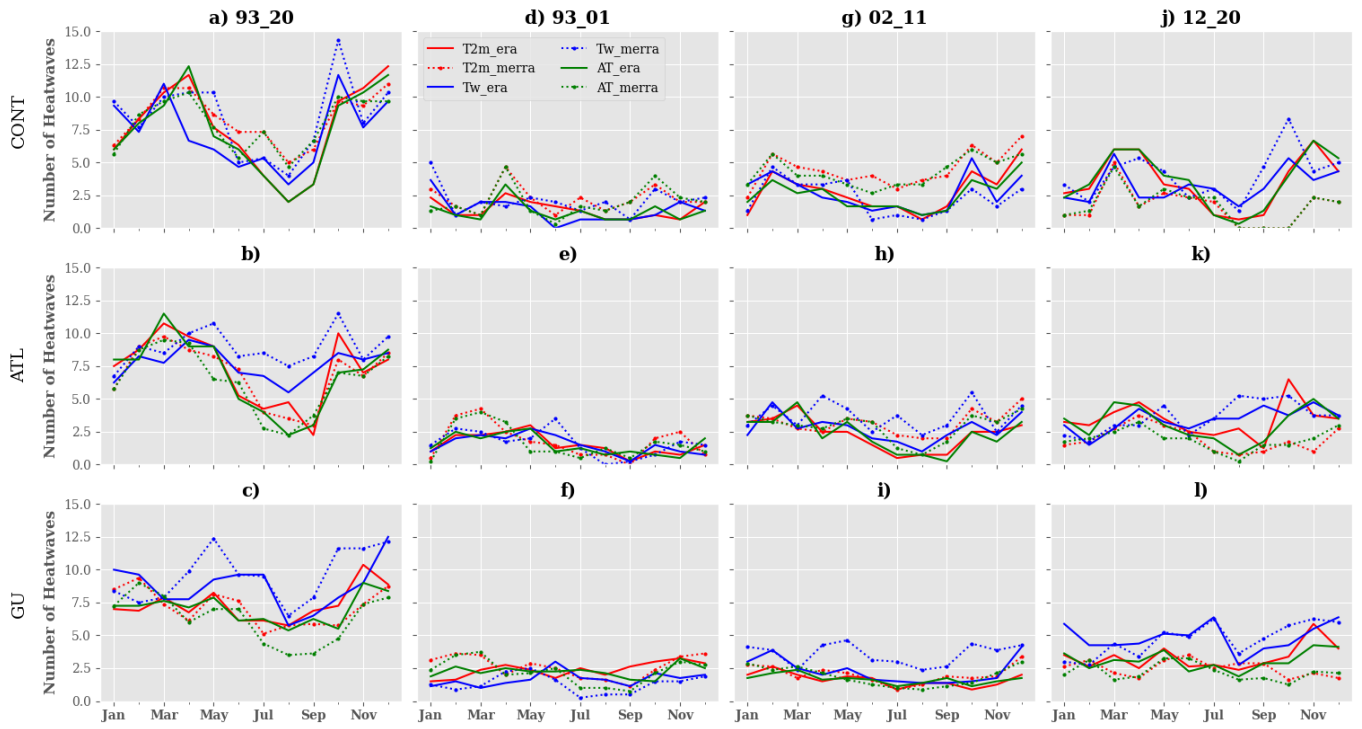


Figure S14. Seasonal variability of heat waves frequency using reanalyses (ERA5, MERRA) and maximum values of indicators T2m, Tw and AT. The first column shows the evolution of heat waves frequency over the whole period 1993-2020 (a – c). The 2nd, 3rd and 4th columns represent the heat wave frequency over the sub-periods 1993-2001 (d – f), 2002-2011 (g – i) and 2012-2020 (j – l) respectively. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions: CONT (a,d,g,j), ATL (b,e,h,k), GU (c,f,i,l) respectively. The Red/blue/green strong and dashed lines represent the evolution of heat waves frequency using T2m, Tw, AT from ERA5 and MERRA respectively. The Y- and X- axis represent the frequency of the heat waves and the time in month respectively.

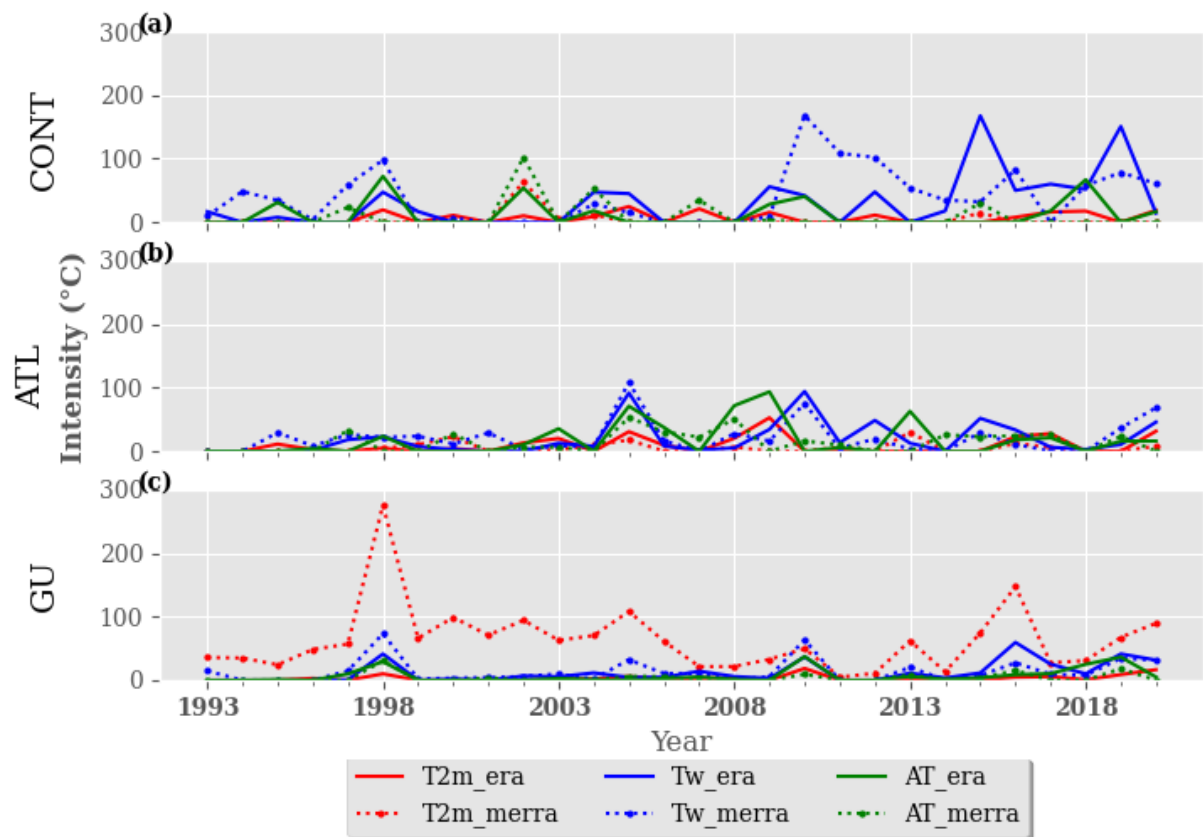


Figure S15. Interannual variability of heat waves intensity using reanalyses (ERA5, MERRA), minimum and maximum values of the indicators T2m, Tw and AT. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions : **a)** CONT, **b)** ATL, **c)** GU. The Red/blue/green strong and dashed lines represent the evolution of heat waves intensity using T2m, Tw, AT from ERA5 and MERRA respectively. The Y-axis represents heat waves intensity and the X-axis represents the time in year.

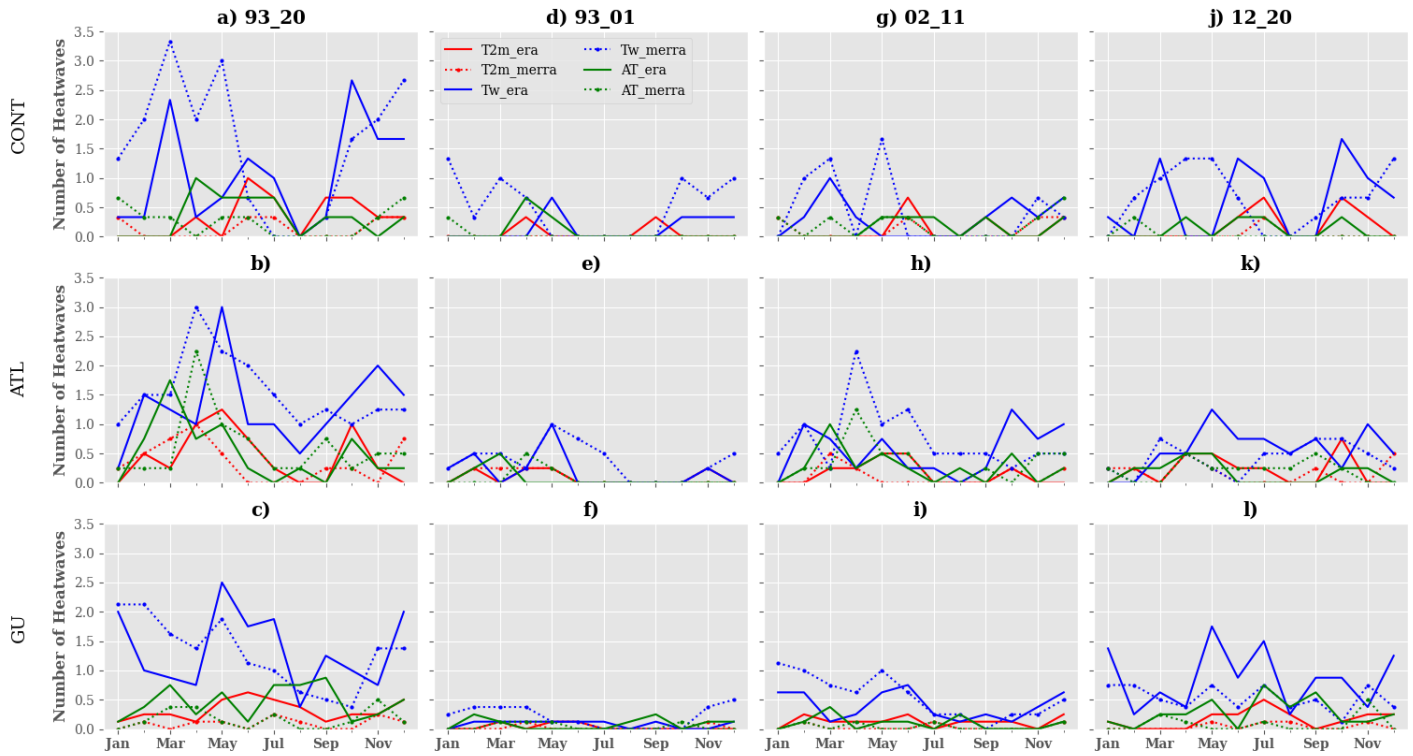


Figure S16. Seasonal variability of heat waves frequency using reanalyses (ERA5, MERRA), minimum and maximum values of indicators $T2m$, Tw and AT . The first column shows the evolution of heat waves frequency over the whole period 1993-2020 (a–c). The 2nd, 3rd and 4th columns represent the heat wave frequency over the sub-periods 1993-2001 (d–f), 2002-2011 (g–i) and 2012-2020 (j–l) respectively. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions: CONT (a,d,g,j), ATL (b,e,h,k), GU (c,f,i,l) respectively. The Red/blue/green strong and dashed lines represent respectively the evolution of heat waves frequency using $T2m$, Tw , AT from ERA5 and MERRA respectively. The Y-axis represents the frequency of heat waves and the X-axis represents the time in month.

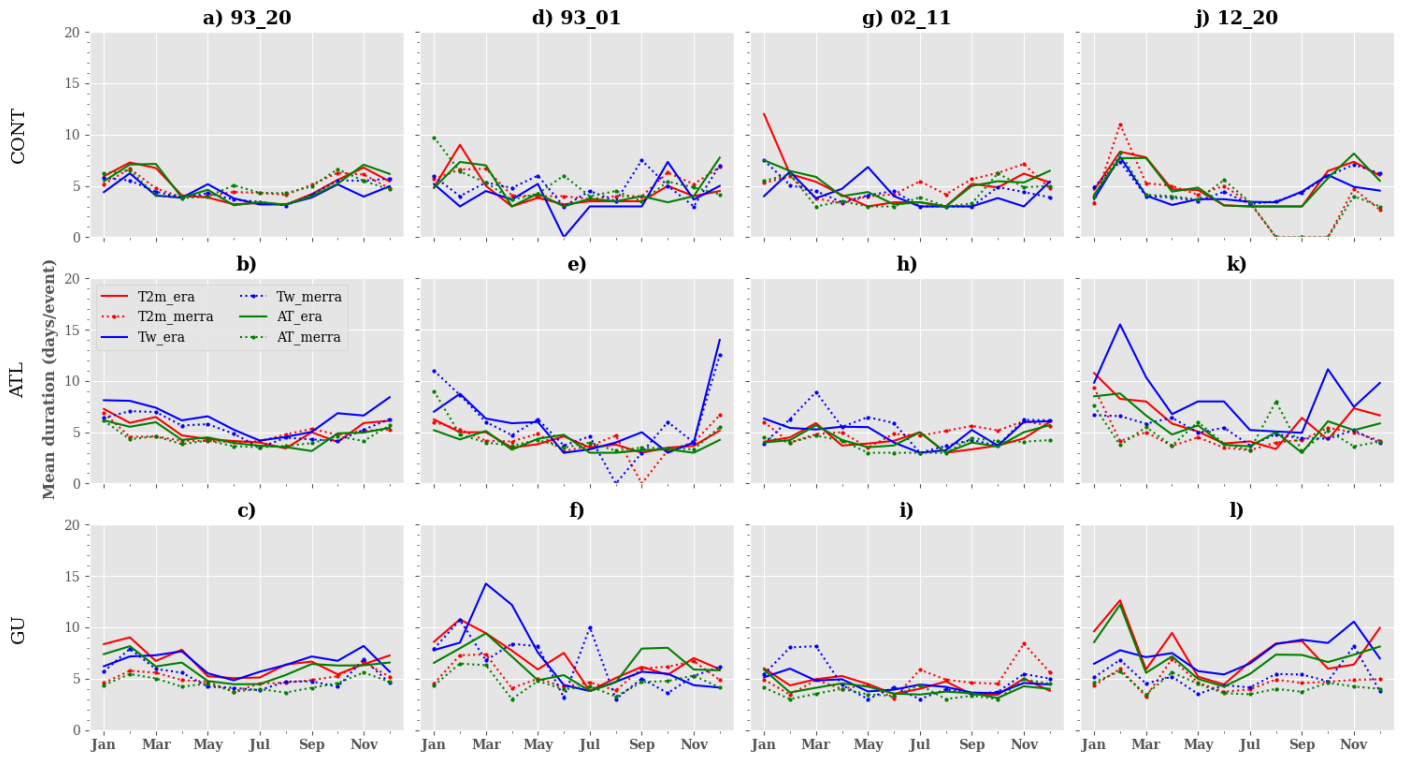


Figure S17. Seasonal variability of heat waves mean duration using reanalyses (ERA5, MERRA) and maximum values of indicators $T2m$, Tw and AT . The first column shows the evolution of heat wave mean duration over the whole period 1993-2020 (a – c). The 2nd, 3rd and 4th columns represent respectively the heat wave mean duration over the sub-periods 1993-2001 (d – f), 2002-2011 (g – i) and 2012-2020 (j – l) respectively. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions : CONT (a,d,g,j), ATL (b,e,h,k), GU (c,f,i,l) respectively. The Red/blue/green strong and dashed lines represent the evolution of heat wave mean duration using $T2m$, Tw , AT from ERA5 and MERRA respectively. The Y- and X- axis represent the mean duration of the heat waves and the time in month respectively.

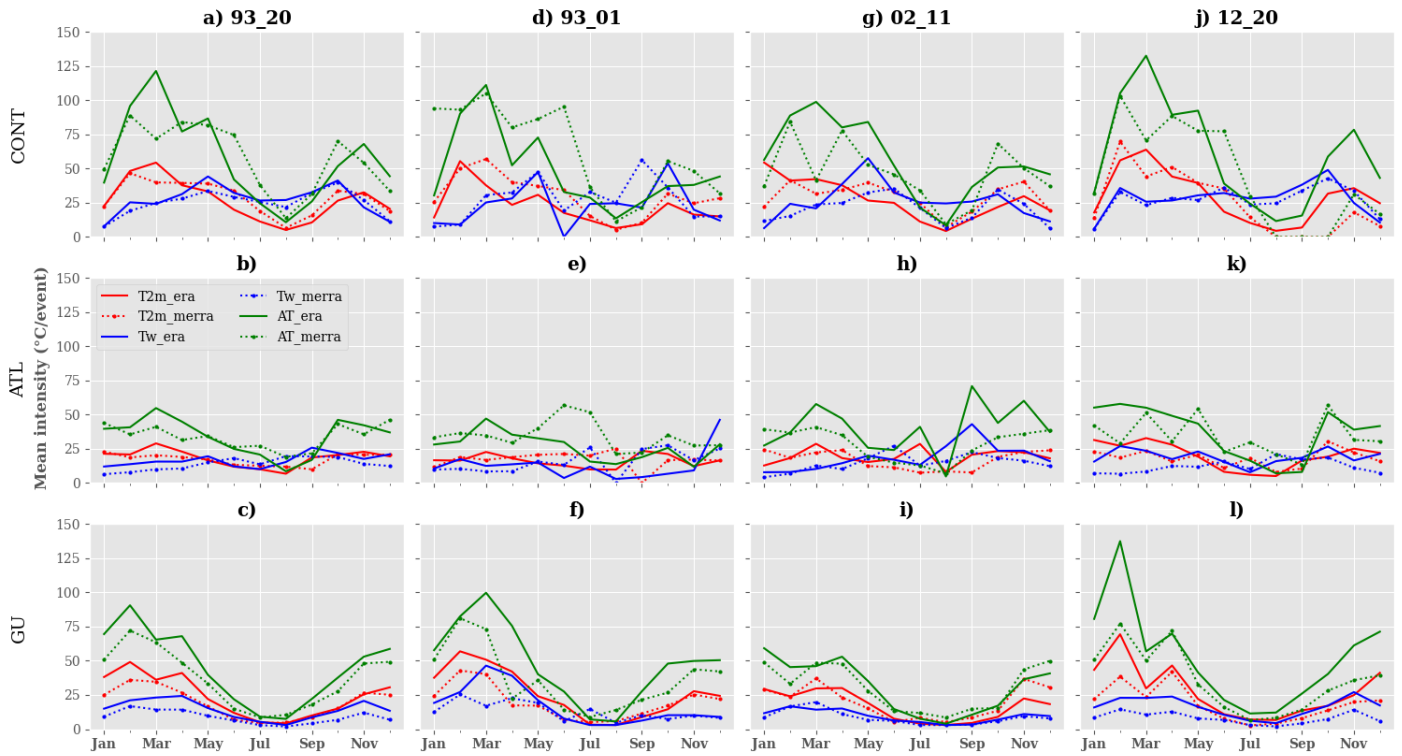


Figure S18. Seasonal variability of heat waves mean intensity using reanalyses (ERA5, MERRA) and maximum values of indicators $T2m$, Tw and AT . The first column shows the evolution of heat waves mean intensity over the whole period 1993-2020 (a – c). The 2nd, 3rd and 4th columns represent the heat waves mean intensity over the sub-periods 1993-2001 (d – f), 2002-2011 (g – i) and 2012-2020 (j – l) respectively. The detection of heat waves is done using the climatological daily 90th percentile as threshold in the different regions : CONT (a,d,g,j), ATL (b,e,h,k), GU (c,f,i,l) respectively. The Red/blue/green strong and dashed lines represent the evolution of heat waves mean intensity using $T2m$, Tw , AT from ERA5 and MERRA respectively. The Y- and X- axis represent the mean intensity of the heat waves and the time in month respectively.




Figure S19. Classification of heat waves using MERRA reanalysis based on their persistence over the period 1993-2020 : **a)** T2m, **b)** Tw and **c)** AT. The detection of heat waves is done using maximum values of the indicators and the climatological daily 90th percentile. Heat waves detection is firstly proceed and then their duration is computed. Clusters of heat waves based on their duration (3d, 4d-6d, 7d-9d, 10d-12d, +13d) are created and finally, we quantify the proportion of each class of heat waves to the total number of events detected. The Y- and X- axis represent the percentage of the heat waves per class and the duration in day respectively. The Red/blue/green bars represent the percentage of heat waves detected over CONT/ATL/GU regions respectively (see region of interest section for more details). The sum of the contribution of heat waves in different clusters is equal to 1 for each region.

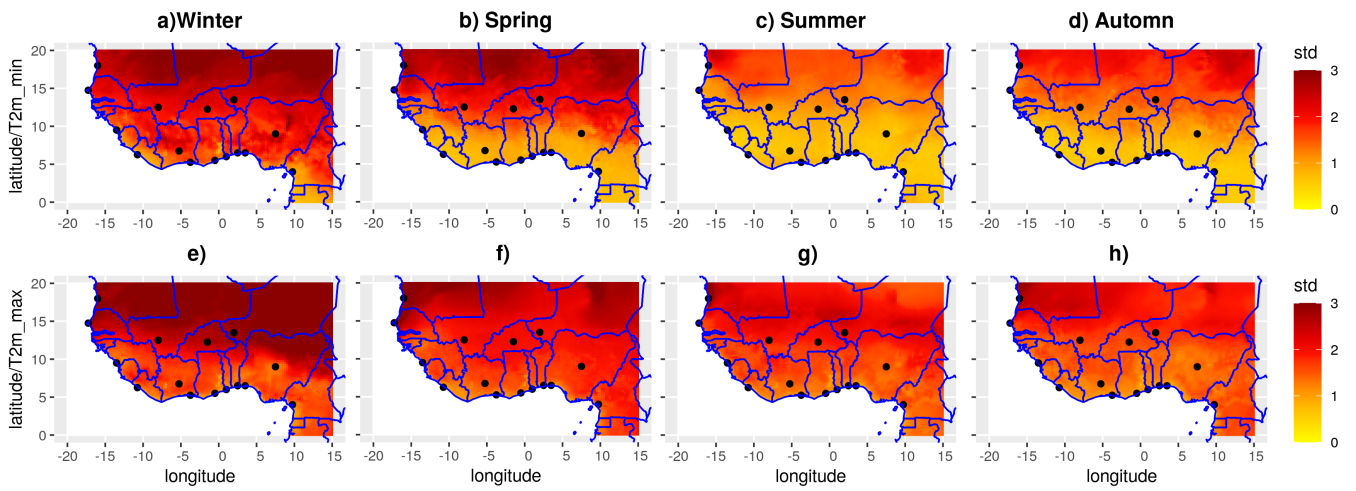


Figure S20. Spatial interannual variability of standard deviation (std) over West Africa regions over the period 1993-2020 using ERA5 reanalysis and T2m. The first/second row shows the distribution of the std when using minimum/maximum values of T2m. X- and Y- axis represent the longitude and latitude in degrees respectively. The color bar shows the values of the std.

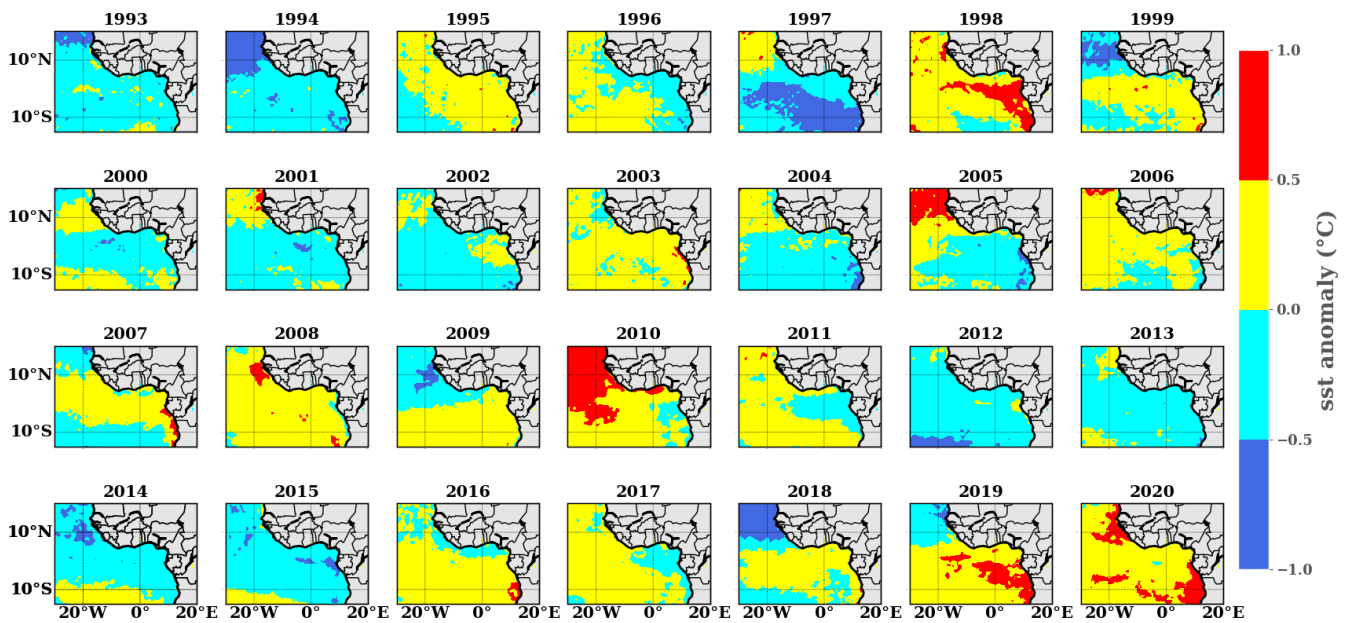


Figure S21. Spatial interannual variability of the SST anomalies over the period 1993-2020 using ERA5 reanalysis. The anomalies are computed as the difference between the annual mean SST and the climatology of the SST computed over the whole period. The X- and Y- axis represent the longitude and latitude in degree respectively. The color bar shows the values of the anomalies in degree Kelvin.

Annexe B

Prévisibilité des vagues de chaleur de l'échelle intra-saisonnière à l'échelle saisonnière dans les villes ouest-Africaines

Supplementary materials of: "Subseasonal-to-seasonal forecasts of Heat waves in West African cities"

Cedric G. Ngoungue Langué^{1,2}, Christophe Lavaysse^{2,3}, and Cyrille Flamant¹

¹Laboratoire Atmosphères, Milieux, Observations Spatiales (LATMOS) - UMR 8190 CNRS/Sorbonne Université/UVSQ, 78280 Guyancourt, France.

²Université Grenoble Alpes, CNRS, IRD, G-INP, IGE, 38000 Grenoble, France

³European Commission, Joint Research Centre (JRC), 21027 Ispra, VA, Italy

Correspondence: Ngoungue Langué Cedric Gacial (cedric-gacial.ngoungue-langué@latmos.ipsl.fr)

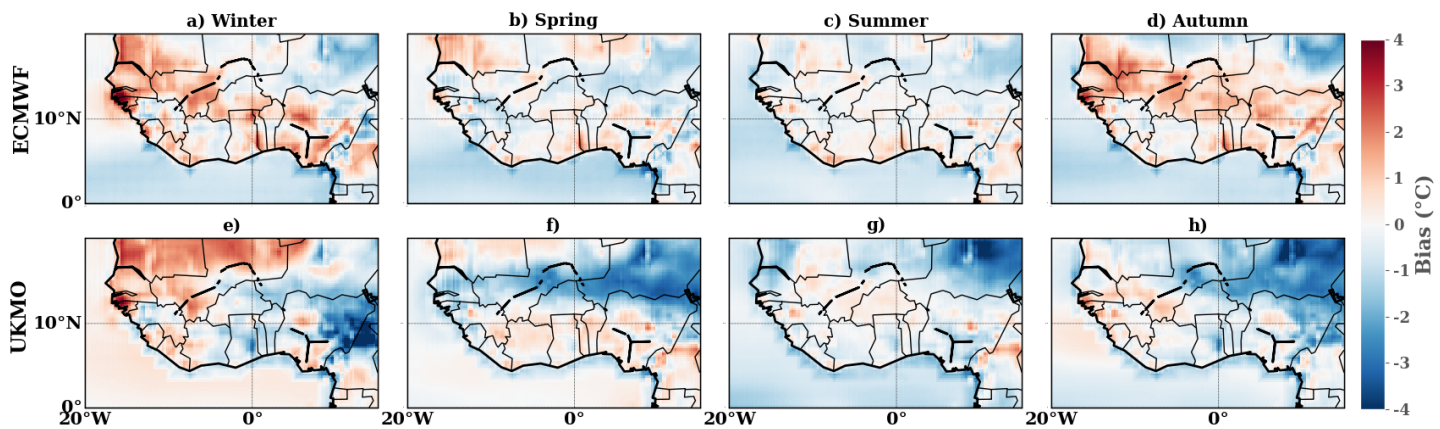


Figure S1. Spatial variability of the climatological bias between the forecast models ensemble mean and MERRA reanalysis over the period 2001-2020 for T2m_min during the seasons : (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is computed as the difference between the forecast models and ERA5. The color indicates the bias values in degrees Celsius. The X and Y axes represent the longitude and latitude respectively.




Figure S2. Evolution of the mean climatological biases between the forecast models and reanalyses using T2m_min over the period 2001-2020 during the seasons : (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The solid black line indicates the zero value (no bias). Yellow, green, blue solid- and dotted- lines represent the bias calculated using ERA5 and MERRA as references over the AT, GU and CO regions respectively. The Y and X axes represent the bias values in degree Kelvin and the time in days respectively.

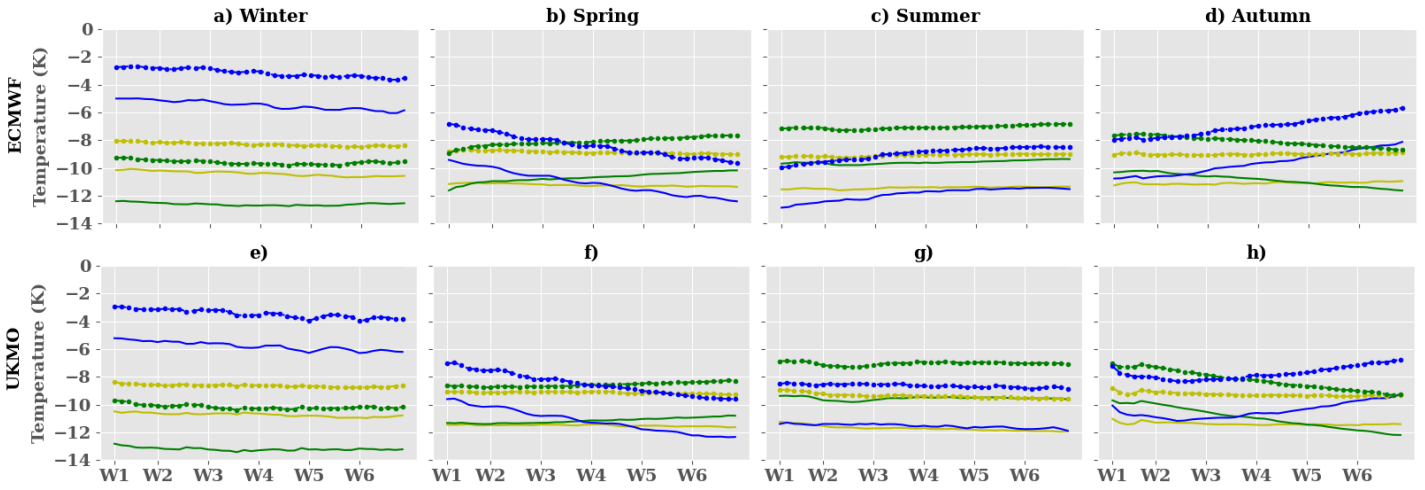


Figure S3. Evolution of the mean climatological biases between the forecast models and reanalyses using Tw over the period 2001-2020 during the seasons : (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. Yellow, green, blue solid- and dotted- lines represent the bias calculated using ERA5 and MERRA as references over the AT, GU and CO regions respectively. The Y and X axes represent the bias values in degree Kelvin and the time in days respectively.




Figure S4. Evolution of the CRPS score between the forecast models and ERA5 reanalysis over the period 2001-2020 during the seasons using Tw : (a) winter, (b) spring, (c) summer and (d) autumn. The dot and cross symbols indicate the CRPS score obtained with ECMWF and UKMO respectively. The Y and X axes show the CRPS values and the lead times (W2: week2 and W5: week5) respectively.




Figure S5. Evolution of the Brier score between the forecast models and ERA5 reanalysis over the period 2001-2020 during the seasons for Tw : (a) winter, (b) spring, (c) summer and (d) autumn. The dot and cross symbols indicate the Brier score obtained with ECMWF and UKMO respectively. The Y and X axes show the CRPS values and the lead times (W2: week2 and W5: week5) respectively.

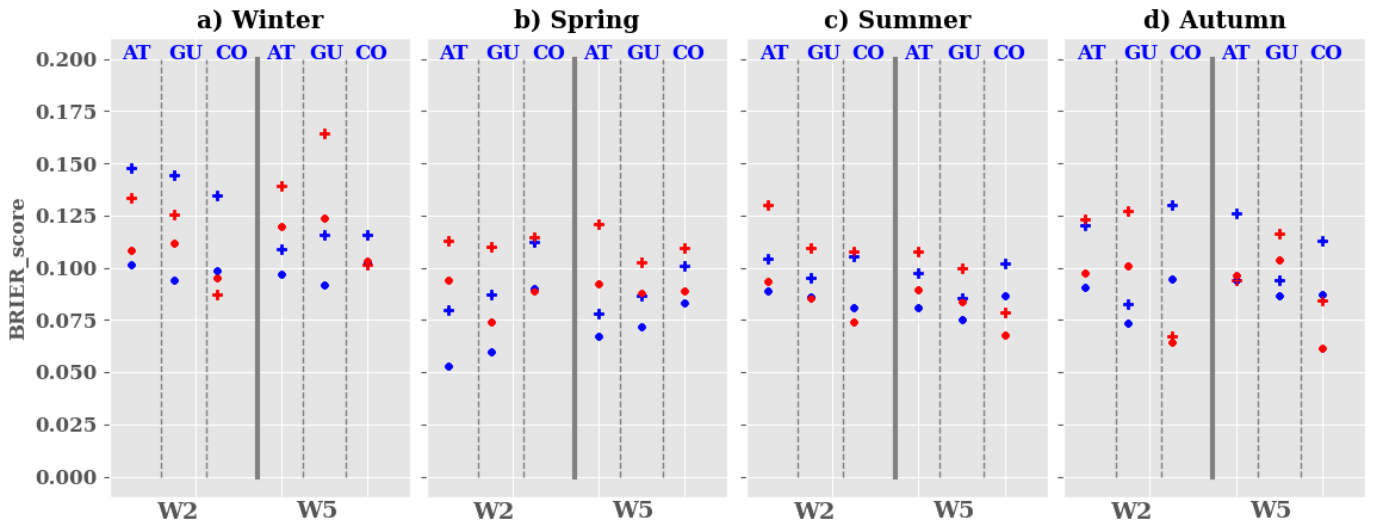


Figure S6. Evolution of the Brier score between the forecast models and MERRA reanalysis over the period 2001-2020 during the seasons : (a) winter, (b) spring, (c) summer and (d) autumn. The blue and red colors represent the Brier score calculated using T2m_min and T2m_max values respectively. The dot and cross symbols indicate the Brier score obtained with ECMWF and UKMO respectively. The Y and X axes show the CRPS values and the lead times (W2: week2 and W5: week5) respectively.

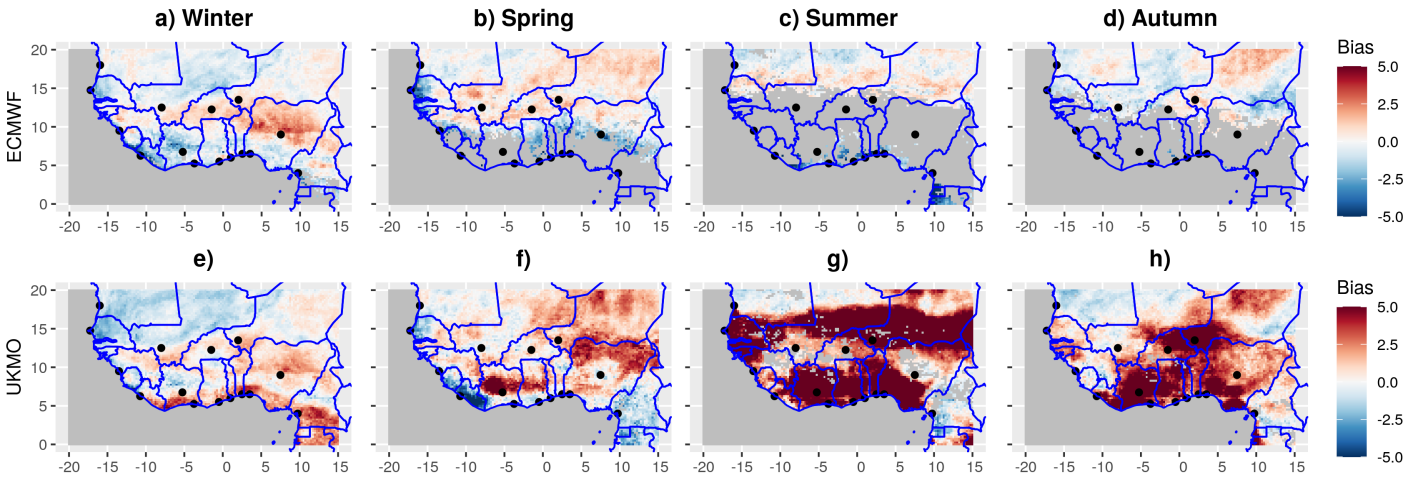


Figure S7. Spatial variability of heat wave duration bias between forecast models and ERA5 over West Africa from 2001 to 2020 using T_w during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave duration between the forecast models and ERA5. This analysis is performed using the unperturbed member of the models. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

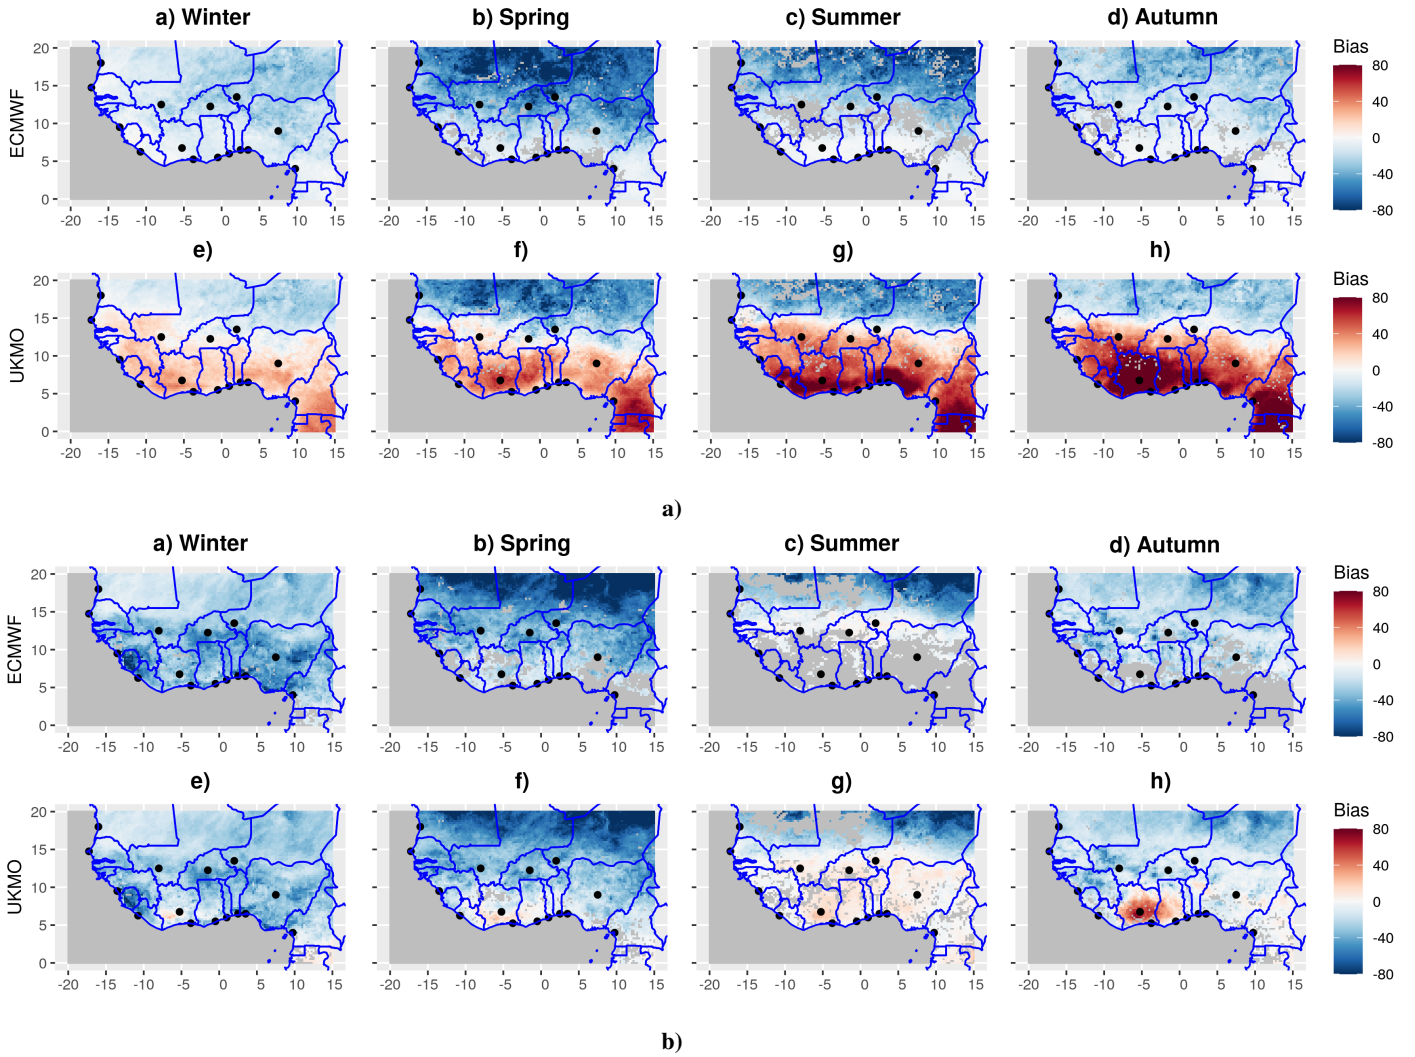


Figure S8. Spatial variability of heat wave intensity bias between the forecast models and ERA5 over West Africa from 2001 to 2020 for: **(a)** T2m_min values and **(b)** T2m_max values, during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave intensity between the models and ERA5. This analysis is performed using the unperturbed member of the models over years where heat waves were detected. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

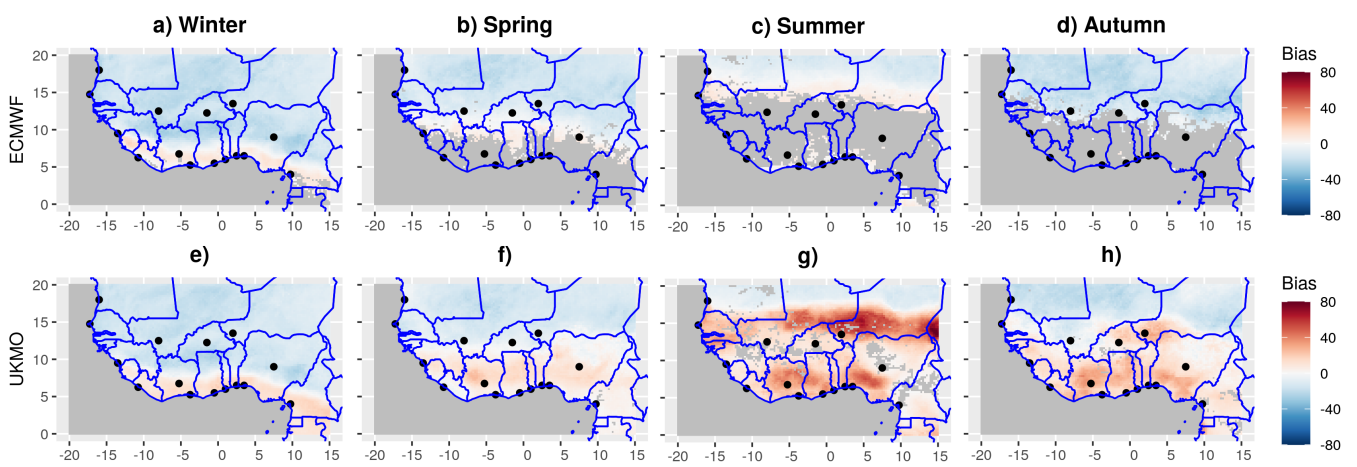


Figure S9. Spatial variability of heat wave intensity bias between the forecast models and ERA5 over West Africa from 2001 to 2020 for T_w during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave intensity between the models and ERA5. This analysis is performed using the unperturbed member of the models over years where heat waves were detected. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

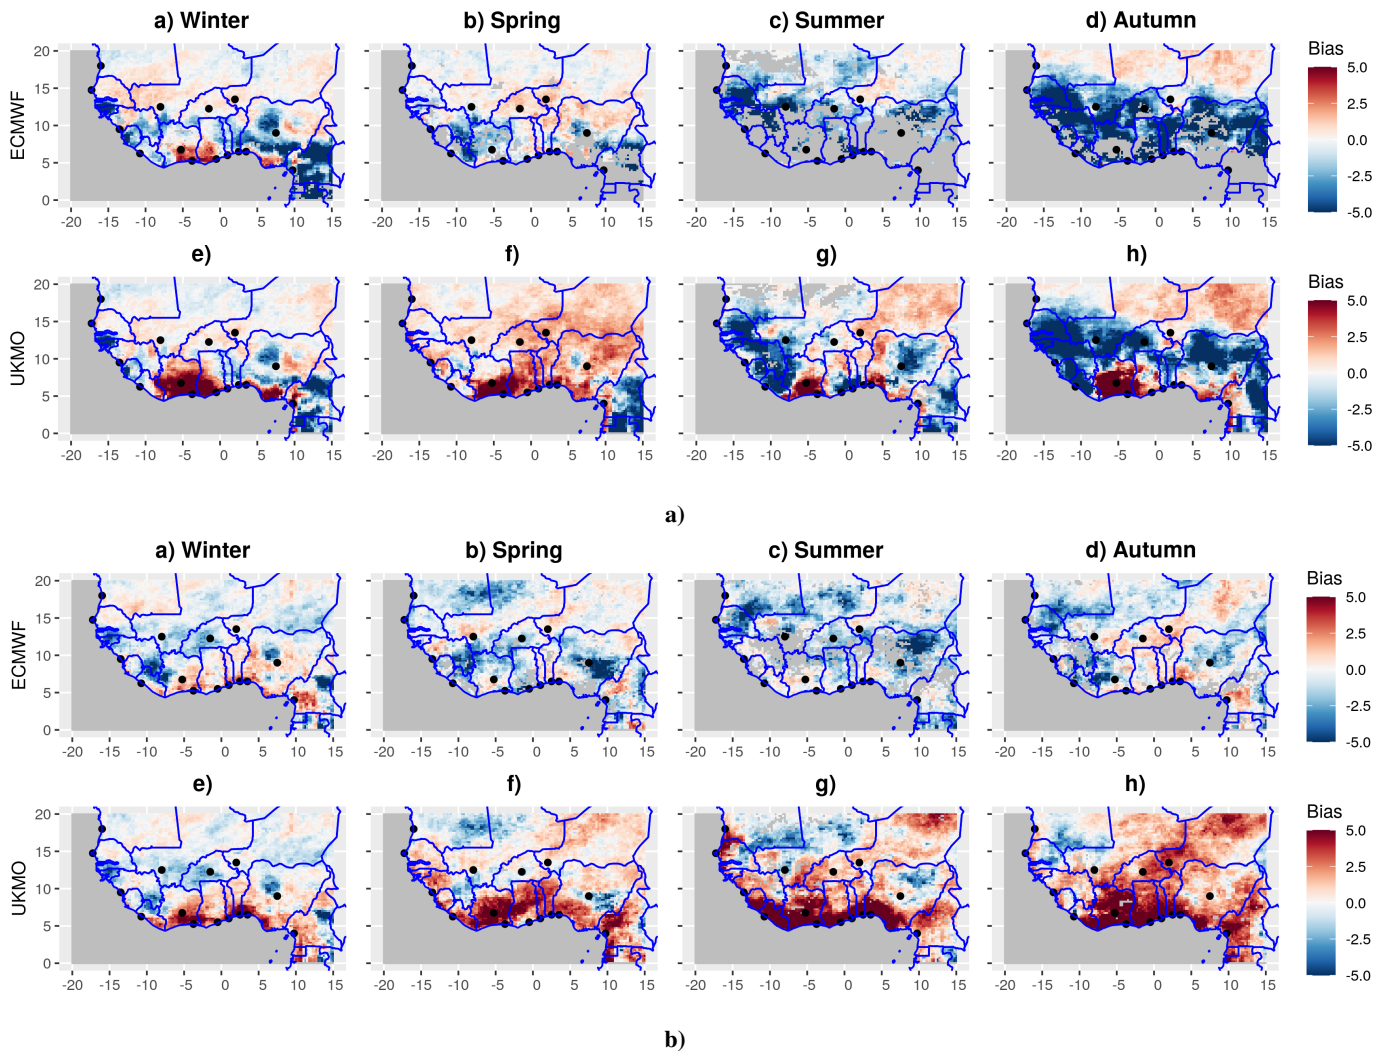


Figure S10. Spatial variability of heat wave duration bias between the forecast models and MERRA over West Africa from 2001 to 2020 for: **(a)** T2m_min values and **(b)** T2m_max values, during: (a,e) winter; (b,f) spring; (c,g) summer and (d,h) autumn. The bias is calculated as the difference in heat wave duration between the models and ERA5. This analysis is performed using the unperturbed member of the models over years where heat waves were detected. The color bar indicates the bias values without units. The X and Y axes represent longitude and latitude respectively.

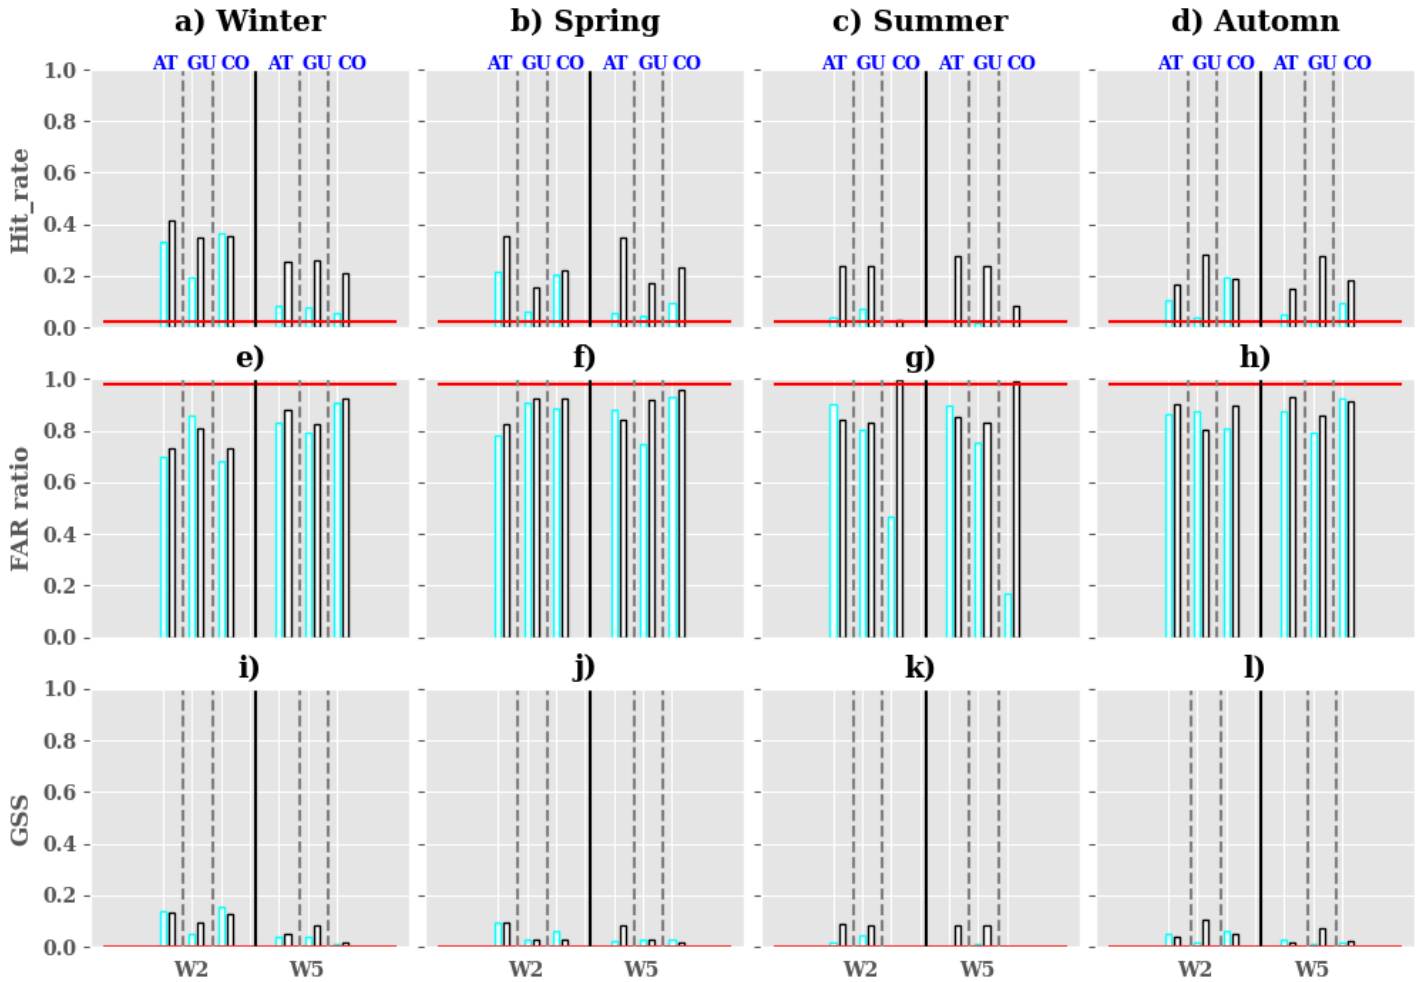


Figure S11. Evaluation of heat waves detection in the forecast models with respect to ERA5 at daily time scale over the period 2001-2020 using T_w for : (a-d) hit-rate, (e-h) FAR ratio and (i-l) GSS. The metrics were computed using the optimized forecasts (see section Methods for the optimisation of the ensemble forecasts). The metrics were calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the metrics obtained when using ECMWF and UKMO respectively. The Y and X axes show the metrics values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.

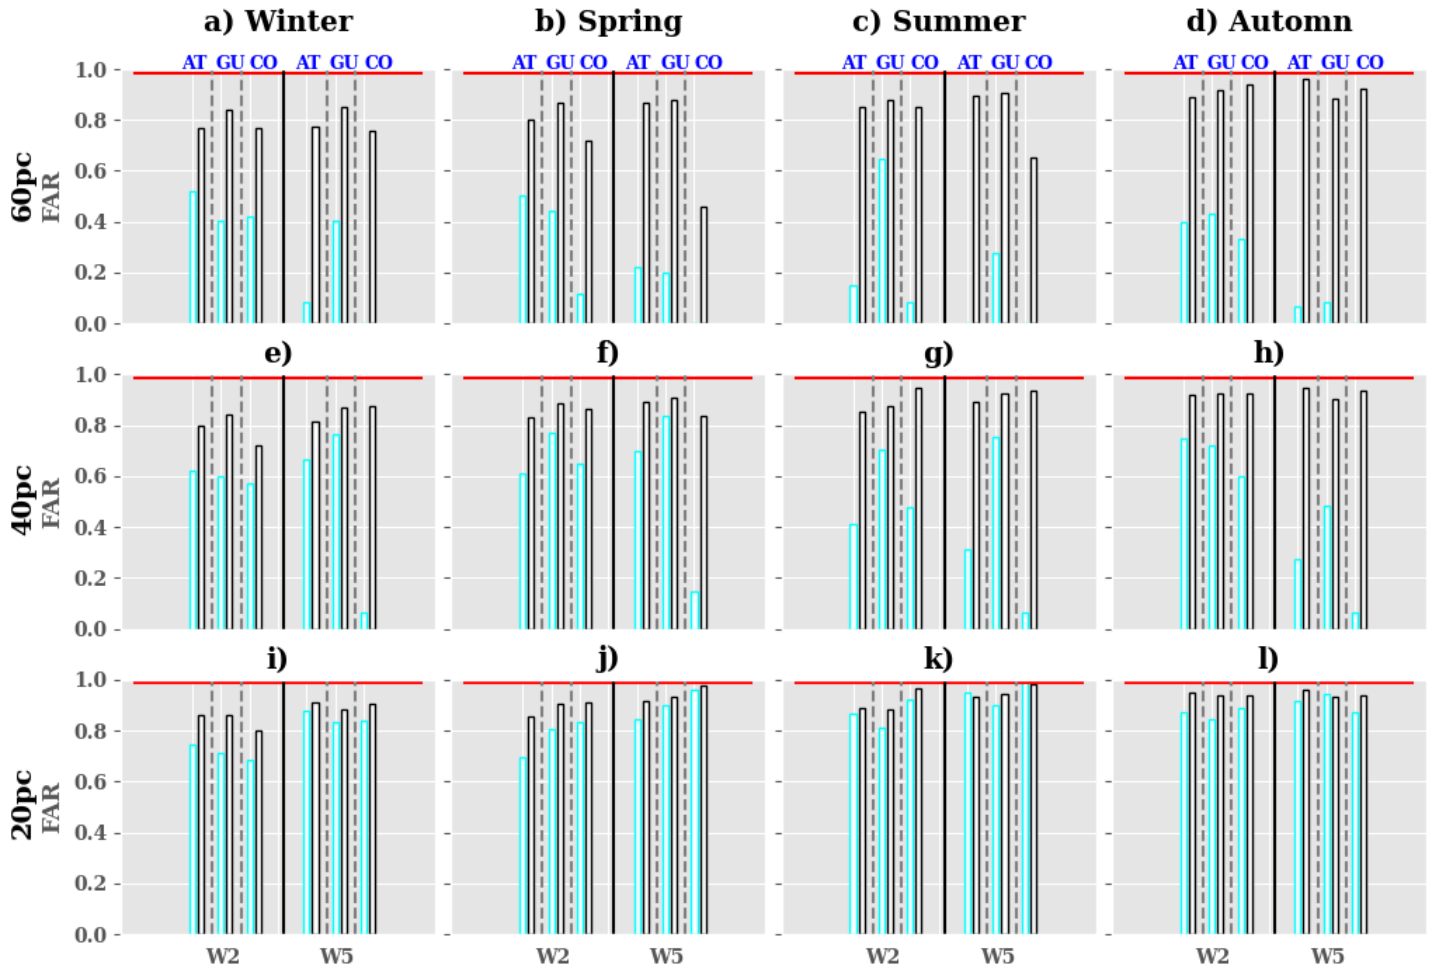


Figure S12. Sensitivity of the FAR ratio to the thresholds used to optimize forecasts over the period 2001-2020 using T2m_min values at daily time scale for : (a-d) a 60 percentile threshold, (e-h) a 40 percentile threshold and (i-l) a 20 percentile threshold (see Section Methods on optimization forecasts for more details). The FAR ratio is calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the FAR ratio obtained when using ECMWF and UKMO respectively. The Y and X axes show the FAR ratio values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.

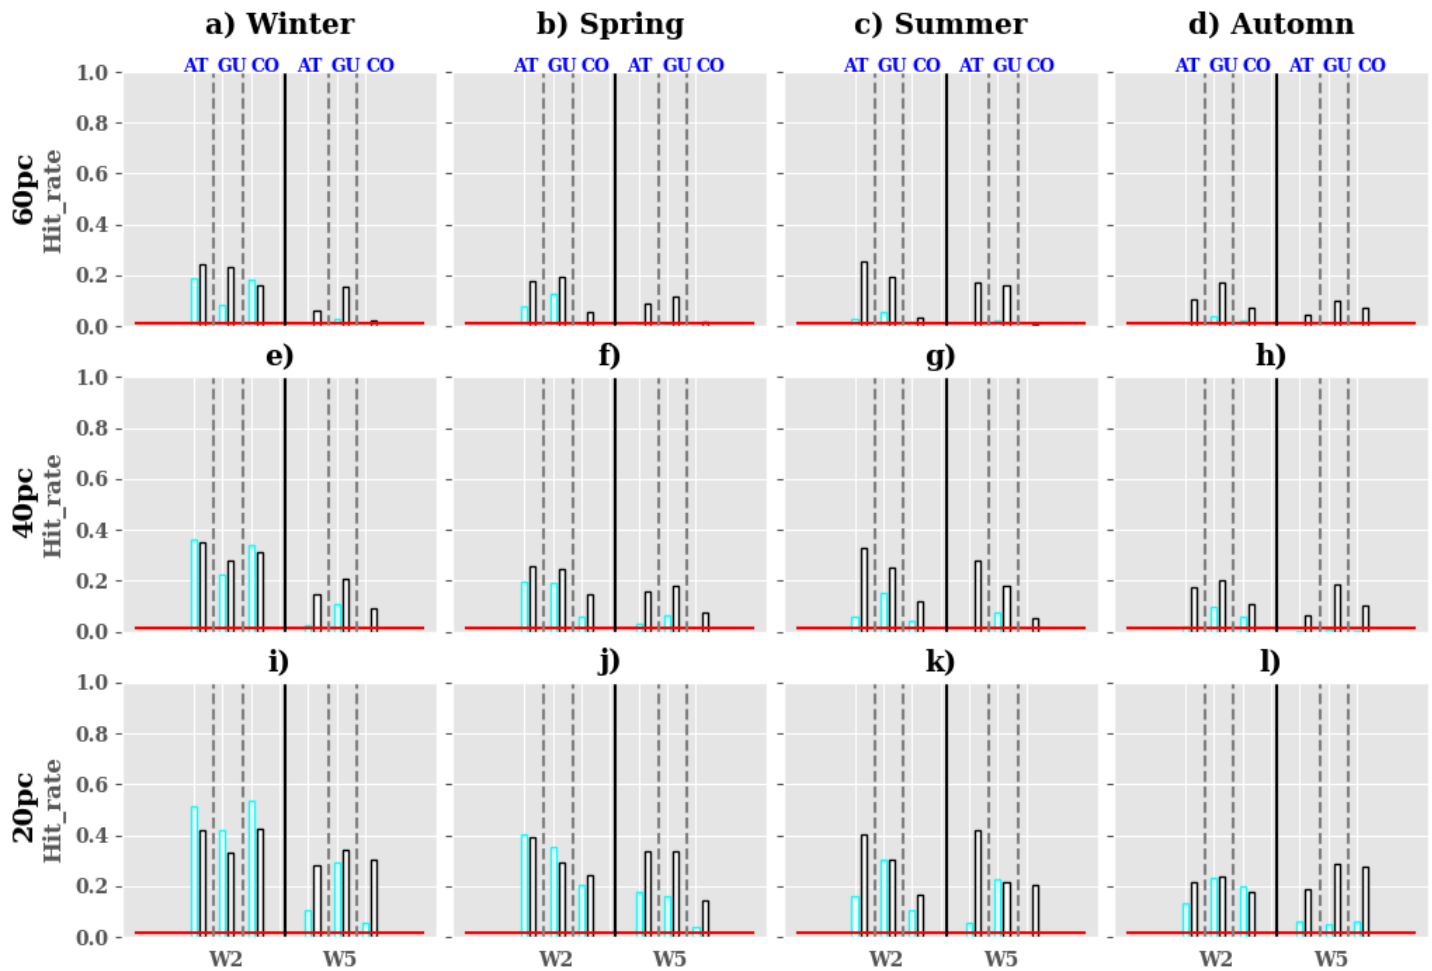


Figure S13. Sensitivity of the hit-rate to the thresholds used to optimize forecasts over the period 2001-2020 using T2m_min values at daily time scale for : (a-d) a 60 percentile threshold, (e-h) a 40 percentile threshold and (i-l) a 20 percentile threshold (see Section Methods on optimization forecasts for more details). The hit-rate is calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the hit-rate obtained when using ECMWF and UKMO respectively. The Y and X axes show the hit-rate values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.

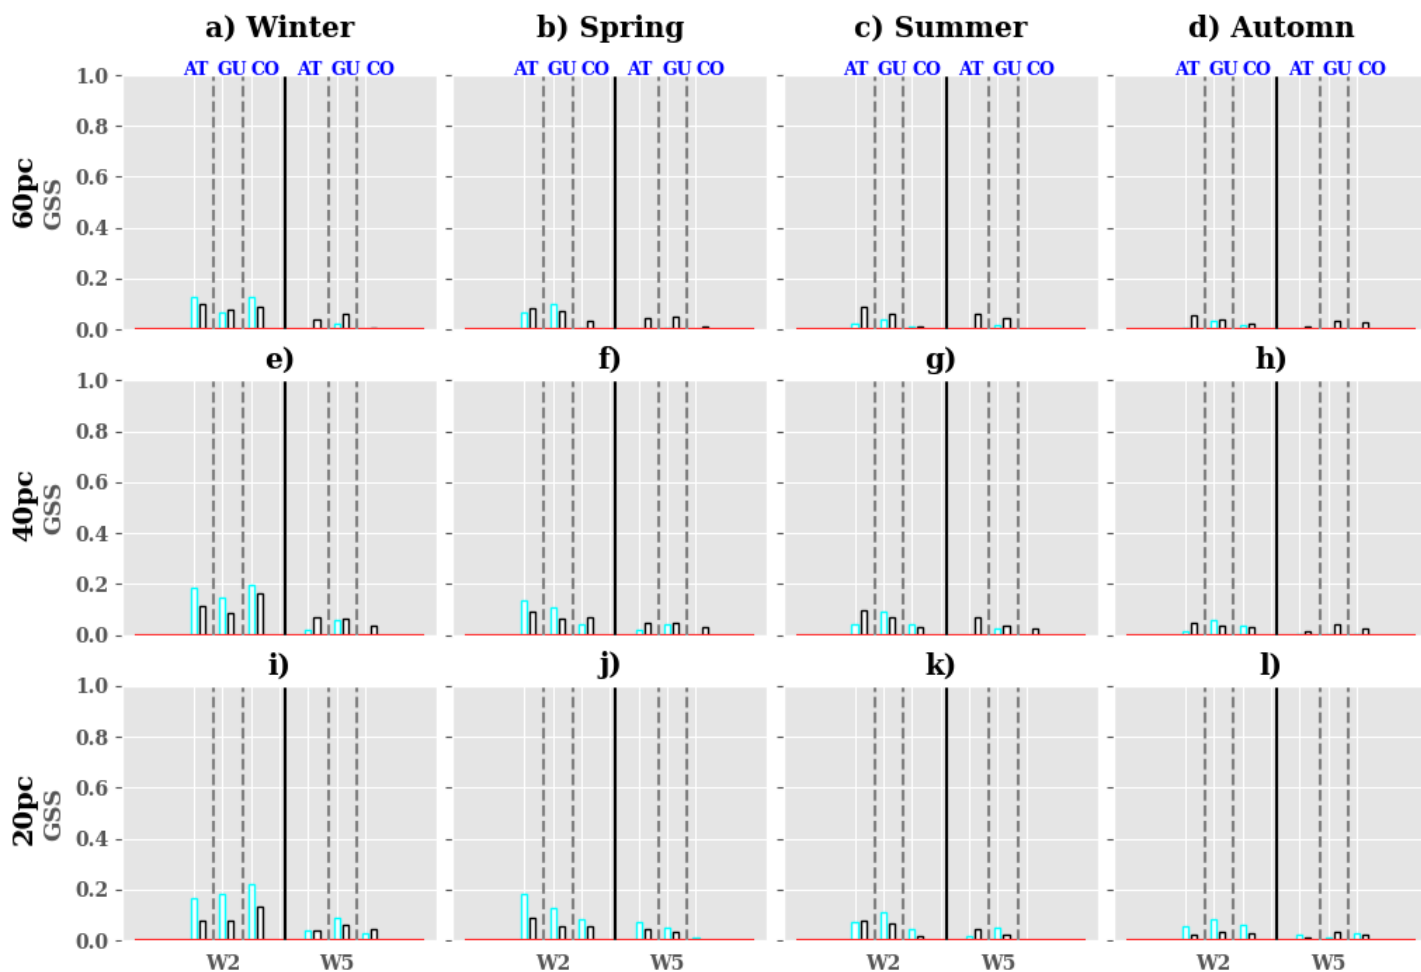


Figure S14. Sensitivity of the GSS to the thresholds used to optimize forecasts over the period 2001-2020 using T2m_min values at daily time scale for : (a-d) a 60 percentile threshold, (e-h) a 40 percentile threshold and (i-l) a 20 percentile threshold (see Section Methods on optimization forecasts for more details). The GSS is calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the GSS obtained when using ECMWF and UKMO respectively. The Y and X axes show the GSS values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.

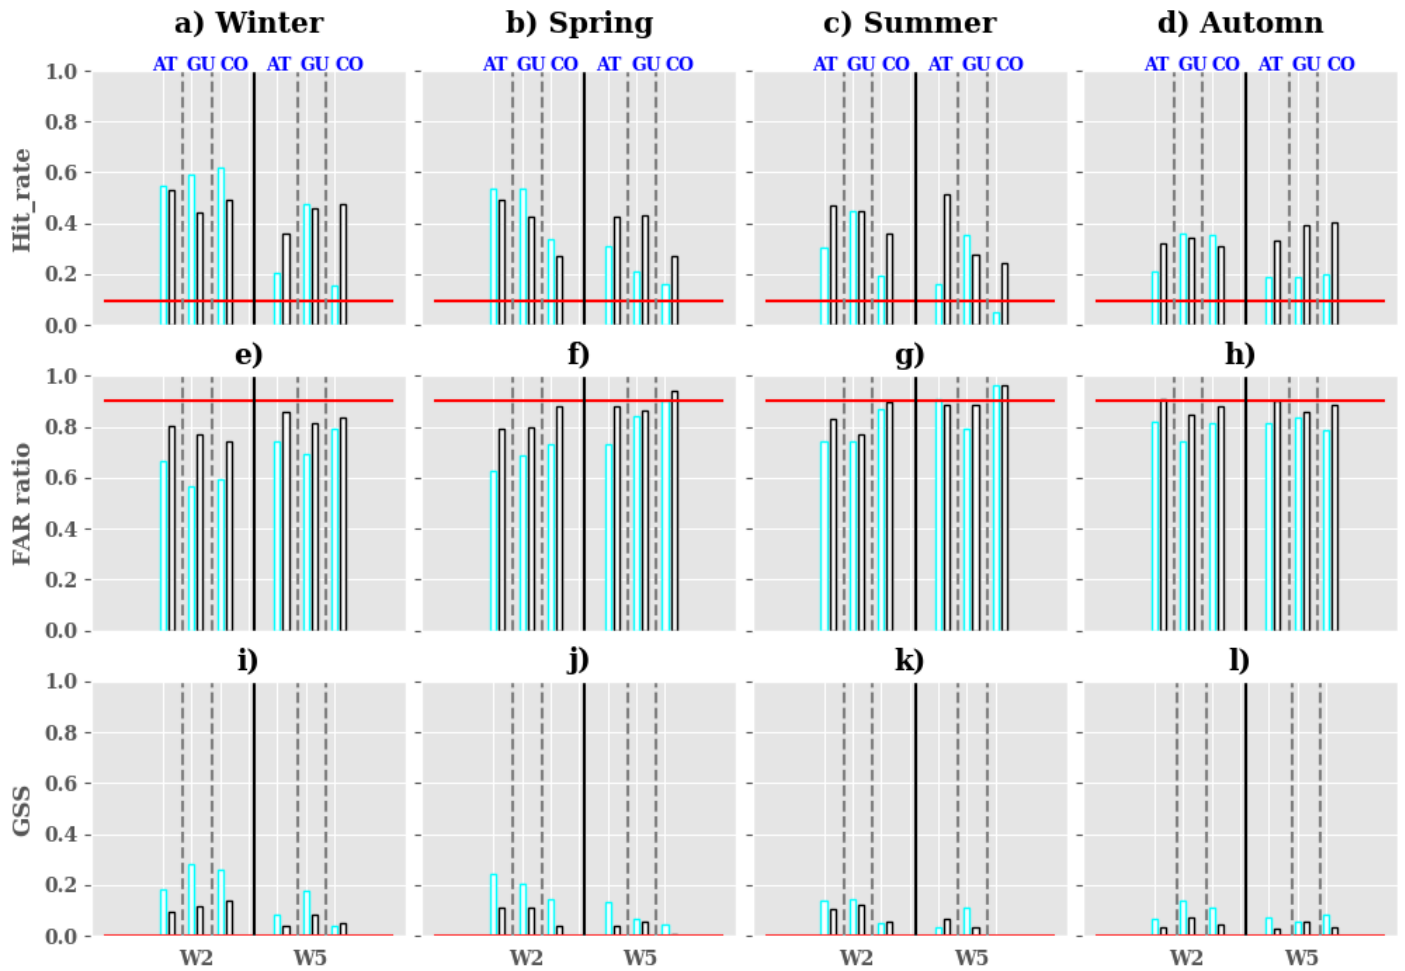


Figure S15. Evaluation of heat waves detection metrics in the models with respect to ERA5 at weekly time scale over the period 2001-2020 using T2m_min values for : (a-d) hit-rate, (e-h) FAR ratio and (i-l) GSS. The metrics were computed using the optimized forecasts (see section Methods for the optimisation of the ensemble forecasts). The metrics were calculated during the seasons : (a,e,i) winter; (b,f,j) spring; (c,g,k) summer and (d,h,l) autumn. The cyan and black borders of bar plots indicate the metrics obtained when using ECMWF and UKMO respectively. The Y and X axes show the metrics values and the lead times (W2: week2 and W5: week5) respectively. The horizontal red line represents the baseline climatology.

Annexe C

Utilisation des méthodes d'apprentissage automatique pour l'optimisation des prévisions des vagues de chaleur dans les modèles de prévisions intra-saisonniers




Figure C.1 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant T_{max} dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de hit-rate associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du hit-rate.




Figure C.2 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant T_{max} dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs de GSS associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du GSS.




Figure C.3 – Évaluation de la prédictibilité des jours dans les vague de chaleur durant la période de test (2003,2008,2012,2019) en utilisant T_{max} dans les différentes régions : a) AT, b) CONT et c) GU. Les barres de fond blanc et de bordure de couleur cyan, noire, bleue et rouge représentent respectivement les valeurs du FAR associées aux modèles CEPMMT, UKMO, BRF appliqué aux prévisions du CEPMMT et BRF appliqué aux prévisions UKMO. Les axes des abscisses et ordonnées représentent respectivement le temps en semaine et les valeurs du FAR.

Figure C.4 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant Tmin à Nouakchott pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.5 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Dakar pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.6 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Conakry pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.7 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Monrovia pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.8 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Bamako pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.9 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Ouagadougou pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.10 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Niamey pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.11 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Yamoussoukro pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.12 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Abidjan pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.13 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Accra pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.14 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Lomé pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.




Figure C.15 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Cotonou pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.

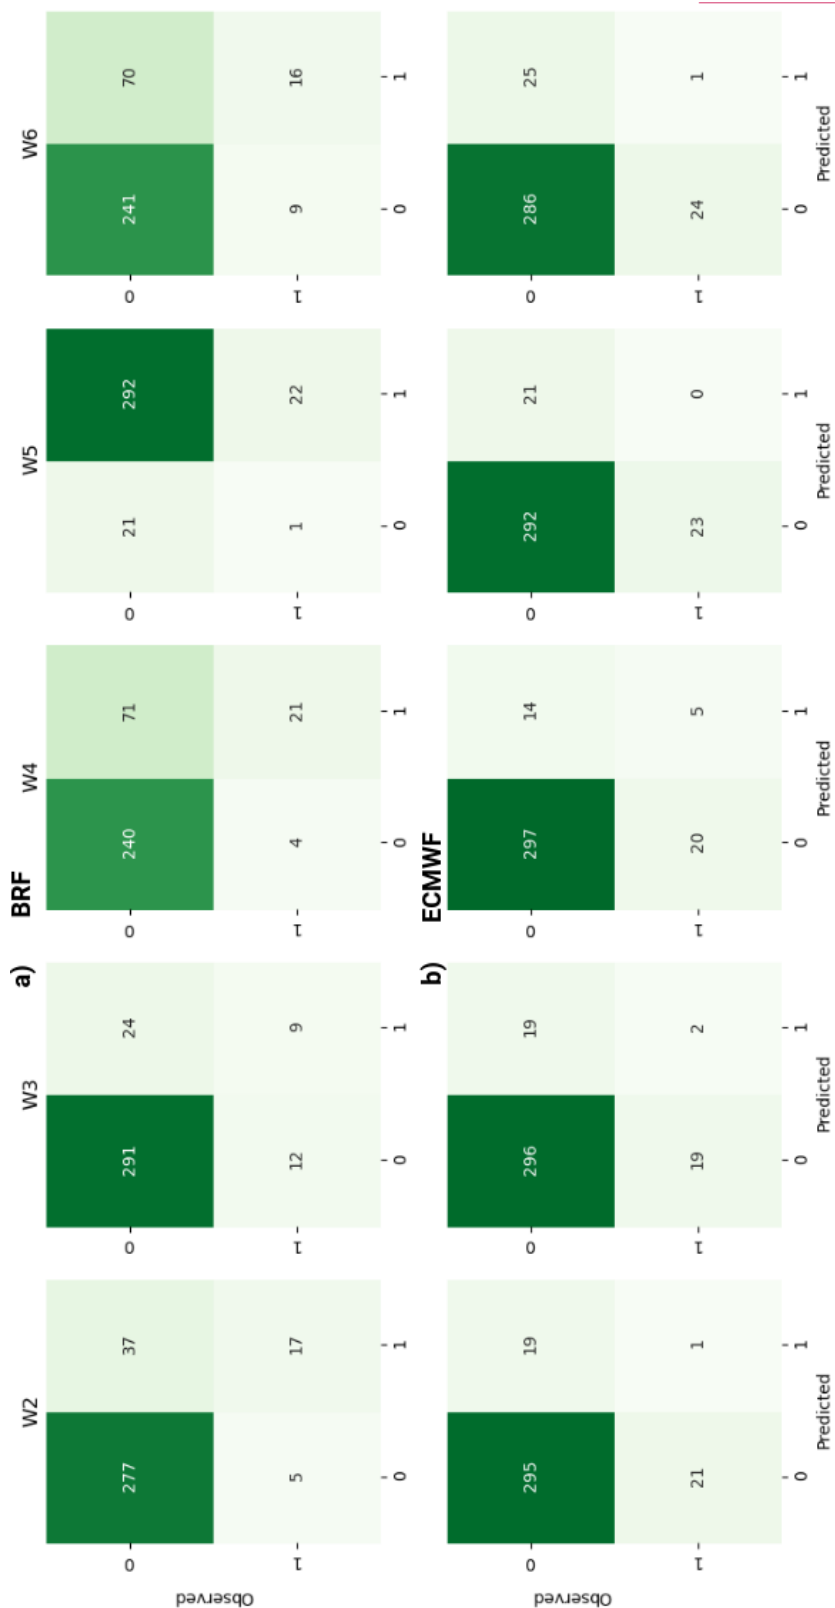


Figure C.16 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Lagos pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.

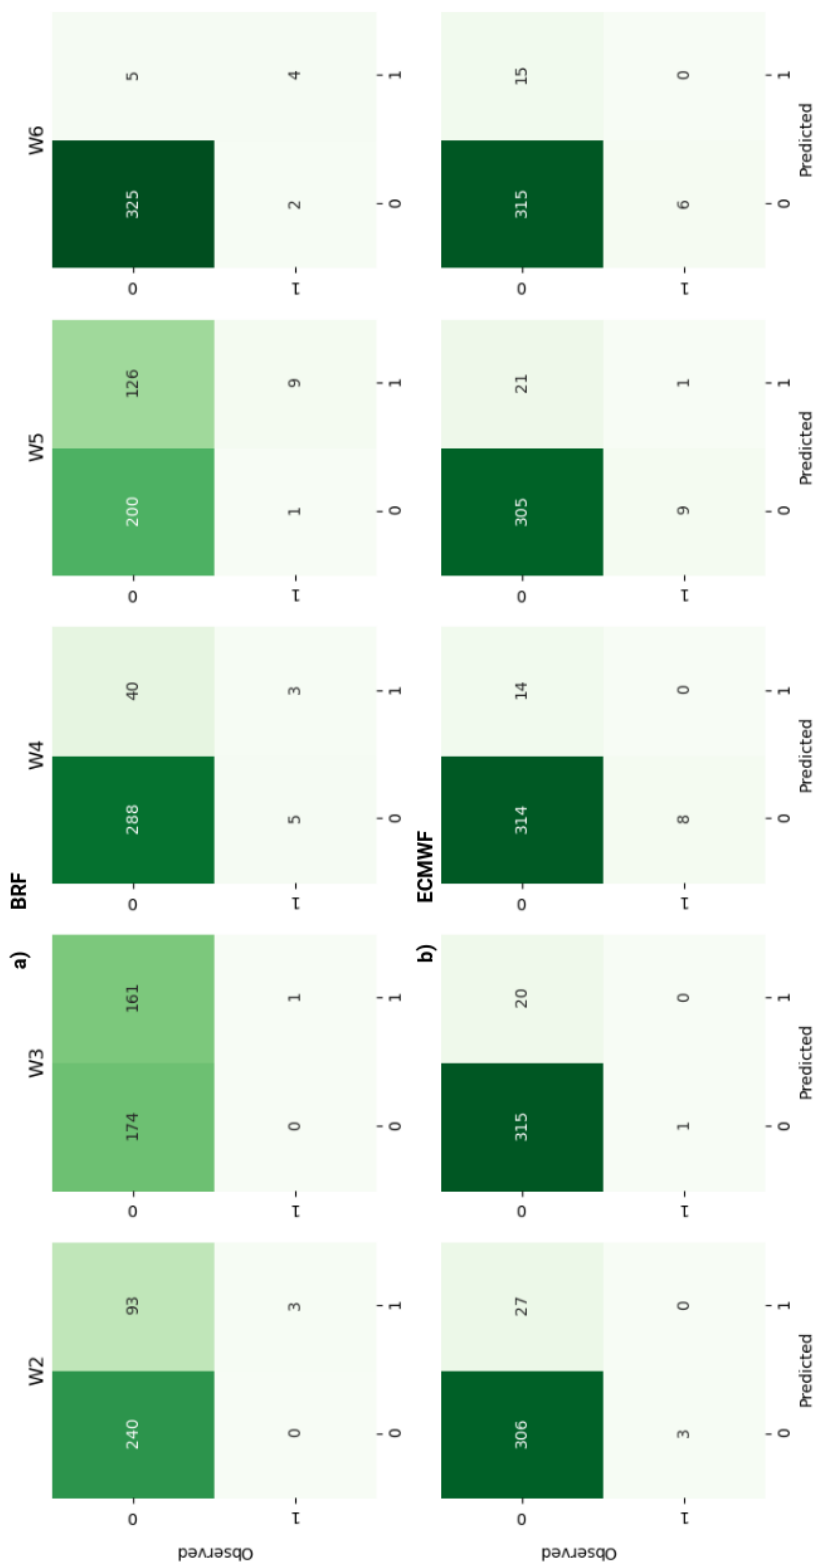


Figure C.17 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Abuja pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.





Figure C.18 – Évaluation des résultats de prédiction des jours dans les vagues de chaleur en utilisant T_{min} à Douala pour : a) le modèle BRF et b) le modèle du CEPMMT. L'axe des ordonnées indique les événements observés dans ERA5 et l'axe des abscisses, les événements prédits par les modèles.



Annexe D

Prévisibilité de potentiels prédicteurs aux vagues de chaleur en Afrique de l'Ouest

Supplement of Weather Clim. Dynam., 2, 893–912, 2021
<https://doi.org/10.5194/wcd-2-893-2021-supplement>
© Author(s) 2021. CC BY 4.0 License.



Supplement of

Seasonal forecasts of the Saharan heat low characteristics: a multi-model assessment

Cedric G. Ngoungue Langue

Correspondence to: Cedric G. Ngoungue Langue (cedric-gacial.ngoungue-langue@latmos.ipsl.fr)

The copyright of individual parts of the supplement might differ from the article licence.

1 Table

Table S1. Correlation between the HLW(HLE) phases in the models and ERA5: values in brackets/bold indicate the correlation using respectively the corrected anomalies/ temperatures over the 2 boxes (East and West SHL).

	ERA5(W)	ERA5 (E)
SEAS5(W,E)	0.29 (0.00)	0.12 (-0.09)
MF7(W,E)	0.30 (-0.03)	0.14 (-0.06)

2 Figures

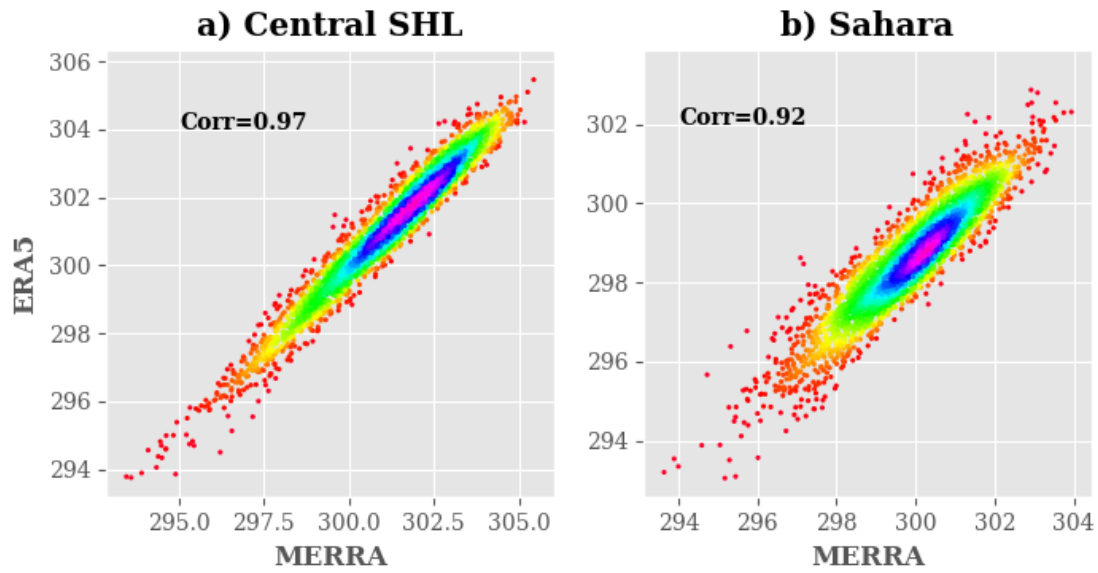


Figure S1. Correlation analysis between the reanalyses ERA5 and MERRA from 1993-2016 during the JJAS period over : a) Central SHL and b) Sahara. Y-axis/X-axis indicate T850 in ERA5/MERRA.

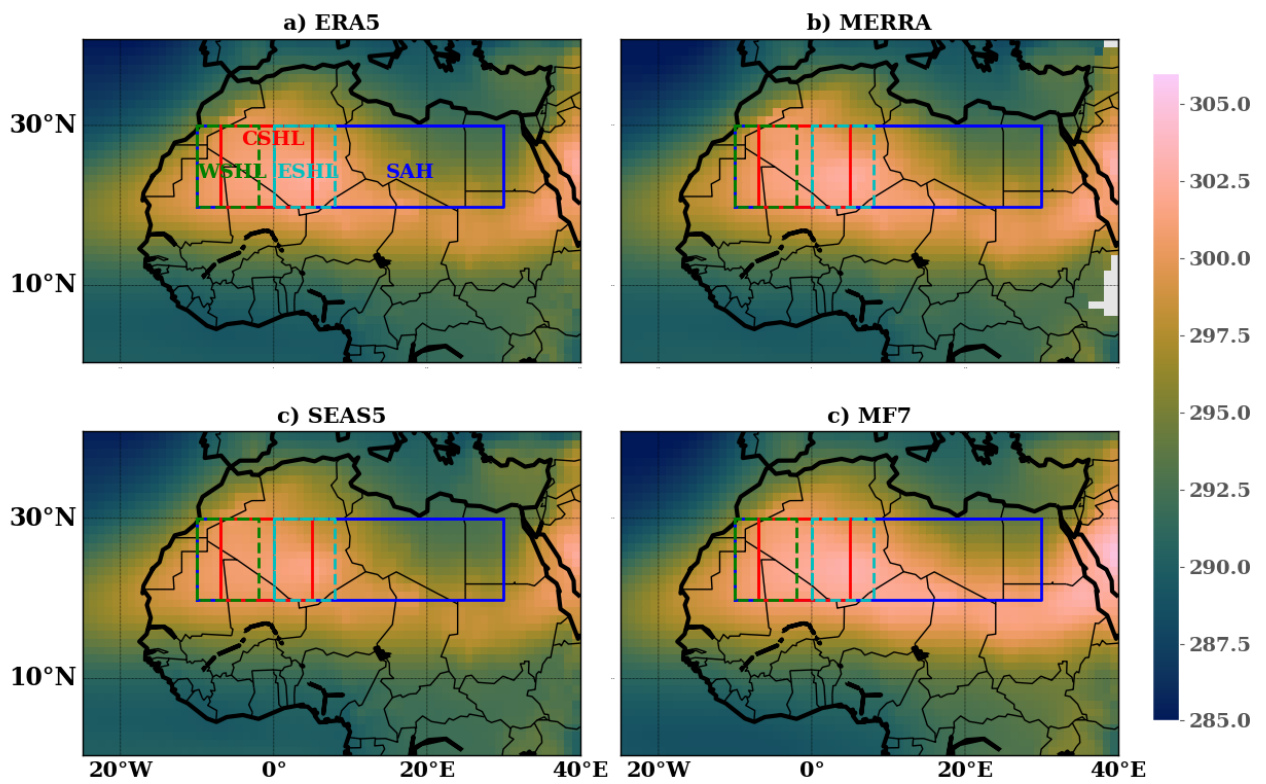


Figure S2. Climatology of the SHL from 1993-2016 during the JJAS period : a) ERA5 , b) MERRA, c) SEAS5 and d) MF7 respectively. The boxes are the same as in Fig.2; the color bar indicates T850 in degree Kelvin. The computation was made using the ensemble mean for seasonal forecast models.

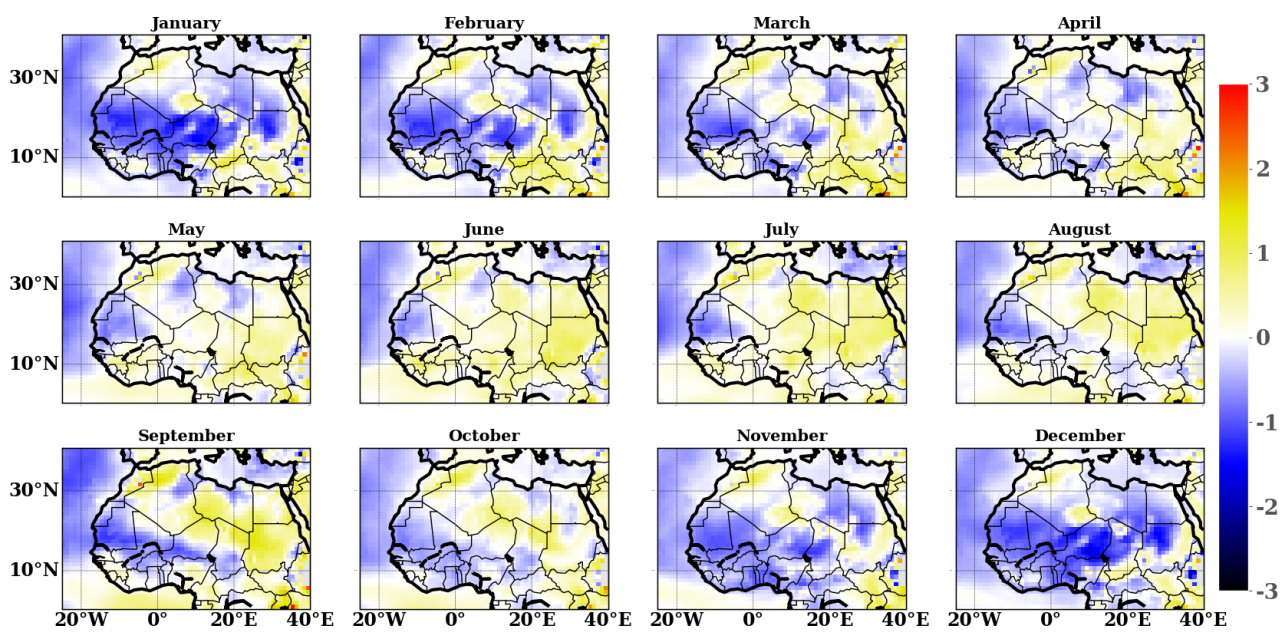


Figure S3. Differences between ERA5 and MERRA reanalyses over the period 1993-2016 during the season. The color bar indicates the bias value in Kelvin. Y-axis indicates latitudes and X-axis the longitudes of our domain.

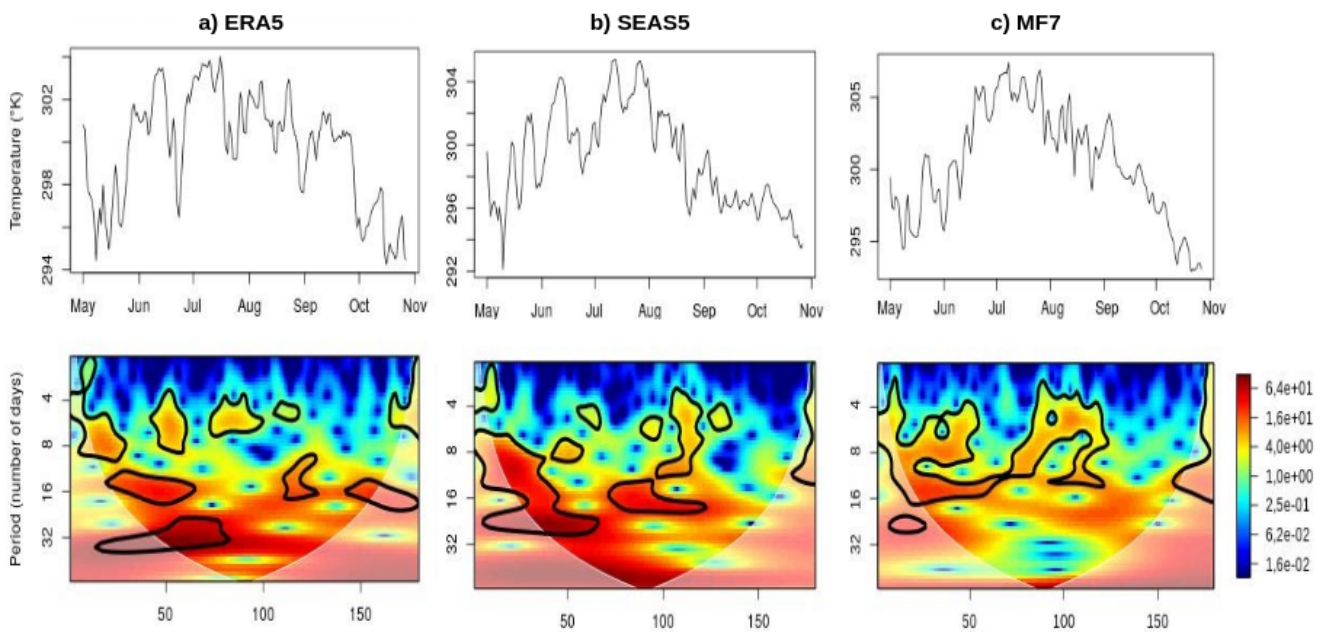


Figure S4. Wavelet Analysis on the temperature signal over the central SHL box when the models have been launched in May respectively for: **a) ERA5**, **b) SEAS5** and **c) MF7** for the year 2016. The above plots represent the temperature time series and the bottom plots the corresponding wavelet decomposition. In the upper plots, the X-axis represents the time (days) and the Y-axis indicates the temperature in degree Kelvin. In wavelet decomposition, the X-axis indicates the time (days) and the Y-axis the frequency or period (days). The color bar represents the intensity of the wavelet, the values are normalized. The computation was realized using the unperturbed member for the ensemble forecast models.

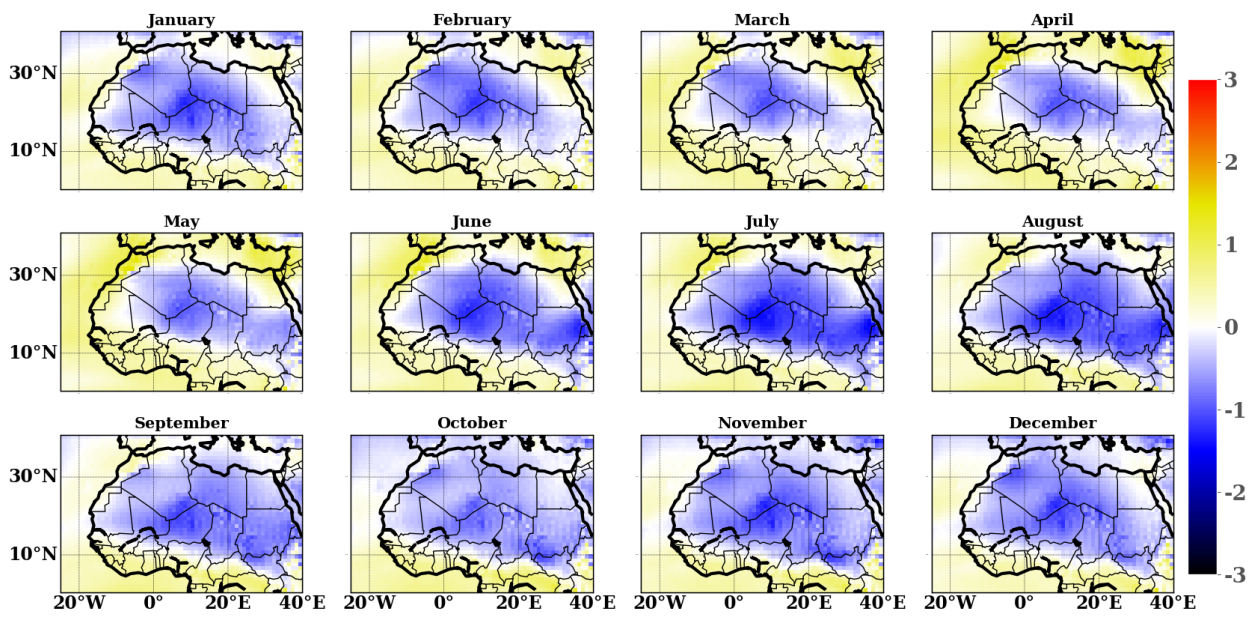


Figure S5. Climatology of monthly bias temperature over the Sahara region during 1981-2016 between SEAS5 and ERA5. The bias is computed using diurnal cycle temperature (mean between temperature at 00:00 and 12:00 UTC). The computation was made using the ensemble mean member of the models. The color bar indicates the bias value in Kelvin. Y-axis indicates latitudes and X-axis the longitudes of our domain.

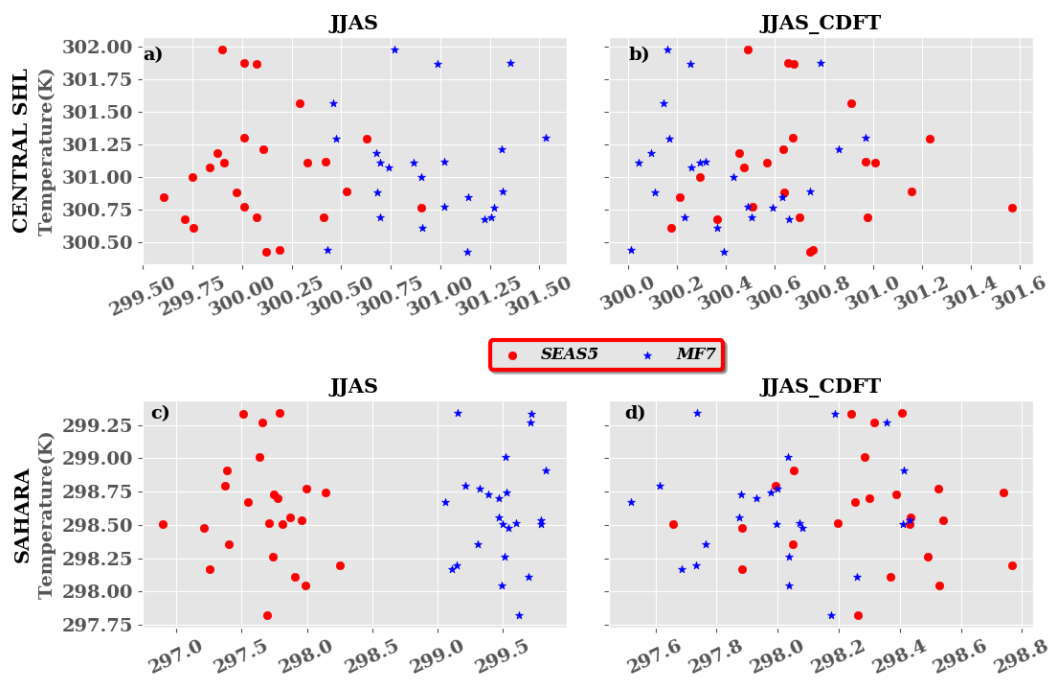


Figure S6. Analysis of the correlation between reanalysis ERA5 and seasonal forecast models during the JJAS period from 1993-2016 with an initialization of the models on the 1st of June over: **a), b)** central SHL box and **c), d)** Sahara. Red points and blue stars represent the corresponding forecast for a given temperature in ERA5 respectively for SEAS5 and MF7. JJAS and JJAS_CDFT refer to the [June, July, August, September] period for SEAS5, MF7 raw and corrected forecasts respectively. The computation was made just using the unperturbed member of the ensemble forecast models.

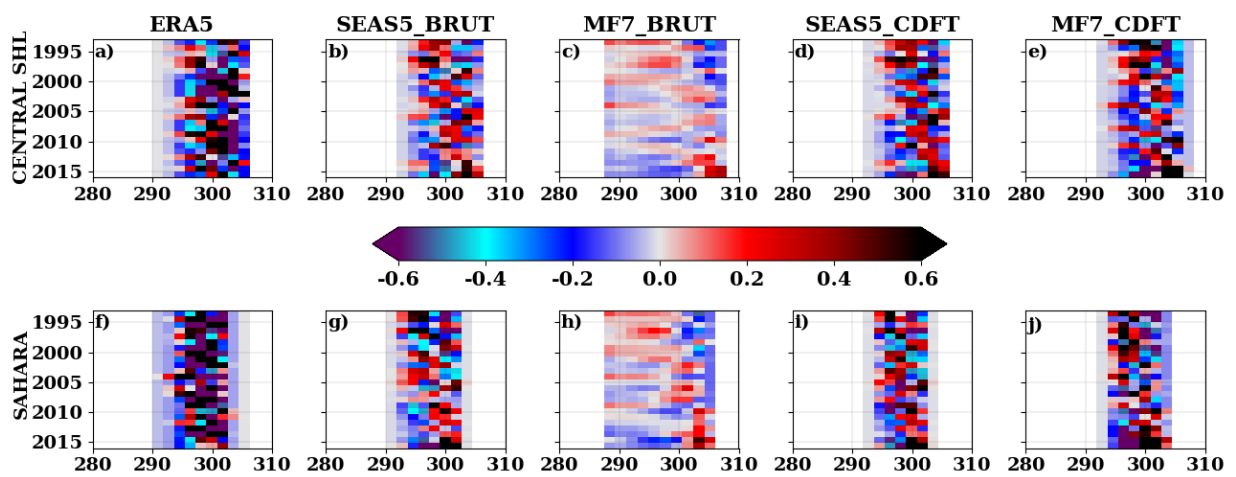


Figure S7. Anomaly of temperature occurrence over JJAS period during 1993-2016 over: a) - e) central SHL box and f) - j) Sahara respectively. "ERA5", "SEAS5_BRUT", "MF7_BRUT" here correspond to the anomaly of the SHL using reanalysis data, SEAS5 and MF7 raw climate forecasts respectively. "SEAS5_CDFT", "MF7_CDFT" refer to the anomaly of the SHL using SEAS5 and MF7 corrected forecasts respectively. The computation was made using the ensemble member of the forecast models. The X-axis represents the temperature in degree Kelvin and Y-axis the time in year. The color bar indicates the anomaly of occurrence values (no unit).

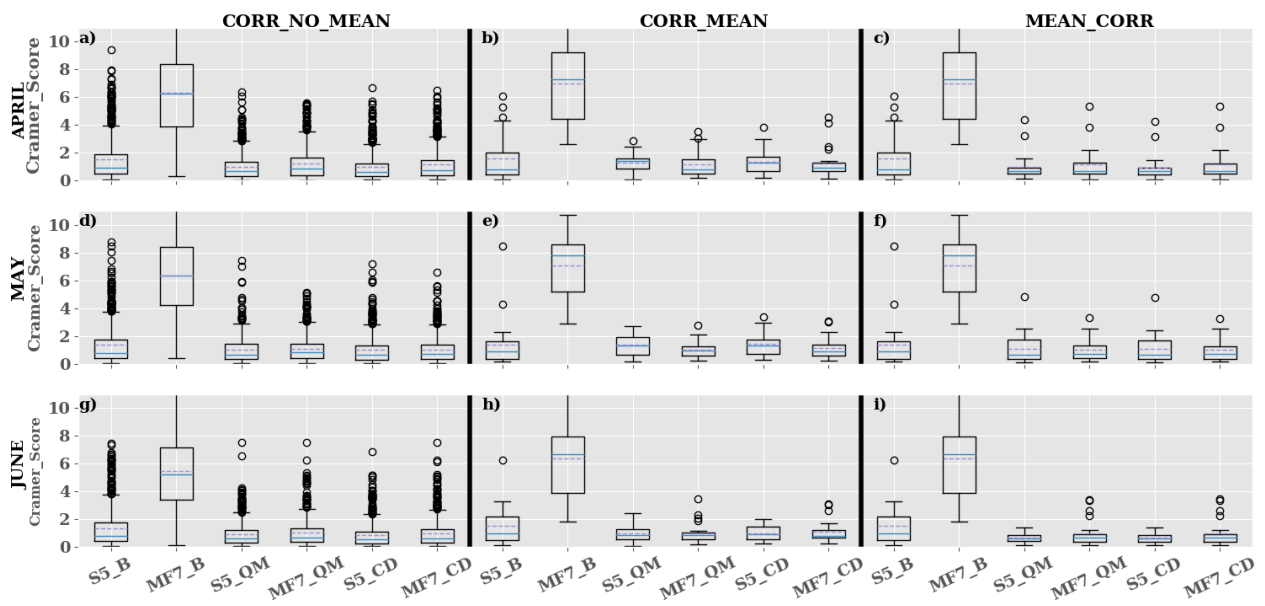


Figure S8. Bias Correction evaluation using Cramer Von Mises score over JJAS period during 1993-2016 over the Sahara at different initialization months: a) - c) April, d) - f) May and g) - i) June respectively. "CORR_NO_MEAN", "CORR_MEAN" and "MEAN_CORR" methods are well described in section 3.4. "S5_B", "S5_CD", "S5_QM" represent the Cramer score computed using respectively SEAS5 raw forecasts, SEAS5 corrected with CDF-t and QMAP methods. Idem for "MF7_B", "MF7_CD", "MF7_QM" with the MF7 model. Y-axis indicates the Cramer score and X-axis the different products used for the computation of Cramer score.

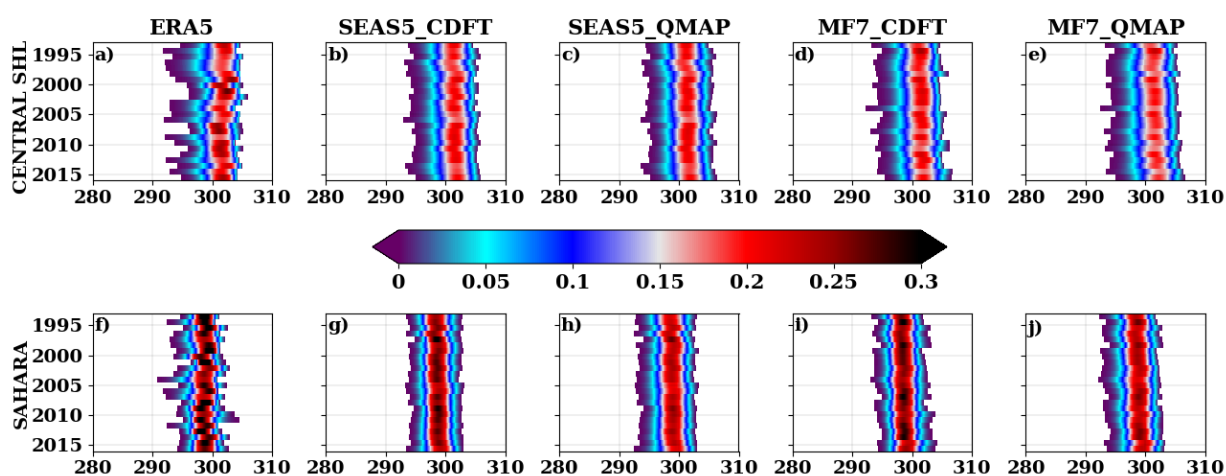


Figure S9. Distribution of yearly temperature over JJAS period during 1993-2016 respectively over: **a) - e)** central SHL and **f) - j)** Sahara. "ERA5", "SEAS5_CDFT", "MF7_CDFT" here correspond to the intensity of the SHL using respectively reanalysis data, SEAS5 and MF7 corrected forecasts with CDF-t method. "SEAS5_QMAP", "MF7_QMAP" refer to the intensity of the SHL using respectively SEAS5 and MF7 corrected forecasts with QMAP method. The computation was made using the ensemble member of the forecast models. Y-axis indicates time in year and X-axis respectively time in year and temperature in degree Kelvin. The color bar in each case indicates the probability of occurrence.




Figure S10. Evolution of the yearly mean temperature during the JJAS period for June lead time 0 (models initialization on June for the JJAS period). "MF7_CSHL", "SEAS5_CSHL", "ERA5_CSHL" and "MF7_S", "SEAS5_S", "ERA5_S" represent respectively the seasonal forecasts for MF7 and SEAS5, and the reanalyses ERA5 over central SHL box and the Sahara region. The computation was made using the raw forecasts and the ensemble members for MF7 and SEAS5. The X-axis represents the time in year and the Y-axis indicates the temperature in degree Kelvin.

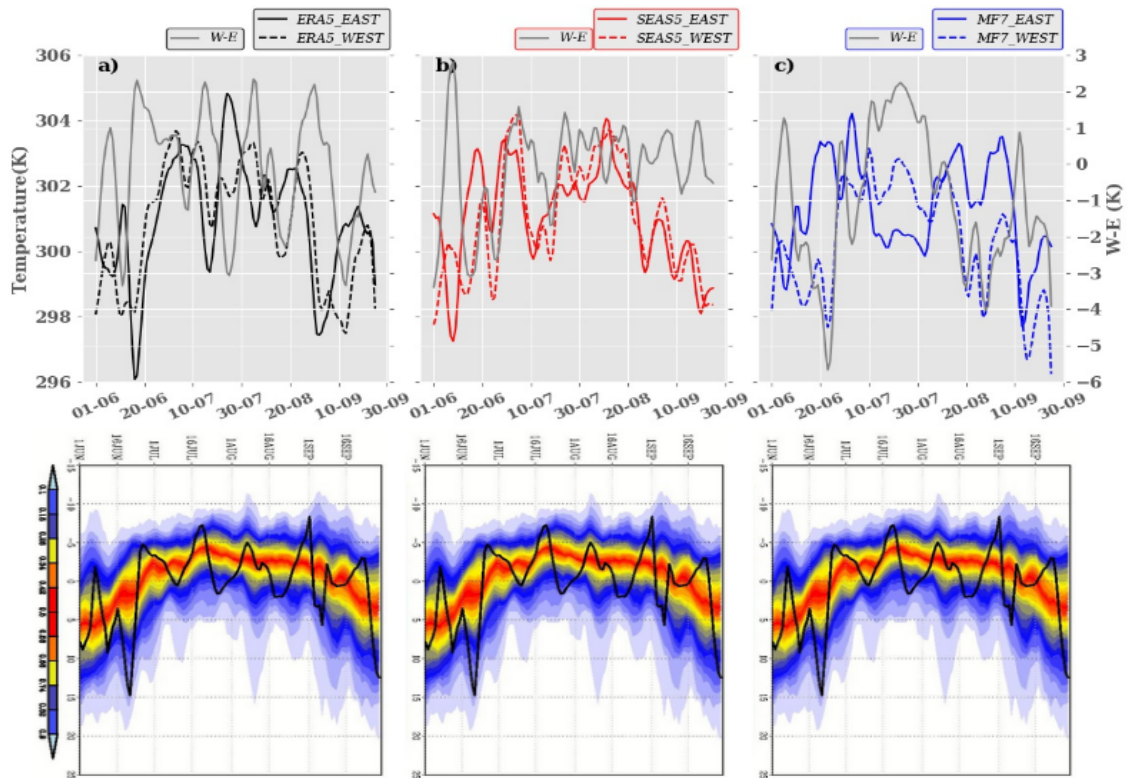


Figure S11. Detection method of the East and West SHL components using the dipole approach for the year 2005 at June lead time 0 respectively for: **a)** ERA5, **b)** SEAS5, **c)** MF7. "ERA5_EAST", "SEAS5_EAST", "MF7_EAST" represent the HLE computed respectively from ERA5, SEAS5 and MF7. "ERA5_WEST", "SEAS5_WEST", "MF7_WEST" represent the HLW computed respectively from ERA5, SEAS5 and MF7. The gray line represents the dipole for each product ("W - E"). The bottom panel represents the evolution of the seasonal SHL location with respect to the barycenter (black line). The first and second Y-axis indicate respectively the temperature and the dipole values in degree Kelvin. X-axis indicates the time (days). The computation was made using the unperturbed member of the ensemble models.

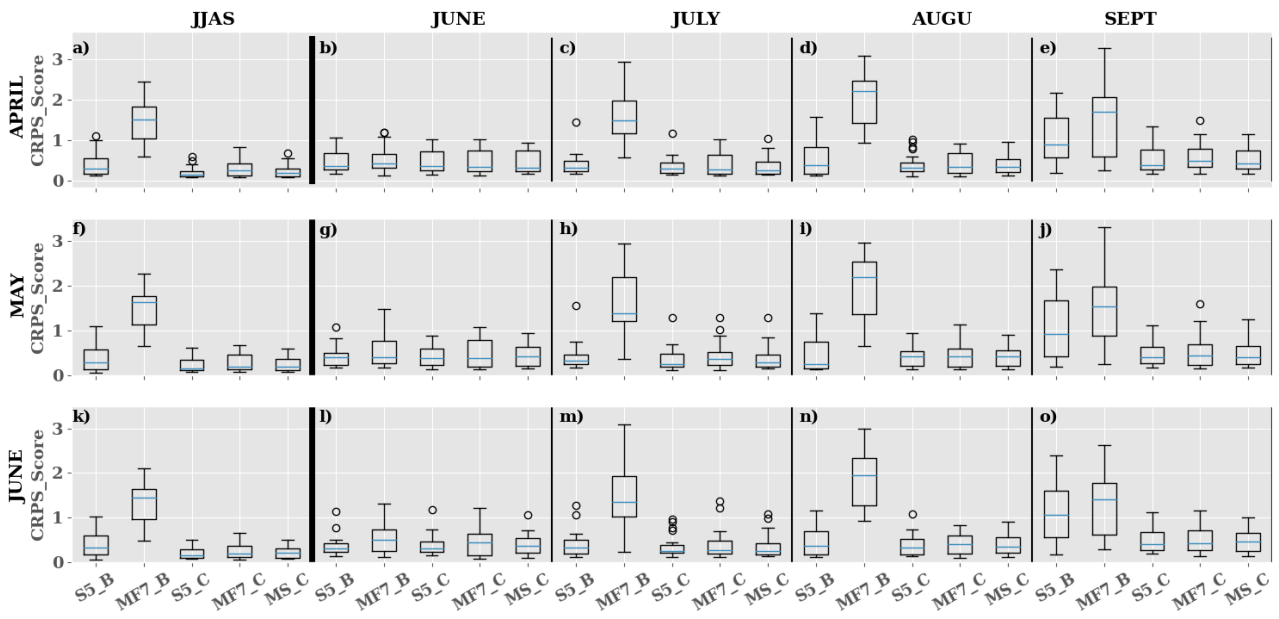


Figure S12. Evaluation of the interannual variability of the SHL over JJAS period and separately on June, July, August, September during 1993-2016 using monthly mean T850 over the Sahara at different lead times: **a) - e)** April, **f) - j)** May and **k) - o)** June respectively. "S5_B", "SS5_C" represent respectively the CRPS score evaluated using raw SEAS5 forecasts and SEAS5 corrected forecasts with CDF-t method. Idem for "MF7_B", "MF7_C" with the MF7 model. "MS_C" represents the CRPS score evaluated on the multi-model formed by SEAS5 and MF7 corrected forecasts with the CDF-t method. The computation was made using the ensemble member both for corrected and raw forecasts. The Y-axis indicates the CRPS score values and X-axis, the data type used for the computation of the CRPS.

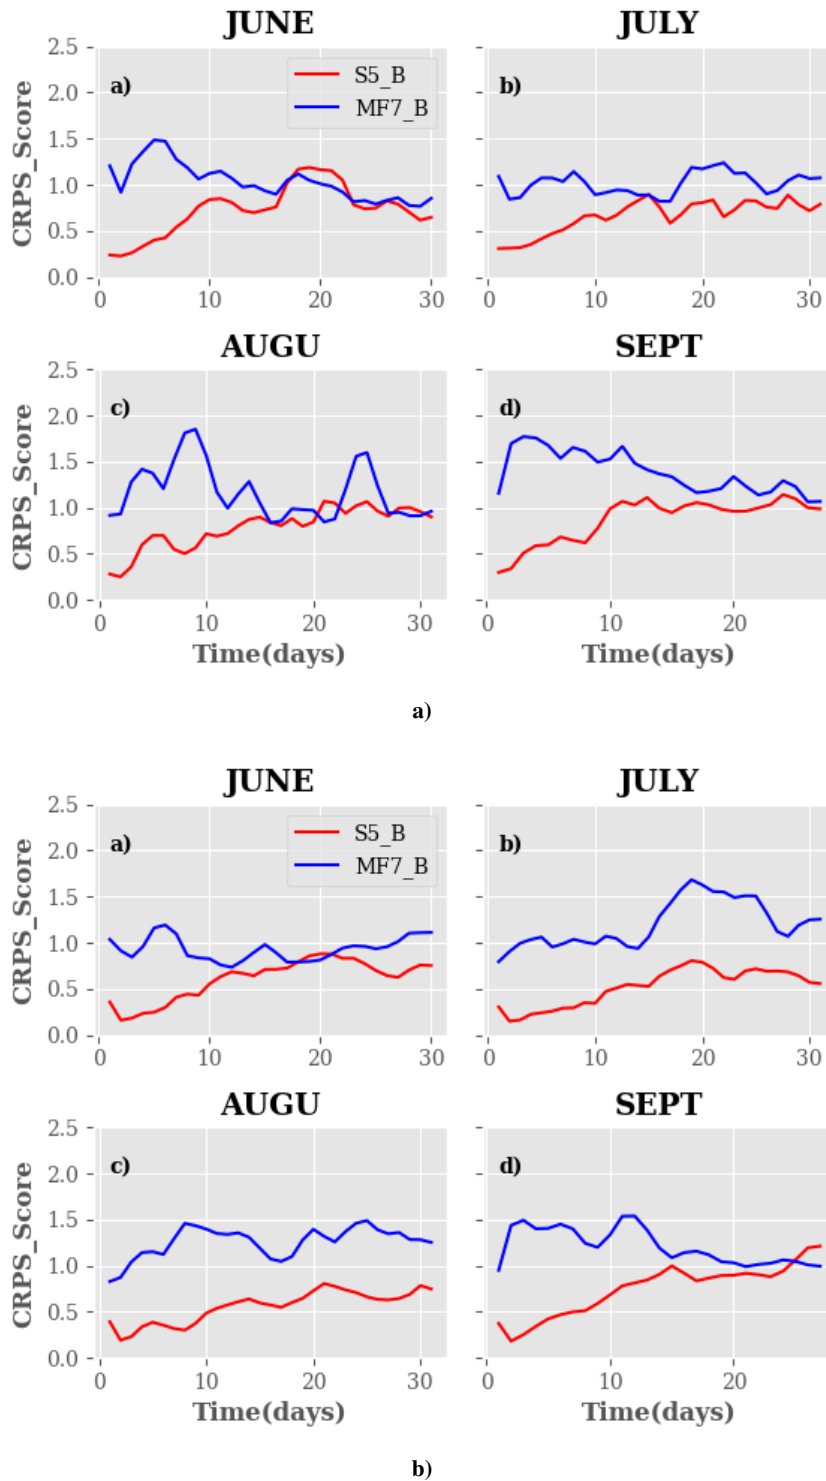
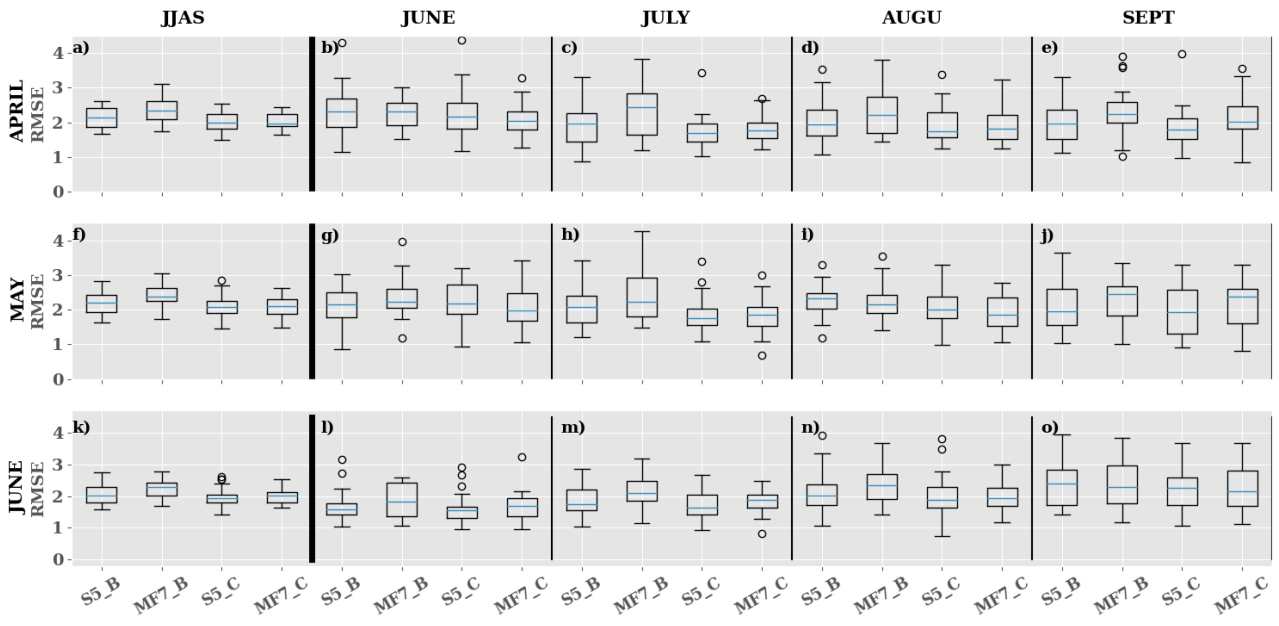
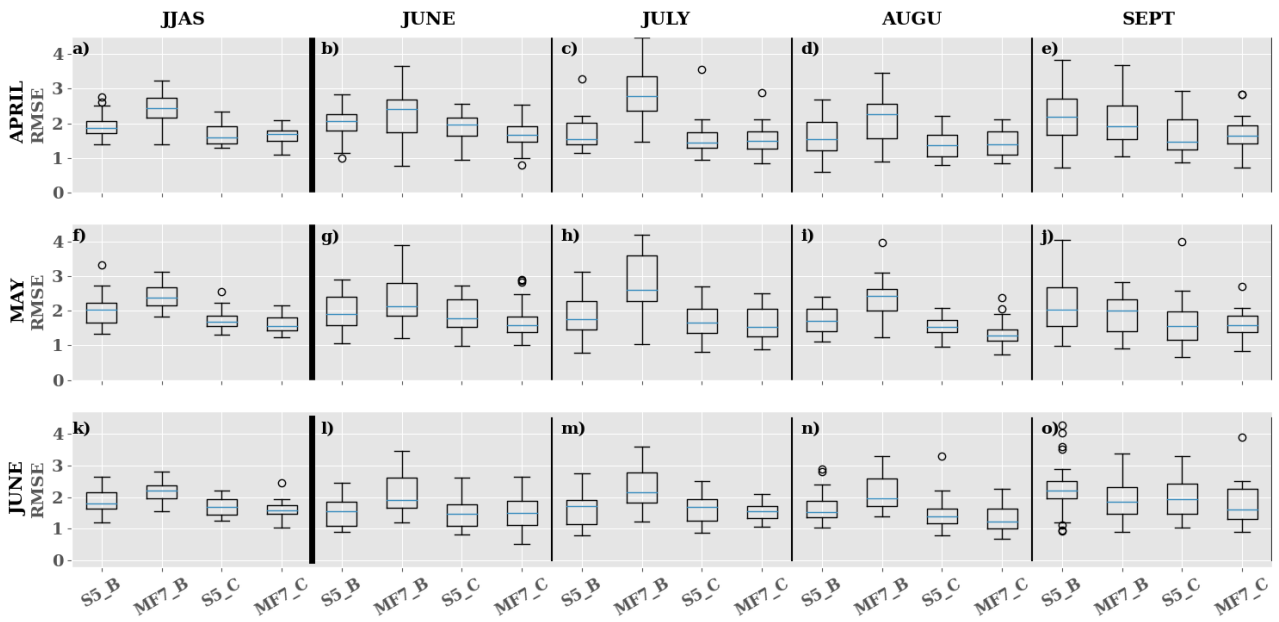


Figure S13. Evaluation of the interannual variability of the SHL in seasonal forecast models (SEAS5, MF7) separately on June, July, August, September at lead time 0 during the period 1993-2016 using daily T850 over : a) Central SHL and b) Sahara. "S5_B" / "MF7_B" represent respectively the raw SEAS5/MF7 forecasts. The computation was made using the ensemble member for the seasonal models. The Y-axis indicates the CRPS score values and the X-axis, the time in days.



a)



b)

Figure S14. Evaluation of the interannual variability of the SHL over the JJAS period and separately on June, July, August, September during 1993-2016 using daily T850 over : a) Central SHL and b) Sahara at different lead times: a) - e) April, f) - j) May and k) - o) June respectively. "S5_B"/"S5_C" represent respectively the RMSE metric evaluated using raw/corrected SEAS5 forecasts. Idem for "MF7_B", "MF7_C" with the MF7 model. The computation was made using the unperturbed member both for the corrected and raw forecasts. The Y-axis indicates the RMSE metric values.

a) CORRELATION using Daily T850								
	JUNE		JULY		AUGU		SEPT	
	CSHL	SAH	CSHL	SAH	CSHL	SAH	CSHL	SAH
SEAS5	0.5	0.30	0.31	0.33	0.4	0.42	0.5	0.48
MF7	0.52	0.27	0.23	0.28	0.35	0.30	0.51	0.43

b) CORRELATION using monthly mean T850								
	JUNE		JULY		AUGU		SEPT	
	CSHL	SAH	CSHL	SAH	CSHL	SAH	CSHL	SAH
SEAS5	0.61	0.39	0.25	0.44	0.18	0.50	0.43	0.55
MF7	0.38	0.32	0.21	0.29	0.34	0.61	0.46	0.37

Figure S15. Analysis of the correlation between the seasonal forecast models and ERA5 separately for June, July, August and September at lead time 0 using : a) daily T850 and b) mean monthly T850. "SEAS5" / "MF7" represent respectively the raw SEAS5/MF7 forecasts. The computation was made using the unperturbed member for the seasonal forecast models.

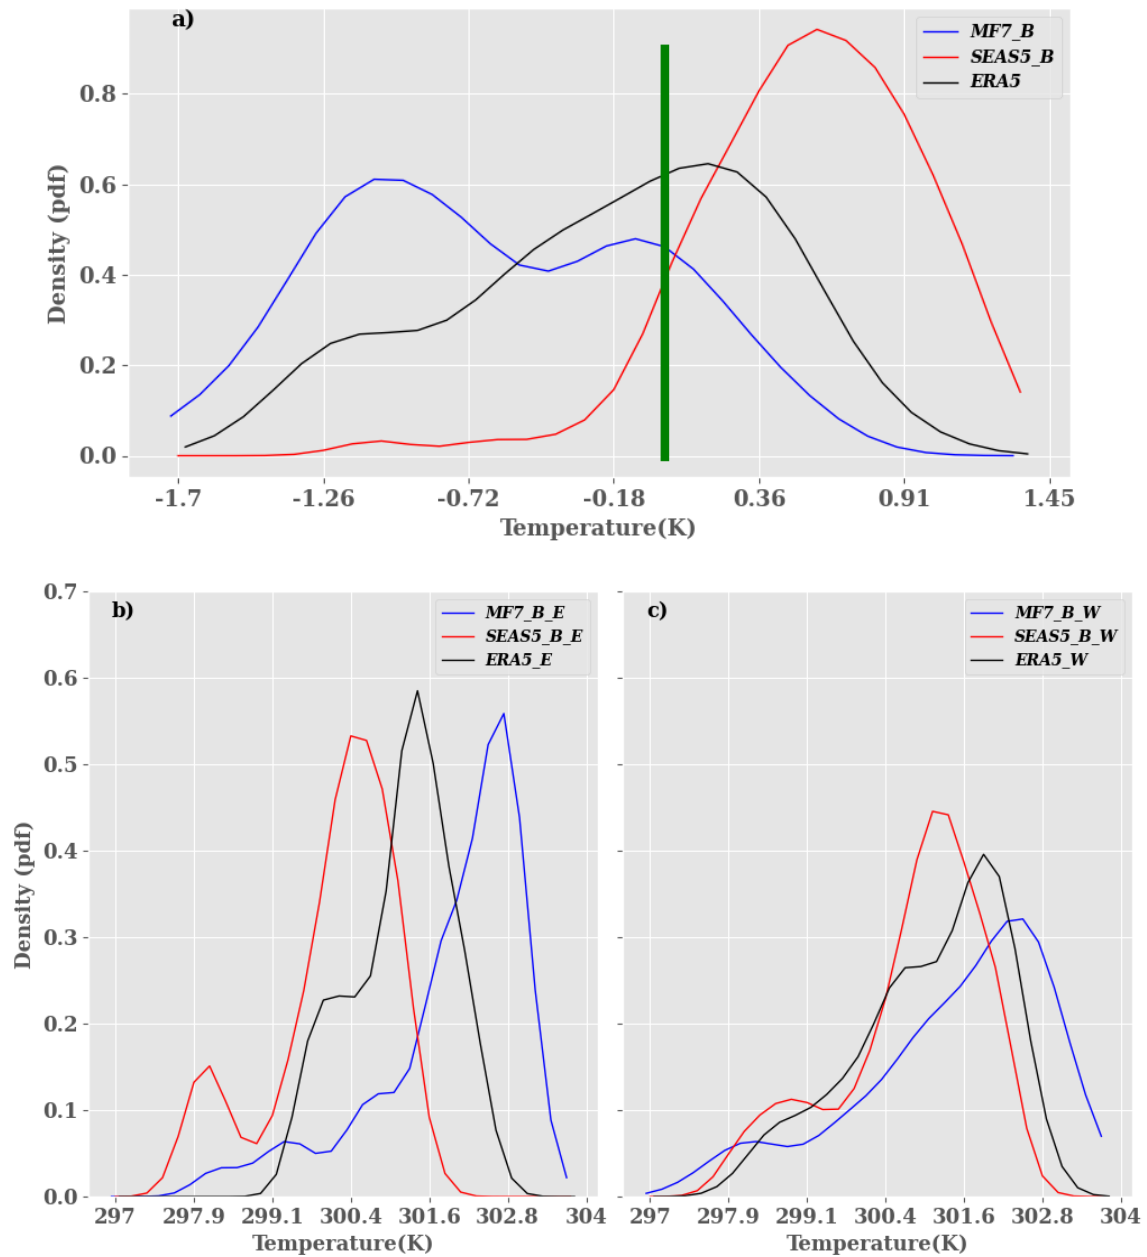


Figure S16. Distribution of the climatology over the period 20th June – 17th September from 1993 to 2016 at June lead time 0 for: **a)** the dipole which represents the difference between heat low West and heat low East, **b)** Heat low East and **c)** Heat low West. MF7_B and SEAS5_B refer respectively to the MF7/SEAS5 raw forecasts. "ERA5_E", "MF7_B_E" and "SEAS5_B_E" refer respectively to the HLE in the reanalyses, MF7/SEAS5 raw forecasts. "ERA5_W", "MF7_B_W" and "SEAS5_B_W" refer respectively to the HLW in the reanalyses, MF7/SEAS5 raw forecasts. Y-axis indicates the probability of occurrence and X-axis the temperature in degree Kelvin. The vertical green bar represents the boundary between the HLE and HLW phases. The analysis was carried out using the unperturbed member.

Bibliographie

- Heatwaves and health : guidance on warning-system development*. 2015. URL http://www.who.int/globalchange/publications/WMO_WHO_Heat_Health_Guidance_2015.pdf. OCLC : 939555806.
- R. Akbani, S. Kwek, and N. Japkowicz. Applying support vector machines to imbalanced datasets. In *Machine Learning : ECML 2004 : 15th European Conference on Machine Learning, Pisa, Italy, September 20-24, 2004. Proceedings 15*, pages 39–50. Springer, 2004.
- L. Alexander. Extreme heat rooted in dry soils. *Nature Geoscience*, 4(1) :12–13, 2011. Publisher : Nature Publishing Group.
- B. G. Anderson and M. L. Bell. Weather-related mortality : how heat, cold, and heat waves affect mortality in the united states. *Epidemiology (Cambridge, Mass.)*, 20(2) :205, 2009.
- T. Anjali, K. Chandini, K. Anoop, and V. Lajish. Temperature prediction using machine learning approaches. In *2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)*, volume 1, pages 1264–1268. IEEE, 2019.
- S. B. H. S. Asadollah, N. Khan, A. Sharafati, S. Shahid, E.-S. Chung, and X.-J. Wang. Prediction of heat waves using meteorological variables in diverse regions of iran with advanced machine learning models. *Stochastic environmental research and risk assessment*, pages 1–16, 2021.
- D. O. Åström, F. Bertil, and R. Joacim. Heat wave impact on morbidity and mortality in the elderly population : a review of recent studies. *Maturitas*, 69(2) :99–105, 2011.
- B. Azari, K. Hassan, J. Pierce, and S. Ebrahimi. Evaluation of machine learning methods application in temperature prediction. *Environ Eng*, 8 :1–12, 2022.

- L. Bai, G. Ding, S. Gu, P. Bi, B. Su, D. Qin, G. Xu, and Q. Liu. The effects of summer temperature and heat waves on heat-related illness in a coastal city of china, 2011–2013. *Environmental research*, 132 :212–219, 2014.
- J. Barbier, F. Guichard, D. Bouniol, F. Couvreur, and R. Roehrig. Detection of intraseasonal large-scale heat waves : Characteristics and historical trends during the sahelian spring. *Journal of Climate*, 31(1) :61–80, 2018.
- L. Batté, C. Ardilouze, and M. Déqué. Forecasting west african heat waves at subseasonal and seasonal time scales. 146(3) :889–907, 2018. ISSN 1520-0493, 0027-0644. doi : 10.1175/MWR-D-17-0211.1. URL <https://journals.ametsoc.org/view/journals/mwre/146/3/mwr-d-17-0211.1.xml>. Publisher : American Meteorological Society Section : Monthly Weather Review.
- M. Beniston, M. Stoffel, and S. Guillet. Comparing observed and hypothetical climates as a means of communicating to the public and policymakers : The case of european heatwaves. 67 :27–34, 2017. ISSN 14629011. doi : 10.1016/j.envsci.2016.11.008. URL <https://linkinghub.elsevier.com/retrieve/pii/S1462901116302465>.
- K. Błażejczyk, M. Kuchcik, A. Błażejczyk, P. Milewski, and J. Szmyd. Assessment of urban thermal stress by utci–experimental and modelling studies : an example from poland. *DIE ERDE–Journal of the Geographical Society of Berlin*, 145(1-2) :16–33, 2014.
- G. Boschat, A. Pezza, I. Simmonds, S. Perkins, T. Cowan, and A. Purich. Large scale and sub-regional connections in the lead up to summer heat wave and extreme rainfall events in eastern australia. *Climate Dynamics*, 44(7) :1823–1840, 2015.
- A. L. Braga, A. Zanobetti, and J. Schwartz. The effect of weather on respiratory and cardiovascular deaths in 12 us cities. *Environmental health perspectives*, 110(9) :859–863, 2002.
- L. Breiman. Random forests. *Machine learning*, 45 :5–32, 2001.

- N. D. Brenowitz and C. S. Bretherton. Prognostic validation of a neural network unified physics parameterization. *Geophysical Research Letters*, 45(12) :6289–6298, 2018.
- G. Ceccherini, S. Russo, I. Amezttoy, A. F. Marchese, and C. Carmona-Moreno. Heat waves in africa 1981–2015, observations and reanalysis. 17(1) :115–125, 2017. ISSN 1684-9981. doi : 10.5194/nhess-17-115-2017. URL <https://nhess.copernicus.org/articles/17/115/2017/>.
- J. G. Charney and J. G. DeVore. Multiple flow equilibria in the atmosphere and blocking. *Journal of Atmospheric Sciences*, 36(7) :1205–1216, 1979.
- A. Chattopadhyay, E. Nabizadeh, and P. Hassanzadeh. Analog forecasting of extreme-causing weather patterns using deep learning. *Journal of Advances in Modeling Earth Systems*, 12(2) : e2019MS001958, 2020.
- F. Chauvin, R. Roehrig, and J.-P. Lafore. Intraseasonal variability of the saharan heat low and its link with midlatitudes. *Journal of Climate*, 23(10) :2544–2561, 2010.
- N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer. Smote : synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16 :321–357, 2002.
- C. Chen, A. Liaw, L. Breiman, et al. Using random forest to learn imbalanced data. *University of California, Berkeley*, 110(1-12) :24, 2004.
- D. Chicco and G. Jurman. The advantages of the matthews correlation coefficient (mcc) over f1 score and accuracy in binary classification evaluation. *BMC genomics*, 21(1) :1–13, 2020.
- J. Colin, M. Déqué, R. Radu, and S. Somot. Sensitivity study of heavy precipitation in limited area model climate simulations : influence of the size of the domain and the use of the spectral nudging technique. *Tellus A : Dynamic Meteorology and Oceanography*, 62(5) :591–604, 2010.
- M. Coughlan. A comparative climatology of blocking action in the two hemispheres. *Australian meteorological magazine Melbourne*, 31(1) :3–13, 1983.

- F. Couvreur, F. Guichard, O. Bock, B. Campistron, J.-P. Lafore, and J.-L. Redelsperger. Synoptic variability of the monsoon flux over west africa prior to the onset. *Quarterly Journal of the Royal Meteorological Society*, 136(S1) :159–173, 2010.
- T. Cowan, A. Purich, S. Perkins, A. Pezza, G. Boschat, and K. Sadler. More frequent, longer, and hotter heat waves for australia in the twenty-first century. 27(15) :5851–5871, 2014.
- M. Déqué. Frequency of precipitation and temperature extremes over france in an anthropogenic scenario : Model results and statistical correction according to observed values. *Global and Planetary Change*, 57(1-2) :16–26, 2007.
- M. Déqué and J. P. Piedelievre. High resolution climate simulation over europe. *Climate dynamics*, 11 :321–339, 1995.
- M. Déqué, P. Marquet, and R. Jones. Simulation of climate change over europe using a global variable resolution general circulation model. *Climate Dynamics*, 14 :173–189, 1998.
- M. Déqué, S. Calmanti, O. B. Christensen, A. D. Aquila, C. F. Maule, A. Haensler, G. Nikulin, and C. Teichmann. A multi-model climate response over tropical africa at+ 2° c. *Climate Services*, 7 : 87–95, 2017.
- C. Di Napoli, F. Pappenberger, and H. L. Cloke. Verification of heat stress thresholds for a health-based heat-wave definition. *Journal of Applied Meteorology and Climatology*, 58(6) :1177–1194, 2019.
- C. Di Napoli, C. Barnard, C. Prudhomme, H. L. Cloke, and F. Pappenberger. ERA5-HEAT : A global gridded historical dataset of human thermal comfort indices from climate reanalysis. 8(1) :2–10, 2021. ISSN 2049-6060. doi : 10.1002/gdj3.102. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/gdj3.102>. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/gdj3.102>.
- T. Ding, W. Qian, and Z. Yan. Changes in hot days and heat waves in china during 1961–2007. *International Journal of Climatology*, 30(10) :1452–1462, 2010.

- F. J. Doblas-Reyes, J. García-Serrano, F. Lienert, A. P. Biescas, and L. R. Rodrigues. Seasonal climate predictability and forecasting : status and prospects. *Wiley Interdisciplinary Reviews : Climate Change*, 4(4) :245–268, 2013.
- A. Dosio and P. Paruolo. Bias correction of the ENSEMBLES high-resolution climate change projections for use by impact models : Evaluation on the present climate. *Journal of Geophysical Research : Atmospheres*, 116, 2011.
- T. Druge, P. Nabat, M. Mallet, and S. Somot. Future euro-mediterranean climate sensitivity to aerosols. In *Geophysical Research Abstracts*, volume 21, 2019.
- C. Drummond, R. C. Holte, et al. C4. 5, class imbalance, and cost sensitivity : why under-sampling beats over-sampling. In *Workshop on learning from imbalanced datasets II*, volume 11, pages 1–8, 2003.
- P. D. Dueben and P. Bauer. Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, 11(10) :3999–4009, 2018.
- M. Déqué, S. Calmanti, O. B. Christensen, A. Dell Aquila, C. F. Maule, A. Haensler, G. Nikulin, and C. Teichmann. A multi-model climate response over tropical africa at +2°C. 7 :87–95, 2017-08-01. ISSN 2405-8807. doi : 10.1016/j.cliser.2016.06.002. URL <https://www.sciencedirect.com/science/article/pii/S240588071630005X>.
- N. Elguindi, S. Somot, M. Déqué, and W. Ludwig. Climate change evolution of the hydrological balance of the mediterranean, black and caspian seas : impact of climate model resolution. *Climate dynamics*, 36 :205–228, 2011.
- M. M. Engdaw, A. P. Ballinger, G. C. Hegerl, and A. K. Steiner. Changes in temperature and heat waves over africa using observational and reanalysis data sets. *International Journal of Climatology*, 42(2) :1165–1180, 2022.
- A. T. Evan, C. Flamant, C. Lavaysse, C. Kocha, and A. Saci. Water vapor–forced greenhouse war-

- ming over the sahara desert and the recent recovery from the sahelian drought. *Journal of Climate*, 28(1) :108–123, 2015.
- C. M. N. Fall, C. Lavaysse, M. S. Drame, G. Panthou, and A. T. Gaye. Wet and dry spells in senegal : comparison of detection based on satellite products, reanalysis, and in situ estimates. *Natural Hazards and Earth System Sciences*, 21(3) :1051–1069, 2021.
- E. M. Fischer and C. Schär. Consistent geographical patterns of changes in high-impact european heatwaves. *Nature geoscience*, 3(6) :398–403, 2010.
- E. M. Fischer and C. Schär. Consistent geographical patterns of changes in high-impact european heatwaves. 3(6) :398–403, 2010. Publisher : Nature Publishing Group.
- E. M. Fischer, S. I. Seneviratne, D. Lüthi, and C. Schär. Contribution of land-atmosphere coupling to recent european summer heat waves. *Geophysical Research Letters*, 34(6), 2007a. Publisher : Wiley Online Library.
- E. M. Fischer, S. I. Seneviratne, P. L. Vidale, D. Lüthi, and C. Schär. Soil moisture–atmosphere interactions during the 2003 european summer heat wave. *Journal of Climate*, 20(20) :5081–5099, 2007b.
- M. Fisher and E. Andersson. Developments in 4d-var and kalman filtering. 2001.
- B. Fontaine, S. Janicot, and P.-A. Monerie. Recent changes in air temperature, heat waves occurrences, and atmospheric circulation in northern africa. *Journal of Geophysical Research : Atmospheres*, 118(15) :8536–8552, 2013a.
- B. Fontaine, S. Janicot, and P.-A. Monerie. Recent changes in air temperature, heat waves occurrences, and atmospheric circulation in northern africa. 118(15) :8536–8552, 2013b. ISSN 2169-8996. doi : 10.1002/jgrd.50667. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/jgrd.50667>. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/jgrd.50667>.
- A. Fouillet, G. Rey, F. Laurent, G. Pavillon, S. Bellec, C. Guihenneuc-Jouyaux, J. Clavel, E. Jouglà,

- and D. Hémon. Excess mortality related to the august 2003 heat wave in france. *International archives of occupational and environmental health*, 80(1) :16–24, 2006.
- A. Gasparri and B. Armstrong. The impact of heat waves on mortality. *Epidemiology (Cambridge, Mass.)*, 22(1) :68, 2011.
- P. Gentine, M. Pritchard, S. Rasp, G. Reinaudi, and G. Yacalis. Could machine learning break the convection parameterization deadlock? *Geophysical Research Letters*, 45(11) :5742–5751, 2018.
- A. Gershunov and K. Guirguis. California heat waves in the present and future. 39(18), 2012. Publisher : Wiley Online Library.
- K. Giamalaki, C. Beaulieu, and J. Prochaska. Assessing predictability of marine heatwaves with random forests. *Geophysical Research Letters*, 49(23) :e2022GL099069, 2022.
- A.-L. Gibelin and M. Déqué. Anthropogenic climate change over the mediterranean region simulated by a global variable resolution model. *Climate dynamics*, 20 :327–339, 2003.
- L. Gudmundsson, J. Bremnes, J. Haugen, and T. E. Skaugen. Downscaling rcm precipitation to the station scale using quantile mapping—a comparison of methods. *Hydrology & Earth System Sciences Discussions*, 9(5) :6185–6201, 2012.
- K. H. Guigma, M. Todd, and Y. Wang. Characteristics and thermodynamics of sahelian heatwaves analysed using various thermal indices. *Climate Dynamics*, 55 :3151–3175, 2020a.
- K. H. Guigma, M. Todd, and Y. Wang. Characteristics and thermodynamics of sahelian heatwaves analysed using various thermal indices. 55(11) :3151–3175, 2020b. ISSN 1432-0894. doi : 10.1007/s00382-020-05438-5. URL <https://doi.org/10.1007/s00382-020-05438-5>.
- K. H. Guigma, F. Guichard, M. Todd, P. Peyrille, and Y. Wang. Atmospheric tropical modes are important drivers of sahelian springtime heatwaves. *Climate Dynamics*, 56(5) :1967–1987, 2021a.
- K. H. Guigma, D. MacLeod, M. Todd, and Y. Wang. Prediction skill of sahelian heatwaves out to subseasonal lead times and importance of atmospheric tropical modes of variability. *Climate Dynamics*, 57 :537–556, 2021b.

- S. Hagelin, J. Son, R. Swinbank, A. McCabe, N. Roberts, and W. Tennant. The met office convective-scale ensemble, mogreps-uk. *Quarterly Journal of the Royal Meteorological Society*, 143(708) : 2846–2861, 2017.
- T. Haiden, J. Bidlot, L. Ferranti, P. Bauer, M. Dahoui, M. Janousek, F. Prates, F. Vitart, and D. Richardson. *Evaluation of ECMWF forecasts, including 2014-2015 upgrades*. European Centre for Medium-Range Weather Forecasts, 2015.
- S. Hajat, R. S. Kovats, and K. Lachowycz. Heat-related and cold-related deaths in england and wales : who is at risk? *Occupational and environmental medicine*, 64(2) :93–100, 2007.
- J. W. Hansen, S. J. Mason, L. Sun, and A. Tall. Review of seasonal climate forecasting for agriculture in sub-saharan africa. *Experimental agriculture*, 47(2) :205–240, 2011.
- M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf. Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4) :18–28, 1998.
- H. Hersbach. The era5 atmospheric reanalysis. In *AGU fall meeting abstracts*, volume 2016, pages NG33D–01, 2016.
- H. Hersbach, B. Bell, P. Berrisford, S. Hirahara, A. Horányi, J. Muñoz-Sabater, J. Nicolas, C. Peubey, R. Radu, D. Schepers, A. Simmons, C. Soci, S. Abdalla, X. Abellan, G. Balsamo, P. Bechtold, G. Biavati, J. Bidlot, M. Bonavita, G. De Chiara, P. Dahlgren, D. Dee, M. Diamantakis, R. Dragani, J. Flemming, R. Forbes, M. Fuentes, A. Geer, L. Haimberger, S. Healy, R. J. Hogan, E. Hólm, M. Janisková, S. Keeley, P. Laloyaux, P. Lopez, C. Lupu, G. Radnoti, P. de Rosnay, I. Rozum, F. Vamborg, S. Villaume, and J.-N. Thépaut. The ERA5 global reanalysis. 146(730) :1999–2049, 2020. ISSN 1477-870X. doi : 10.1002/qj.3803. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/qj.3803>. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/qj.3803>.
- M. Hirschi, S. I. Seneviratne, V. Alexandrov, F. Boberg, C. Boroneant, O. B. Christensen, H. Formayer, B. Orlowsky, and P. Stepanek. Observational evidence for soil-moisture impact on hot extremes in southeastern europe. *Nature Geoscience*, 4(1) :17–21, 2011. Publisher : Nature Publishing Group.

- R. Huth. Disaggregating climatic trends by classification of circulation patterns. *International Journal of Climatology : A Journal of the Royal Meteorological Society*, 21(2) :135–153, 2001.
- M.-M. Huynen, P. Martens, D. Schram, M. P. Weijnenberg, and A. E. Kunst. The impact of heat waves and cold spells on mortality rates in the dutch population. *Environmental health perspectives*, 109(5) :463–470, 2001.
- K. Ingram, M. Roncoli, and P. Kirshen. Opportunities and constraints for farmers of west africa to use seasonal precipitation forecasts with burkina faso as a case study. *Agricultural systems*, 74 (3) :331–349, 2002.
- H. Johnson, R. S. Kovats, G. McGregor, J. Stedman, M. Gibbs, H. Walton, L. Cook, and E. Black. The impact of the 2003 heat wave on mortality and hospital admissions in england. *Health Statistics Quarterly*, 25 :6, 2005.
- T. R. Karl and R. W. Knight. The 1995 chicago heat wave : How likely is a recurrence? 78(6) :1107–1120, 1997. ISSN 0003-0007, 1520-0477. doi : 10.1175/1520-0477(1997)078<1107:TCHWHL>2.0.CO;2. URL https://journals.ametsoc.org/view/journals/bams/78/6/1520-0477_1997_078_1107_tchwhl_2_0_co_2.xml. Publisher : American Meteorological Society Section : Bulletin of the American Meteorological Society.
- P. Katsafados, A. Papadopoulos, G. Varlas, E. Papadopoulou, and E. Mavromatidis. Seasonal predictability of the 2010 russian heat wave. *Natural Hazards and Earth System Sciences*, 14(6) : 1531–1542, 2014.
- L.-A. Kautz, O. Martius, S. Pfahl, J. G. Pinto, A. M. Ramos, P. M. Sousa, and T. Woollings. Atmospheric blocking and weather extremes over the euro-atlantic sector—a review. *Weather and climate dynamics*, 3(1) :305–336, 2022.
- F. Khan and J. Pilz. Statistical methodology for evaluating process-based climate models. In *Climate Change and Global Warming*. IntechOpen, 2018.

- N. Khan, S. Shahid, L. Juneng, K. Ahmed, T. Ismail, and N. Nawaz. Prediction of heat waves in pakistan using quantile regression forests. *Atmospheric research*, 221 :1–11, 2019.
- N. Khan, S. Shahid, T. B. Ismail, and F. Behlil. Prediction of heat waves over pakistan using support vector machine algorithm in the context of climate change. *Stochastic Environmental Research and Risk Assessment*, 35 :1335–1353, 2021.
- V. V. Kharin, F. W. Zwiers, X. Zhang, and G. C. Hegerl. Changes in temperature and precipitation extremes in the ipcc ensemble of global coupled model simulations. *Journal of Climate*, 20(8) : 1419–1444, 2007.
- E. J. Kirkland and E. J. Kirkland. Bilinear interpolation. *Advanced Computing in Electron Microscopy*, pages 261–263, 2010.
- R. S. Kovats and S. Hajat. Heat stress and public health : a critical review. *Annu. Rev. Public Health*, 29 :41–55, 2008.
- M. Kubat, S. Matwin, et al. Addressing the curse of imbalanced training sets : one-sided selection. In *icml*, volume 97, page 179. Citeseer, 1997.
- M. Kueh, C. Lin, Y. Chuang, Y. Sheng, and Y. Chien. Climate variability of heat waves and their associated diurnal temperature range variations in taiwan. *Environmental Research Letters*, 12 (7) :074017, 2017.
- Y. Langeron, F. Guichard, R. Roehrig, F. Couvreur, and J. Barbier. The april 2010 north african heatwave : when the water vapor greenhouse effect drives nighttime temperatures. 54(9) : 3879–3905, 2020. ISSN 1432-0894. doi : 10.1007/s00382-020-05204-7. URL <https://doi.org/10.1007/s00382-020-05204-7>.
- N.-C. Lau and M. J. Nath. Model simulation and projection of european heat waves in present-day and future climates. *Journal of Climate*, 27(10) :3713–3730, 2014.

- C. Lavaysse, C. Flamant, S. Janicot, D. J. Parker, J.-P. Lafore, B. Sultan, and J. Pelon. Seasonal evolution of the west african heat low : a climatological perspective. *Climate Dynamics*, 33(2) :313–330, 2009.
- C. Lavaysse, C. Flamant, and S. Janicot. Regional-scale convection patterns during strong and weak phases of the saharan heat low. *Atmospheric Science Letters*, 11(4) :255–264, 2010.
- C. Lavaysse, M. Vrac, P. Drobinski, M. Lengaigne, and T. Vischel. Statistical downscaling of the french mediterranean climate : assessment for present and projection in an anthropogenic scenario. *Natural Hazards and Earth System Sciences*, 12(3) :651–670, 2012.
- C. Lavaysse, C. Cammalleri, A. Dosio, G. van der Schrier, A. Toreti, and J. Vogt. Towards a monitoring system of temperature extremes in europe. *Natural Hazards and Earth System Sciences*, 18(1) :91–104, 2018a.
- C. Lavaysse, C. Cammalleri, A. Dosio, G. van der Schrier, A. Toreti, and J. Vogt. Towards a monitoring system of temperature extremes in europe. 18(1) :91–104, 2018b. ISSN 1561-8633. doi : 10.5194/nhess-18-91-2018. URL <https://nhess.copernicus.org/articles/18/91/2018/>. Publisher : Copernicus GmbH.
- C. Lavaysse, G. Naumann, L. Alfieri, P. Salamon, and J. Vogt. Predictability of the european heat and cold waves. *Climate Dynamics*, 52(3) :2481–2495, 2019.
- C. X. Ling and C. Li. Data mining for direct marketing : Problems and solutions. In *Kdd*, volume 98, pages 73–79, 1998.
- A. Liss, R. Wu, K. K. H. Chui, and E. N. Naumova. Heat-related hospitalizations in older adults : An amplified effect of the first seasonal heatwave. *Scientific reports*, 7(1) :39581, 2017.
- R. Lorenz, E. B. Jaeger, and S. I. Seneviratne. Persistence of heat waves and its link to soil moisture memory. *Geophysical Research Letters*, 37(9), 2010. Publisher : Wiley Online Library.
- M. Lothon, F. Saïd, F. Lohou, and B. Campistron. Observation of the diurnal cycle in the low troposphere of west africa. *Monthly Weather Review*, 136(9) :3477–3500, 2008.

- M. Loughnan. Heatwaves are silent killers. *Geodate*, 27(1) :7–10, 2014.
- R. Lowe, M. García-Díez, J. Ballester, J. Creswick, J.-M. Robine, F. R. Herrmann, and X. Rodó. Evaluation of an early-warning system for heat wave-related mortality in europe : Implications for sub-seasonal to seasonal forecasting and climate services. *International journal of environmental research and public health*, 13(2) :206, 2016.
- G. Luber and M. McGeehin. Climate change and extreme heat events. *American journal of preventive medicine*, 35(5) :429–435, 2008.
- P. Lucas-Picher, E. Brisson, C. Caillaud, A. Alias, P. Nabat, A. Lemonsu, N. Poncet, V. E. C. Hernandez, Y. Michau, A. Doury, et al. Evaluation of the convection-permitting regional climate model cnrm-arome41t1 over northwestern europe. 2022.
- M. E. Mann, S. Rahmstorf, K. Kornhuber, B. A. Steinman, S. K. Miller, and D. Coumou. Influence of anthropogenic climate change on planetary wave resonance and extreme weather events. *Scientific reports*, 7(1) :1–12, 2017.
- D. Maraun. Bias correction, quantile mapping, and downscaling : Revisiting the inflation issue. *Journal of Climate*, 26(6) :2137–2143, 2013.
- A. Marshall, D. Hudson, M. Wheeler, O. Alves, H. Hendon, M. Pook, and J. Risbey. Intra-seasonal drivers of extreme heat over australia in observations and poama-2. *Climate dynamics*, 43 : 1915–1937, 2014.
- M. Matsueda. Predictability of euro-russian blocking in summer of 2010. *Geophysical Research Letters*, 38(6), 2011.
- A. McGovern, K. Elmore, and D. Gagne. li. haupt se, karstens cd, lagerquist r, et al. using artificial intelligence to improve real-time decision-making for high-impact weather. *Bull Amer Meteor Soc*, 98 :2073–90, 2017.
- G. A. Meehl and C. Tebaldi. More intense, more frequent, and longer lasting heat waves in the

- 21st century. 305(5686) :994–997, 2004. Publisher : American Association for the Advancement of Science.
- F. J. Meza, J. W. Hansen, and D. Osgood. Economic value of seasonal climate forecasts for agriculture : review of ex-ante assessments and recommendations for future research. *Journal of applied meteorology and climatology*, 47(5) :1269–1286, 2008.
- P.-A. Michelangeli, M. Vrac, and H. Loukos. Probabilistic downscaling approaches : Application to wind cumulative distribution functions. *Geophysical Research Letters*, 36(11), 2009a.
- P.-A. Michelangeli, M. Vrac, and H. Loukos. Probabilistic downscaling approaches : Application to wind cumulative distribution functions. *Geophysical Research Letters*, 36(11), 2009b.
- G. Miloshevich, B. Cozian, P. Abry, P. Borgnat, and F. Bouchet. Probabilistic forecasts of extreme heatwaves using convolutional neural networks in a regime of lack of data. *Physical Review Fluids*, 8(4) :040501, 2023.
- D. G. Miralles, A. J. Teuling, C. C. Van Heerwaarden, and J. V.-G. De Arellano. Mega-heatwave temperatures due to combined soil desiccation and atmospheric heat accumulation. *Nature geoscience*, 7(5) :345–349, 2014. Publisher : Nature Publishing Group.
- T. R. Moore, H. D. Matthews, C. Simmons, and M. Leduc. Quantifying changes in extreme weather events in response to warmer global temperature. *Atmosphere-ocean*, 53(4) :412–425, 2015.
- V. Moron, B. Oueslati, B. Pohl, S. Rome, and S. Janicot. Trends of mean temperatures and warm extremes in northern tropical africa (1961–2014) from observed and ppca-reconstructed time series. *Journal of Geophysical Research : Atmospheres*, 121(10) :5298–5319, 2016.
- B. Mueller and S. I. Seneviratne. Hot days induced by precipitation deficits at the global scale. *Proceedings of the national academy of sciences*, 109(31) :12398–12403, 2012. Publisher : National Acad Sciences.
- W. Y. N. Naing and Z. Z. Htike. Forecasting of monthly temperature variations using random forests. *ARPJ. Eng. Appl. Sci*, 10(21) :10109–10112, 2015.

- J. R. Nairn and R. G. Fawcett. *Defining heatwaves : heatwave defined as a heat-impact event serving all community and business sectors in Australia*. Centre for Australian Weather and Climate Research, 2013.
- J. R. Nairn and R. J. Fawcett. The excess heat factor : a metric for heatwave intensity and its use in classifying heatwave severity. *International journal of environmental research and public health*, 12(1) :227–253, 2015.
- C. G. Ngoungue Langué, C. Lavaysse, M. Vrac, P. Peyrille, and C. Flamant. Seasonal forecasts of the saharan heat low characteristics : A multi-model assessment. *Weather and Climate Dynamics*, 2(3) :893–912, 2021.
- C. G. Ngoungue Langué, C. Lavaysse, M. Vrac, and C. Flamant. Heat wave monitoring over west african cities : uncertainties, characterization and recent trends. *Natural Hazards and Earth System Sciences*, 23(4) :1313–1333, 2023.
- L. Nicholls and Y. Strengers. Heatwaves, cooling and young children at home : Integrating energy and health objectives. *Energy research & social science*, 39 :1–9, 2018.
- W. S. Noble. What is a support vector machine? *Nature biotechnology*, 24(12) :1565–1567, 2006.
- B. Oueslati, B. Pohl, V. Moron, S. Rome, and S. Janicot. Characterization of heat waves in the sahel and associated physical mechanisms. 30(9) :3095–3115, 2017.
- D. J. Parker, R. R. Burton, A. Diongue-Niang, R. J. Ellis, M. Felton, C. M. Taylor, C. D. Thorncroft, P. Bessemoulin, and A. M. Tompkins. The diurnal cycle of the west african monsoon circulation. *Quarterly Journal of the Royal Meteorological Society : A journal of the atmospheric sciences, applied meteorology and physical oceanography*, 131(611) :2839–2860, 2005.
- S. E. Perkins. A review on the scientific understanding of heatwaves—their measurement, driving mechanisms, and changes at the global scale. 164 :242–267, 2015. Publisher : Elsevier.
- S. E. Perkins and L. V. Alexander. On the measurement of heat waves. 26(13) :4500–4517, 2013.

- S. E. Perkins, L. V. Alexander, and J. R. Nairn. Increasing frequency, intensity and duration of observed global heatwaves and warm spells. 39(20), 2012. ISSN 1944-8007. doi : <https://doi.org/10.1029/2012GL053361>. URL <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2012GL053361>. _eprint : <https://agupubs.onlinelibrary.wiley.com/doi/pdf/10.1029/2012GL053361>.
- S. Perkins-Kirkpatrick, C. White, L. Alexander, D. Argüeso, G. Boschat, T. Cowan, J. Evans, M. Ekström, E. Oliver, A. Phatak, et al. Natural hazards in australia : heatwaves. *Climatic Change*, 139 : 101–114, 2016.
- P. Peyrillé and J.-P. Lafore. An idealized two-dimensional framework to study the west african monsoon. part II : Large-scale advection and the diurnal cycle. *Journal of the atmospheric sciences*, 64(8) :2783–2803, 2007.
- A. B. Pezza, P. Van Rensch, and W. Cai. Severe heat waves in southern australia : synoptic climatology and large scale connections. *Climate Dynamics*, 38 :209–224, 2012.
- C. W. Richardson. Stochastic simulation of daily precipitation, temperature, and solar radiation. *Water resources research*, 17(1) :182–190, 1981.
- A. W. Robertson, S. Kirshner, and P. Smyth. Downscaling of daily rainfall occurrence over northeast brazil using a hidden markov model. *Journal of climate*, 17(22) :4407–4424, 2004.
- P. J. Robinson. On the definition of a heat wave. 40(4) :762–775, 2001. Publisher : American Meteorological Society.
- J. Rocklöv, B. Forsberg, K. Ebi, and T. Bellander. Susceptibility to mortality related to temperature and heat and cold wave duration in the population of stockholm county, sweden. *Global health action*, 7(1) :22737, 2014.
- R. Roehrig. *Variabilité intrasaisonnière de la mousson africaine : caractérisation et modélisation*. PhD thesis, Paris Est, 2010.

- R. Roehrig, F. Chauvin, and J.-P. Lafore. 10–25-day intraseasonal variability of convection over the sahel : A role of the saharan heat low and midlatitudes. *Journal of climate*, 24(22) :5863–5878, 2011.
- C. Roncoli, C. Jost, P. Kirshen, M. Sanon, K. T. Ingram, M. Woodin, L. Somé, F. Ouattara, B. J. Sanfo, C. Sia, et al. From accessing to assessing forecasts : an end-to-end study of participatory climate forecast dissemination in burkina faso (west africa). *Climatic Change*, 92 :433–460, 2009.
- S. Russo, A. Dosio, R. G. Graversen, J. Sillmann, H. Carrao, M. B. Dunbar, A. Singleton, P. Montagna, P. Barbola, and J. V. Vogt. Magnitude of extreme heat waves in present climate and their projection in a warming world. *Journal of Geophysical Research : Atmospheres*, 119(22) :12–500, 2014a.
- S. Russo, A. Dosio, R. G. Graversen, J. Sillmann, H. Carrao, M. B. Dunbar, A. Singleton, P. Montagna, P. Barbola, and J. V. Vogt. Magnitude of extreme heat waves in present climate and their projection in a warming world. 119(22) :12–500, 2014b. Publisher : Wiley Online Library.
- S. Russo, J. Sillmann, and E. M. Fischer. Top ten european heatwaves since 1950 and their occurrence in the coming decades. *Environmental Research Letters*, 10(12) :124003, 2015.
- S. Russo, A. F. Marchese, J. Sillmann, and G. Immé. When will unusual heat waves become normal in a warming africa? *Environmental Research Letters*, 11(5) :054016, 2016a.
- S. Russo, A. F. Marchese, J. Sillmann, and G. Immé. When will unusual heat waves become normal in a warming africa? 11(5) :054016, 2016b. ISSN 1748-9326. doi : 10.1088/1748-9326/11/5/054016. URL <https://doi.org/10.1088/1748-9326/11/5/054016>. Publisher : IOP Publishing.
- S. Salcedo-Sanz, R. Deo, L. Carro-Calvo, and B. Saavedra-Moreno. Monthly prediction of air temperature in australia and new zealand with machine learning algorithms. *Theoretical and applied climatology*, 125 :13–25, 2016.
- S. Scher and G. Messori. Weather and climate forecasting with neural networks : using gene-

- ral circulation models (gcms) with different complexity as a study ground. *Geoscientific Model Development*, 12(7) :2797–2809, 2019.
- T. Schneider, S. Lan, A. Stuart, and J. Teixeira. Geophysical research letters earth system modeling 2.0 : a blueprint for models that learn from observations and targeted high-resolution simulations. *Wiley Online Libr.*, 44(12), 2017.
- R. Schoetter, J. Cattiaux, and H. Douville. Changes of western european heat wave characteristics projected by the CMIP5 ensemble. 45(5) :1601–1616, 2015. ISSN 1432-0894. doi : 10.1007/s00382-014-2434-8. URL <https://doi.org/10.1007/s00382-014-2434-8>.
- M. A. Semenov and E. M. Barrow. Use of a stochastic weather generator in the development of climate change scenarios. *Climatic change*, 35(4) :397–414, 1997.
- M. A. Semenov, R. J. Brooks, E. M. Barrow, and C. W. Richardson. Comparison of the wgen and lars-wg stochastic weather generators for diverse climates. *Climate research*, 10(2) :95–107, 1998.
- D. Shaposhnikov, B. Revich, T. Bellander, G. B. Bedada, M. Bottai, T. Kharkova, E. Kvasha, E. Lezina, T. Lind, E. Semutnikova, and G. Pershagen. Mortality related to air pollution with the moscow heat wave and wildfire of 2010. *Epidemiology (Cambridge, Mass.)*, 25(3) :359–364, 2014. ISSN 1044-3983. doi : 10.1097/EDE.0000000000000090. URL <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3984022/>.
- S. Singh and P. Gupta. Comparative study id3, cart and c4. 5 decision tree algorithm : a survey. *International Journal of Advanced Information Science and Technology (IJAIST)*, 27(27) :97–103, 2014.
- T. T. Smith, B. F. Zaitchik, and J. M. Gohlke. Heat waves in the united states : definitions, patterns and trends. 118(3) :811–825, 2013. ISSN 1573-1480. doi : 10.1007/s10584-012-0659-2. URL <https://doi.org/10.1007/s10584-012-0659-2>.
- K. E. Smoyer-Tomic, R. Kuhn, and A. Hudson. Heat wave hazards : an overview of heat wave impacts in canada. *Natural hazards*, 28(2) :465–486, 2003.

- R. G. Steadman. The assessment of sultriness. part i : A temperature-humidity index based on human physiology and clothing science. 18(7) :861–873, 1979a. ISSN 1520-0450. doi : 10.1175/1520-0450(1979)018<0861:TAOSPI>2.0.CO;2. URL https://journals.ametsoc.org/view/journals/apme/18/7/1520-0450_1979_018_0861_taospi_2_0_co_2.xml. Publisher : American Meteorological Society Section : Journal of Applied Meteorology and Climatology.
- R. G. Steadman. The assessment of sultriness. part II : Effects of wind, extra radiation and barometric pressure on apparent temperature. 18(7) :874–885, 1979b. ISSN 0021-8952. URL <https://www.jstor.org/stable/26179217>. Publisher : American Meteorological Society.
- R. G. Steadman. A universal scale of apparent temperature. *Journal of Applied Meteorology and Climatology*, 23(12) :1674–1687, 1984.
- M. Stefanon, F. D’Andrea, and P. Drobinski. Heatwave classification over europe and the mediterranean region. 7(1) :014023, 2012. Publisher : IOP Publishing.
- P. Stott. How climate change affects extreme weather events. *Science*, 352(6293) :1517–1518, 2016.
- R. Stull. Wet-bulb temperature from relative humidity and air temperature. *Journal of applied meteorology and climatology*, 50(11) :2267–2269, 2011.
- B. Sultan and S. Janicot. The west african monsoon dynamics. part II : The “preonset” and “onset” of the summer monsoon. *Journal of climate*, 16(21) :3407–3427, 2003.
- B. Sultan, B. Barbier, J. Fortilus, S. M. Mbaye, and G. Leclerc. Estimating the potential economic value of seasonal forecasts in west africa : A long-term ex-ante assessment in senegal. *Weather, Climate, and Society*, 2(1) :69–87, 2010.
- S. Suthaharan and S. Suthaharan. Support vector machine. *Machine learning models and algorithms for big data classification : thinking with examples for effective learning*, pages 207–235, 2016.
- A. Tall. Climate forecasting to serve communities in west africa. *Procedia Environmental Sciences*, 1 :421–431, 2010.

- A. Tall, S. J. Mason, M. Van Aalst, P. Suarez, Y. Ait-Chellouche, A. A. Diallo, and L. Braman. Using seasonal climate forecasts to guide disaster management : the red cross experience during the 2008 west africa floods. *International Journal of Geophysics*, 2012, 2012.
- J. Tan, Y. Zheng, G. Song, L. S. Kalkstein, A. J. Kalkstein, and X. Tang. Heat wave impacts on mortality in shanghai, 1998 and 2003. *International journal of biometeorology*, 51 :193–200, 2007.
- B. Tang, W. Liu, and T. Song. Wind turbine fault diagnosis based on morlet wavelet transformation and wigner-ville distribution. *Renewable Energy*, 35(12) :2862–2866, 2010. ISSN 09601481. doi : 10.1016/j.renene.2010.05.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S0960148110002302>.
- P. Termonia, C. Fischer, E. Bazile, F. Bouyssel, R. Brožková, P. Bénard, B. Bochenek, D. Degrauwe, M. Derková, R. El Khatib, et al. The aladin system and its canonical model configurations arome cy41t1 and alaro cy40t1. *Geoscientific Model Development*, 11(1) :257–281, 2018.
- M. Tiedtke. A comprehensive mass flux scheme for cumulus parameterization in large-scale models. *Monthly weather review*, 117(8) :1779–1800, 1989.
- R. M. Trigo, R. García-Herrera, J. Díaz, I. F. Trigo, and M. A. Valente. How exceptional was the early august 2003 heatwave in france? *Geophysical research letters*, 32(10), 2005.
- A. Troccoli. Seasonal climate forecasting. *Meteorological Applications*, 17(3) :251–268, 2010.
- G. S. University and Y. H. College. What causes a heat wave? URL <https://www.treehugger.com/what-causes-heat-wave-4863232>. Section : Treehugger.
- C. van Straaten, K. Whan, D. Coumou, B. van den Hurk, and M. Schmeits. Correcting sub-seasonal forecast errors with an explainable ann to understand misrepresented sources of predictability of european summer temperatures. *Artificial Intelligence for the Earth Systems*, pages 1–49, 2023.
- F. Vitart and A. W. Robertson. The sub-seasonal to seasonal prediction project (s2s) and the prediction of extreme events. *Npj Climate and Atmospheric Science*, 1(1) :3, 2018.

- F. Vitart, C. Ardilouze, A. Bonet, A. Brookshaw, M. Chen, C. Codorean, M. Déqué, L. Ferranti, E. Fucile, M. Fuentes, et al. The subseasonal to seasonal (s2s) prediction project database. *Bulletin of the American Meteorological Society*, 98(1) :163–173, 2017.
- M. Vrac, K. Hayhoe, and M. Stein. Identification and intermodel comparison of seasonal circulation patterns over north america. *International Journal of Climatology : A Journal of the Royal Meteorological Society*, 27(5) :603–620, 2007.
- M. Vrac, P. Drobinski, A. Merlo, M. Herrmann, C. Lavaysse, L. Li, and S. Somot. Dynamical and statistical downscaling of the french mediterranean climate : uncertainty assessment. *Natural Hazards and Earth System Sciences*, 12(9) :2769–2784, 2012.
- P. Wang, J. Tang, X. Sun, S. Wang, J. Wu, X. Dong, and J. Fang. Heat waves in china : Definitions, leading patterns, and connections to large-scale atmospheric circulation and ssts. *Journal of Geophysical Research : Atmospheres*, 122(20) :10–679, 2017.
- M. Wehner, F. Castillo, and D. Stone. The impact of moisture and temperature on human health in heat waves. In *Oxford Research Encyclopedia of Natural Hazard Science*. 2017.
- J. A. Weyn, D. R. Durran, and R. Caruana. Can machines learn to predict weather? using deep learning to predict gridded 500-hpa geopotential height from historical weather data. *Journal of Advances in Modeling Earth Systems*, 11(8) :2680–2693, 2019.
- C. J. White, 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. Potential applications of subseasonal-to-seasonal (s2s) predictions. *Meteorological applications*, 24(3) :315–325, 2017.
- R. L. Wilby and T. M. Wigley. Downscaling general circulation model output : a review of methods and limitations. *Progress in physical geography*, 21(4) :530–548, 1997.
- J. B. Worfolk. Heat waves : their impact on the health of elders. *Geriatric Nursing*, 21(2) :70–77, 2000.

Q. You, Z. Jiang, L. Kong, Z. Wu, Y. Bao, S. Kang, and N. Pepin. A comparison of heat wave climatologies and trends in china based on multiple definitions. *Climate Dynamics*, 48 :3975–3989, 2017.

S. Yu, S. F. Tett, N. Freychet, and Z. Yan. Changes in regional wet heatwave in eurasia during summer (1979–2017). *Environmental Research Letters*, 16(6) :064094, 2021a.

S. Yu, S. F. B. Tett, N. Freychet, and Z. Yan. Changes in regional wet heatwave in eurasia during summer (1979–2017). 16(6) :064094, 2021b. ISSN 1748-9326. doi : 10.1088/1748-9326/ac0745. URL <https://doi.org/10.1088/1748-9326/ac0745>. Publisher : IOP Publishing.

Z. Zhu and T. Li. Extended-range forecasting of chinese summer surface air temperature and heat waves. *Climate dynamics*, 50(5-6) :2007–2021, 2018.