



HAL
open science

Besoin en eau et rendements des céréales en Méditerranée du Sud : observation, prévision saisonnière et impact du changement climatique

El Houssaine Bouras

► **To cite this version:**

El Houssaine Bouras. Besoin en eau et rendements des céréales en Méditerranée du Sud : observation, prévision saisonnière et impact du changement climatique. Hydrologie. Université Paul Sabatier - Toulouse III; Université Cadi Ayyad (Marrakech, Maroc), 2021. Français. NNT : 2021TOU30150 . tel-03616186

HAL Id: tel-03616186

<https://theses.hal.science/tel-03616186>

Submitted on 22 Mar 2022

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.



THÈSE

En vue de l'obtention du DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par l'Université Toulouse 3 - Paul Sabatier

Cotutelle internationale: Université Cadi Ayyad

Présentée et soutenue par
El Houssaine BOURAS

Le 19 novembre 2021

**Besoin en eau et rendements des céréales en Méditerranée du
Sud : observation, prévision saisonnière et impact du
changement climatique**

Ecole doctorale : **SDU2E - Sciences de l'Univers, de l'Environnement et de
l'Espace**

Spécialité : **Océan, Atmosphère, Climat**

Unité de recherche :
CESBIO - Centre d'Etudes Spatiales de la Biosphère

Thèse dirigée par
Lionel JARLAN et Salah ER-RAKI

Jury

Mme Inbal BECKER-RESHEF, Rapporteur
M. Benjamin SULTAN, Rapporteur
M. Riad BALAGHI, Examineur
M. Abderrahmane LAHROUNI, Examineur
M. Lionel JARLAN, Directeur de thèse
M. Salah ER-RAKI, Co-directeur de thèse

Remerciements

Enfin, le moment est venu pour remercier toutes les personnes qui ont contribué de près ou de loin à la réalisation et à l'aboutissement de cette thèse. En effet, l'ensemble de ces travaux de recherche n'auraient pu être réalisés et menés à leur terme, sans le soutien de nombreuses personnes.

Tout d'abord, je tiens à exprimer ma profonde gratitude et ma vive reconnaissance à mes directeurs de thèse : Pr. **Salah Er-Raki** et Dr. **Lionel Jarlan**, ainsi qu'à mon co-encadrant Pr. **Saïd Khabba**. Merci à vous tous de m'avoir donné l'opportunité de réaliser ce travail.

Dès la fin de mon stage de fin d'étude de master, vous avez cru en moi et en mes compétences, et vous m'avez fait confiance pour intégrer votre équipe, ainsi que pour faire en sorte que je puisse réussir dans le domaine de la recherche, chose que j'ai vraiment appréciée et qui m'a énormément encouragé. Les lignes inscrites sur cette page ne sauraient suffire pour exprimer ma gratitude pour l'énergie et le temps que vous avez investi dans notre collaboration et dans ma formation. Merci à vous d'avoir contribué à mon développement aussi bien professionnel que personnel

Je suis également très reconnaissant envers les membres du jury pour avoir accepté d'évaluer mon travail de thèse. Je remercie Dr. **Inbal Becker-Reshef**, Dr. **Benjamin Sultan** et Pr. **Abderrahmane Lharouni**, d'avoir consacré de leur temps pour juger mon travail en tant que rapporteurs. Je remercie aussi Dr. **Abdelghani Chehbouni** et Dr. **Riad Balaghi** d'avoir accepté d'examiner mon travail de thèse.

Mes remerciements vont aussi aux camarades de LMI-TREMA : Hakim, Nadia, Jamal, Youssef, Bouchra, Chakir, Si Mohamed, Antoine.

Mes remerciements s'adressent également à l'ensemble du personnel de laboratoire CESBIO pour leur accueil chaleureux pendant mes séjours à Toulouse.

Merci à mes amis, qui n'ont peut-être toujours pas compris pourquoi j'étais toujours occupé, mais qui m'ont soutenu durant ces années de thèse : Anouar, Said, Nafiaa, Soufian, Hatim, Youssef, Hamed, Omar, Mohamed Malak, Soumia, Myriam. Merci également à Tassano pour son soutien durant ces années de thèse.

Je vais finalement conclure en exprimant toute ma gratitude à ma famille, en particulier mon père, ma mère, mes frères, mes sœurs. Merci pour vos encouragements, votre enthousiasme et surtout votre soutien « Tanmert chigan ».

†.ICΞO†

Fiche présentative de la thèse

- Nom et Prénom de l'auteur : **Bouras El houssaine**
- Intitulé du travail : **Besoin en eau et rendements des céréales en Méditerranée du Sud observation, prévision saisonnière et impact du changement climatique**
- Encadrant (s):
 - **Er-Raki Salah**, Professeur d'Enseignement Supérieur
Laboratoire des Procédés pour l'Energie Durable et Environnement (ProcEDE),
Département de Physique Appliquée, Faculté des Sciences et Techniques Guéliz, Université Cadi Ayyad.
 - **Jarlan Lionel**, Directeur de Recherche
Centre d'Étude Spatiales de la BIOSphère (CESBIO) Université Toulouse III Paul Sabatier (UPS), Institut de recherche pour le développement (IRD).
- Co-encadrent :
 - **Khabba Said**, Professeur d'Enseignement Supérieur,
Laboratoire de Mécanique des Fluides et d'Energétique (LMFE), Faculté des Sciences Semlalia Marrakech, Université Cadi Ayyad.
- Lieux de réalisation des travaux (laboratoires, institution) :
 - Laboratoire Mixte International " Laboratoire Télédétection et Ressources en Eau en Milieux semi Arides (LMI-TREMA) ". Centre Jaber, Faculté des Sciences Semlalia. Université Cadi Ayyad, Marrakech.
 - Centre d'Étude Spatiales de la BIOSphère (CESBIO), 18 avenue. Edouard Belin, bpi 2801, 31401 Toulouse cedex 9, France.
 - Laboratoire des Procédés pour l'Energie Durable et Environnement (ProcEDE), Département de Physique Appliquée, Faculté des Sciences et Techniques Guéliz, Université Cadi Ayyad.

Période de réalisation du travail de thèse : Janvier 2018 - Novembre 2021

- Rapporteurs autres que l'encadrant (nom, prénom, grade, institution) :
 - **Lahrouni Abderrahim**, Professeur d'Enseignement Supérieur, Faculté des Sciences Semlalia Marrakech.
 - **Benjamin Sultan**, Directeur de recherche, ESPACE-DEV, Institut de Recherche pour le Développement, Montpellier.
 - **Becker-Reshef Inba**, Professeur d'Enseignement Supérieur, Université du Maryland, NASA
- Cadres de coopération (ou de soutien) :

- Laboratoire Mixte International " Laboratoire Télédétection et Ressources en Eau en Milieux semi Arides (LMI-TREMA).
 - Allocations de recherche pour une thèse au sud (ARTS), Institute de recherche pour le développement (IRD)
 - Accounting for Climate Change in Water and Agriculture management, The ACCWA Project
 - Global CHange: Assessment and Adaptation to Mediterranean region water Scarcity, The CHAAMS Project.
- Ce travail a donné lieu aux résultats suivants (publications et communications) :

Articles dans des revues internationales à comité de lecture

1. **Bouras E.**, Jarlan L., Khabba S., Er-Raki S., Dezetter A., Sghir F., Trambly Y., (2019) Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco, *Nature Scientific Report*. <https://doi.org/10.1038/s41598-019-55251-2>
2. **Bouras E.**, Jarlan L., Er-Raki S., Albergel C., Richard B., Balaghi R., Khabba S., (2020) Linkages between Rainfed Cereal Production and Agricultural Drought through Remote Sensing Indices and a Land Data Assimilation System: A Case Study in Morocco. *Remote Sensing*. <https://doi.org/10.3390/rs12244018>
3. **Bouras E.**, Jarlan L., Er-Raki S., Balaghi R., Amazirh A., Richard B., Khabba S., (2021) Cereal Yield Forecasting with Satellite Drought-Based Indices, Weather Data and Regional Climate Indices Using Machine Learning in Morocco. *Remote Sensing*. <https://doi.org/10.3390/rs13163101>
4. Amazirh, A., **Bouras, E.**, Er-Raki, S., Chehbouni A., (2021) Retrieving Crop Albedo Based on Radar Sentinel-1 and Random Forest Approach, *Remote Sensing*. <https://doi.org/10.3390/rs13163181>
5. Er-Raki, S., **Bouras, E.**, Rodriguez J.C., Watts C.J., Lizarraga-Celaya C., Chehbouni A., (2020) Parameterization of the AquaCrop model for simulating table grapes growth and water productivity in an arid region of Mexico. *Agricultural Water Management*. <https://doi.org/10.1016/j.agwat.2020.106585>
6. Ouaadi N., Jarlan L., Ezzahar J., Zribi M., Khabba S., **Bouras E.**, Bousbih S., Frison P. (2020) Monitoring of wheat crops using the backscattering coefficient and the interferometric coherence derived from Sentinel-1 in semi-arid areas. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2020.112050>
7. Belaqziz, S., Khabba, S., Kharrou, M., **Bouras, E.**, Er-Raki, S., Chehbouni, A. (2021) Optimizing the sowing date to improve water management and wheat yield in a large irrigation scheme, through a remote sensing and an evolution strategy-based approach, *Remote Sensing*. <https://doi.org/10.3390/rs13183789>.
8. Amazirh, A., Chehbouni A., Ojha, O., **Bouras, E.**, Rivalland, V., Merlin O., Er-Raki, S., 2021. Assimilation of SMAP disaggregated soil moisture and Landsat land surface temperature to improve FAO-56 estimates of ET in semi-arid regions. *Agricultural Water Management*. <https://doi.org/10.1016/j.agwat.2021.107290>
9. Amazirh, A., Merlin, O., Er-Raki, S., **Bouras E.**, Chehbouni, A., (2020) Implementing a new texture-based soil evaporation reduction coefficient in the FAO dual crop coefficient method. *Agricultural Water Management*. <https://doi.org/10.1016/j.agwat.2021.106827>
10. Hajhouji Y., Fakir Y., Simonneaux V., Gascoin S., **Bouras E.**, Chehbouni A. (2020)

- Effects of Climate Change at the 2040's Horizon on the Hydrology of the Pluvio-Nival Rheraya Watershed Near Marrakesh, Morocco. In: *Advances in Smart Technologies Applications and Case Studies. SmartICT 2019. Lecture Notes in Electrical Engineering, vol 684.* Springer, Cham. https://doi.org/10.1007/978-3-030-53187-4_48.
11. Moucha, A., Hanich, L., Trambly, Y., Saadi, A., Gascoin, S., Martin, E., Lepage, M., Szczypta, C., **Bouras E.**, Jarlan, L. (2021) Present and Future High-Resolution Climate Forcings over Semiarid Catchments: Case of the Tensift (Morocco). *Atmosphere*. <https://doi.org/10.3390/atmos12030370>

Communications dans des colloques nationaux et internationaux

- **Bouras, E.**, Jarlan, L., Er-Raki, S., Balaghi, R., Amazirh, A., Richard, B., and Khabba, S. (2021) Combining multi-source data and machine learning approaches to predict cereal yield in Morocco, AgriNov2021, Beni-Mellal, Morocco, 27-30 October 2021.
- **Bouras, E.**, Jarlan, L., Er-Raki, S., Balaghi, R., Amazirh, A., Richard, B., and Khabba, S. (2021) Cereal yield forecasting combining satellite drought-based indices, regional climate and weather data using machine learning approaches in Morocco, EGU General Assembly 2021, online, 19–30 Apr 2021, EGU21-14590, <https://doi.org/10.5194/egusphere-egu21-14590>
- **Bouras, E.**, Jarlan, L., Khabba, S., Er-Raki, Dezetter A., Sghir F., Trambly, Y., (2020) Agriculture in Southern Mediterranean areas under climate change: Impacts on irrigated wheat grain yield and irrigation requirements. European Geosciences Union General Assembly. Vienna, 08-13 April. <https://doi.org/10.5194/egusphere-egu2020-7458>
- **Bouras, E.**, Jarlan, L., Khabba, S., Er-Raki, S., Sghir, F., Toumi, J., Chehbouni, G., Trambly, Y., (2017) Impact of climate change on wheat yields and irrigation water supply in the South Mediterranean: Case study in the Tensift region (Morocco). International Mistral Workshop: Climate Change impacts in the Mediterranean region, 16-18 October. Montpellier-France.
- **Bouras, E.**, Jarlan, L., Khabba, S., Er-Raki, S., Sghir, F., Toumi, J., Chehbouni, A., Trambly, Y., (2018) Impact of climate change on wheat yields and irrigation water supply in the South Mediterranean: Case study in the Tensift region (Morocco). Assessment of changes in Mediterranean Hydro-resources in the South: river basin Trajectories (AMETHYST- projet ANR). 12-13 Mars, Centre d'Etudes Spatiales de la Biosphère (CESBIO), Toulouse-France.
- **Bouras, E.**, Jarlan, L., Khabba, S., Er-Raki, S., Sghir, F., Toumi, J., Chehbouni, A., Trambly, Y., (2018) Impact of climate change on wheat yields and irrigation water supply in the South Mediterranean: Case study in the Tensift region (Morocco). European Geosciences Union General Assembly. Vienna, 08-13 April. Vienne-Austria.
- **Bouras, E.**, Jarlan, L., Er-Raki, Albergel, C., Balaghi R, Khabba, S., (2019) Assessing the linkages between agricultural drought index derived from remote sensing data and a Land Data Assimilation system and cereal production in Morocco. European Geosciences Union General Assembly. Vienna, 07-12 April. Vienne-Austria.
- Er-Raki, S., **Bouras, E.**, Rodriguez J.C., Chehbouni A (2021) Assessment of the water use efficiency and crop productivity of table grapes (*vitis vinifera*) in Mexico: measurements and modeling, AgriNov2021, Beni-Mellal, Morocco, 27-30 October 2021.
- Hajhouji, Y., Fakir, Y; Simonneaux, V., Gascoin, S., Jarlan L., **Bouras, E.**, Chehbouni, A., (2019) Projected effects of climate change on the hydrology and water

resources at the 2040's horizon in the Rheraya watershed (Marrakech, Morocco). European Geosciences Union General Assembly. Vienna, 07-12 April. Vienna-Austria.

- Ouaadi, N., Jarlan, L., Ezzahar, J., Zribi, M., Khabba, S., **Bouras, E.**, and Frison, P. L (2020) Surface Soil Moisture Retrieval Over Irrigated Wheat Crops in Semi-Arid Areas using Sentinel-1 Data. IEEE Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS) 2020, 9–11 March 2020, Tunis, Tunisia, 212–215, <https://doi.org/10.1109/M2GARSS47143.2020.9105282>
- Ouaadi, N., Jarlan, L., Ezzahar, J., Khabba, S., **Bouras, E.**, Frison, P. L (2019) Soil moisture retrieval over wheat fields using the backscattering coefficient and the interferometric coherence derived from Sentinel-1. European Geosciences Union (EGU2019), 7–12 April 2019, Vienna, Austria. <https://meetingorganizer.copernicus.org/EGU2019/EGU2019-5577.pdf>
- Ouaadi, N., Jarlan, L., Ezzahar, J., Zribi, M., Khabba, S., **Bouras, E.**, Bousbih, S., Frison, P. L., (2020) Mapping surface soil moisture over wheat crops in southern Mediterranean regions using the backscattering coefficient and the interferometric coherence derived from Sentinel-1. European Geosciences Union (EGU2020): Sharing Geoscience Online, 4–8 May 2020, <https://doi.org/10.5194/egusphere-egu2020-7408>

Résumé

Le secteur agricole est l'un des piliers de l'économie marocaine. En plus de contribuer à 15% au Produit Intérieur Brut (PIB) et de fournir 35% des opportunités d'emploi, il a un impact sur les taux de croissance. Ces dernières sont affectées négativement ou positivement par les conditions climatiques et la pluviométrie en particulier. Lors des années de sécheresse, caractérisées par une baisse de la production agricole, en particulier celle des céréales, la croissance de l'économie marocaine a été sévèrement affectée et les importations alimentaires du royaume ont augmenté de manière significative. Dans ce contexte, il est important d'évaluer l'impact de la sécheresse agricole sur les rendements céréaliers et de développer des modèles de prévision précoce des rendements, ainsi que de déterminer l'impact futur du changement climatique sur le rendement du blé et leurs besoins en eau.

Le but de ce travail est, premièrement, d'approfondir la compréhension de la relation entre le rendement des céréales et la sécheresse agricole dans notre pays. Afin de détecter la sécheresse, nous avons utilisé des indices de sécheresse agricole provenant de différentes données satellitaires. En outre, nous avons utilisé les sorties du système d'assimilation des données terrestres (LDAS). Deuxièmement, nous avons développé des modèles empiriques de la prévision précoce des rendements des céréales à l'échelle provinciale. Pour atteindre cet objectif, nous avons construit des modèles de prévision en utilisant des données multi-sources comme prédicteurs, y compris des indices basés sur la télédétection, des données météorologiques et des indices climatiques régionaux. Pour construire ces modèles, nous nous sommes appuyés sur des algorithmes de machine learning tels que : Multiple Linear Regression (MLR), Support Vector Machine (SVM), Random Forest (RF) et eXtreme Gradient Boost (XGBoost). Enfin, nous avons évalué l'impact du changement climatique sur le rendement du blé et ses besoins en eau. Pour ce faire, nous nous sommes appuyés sur cinq modèles climatiques régionaux disponibles dans la base de données Med-CORDEX sous deux scénarios RCP4.5 et RCP8.5, ainsi que sur le modèle AquaCrop et nous nous sommes basés sur trois périodes, la période de référence 1991-2010, la deuxième période 2041-2060 et la troisième période 2081-2100.

Les résultats ont montré qu'il y a une corrélation étroite entre le rendement des céréales et les indices de sécheresse liés à l'état de végétation pendant le stade d'épiaison (mars et avril) et qui sont liés à la température de surface pendant le stade de développement en janvier-février, et qui sont liés à l'humidité du sol pendant le stade d'émergence en novembre-décembre. Les résultats ont également montré que les sorties du LDAS sont capables de suivre avec précision

la sécheresse agricole. En ce qui concerne la prévision du rendement, les résultats ont montré que la combinaison des données provenant de sources multiples a donné des meilleurs résultats que les modèles basés sur une seule source. Dans ce contexte, le modèle XGBoost a été capable de prévoir le rendement des céréales dès le mois de janvier (environ quatre mois avant la récolte) avec des métriques statistiques satisfaisants ($R^2 = 0.88$ et $RMSE = 0.22 \text{ t. ha}^{-1}$). En ce qui concerne l'impact du changement climatique sur le rendement et les besoins en eau du blé, les résultats ont montré que l'augmentation de la température de l'air de 6°C entraînera un raccourcissement du cycle de croissance du blé d'environ 50 jours. Les résultats ont également montré une diminution du rendement du blé jusqu'à 30% si l'augmentation du CO_2 n'est pas prise en compte. Cependant, l'effet de la fertilisation au CO_2 peut compenser les pertes du rendement, et ce dernier peut augmenter jusqu'à 27%. Finalement, les besoins en eau devraient diminuer de 13 à 42%, et cette diminution est associée à une modification de calendrier d'irrigation, le pic des besoins arrivant deux mois plus tôt que dans les conditions actuelles.

Mots clés : Rendement des Céréales, Besoin en eau, Télédétection, Sècheresse, Changement Climatique, Machine Learning, AquaCrop.

Abstract

The agricultural sector is one of the pillars of the Moroccan economy. In addition to contributing 15% in GDP and providing 35% of employment opportunities, it has an impact on growth rates that are negatively or positively affected by climatic conditions and rainfall in particular. During drought years characterized by a decline in agricultural production and in particular cereal production, the growth of the Moroccan economy was severely affected and the kingdom's food imports increased significantly. In this context, it's important to assess the impact of agricultural drought on cereal yields and to develop early yield prediction models, as well as to determine the future impact of climate change on wheat yield and water requirements.

The aim of this work is, firstly to further understand the linkage between cereal yield and agricultural drought in Morocco. In order to identify this drought, we used agricultural drought indices from remotely sensed satellite data. In addition, we used the outputs of Land Data Assimilation System (LDAS). Secondly, to develop empirical models for early prediction of cereal yields at provincial scale. To achieve this goal, we built forecasting models using multi-source data as predictors, including remote sensing-based indices, weather data and regional climate indices. And to build these models, we relied on machine learning algorithms such as Multiple Linear Regression (MLR), Support Vector Machine (SVM), Random Forest (RF) and eXtreme Gradient Boost (XGBoost). Finally, to evaluate the impact of climate change on the wheat yield its water requirements. To do this, we relied on five regional climate models available in the Med-CORDEX database under two scenarios RCP4.5 and RCP8.5, as well as the AquaCrop model and we based on three periods, the reference period 1991-2010, the second period 2041-2060 and the third period 2081-2100.

The results showed that there is a close correlation between cereals yield and drought indices related to canopy condition during the heading stage (March and April) and which are related to surface temperature during the development stage in January -February, and which are related to soil moisture during the emergence stage in November -December. The results also showed that the outputs of LDAS are able to accurately monitor agricultural drought. Concerning, cereal yield forecasting, the results showed that combining data from multiple sources outperformed models based on one data set only. In this context, the XGBoost was able to predict cereal yield as early as January (about four months before harvest) with satisfactory statistical metrics ($R^2 = 0.88$ and $RMSE = 0.22 \text{ t. ha}^{-1}$). Regarding the impact of climate change on wheat yield and water requirements, the results showed that the increase in air temperature

by 6°C will result in a shortening of the wheat growth cycle by about 50 days. The results also showed a decrease in wheat yield up to 30% if the rising in CO₂ was not taken into account. The effect of fertilizing of CO₂ can offset the yield losses, and yield can increase up to 27 %. Finally, water requirements are expected to decrease by 13 to 42%, and this decrease is associated with a change in temporal patterns, with the requirement peak coming two months earlier than under current conditions.

Keywords: Cereal yield, Water requirements, Remote sensing, Drought, Climate Change, Machine Learning, AquaCrop

ملخص الرسالة

يعتبر قطاع الزراعة ركيزة أساسية في الاقتصاد المغربي، فإلى جانب إسهامه بنسبة 15% من الناتج المحلي الإجمالي وتوفيره لمناصب الشغل لـ 35% من اليد العاملة، لديه أثر واضح في معدلات النمو التي تتأثر سلباً أو إيجاباً بالتقلبات المناخية والتساقطات المطرية على وجه الخصوص. ففي سنوات الجفاف التي يتقلص فيها الإنتاج الزراعي (الحبوب خصوصاً) يتأثر نمو الاقتصاد المغربي بشكل كبير وترتفع فيها بشكل ملحوظ واردات المملكة من السلع الغذائية. في هذا السياق، من الضروري تقييم تأثير الجفاف الزراعي على مردودية الحبوب ووضع نماذج للتنبؤ المبكر بمردودية الحبوب، وأيضاً تحديد التأثير المستقبلي لتغير المناخ على مردودية القمح واحتياجاته من الماء.

يهدف العمل المنجز خلال هذه الأطروحة، أولاً إلى تعميق فهم العلاقة بين مردودية الحبوب والجفاف الزراعي في المغرب؛ من أجل الكشف عن هذا الجفاف قمنا باستعمال مؤشرات الجفاف الزراعي من بيانات أقمار الاستشعار عن بعد. بالإضافة إلى ذلك قمنا باستعمال مخرجات نظام استيعاب بيانات الأراضي (LDAS) من أجل الكشف عن الجفاف الزراعي. ثانياً، بناء نماذج تجريبية من أجل التنبؤ المبكر بمردودية الحبوب على نطاق إقليمي. من أجل الوصول إلى هذا الهدف قمنا ببناء نماذج التنبؤ باستعمال بيانات متعددة المصادر كمتنبئات لمردودية الحبوب وتشمل مؤشرات الجفاف الزراعي من أقمار الاستشعار عن بعد، بيانات الطقس بالإضافة لبيانات أنماط دوران الغلاف الجوي. واستندنا في بناء هذه النماذج على خوارزميات تعليم الآلة وهي كالتالي (Multiple Linear Regression (MLR و Support Vector Machine (SVM) و Random Forest (RF) و eXtreme Gradient Boost (XGBoost). وأخيراً تقييم تأثير التغيرات المناخية على مردودية القمح المرورية واحتياجاتها المائية في منطقة تانسيفت في المغرب نمودجاً. اعتمدنا في ذلك على خمس نماذج مناخية إقليمية متاحة في قاعة بيانات Med-CORDEX وفق السيناريوهين RCP 4.5 و RCP 8.5 وكذلك على النموذج AquaCrop وقد استندنا في دراستنا على ثلاث فترات زمنية، وهي 1991-2010 كفترة أساس و2041-2060 كفترة ثانية و2081-2100 كفترة ثالثة.

بينت النتائج المحصل عليها أن هناك ارتباط وثيق بين مردودية الحبوب ومؤشرات الجفاف المتعلقة بحالة الغطاء النباتي خلال مرحلة الطرد وتكوين الحبوب في شهر مارس وأبريل والمتعلقة بحرارة سطح التربة خلال مرحلة الاستطالة في شهر يناير وفبراير والمتعلقة برطوبة التربة خلال مرحلة الانبات في شهر نونبر ودجنبر. وبينت النتائج أيضاً أن الدمج بين بيانات الاستشعار عن بعد عبر الأقمار الصناعية ونماذج سطح الأرض في إطار نظام استيعاب بيانات الأراضي تمكن من رصد الجفاف الزراعي بشكل دقيق. وبخصوص التنبؤ المبكر بمردودية الحبوب بينت النتائج المحصل عليها أن استعمال جمل البيانات المختلفة المصادر يمكن من الحصول على تنبؤ دقيق مقارنة باستعمال بيانات من مصدر واحد. في هذا الإطار مكنت خوارزمية XGBoost من التنبؤ بمردودية الحبوب بشكل مبكر منذ شهر يناير (أربع شهور قبل الحصاد تقريباً) بمقاييس إحصائية مرضية ($R^2=0.88$ و $RMSE=0.22 \text{ t. ha}^{-1}$). فيما يتعلق بتأثير التغيرات المناخية على مردودية القمح واحتياجاته المائية، أظهرت النتائج أن ارتفاع درجة حرارة الهواء سيتسبب في تقصير دورة نمو القمح بحوالي 50 يوماً. أظهرت النتائج أيضاً انخفاض في مردودية القمح في حدود 7 إلى 30% إذا لم يؤخذ بعين الاعتبار ارتفاع تركيز ثاني أكسيد الكربون. ويمكن أن يوازن تأثير تسميد هذا الأخير خسائر المردودية، حيث يمكن أن تزيد المردودية بنسبة 23% أخيراً، من المتوقع أن تنخفض الاحتياجات القمح من الماء بنسبة 13 إلى 42%، ويرتبط هذا الانخفاض أيضاً بتغيير في الجدولة الزمنية للسقي، حيث تأتي ذروة المتطلبات قبل شهرين مقارنة بالظروف الحالية.

الكلمات المفتاحية: محصول الحبوب، الاستشعار عن بعد، الجفاف، تغير المناخ، التعلم الآلي، AquaCrop

Table des matières

Fiche présentative de la thèse	i
Résumé	vi
Abstract	viii
ملخص الرسالة	x
Table des matières	xi
Liste des tableaux	xv
Liste des abréviations	xvi
Introduction générale	17
I) Contexte sociétal et enjeux	18
II) Contexte scientifique et questions	21
III) Objectifs et approches	28
Chapitre I : Rendements céréaliers et sécheresses, prévision saisonnière et impact du changement climatique	31
I) La sécheresse	32
I-1) Définition et type de sécheresse	32
I-2) Suivi de la sécheresse agricole	34
I-2-1) Les indices in situ de suivi de la sécheresse agricole.....	35
I-2-2) Le suivi de la sécheresse agricole par télédétection.....	37
a) Suivi de la sécheresse par télédétection visible et proche infra-rouge	38
b) Suivi de la sécheresse par télédétection infrarouge thermique	42
c) Suivi de la sécheresse par télédétection micro-ondes.....	44
d) Suivi de la sécheresse par télédétection multi-capteurs	46
I-2-3) Les Land Data Assimilation Systèmes.....	50
a) Généralités.....	50
b) Le LDAS du CNRM	50
II) La prévision saisonnière des rendements des cultures	51
II-1) Prévision du rendement des cultures à l'aide des modèles agronomiques	51
II-2) Prévision du rendement des cultures avec la méthode statistique.....	54
II-2-1) Les approches linéaires.....	56
II-2-2) Les approches non-linéaires.....	56
a) Machines à vecteurs de support.....	57
b) Random forest.....	58
c) Extrem Gradient Boosting.....	59
III) Etude de l'impact du changement climatique sur la production	60
III-1) Le changement climatique	60
III-1-1) Définition et enjeux	60

III-1-2) Projections et scénarios climatiques	62
a) Les scénarios RCPs	62
b) Etablissement des projections climatiques à grande échelle	64
c) Descente d'échelle (Downscaling).....	64
d) Initiative Med-CORDEX	66
III-2) La modélisation des agrosystèmes.....	67
III-2-1) Généralités.....	67
III-2-2) Model AquaCrop.....	69
a) Description du modèle AquaCrop.....	69
b) De l'approche Ky au modèle AquaCrop.....	70
c) Schéma de calcul.....	73
d) Données d'entrées requises.....	74
III-3) Impact du changement climatique sur la production des cultures	79
III-3-1) Impact d'augmentation de CO ₂	79
III-3-2) Impact de la hausse de température.....	80
IV) Conclusion	81
Chapitre II : La sécheresse agricole et la production des céréales au Maroc.	
.....	83
I) Introduction.....	84
II) Résumé de l'article	84
III) Article.....	88
IV) Conclusion	124
Chapitre III : Prévision saisonnière des rendements des céréales au Maroc	
.....	125
I) Introduction.....	126
II) Résumé de l'article	126
III) Article.....	127
IV) Conclusion	149
Chapitre IV : Impact du changement climatique sur les rendements et les besoins en eau du blé.....	150
I) Introduction.....	151
II) Résumé de l'article	151
III) Article.....	153
IV) Conclusion	174
Conclusion générale et perspectives	176
Références	183

Liste des figures

Figure 1: La production et la superficie céréalière au Maroc entre 1961 et 2019. Source FAOSTAT	21
Figure 2 : Mise en évidence du lien existant entre les types de sécheresse. Causes et conséquences des sécheresses. (Source : Organisation Météorologique Mondiale (OMM), rapport n°1006, 2006)	34
Figure 4: Le principe de SVM	58
Figure 5: Le principe de l’algorithme RF.	59
Figure 6: Le principe d’algorithme XGBoost.	60
Figure 7: Carte de l’évolution des températures en surface observée entre 1901 et 2012 (Ipcc, 2013).	61
Figure 8: Émissions de dioxyde de carbone (CO ₂) selon les profils représentatifs d’évolution de concentration (RCP) uniquement (traits de couleur) et catégories de scénarios associées utilisées par le GTIII (ombrages en couleur représentant la fourchette de 5 à 95 %). Les catégories de scénarios utilisées par le GTIII condensent le vaste ensemble de scénarios d’émissions décrits dans les publications scientifiques ; leurs définitions se basent sur les niveaux de concentration en équivalent CO ₂ (en ppm) en 2100 (IPCC, 2014).	63
Figure 9: Évolution de la température moyenne en surface (a) et évolution des précipitations moyennes (b) fondées sur des projections multi-modèles moyennes pour la période 2081–2100 par rapport à la période 1986–2005, selon les scénarios RCP2,6 (à gauche) et RCP8,5 (à droite). Le nombre de modèles utilisés pour calculer la moyenne multi-modèle figure dans l’angle supérieur droit de chaque image. Les pointillés signalent les régions dans lesquelles le changement projeté est grand par rapport à la variabilité naturelle interne et dans lesquelles 90 % au moins des modèles s’accordent sur le signe du changement. Les hachures signalent les régions dans lesquelles le changement projeté est inférieur à un écart type de la variabilité naturelle interne (IPCC, 2014).	63
Figure 10: La relation entre le déclin relatif du rendement ($1 - Y/Y_x$) et le déficit relatif en évapotranspiration ($1 - ET/ET_x$) (Raes et al., 2009).	71
Figure 11: composantes principales du continuum sol-plante- atmosphère et les paramètres caractérisant la phénologie, la couverture de la canopée, la transpiration, la production de biomasse et le rendement final. (I, irrigation ; T _n , température minimale de l’air ; T _x , température maximale de l’air ; E _{To} , évapotranspiration de référence ; E, évaporation du sol ; Tr, transpiration de la canopée ; g _s , conductance stomatique ; WP, productivité de l’eau ; HI, indice de récolte ; CO ₂ , concentration atmosphérique en dioxyde de carbone ; (1), (2), (3), (4), fonctions de réponse au stress hydrique sur : l’expansion des feuilles, la sénescence, la conductance stomatique et l’indice de récolte) Les traits continus indiquent les liens directs entre les variables et les processus. Les traits interrompus indiquent les feedbacks.....	72
Figure 12 : Schéma de calcul d’AquaCrop indiquant (en flèches pointillés) les processus affectés par le stress hydrique (a à e). CC est la couverture de canopée simulée, CC _p la couverture potentielle de canopée, K _s le coefficient de stress en eau, K _{cb} le coefficient de culture, E _{To} l’évapotranspiration de référence, WP* la productivité de l’eau pour une culture normalisée, et HI l’indice de récolte (Steduto et al., 2011).	74
Figure 13: Données d’entrée du modèle AquaCrop.....	76

Figure 14: Les stades phénologiques de développement d'une culture (Raes et al., 2011).....	78
Figure 15: Les 15 provinces les plus productives considérées dans l'étude et résultats des quatre classifications	86

Liste des tableaux

Tableau 1: Indices in-situ pour le suivi de la sécheresse agricole	37
Tableau 2: Les principaux produits satellitaires couvrant l'ensemble du globe et utilisés pour le suivi de la sécheresse	39
Tableau 3: Indices dérivés de la télédétection optique pour le suivi de la sécheresse agricole	42
Tableau 4: Indices dérivés de la télédétection thermique pour le suivi de la sécheresse agricole.	44
Tableau 5: Indices dérivés de la télédétection micro-ondes pour le suivi de la sécheresse agricole	46
Tableau 6: Indices dérivés de la télédétection multi-capteurs pour le suivi de la sécheresse agricole	49
Figure 3: le processus du Machine learning.....	57
Tableau 7: Simulations disponibles à 50 km de résolution (grille MED44).....	67
Tableau 8: Les statistiques de production, précipitations moyennes et température pour chaque province.....	87
Tableau 9: Synthèse des liens entre les indices de sécheresse dérivés de la télédétection, les sorties du LDAS et les rendements céréaliers pendant la saison agricole (++ corrélation significative, +++ corrélation hautement significative).....	88

Liste des abréviations

ADA : Agence de Développement Agricole
CCI : Climate Change Initiative
CMI : Crop Moisture Index
CSDI : Crop Specific Drought Index
ENSO : El Niño Southern Oscillation
ESA : Agence Spatiale Européenne
ETp : Evapotranspiration potentielle
FAO : Food and Agriculture Organisation
GCM : General Circulation Model
IPCC : Intergovernmental Panel on Climate Change
LAI : Leaf Area Index
LDAS : Land data assimilation system
LST : Land Surface Temperature
MODIS : Moderate-resolution Imaging Spectroradiometer
NAO : North Atlantic Oscillation
NDVI : Normalized Difference Vegetation Index
ONICL : Office National Interprofessionnel des Céréales et Légumineuses
PIBA : Produit Intérieur Brut Agricole
PMV : Plan Maroc Vert
PSDI : Palmer Drought Severity Index
RCM : Regional Climate Model
RCP : Representative Concentration Pathways
RF : Random Forest
SCA : Scandinavian Pattern
SM : Soil Moisture
SMCI : Soil Moisture Condition Index
SPEI : Standardized Precipitation Evapotranspiration Index
SPI : Standardized Precipitation Index SPI
SST : Sea Surface Temperature
SVM : Support Vector Machine
SWI : Soil water index
TCI : Temperature Condition Index
VCI : Vegetation Condition Index
WMO : World Meteorological Organization

Introduction générale

I) Contexte sociétal et enjeux

La sécurité alimentaire dans le monde sera confrontée dans l'avenir à deux défis majeurs : la satisfaction des besoins d'une population croissante tout en assurant la durabilité des ressources en eau et en sol dans un contexte climatique évolutif. En effet, la sécurité alimentaire mondiale repose sur un nombre limité d'espèces (principalement le blé, le maïs et le riz ; [FAO, 2017](#)), produisant de grandes quantités de nourriture mais ayant des impacts négatifs sur les ressources naturelles telles que l'eau, les sols et la biodiversité. Alors qu'elle contribue le moins aux facteurs qui entraînent des changements climatiques mondiaux, l'Afrique est considérée comme particulièrement vulnérable au changement climatique en raison de sa situation géographique et de son niveau de développement économique ainsi que de sa faible capacité d'adaptation ([Hope, 2009](#)). En effet, ce continent est le plus sensible au changement climatique notamment la zone méditerranéenne identifiée comme un 'hot-spot' du changement climatique ([Giorgi, 2006](#)). Le changement climatique affectera et impactera à la fois les systèmes environnementaux et les secteurs socio-économiques ([Harrison et al., 2019](#)). Parmi les secteurs économiques clés touchés, l'agriculture pourrait être très fortement impactée par ces changements annoncés ([Schilling et al., 2020](#)).

Dans notre pays, l'objectif de la politique de sécurité alimentaire tend à assurer les besoins alimentaires nationaux et garder la souveraineté alimentaire du pays qui a d'ailleurs été remise en question lors de la crise liée à la pandémie Covid-19. L'objectif est donc l'autosuffisance agricole même si l'importation des produits agricoles reste possible pour compenser les déficits. Cette politique vise principalement à réduire les déficits de la balance alimentaire et commerciale, en tenant compte de la limitation des ressources en eau, des potentialités agro-climatiques et des besoins croissants de la population ([Balaghi, 2006](#)). Dans un contexte mondial dynamique et évolutif le secteur agricole a dû faire face à des défis et des enjeux environnementaux (la rareté des ressources naturelles, le changement climatique ...) et anthropiques (des enjeux sociaux et économiques). Sur cette base, le Maroc a proposé des mesures politiques incitatives réunies sous bannière du Plan Maroc Vert (PMV) entre 2008 et 2018 dans l'objectif d'améliorer les performances agricoles, tant sur le plan économique que social. Après la mise en œuvre du PMV durant la période de 2008 à 2018, la contribution au Produit Intérieur Brut Agricole (PIBA) a connu une augmentation annuelle de 5.25% contre 3.8% pour les autres secteurs permettant de créer ainsi une valeur ajoutée supplémentaire de 47 milliards de dirhams (Agence de Développement Agricole, -ADA- <https://www.ada.gov.ma/>). Malgré la profonde transformation générée par le PMV, ce plan n'a pas suffi à améliorer

l'utilisation de l'eau agricole. En particulier, l'efficacité de l'irrigation est loin d'être optimale en considérant uniquement les techniques d'irrigation et les pratiques des agriculteurs. La conversion vers l'irrigation goutte-à-goutte était encouragée dans le cadre du PMV pour économiser l'eau. Cependant, plusieurs études menées dans notre pays, basées sur des données expérimentales, ont montré des résultats très différents en termes de perte d'eau par la plante, soit par l'évaporation du sol, soit par le drainage profond (Jarlan et al., 2015; Khabba et al., 2013; Nassah et al., 2018; Sefiani et al., 2019). Ces études ont conclu que la conversion à l'irrigation goutte-à-goutte, ne conduit pas nécessairement à l'économie d'eau par rapport aux méthodes traditionnelles telles que le gravitaire. Ces derniers résultats démontrent l'importance de considérer les résultats des travaux de recherche pour l'élaboration et la mise en place des politiques publiques.

La production et la superficie des céréales dans notre pays sont principalement influencées par la répartition spatiale et temporelle de la pluie, notamment en début de saison, de novembre à début décembre. (Balaghi et al., 2013). La date d'arrivée de ces pluies, qui est très variable d'une année à l'autre, conditionne la date de semis des céréales dans les régions arides et semi-arides, caractérisées par une pluviométrie comprise entre 200 à 400 mm.an⁻¹ (Benaouda et Bouaziz, 1992). La superficie est plus importante quand la pluie est précoce et abondante, car la plupart des agriculteurs sèment après ces premières pluies. On note une tendance forte avec une augmentation continue de la superficie céréalière dans notre pays depuis 1980 avec un rythme moyen de 39.600 hectare.an⁻¹. Il en est évidemment de même pour la production (Figure 1). La variabilité de la production est due aussi à des périodes de sécheresse récurrentes, surtout si elles ont lieu pendant les stades phénologiques critiques (Balaghi, 2009). Le Maroc a connu au cours de ces dernières décennies plusieurs périodes de sécheresse d'intensité variée. Certaines ont eu des impacts négatifs sur la production des céréales et sur les conditions socio-économiques de la population notamment rurale. Par exemple, la production de céréales est passée de 9.1 millions de tonnes en 1994 à 1.6 millions de tonnes en 1995 en raison d'une sécheresse sévère (Figure 1). L'irrigation a été introduite comme un moyen de réduire la vulnérabilité aux risques de sécheresse et d'augmenter la productivité des cultures. L'irrigation utilise aujourd'hui la majeure partie (85%) de l'eau mobilisable (Jarlan et al., 2016), car le Maroc a mis en œuvre, à partir des années 1960, une politique de mobilisation des eaux de surface et de construction des barrages à forte capacité. L'objectif de ces aménagements était principalement orienté vers l'approvisionnement en eau potable, pour l'irrigation et pour la production d'électricité (Jellali, 1997). Cependant, la production agricole fluctue encore

fortement d'une année à l'autre, puisque 85% des terres agricoles restent pluviales (Schilling et al., 2020).

Afin de régulariser le marché national et pour satisfaire les besoins de la population croissante, les importations de céréales représentent les factures les plus lourdes parmi les importations totales de produits agricoles et alimentaires au Maroc. D'après les données de l'Office National Interprofessionnel des Céréales et Légumineuses (ONICL, www.onicl.org.ma), les importations sont en moyenne de 3.5 millions de tonnes sur la période 1990-2020. Elles représentent, en moyenne sur cette période, près de la moitié (54,8%) de la production nationale. La très grande majorité des importations vient du blé tendre (71%), suivi du blé dur (16%) et de l'orge (13%). Depuis le début des années 1990, les importations sont en constante augmentation, surtout pour les blés. Cette part des importations est très variable selon les années, elle peut varier de 24% (en 2009-2010) à 244% (en 2000-2001). Toutefois, même si la récolte nationale peut atteindre des niveaux de rendement élevés, comme celle de la campagne agricole 2014-2015 (11.5 millions tonnes), les importations restent significatives (4,9 millions tonne cette saison-là).

Le défi pour le Maroc est d'approvisionner le marché local à temps et à moindre coût d'importation, tout en promouvant une agriculture durable, dans un contexte climatique incertain en tenant compte à la fois des impacts de la sécheresse et du changement climatique, des ressources en eau limitées et des besoins croissants de la population. En effet, il est essentiel d'anticiper et de précipiter l'importation en cas de production insuffisante pour la consommation intérieure ou pour le stockage des semences (Jarlan, 2016). La prévision saisonnière précoce, précise et fiable des rendements des cultures, est un outil bien adapté à la prise de décision car elle aiderait les décideurs et les gestionnaires à renforcer la sécurité alimentaire dans ces cas (Filippi et al., 2019; Johnson et al., 2016; Kogan, 2019; Peng et al., 2016).

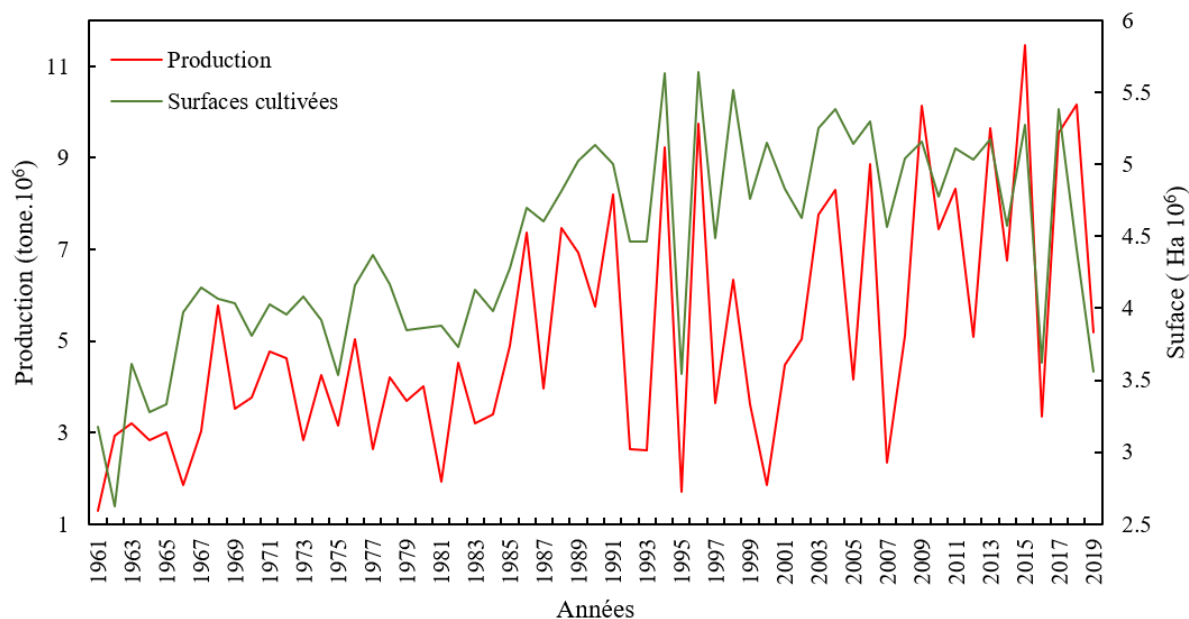


Figure 1: La production et la superficie céréalière au Maroc entre 1961 et 2019. Source FAOSTAT

II) Contexte scientifique et questions

La sécheresse : processus et méthodes de suivi

La sécheresse est un phénomène naturel qui recouvre un certain nombre de processus météorologiques, hydrologiques et biophysiques ayant des implications socio-économiques. La sécheresse est le résultat d'une insuffisance de précipitations par rapport aux valeurs normales, il s'agit donc d'un état plutôt relatif qu'absolu. Elle se produit aussi bien dans des zones à fortes précipitations que dans des zones à faibles précipitations et sous presque tous les climats (Mishra en Singh, 2010). Lorsqu'elle persiste durant une saison entière ou plus, cette insuffisance empêche de répondre comme il convient aux besoins des sociétés humaines et de l'environnement (WMO, 2006). A l'échelle mondiale, les effets de la sécheresse causent jusqu'à 80% des pertes de rendement dans le monde (FAO, 2017). Kogan et al. (2020), elles ont montré que les surfaces affectées par la sécheresse ont une nette tendance positive, en particulier depuis le début des années 2000 et que la production des céréales peut être réduite de 10 à 35% selon l'intensité de la sécheresse (Kogan, 2019). Plusieurs études ont montré une augmentation de la fréquence et de l'intensité des périodes de sécheresse durant ces dernières années sur une grande partie du globe, particulièrement en région méditerranéenne, et cette tendance forte va probablement se renforcer dans le futur. (Dai, 2011; Driouech et al., 2020; IPCC, 2019; Samaniego et al., 2018; Trambly et al., 2020; Vidal et al., 2012; Vogel et al., 2021; Zkhiri et al., 2019). Dans un monde devenu plus vulnérable par l'extension et l'intensification des cultures agricoles, il est important donc d'anticiper et de gérer au mieux les périodes de sécheresse (Le

Page, 2021). Face à ce phénomène complexe, l'élaboration d'indices de sécheresse comme outils d'aide à la décision est nécessaire. La première étape vers l'atténuation des impacts de la sécheresse est le suivi de la sécheresse, il est donc très important de développer un système d'alerte précoce pour ce suivi et d'évaluer ses liens avec les rendements des cultures (Vicente-Serrano et al., 2006). Les premiers systèmes de suivi de la sécheresse étaient principalement basés directement sur la quantité de précipitations (Kumar, 1998) avec des indices tels que l'indice de précipitations normalisé (Standardized Precipitation Index SPI, McKee et al., 1993). Considérant les caractéristiques complexes de la sécheresse agronomique qui va bien au-delà d'un simple déficit de précipitations, d'autres variables renseignant notamment sur le sol ont été utilisées pour le suivi de la sécheresse. En particulier, la température de l'air qui est à la fois une variable clé de la demande évaporative et de l'évapotranspiration des cultures et un facteur qui peut également être limitant pour la production des cultures (Kumar en Panu, 1997). Pour cette raison, le Standardized Precipitation Evapotranspiration Index (SPEI) a été proposé par Vicente-Serrano et al., (2010) pour tenir compte à la fois de la demande évaporative et de l'approvisionnement en eau. Cependant, la faible densité du réseau de stations d'observation sur certaines régions du globe, notamment dans les pays en voie de développement, constitue souvent un obstacle et une limite à l'utilisation de ces indices pour le suivi de la sécheresse, surtout à grande échelle. Afin de répondre à cette limitation, plusieurs indices de sécheresse dérivés d'observations de télédétection, maintenant librement disponibles dans le monde entier, ont été utilisés pour le suivi de l'intensité, la durée et l'étendue spatiale de la sécheresse (Rhee et al., 2010). Les données de télédétection fournissent des informations sur la vigueur de la végétation grâce à des indices de végétation acquis dans le domaine optique, tels que le Normalized Difference Vegetation Index (NDVI), la température de la surface terrestre (Land Surface Temperature, LST) dérivée de données infrarouges thermiques et l'humidité du sol (Soil Moisture, SM) estimée à partir d'observations micro-ondes actives ou passives. La plupart des indices de sécheresse dérivés de la télédétection sont basés sur des anomalies normalisées de ces produits. Parmi ces indices, nous pouvons citer le Vegetation Condition Index (VCI) basé sur le NDVI et le Temperature Condition Index (TCI) basé sur la LST, qui sont très utiles pour le suivi de la sécheresse à l'échelle régionale ou globale (Kogan, 1997). De même, des indices qui sont basés sur l'humidité du sol ont été proposés à savoir le Soil Moisture Condition Index (SMCI) (Zhang and Jia, 2013).

Toutefois, la faible profondeur de détection et la précision incertaine de l'estimation d'humidité du sol par les satellites actuellement disponibles (Beck et al., 2021), ont encouragé l'utilisation

conjointe des modèles de surface terrestre (Land Surface Model, LSM) et des observations par satellite à l'aide de techniques d'assimilation des données dans des systèmes qui sont appelés les Land Data Assimilation System (LDAS), afin d'obtenir des estimations plus précises de l'humidité du sol de la zone racinaire qui est un facteur clé pour le suivi de la sécheresse agricole (Albergel et al., 2018; Bolten en Crow, 2012; Dewaele et al., 2017). Parmi ces LDAS le Global Land Data Assimilation System (GLDAS, Rodell et al., 2004), le North American Land Data et le National Climate Assessment-Land Data Assimilation System (NCA-LDAS, Kumar et al., 2019) développé par la NASA (National Aeronautics and Space Administration) et le LDAS-Monde (Albergel et al., 2020, 2018, 2017; Blyverket et al., 2019) développé par le Centre National de Recherches Météorologiques (CNRM) du Météo-France. Albergel et al. (2018) ont montré que les sorties du LDAS-monde ont une meilleure performance pour caractériser et suivre la sécheresse agricole par rapport aux sorties du modèle sans assimilation (open-loop) en France.

Le changement climatique : scénarios et impacts

Le changement climatique est dû à l'augmentation des gaz à effet de serre d'origine humaine, par exemple le dioxyde de carbone CO₂. Cette augmentation entraîne un réchauffement climatique, une plus forte variabilité des précipitations et une augmentation de l'occurrence des événements extrêmes (sécheresse, inondation ...) à l'échelle mondiale (IPCC, 2019). C'est particulièrement le cas dans la région méditerranéenne, qui est identifiée comme un -hot spot- du changement climatique (Giorgi, 2006; Lionello en Scarascia, 2018; Trambly et al., 2021). Les projections futures des températures montrent, en effet, une augmentation plus rapide en Méditerranée par rapport à la moyenne mondiale : une augmentation de la température maximale globale de 1.5 et 2 °C correspond à une augmentation de 2.2 et 3 °C dans le bassin méditerranéen (Seneviratne et al., 2016). Cette augmentation serait conjuguée à une diminution des précipitations de l'ordre de 20% à 30% dans cette zone (Giorgi en Lionello, 2008).

La nouvelle génération de simulations des Modèles Climatiques Régionaux (RCM, Regional Climate Model) dédiés à la région méditerranéenne, tels que ceux fournis par l'initiative Med-CORDEX (www.medcordex.eu; Ruti et al., 2016) vise à augmenter la fiabilité des informations sur le climat régional passé et à venir, et à comprendre les processus qui sont responsables de la variabilité et de l'évolution du climat méditerranéen. Des études récentes ont déjà utilisé ces données pour étudier l'impact du changement climatique notamment sur les ressources en eau dans la région méditerranéenne (Hajhouji et al., 2020; Marchane et al., 2017; Moucha et al., 2021; Trambly et al., 2018, 2013b)

Au-delà de la variabilité naturelle qui contrôle une partie de la variance des rendements agricoles (Kukal en Irmak, 2018), le changement climatique va affecter dans le futur l'agriculture à l'échelle mondiale (Asseng et al., 2015; FAO, 2016). En effet, pour chaque augmentation de 1°C de la température, la chute de production mondiale de blé attendue est de 6% (Asseng et al., 2013). Certains aspects du changement climatique, notamment l'augmentation de la concentration de CO₂ dans l'atmosphère, la température de l'air et la variabilité de participation, auront un impact positif ou négatif sur la production agricole en fonction de l'interaction entre ces différents aspects (FAO, 2016; Malhi et al., 2021). La production végétale et l'efficacité de l'utilisation de l'eau engendrent des concentrations atmosphériques de CO₂ plus élevées, en particulier pour les plantes de type C3 comme le blé. Cela est dû à des taux plus élevés de photosynthèse (Morison, 1987) et à une meilleure réponse au stress liée à une fermeture stomatique réduite qui régule mieux la transpiration de la plante (Drake et al., 1997). D'autre part, un taux de CO₂ atmosphérique plus élevé peut avoir un effet négatif sur la qualité des grains en réduisant la concentration en protéines du grain (Kimball et al., 2001). Par ailleurs, l'augmentation de la température de l'air peut avoir un impact négatif sur la production des cultures, en raison du stress thermique (Herwaarden et al., 1998). C'est particulièrement le cas si elle se produit à des stades phénologiques sensibles, par exemple la pollinisation pour le blé (Burke et al., 1988). De même, la hausse de la température réduit la durée de la saison de culture, en entraînant une diminution du rayonnement intercepté par les plantes (Mearns et al., 1997). Un autre effet lié à cette hausse de la température est l'augmentation de la demande en eau des plantes en raison d'une évapotranspiration accrue (Peng et al., 2004). Il est évident qu'une pluviométrie plus faible au cours du cycle de développement du blé, à l'émergence, au tallage (Hafid et al., 1998) ou pendant le stade de remplissage des grains (Heng et al., 2007), peut affecter de manière drastique le rendement, en particulier pour les cultures pluviales.

Les modèles de culture forcés par les projections climatiques futures ont été utilisés dans plusieurs études pour étudier l'impact du changement climatique sur la production agricole. (Asseng et al., 2004; Dettori et al., 2017; Lovelli et al., 2010; Ludwig en Asseng, 2006; Vanuytrecht et al., 2011). Si on ne considère que l'augmentation de la température de l'air et les modifications des précipitations, les rendements diminuent (Lobell et al., 2011). En revanche, la plupart des études de simulation réalisées sur des environnements méditerranéens semi-arides suggèrent que les effets de la fertilisation de CO₂ pourraient compenser les impacts négatifs de la hausse des températures, entraînant une augmentation des rendements (Ludwig

en Asseng, 2006; Ruiz-Ramos en Mínguez, 2010; Saadi et al., 2015). Concernant les besoins en eau, Saadi et al. (2015) ont démontré que dans des conditions optimales, les besoins nets en irrigation pourraient diminuer de 11% à l'horizon 2050 dans la région Sud-Méditerranéenne. Toutefois, d'autres études révèlent une augmentation des besoins en eau, Lovelli et al. (2010) et expliquent que l'augmentation de la demande évaporative associée à l'augmentation de la température ne pourrait pas être compensée par le raccourcissement de la durée des stades phénologiques et la fermeture partielle des stomates. Les interactions complexes entre les divers aspects du changement climatique, montrent que les impacts simulés de leurs effets combinés sur le rendement et les besoins en eau dépendent fortement des conditions locales et aussi des diverses représentations des processus utilisés dans les outils de modélisation. En particulier, la précision des projections d'impact dépend de manière critique de la représentation de l'effet de fertilisation de CO₂ dans les modèles de culture (Long et al., 2006). Des expériences d'enrichissement en dioxyde de carbone à l'air libre (Free Air Carbon dioxide Enrichment, FACE) tendent à démontrer que les effets fertilisants projetés sur le rendement peuvent surestimer l'effet fertilisant jusqu'à 50% (Long et al., 2006). Afin de faire face à cette grande incertitude, les études d'impact du changement climatique sur le rendement et les besoins en eau des cultures sont désormais généralement basées sur deux expériences : avec et sans l'effet fertilisant de CO₂.

Prévision précoce du rendement en céréales

Comme cité plus haut, la prévision précoce du rendement des cultures est un outil qui permet de renforcer la sécurité alimentaire (Filippi et al., 2019; Johnson et al., 2016; Kogan, 2019; Peng et al., 2016). En plus de la pratique traditionnelle basée sur l'observation des experts agronomes, les deux approches les plus utilisées pour la prévision du rendement des cultures sont : les modèles empiriques basés sur la régression et les modèles de croissance des cultures alimentés par les prévisions météorologiques (Basso en Liu, 2019).

Les modèles de croissance des cultures sont capables de décrire les principaux processus physiques et physiologiques en représentant les interactions complexes entre la culture, le sol, la météo et les pratiques de gestion (Whisler et al., 1986). Ainsi, ils peuvent fournir une estimation satisfaisante du rendement des cultures à la fin de la saison de croissance, si les données et les paramètres d'entrée sont renseignés avec précision. Une des limitations de l'utilisation de ces modèles pour la prévision du rendement pendant la saison de croissance est liée à l'incertitude de forçage météorologique, entre la date de prévision et la date de récolte (Lawless en Semenov, 2005). De même, la forte demande des données et des paramètres

d'entrée (forçage climatique spatialisé, pédologie, informations sur le type et la variété de culture, les pratiques de gestion, la date de semis, etc.) est difficile à satisfaire ou à évaluer avec une précision suffisante à grande échelle (Fraisie et al., 2001).

Par contraste, les modèles empiriques sont basés uniquement sur la donnée, ils sont simples et ils ont besoin de moins de paramètres que les modèles de croissance des cultures. De ce fait, ils sont extrêmement utilisés dans un contexte de prévision opérationnelle des rendements des cultures comme le Joint Research Centre Monitoring Agricultural Resources (JRC MARS, <https://ec.europa.eu/jrc/en/mars>). Ces modèles reposent sur l'utilisation de certaines variables ou d'indicateurs marqueurs des conditions environnementales (données agrométéorologiques et/ou télédéteectées ...) qui sont utilisées comme variables indépendantes pour prévoir le rendement (Balaghi et al., 2008; Johnson, 2014; Kogan et al., 2013, 2005; Meroni et al., 2016; Salman en Al-Karablieh, 2001). La performance de ces modèles dépend fortement de la quantité et la qualité des données (Martinez et al., 2009). Comme les données observées augmentent en quantité et en qualité ces dernières années, les modèles empiriques basés sur la régression présentent généralement des performances satisfaisantes (Kogan et al., 2013; Mathieu en Aires, 2018).

Les données météorologiques sont utilisées depuis longtemps pour expliquer la variabilité du rendement des cultures (Basso et al., 2013 ; Dumont et al., 2015 ; Mathieu et Aires, 2018). Dans ce contexte, Giri et al. (2017) ont utilisé des variables météorologiques, y compris les températures minimales et maximales, l'humidité relative de l'air et les précipitations à partir de la date de semis jusqu'au stade de pollinisation, comme prédicteurs pour prévoir le rendement du blé en Inde. A cause du manque des stations d'observation à une échelle spatiale plus grande, les recherches se sont concentrées sur l'élaboration des relations entre différents indices extraits des données satellites et le rendement observé (Anderson et al., 2016; Cai et al., 2019; Rembold et al., 2013; Salazar et al., 2007; Sibley et al., 2014). Le principal avantage de l'utilisation des données de télédétection dans la prévision du rendement des cultures, est qu'elles sont gratuitement accessibles et permettent d'obtenir des informations à grande échelle, indépendamment des frontières géographiques. Plusieurs chercheurs ont utilisé le NDVI extrait de données de télédétection, deux à trois mois avant la récolte et ont développé des modèles de régression linéaire pour la prévision des rendements du maïs, du blé ou du riz (Becker-Reshef et al., 2010; Kogan et al., 2013; Skakun et al., 2016; Wang et al., 2014) dans plusieurs régions du globe. Salazar et al. (2007) et Liu et Kogan, (2002) ont également utilisé des indices de sécheresse dérivés des données de télédétection tel que le VCI et le TCI en tant que prédicteurs

du rendement du blé aux États-Unis et du rendement du soja au Brésil. Les modèles de prévision du rendement du blé basés sur les indices de sécheresse dérivés de la télédétection (VCI et TCI) en Espagne ont montré une meilleure performance que les modèles basés sur les anomalies de précipitations (García-León et al., 2019). Cela peut s'expliquer par la forte puissance de ces indices à détecter avec précisions les conditions de sécheresse, car ces indices tiennent compte des conditions climatiques et biophysiques des cultures, par rapport aux indices basés uniquement sur les précipitations. (García-León et al., 2019).

D'autre part, plusieurs études ont montré l'impact des pseudo-oscillations climatiques à grande échelle sur la production agricoles (Ceglar et al., 2017 ; Nguyen-Huy et al., 2017 ; Wang et al., 2020), et sur les précipitations mensuelles futures (Knippertz et al., 2003 ; Wang et al., 2020). Pour cela , les indices et les données climatiques à grande échelle, y compris le El Niño Southern Oscillation (ENSO), le North Atlantic Oscillation (NAO) et le Sea Surface Temperature (SST), ont été utilisés comme prédicteurs du rendement des cultures dans différentes régions du monde (Lehmann et al., 2020 ; Martinez et al., 2009 ; Podestá et al., 2002 ; Wang et al., 2020). Au Maroc, en particulier, il a été démontré que les rendements du blé sont fortement liés au NAO en Décembre et au mode principal de la SST dans l'Atlantique tropical (Jarlan et al., 2014). En Australie, les indices climatiques à grande échelle liés à ENSO ont été utilisés pour prédire le rendement du blé jusqu'à trois mois avant la récolte (Wang et al., 2020). Plusieurs études ont également combiné des données multi-sources pour prévoir le rendement. Cai and Sharma, (2010) ont utilisé le NDVI, les précipitations et la température pour prévoir, respectivement, le rendement du riz et du blé en Inde. D'un point de vue de la méthodologie, la plupart des études antérieures citées sont basées sur la régression linéaire multiple alors que les liens entre les rendements et les prédicteurs potentiels sont probablement non linéaires. Le machine learning est devenu un outil important d'aide à la décision pour la prévision du rendement des cultures (van Klompenburg et al., 2020). Récemment, plusieurs études ont examiné les performances d'algorithmes de machine learning tels que la machine à vecteur de support (SVM), la Random forest (RF), l'eXtreme Gradient Boost (XGBoost), pour la prévision des rendements à différentes échelles en utilisant des données multi-sources et ils ont constaté que les méthodes non linéaires ont une meilleure performance pour la prévision des rendements que la régression linéaire multiple, en raison de la non-linéarité entre le rendement des cultures et ses prédicteurs potentiels. (Abbas et al., 2020; Cao et al., 2020; Feng et al., 2020; Johnson et al., 2016; Kamir et al., 2020; Kang et al., 2020; Mateo-Sanchis et al., 2019).

Les trois principales questions auxquelles nous souhaitons contribuer à répondre dans cette thèse sont les suivantes :

- Quelle est la relation entre la sécheresse agricole identifiée par des indices de télédétection, les sorties du LDAS et les rendements céréaliers au Maroc ?
- Comment prédire précocement les rendements céréaliers ?
- Quels sont les impacts du changement climatique sur le rendement optimal et les besoins en eau du blé dans la région sud de la Méditerranée ?

III) Objectifs et approches

Dans ce contexte, les objectifs de ce travail de thèse sont (i) d'évaluer le lien entre la sécheresse agricole et le rendement des céréales, (ii) de prédire à l'échelle saisonnière ces rendements et finalement, (iii) d'étudier l'impact du changement climatique sur le rendement et les besoins en eau du blé.

Afin d'évaluer le lien entre la sécheresse agricole et le rendement des céréales dans notre pays, nous avons identifié la sécheresse agricole par des indices de télédétection dans 3 domaines de longueur d'ondes : le visible et le proche infrarouge, l'infrarouge thermique et les micro-ondes. Ces indices sont le VCI, TCI, SMCI et le Soil water index (SWI). En plus des indices de télédétection, nous avons identifié la sécheresse par les anomalies des variables clés de la surface, qui sont : l'indice de surface foliaire (LAI), l'humidité du sol (SM) à différentes profondeurs, l'évaporation du sol (Ev) et la transpiration des plantes (Tr) dérivés à partir du LDAS développé par Météo-France. Une analyse de corrélation a été menée pour évaluer les relations entre les indices de sécheresse et le rendement des céréales à l'échelle mensuelle. Puis nous avons intégré ces indices à l'échelle des principaux stades phénologiques du développement du blé et nous avons discuté l'impact de l'intégration de ces indices à différentes échelles temporelles. Ensuite, nous avons évalué la valeur ajoutée de l'utilisation des sorties du LDAS par rapport aux indices de télédétection. Finalement, nous nous sommes focalisés sur la saison agricole 2015-2016 qui est caractérisée par une sécheresse sévère, afin de suivre l'évolution des conditions sécheresses au cours de la saison par les indices de sécheresse.

En exploitant les résultats de l'étude réalisée par [Bouras et al. \(2020\)](#) et les travaux de [Jarlan et al. \(2014\)](#), nous avons développé des modèles empiriques de la prévision précoce du rendement des céréales à l'échelle provinciale au Maroc. Ces modèles sont basés sur des données multi-sources : (i) les indices de sécheresse dérivés de la télédétection (VCI, TCI, SMCI), (ii) les

données météo (température de l'air, précipitation) et (iii) les indices d'oscillations pseudo-climatiques à grande échelle y compris le North Atlantic Oscillation (NAO), le Scandinavian Pattern (SCA), les modes de Sea Surface Temperatures (SST). Nous avons choisi différents algorithmes de machine learning pour développer les modèles de prévision, en plus de l'approche linéaire le Multiple Linear Regression (MLR), nous avons utilisé les approches non-linéaire tel que le Support Vector Machine (SVM), le Random forest (FR) et l'eXtreme Gradient Boost (XGBoost). Dans cette étude, nous avons conçu et appliqué plusieurs expériences avec les méthodes empiriques mentionnées ci-dessus. La première expérience a été conçue pour déterminer la meilleure combinaison des données, comme prédicteurs du rendement qui permet d'obtenir une meilleure prévision du rendement final. La deuxième expérience visait à évaluer la performance des modèles développés avec la meilleure combinaison, pour la prévision précoce, en mars, février et janvier, ce qui correspond à 2, 3 et 4 mois avant la récolte. La dernière expérience a été conçue pour tester la performance pratique de ces modèles développés.

Enfin, nous avons quantifié l'impact du changement climatique sur les rendements de blé irrigués et leur besoin en eau dans la région de Tensift au Maroc. Les projections des températures et de précipitations extraites des bases de données Med-CORDEX selon deux scénarios RCP4.5 et RCP8.5 pour les horizons 2041-2060 (nommé 2050) et 2061-2090 (nommé 2090), sont d'abord évaluées et désagrégées en utilisant l'approche quantile-quantile. Par la suite, nous avons utilisé ces résultats obtenus pour les deux scénarios RCPs pour étudier l'effet de l'augmentation de la température de l'air sur la durée des principaux stades phénologiques de développement du blé. Pour ce faire, nous nous sommes basés sur l'approche degrés-jours et trois dates de semis : semis précoce autour du 15 novembre, semis intermédiaire autour du 15 Décembre et semis tardif autour du 15 janvier, afin de tenir compte des différentes dates de semis dans notre zone d'étude. Les impacts de l'augmentation de la température, de concentration du CO₂ atmosphérique, des changements de précipitations sur les rendements du blé, des besoins en eau et de la productivité, sont ensuite évalués, sur la base du modèle AquaCrop forcé par les projections futures selon 3 expériences : (i) Avec l'augmentation de CO₂ uniquement, (ii) avec l'augmentation de la température et le changement des précipitations uniquement et (iii) avec l'augmentation de CO₂ de la température et le changement des précipitations pour les trois dates de semis. Dans un premier temps, le modèle AquaCrop a été forcé par les observations météorologiques de la période historique (1991-2010) et de la concentration de CO₂ de l'année 2000 fixée à 369 ppm (partie par million). Ces résultats ont

été utilisés pour déterminer la référence du rendement, des besoins en eau et la productivité de l'eau, à partir desquels toute augmentation ou diminution due au changement climatique pourrait être estimée.

Ce manuscrit de thèse est scindé en quatre principaux chapitres :

- L'état de l'art sur la prévision saisonnière et l'impact du changement climatique sur la production des cultures, et le suivi de la sécheresse agricole.
- Le suivi de la sécheresse agricole par la télédétection et les sorties du LDAS et son lien avec la production des céréales.
- La prévision saisonnière du rendement avec des données multi-sources basée sur des modèles empiriques (machine learning)
- Evaluation de l'impact du changement climatique sur le rendement et les besoins en eau du blé.

Chapitre I : Rendements céréaliers et sècheresses, prévision saisonnière et impact du changement climatique

I) La sécheresse

I-1) Définition et type de sécheresse

La sécheresse est un phénomène du système terrestre qui concerne des processus météorologiques, hydrologiques et biophysiques qui peuvent avoir des implications socio-économiques (Wilhite et Pulwarty, 2017). La sécheresse est initialement un phénomène météorologique, les périodes de déficit des précipitations peuvent entraîner une pénurie d'eau sur certains réservoirs ou dans l'ensemble du cycle hydrologique (McKee et al., 1993), qui à son tour affecte la production des cultures (Chaves et al., 2003) et divers systèmes environnementaux (Figure 2) (Vicente-Serrano et al., 2020). Contrairement à l'aridité, qui est une caractéristique permanente du climat et qui est limitée aux zones à faibles précipitations (Wilhite, 2000), une sécheresse est une aberration temporaire qui peut se produire dans toutes les conditions climatiques et toutes les zones du globe, ce phénomène a des effets néfastes très divers (Dai, 2011). On confond souvent une vague de chaleur et une sécheresse, Chang et Wallace (1987) ont souligné la distinction entre une vague de chaleur et une sécheresse, notant qu'une vague de chaleur est associée à une échelle du temps typique de l'ordre d'une semaine, alors qu'une sécheresse peut persister pendant des mois, voire des années dans des cas extrêmes. La sécheresse peut être causée aussi par des processus autres que le manque des précipitations, tel que l'augmentation de la demande atmosphérique en évaporation (Vicente-Serrano et al., 2020) ce qui amplifie le déficit hydrique. De même, les processus biophysiques peuvent être plus ou moins affectés par les déficits en eau (McDowell et al., 2008), et la réponse de la végétation aux sécheresses peut également affecter la disponibilité en eau par la modulation de l'évapotranspiration (Swann, 2018; Teuling et al., 2013).

Quatre types de sécheresse sont largement définis et reconnus dans la littérature (McVicar en Jupp, 1998; Wilhite, 2000; Wilhite en Glantz, 1985) : (1) la sécheresse météorologique caractérisée par un déficit des précipitations, solides et liquides (Olukayode Oladipo, 1985; Palmer, 1965). Ainsi, il s'agit d'une période, qui peut varier du mois à l'année voire dans des cas extrêmes à plusieurs années, durant laquelle les précipitations sont inférieures à la moyenne historique ; (2) la sécheresse agricole caractérisée par un déficit lié à la réserve en eau du sol. Il s'agit d'une période pendant la saison de croissance des cultures durant laquelle l'humidité du sol est inférieure à sa valeur moyenne, ce qui a des conséquences négatives sur le développement et le rendement des cultures (Panu en Sharma, 2002). La sécheresse agricole est généralement provoquée par un cumul des précipitations inférieur à la normale (Narasimhan et Srinivasan, 2005) ou par une distribution temporelle irrégulière des précipitations. Aussi,

elle peut parfois être engendrée par des taux d'évapotranspiration plus élevés (Ciais et al., 2005; Hanson, 1991; Rind et al., 1990; Vicente-Serrano et al., 2010). (3) la sécheresse hydrologique désigne les périodes de déficit du débit des cours d'eau ou du stockage des eaux souterraines. (Dracup et al., 1980; Tallaksen et al., 1997; Yevjevich, 1967). L'impact d'une sécheresse hydrologique est important sur les activités humaines, puisqu'elle va avoir de fortes conséquences sur l'irrigation, les activités touristiques, la production d'énergie hydroélectrique, les transports (dans certains pays) et l'alimentation en eau potable; (4) la sécheresse socio-économique désigne l'effet d'une ou plusieurs des trois précédentes sur les activités humaines généralement mesurée par des indicateurs sociaux et économiques (Senay et al., 2014).

Ces différents types de sécheresse sont liés les uns aux autres et constituent ce qu'on appelle une « cascade ». La Figure 2 illustre la relation entre les différents types de sécheresses ainsi la propagation de la sécheresse en fonction de la durée. En effet, les sécheresses de types agricole, hydrologique ou socio-économique sont décalées dans le temps par rapport à la sécheresse météorologique. Par exemple, il faut souvent plusieurs semaines ou mois avant que l'insuffisance des précipitations se traduise par un déficit d'humidité du sol et que les cultures, commencent à souffrir. Cette présentation reste théorique car les caractéristiques climatiques diffèrent d'une région à l'autre, tout comme la démographie, la nature des activités humaines et les moyens mis en œuvre pour lutter contre la sécheresse, éléments qui peuvent avoir des effets sur la propagation de la sécheresse. Dans ce travail, nous nous concentrerons sur la sécheresse agricole, car elle est considérée comme l'un des problèmes les plus importants qui affecte l'économie, la sécurité alimentaire et la stabilité sociale dans la majorité des pays du monde, en particulier pour ceux situés dans la région méditerranéenne (Tramblay et al., 2020). En général, la sécheresse agricole est le résultat de deux facteurs qui provoquent un déficit d'humidité du sol : (i) un manque de précipitations et/ou (ii) une augmentation de la température qui provoque une augmentation d'évapotranspiration (Figure 2). Les impacts de la sécheresse sur la production agricole dépendent du stade de croissance à laquelle elle intervient, de son intensité, de l'étendue spatiale et de sa durée (Mishra et Singh, 2010). Par exemple, si la sécheresse agricole se produit occasionnellement sur une longue période de temps, les cultures peuvent être capables d'atteindre la maturité avant que la sécheresse ne cause des impacts graves sur ces productions. Par contraste, une sécheresse de courte durée coïncidant avec des stades critiques de développement des cultures (stade de remplissage des grains par exemple pour le blé) peut avoir des conséquences graves, car les cultures ont généralement besoin d'une plus grande quantité d'eau durant cette période (Kharrou et al., 2011).

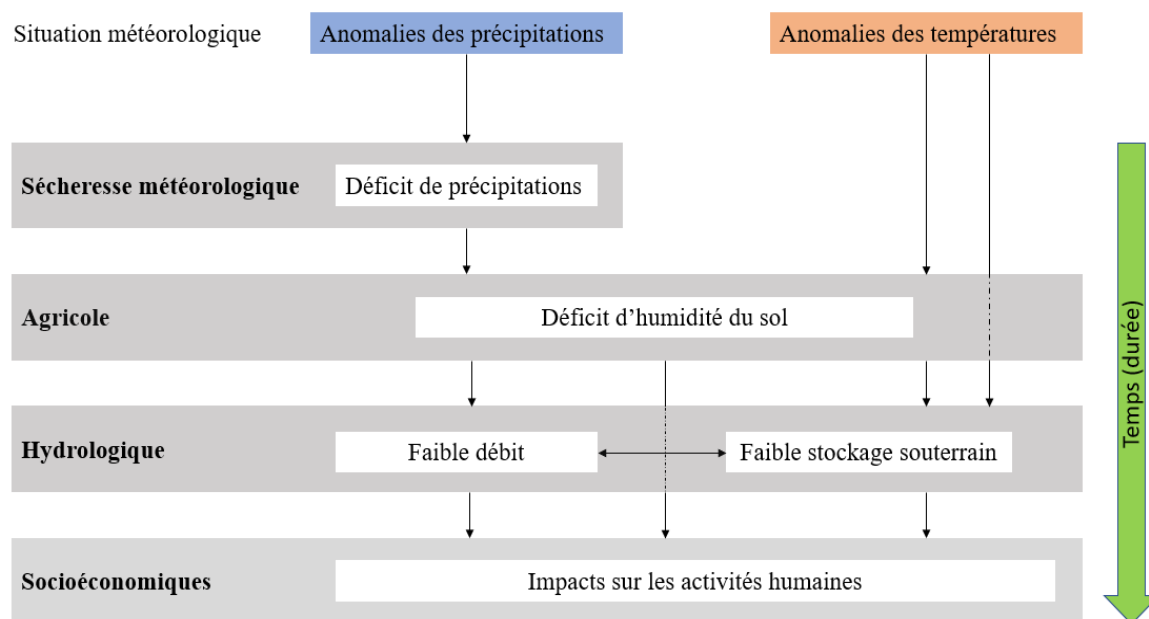


Figure 2 : Mise en évidence du lien existant entre les types de sécheresse. Causes et conséquences des sécheresses. (Source : Organisation Météorologique Mondiale (OMM), rapport n°1006, 2006)

I-2) Suivi de la sécheresse agricole

La sécurité alimentaire est un vaste sujet qui nécessite le suivi de plusieurs indicateurs, tels que la croissance et le rendement des cultures, la sécheresse, l'irrigation et la propagation des maladies (FAO, 2016). Afin de développer une telle stratégie de gestion de risque liée à la sécheresse agricole, il est nécessaire de connaître son évolution. Pour ce faire, il est important de disposer d'outils et des moyens adaptés permettant de fournir des informations sur l'intensité, l'étendue et la durée de ce phénomène (WMO, 2006). Le suivi de la sécheresse agricole est une composante essentielle pour une meilleure gestion des risques liée à la sécheresse. Il comprend, le suivi et l'évaluation continue des quantités et des régimes de précipitations, des conditions d'humidité du sol et de végétation, de l'évapotranspiration et de la température pendant la saison de croissance en temps quasi réel, pour l'objectif de développer des indices/indicateurs qui permettent de déterminer l'intensité, l'étendue et la durée de sécheresse (Senay et al., 2014).

Les indices de suivi de la sécheresse agricole peuvent être divisés, selon leurs sources des données de calcul, en indices basés sur (i) les mesures in-situ, (ii) les données de télédétection et (iii) les sorties des systèmes d'assimilation des données terrestres, qui combinent les modèles de surface et les observations in-situ ou de télédétection.

I-2-1) Les indices in situ de suivi de la sécheresse agricole

Les indices de suivi de la sécheresse agricole basés sur les mesures in situ sont les plus précis pour la surveillance et la détection de la sécheresse (Maes et Steppe, 2012). Ces indices sont basés sur des mesures hydro-climatiques (y compris les précipitations, la température, l'humidité relative et la teneur en eau du sol), le Tableau 1 présente quelques indices de suivi de la sécheresse agricole in situ les plus utilisés avec leurs avantages et inconvénients. Le Palmer Drought Severity Index (PDSI) est l'un des premiers indices utilisé pour déceler la sécheresse (Palmer, 1965). Il se calcule à partir des valeurs mensuelles des températures et de précipitations, complétées par des informations sur la capacité de rétention d'eau du sol. Le PDSI est une mesure standardisée, allant d'environ -10 (sec) à +10 (humide), les valeurs inférieures à 3 représentant une sécheresse sévère à extrême. L'inclusion des données sur le sol et le calcul du bilan hydrique font du PDSI un indice robuste pour déceler la sécheresse. Cependant, la nécessité de disposer d'une série complète de données (d'environ neuf mois) peut être une limitation dans les régions peu ou pas jaugées. Enfin, le PDSI n'est pas adapté pour détecter les sécheresses qui se forment rapidement car il est mieux adapté pour une échelle de temps de 9 à 18 mois (Guttman, 1998; Palmer, 1968). Considérant ces limitations, Palmer (1968) a développé le Crop Moisture Index (CMI) pour décrire les conditions de sécheresse à court terme qui influent sur l'agriculture des régions céréalières des États-Unis. Le CMI est basé sur les précipitations et les températures moyennes journalières pour estimer le bilan hydrique du sol (Palmer, 1968). Il est égal ou proche de zéro en début de la saison de croissance et il reste proche de zéro tant que les conditions météorologiques sont favorables, et revient à un niveau proche de zéro à la fin de la saison de croissance. Pendant les périodes de sécheresse, les valeurs de CMI sont négatives (Palmer, 1968). Le PDSI et le CMI détectent les conditions de sécheresse qui affectent le développement des cultures, mais n'indiquent pas les impacts probables sur le rendement. Pour cette raison le Crop Specific Drought Index (CSDI) a été élaboré pour étudier l'impact de la sécheresse sur le rendement réel des cultures (Meyer et al., 1993). Grâce au calcul du bilan hydrique du sol, le CSDI analyse l'impact de la sécheresse, il détermine aussi à quel moment le stress hydrique a débuté pendant la croissance et quelles en seront les répercussions sur le rendement final. Le calcul de CSDI est basé sur les données climatiques journalières (températures maximales et minimales, précipitations, point de rosée, vitesse du vent et rayonnement solaire total), les caractéristiques du profil du sol et des informations sur le rendement et la phénologie de la culture. Le CSDI est donc calculé spécifiquement pour une culture précise et s'appuie sur le développement de la plante. Cependant, les données d'entrée sont assez complexes et de nombreuses régions ne disposent

pas des instruments ou des relevés nécessaires. En plus de ces indices basés sur une approche physique (modèles de bilan hydrique) et qui ont des limitations en termes de suivi de la sécheresse à grande échelle (Vicente-Serrano et al., 2011), des indices basés sur des approches statistiques ont été développés pour le suivi de la sécheresse. McKee et al. (1993) ont proposé le Standardized Precipitation Index (SPI) basé sur les précipitations pour le suivi de la sécheresse, plusieurs études ont montré que le SPI était plus adapté que le PDSI pour suivre les sécheresses (Guttman, 1998; Hayes et al., 1999; Keyantash en Dracup, 2002). Le plus grand avantage de l'indice SPI est qu'il repose uniquement sur les données des précipitations, ce qui le rend très facile à calculer et à utiliser. L'Organisation Météorologique Mondiale (OMM) recommande l'utilisation du SPI pour le suivi de la sécheresse (Hayes et al., 2011; WMO, 2012) en raison de sa simplicité et de sa flexibilité pour surveiller la sécheresse à l'échelle hebdomadaire ou à l'échelle de 10 jours, ou à l'échelle de 1, 3, 6, 9, 12, et 24 mois ou plus. Aussi il s'applique à tous les régimes climatiques et permet de comparer des régions avec des régimes de climats différents. L'indice SPI, malgré sa simplicité et son large usage, ne tient compte que de l'approvisionnement en eau (précipitation) sans la demande d'évaporation atmosphérique (DEA), ce qui pourrait affecter le bilan hydrique et l'utilisation de l'eau dans une région. Afin de prendre en compte le DEA, Vicente-Serrano et al., (2010) ont développés le Standardized Precipitation Evaporation Index (SPEI) qui est similaire sur le principe général au SPI si ce n'est que la demande atmosphérique est prise en compte dans le calcul du SPEI. Cependant, comme le SPEI est un indice mensuel, il pourrait ne pas déceler assez tôt les sécheresses qui s'installent rapidement, également le SPEI est sensible à la méthode de calcul de ETp (Beguería et al., 2014).

En général, ces indices fournissent des estimations très précises sur les conditions de la sécheresse agricole aux endroits où les variables d'entrée sont acquises. Cependant, la répartition spatiale inégale des stations de mesure impose souvent une incertitude dans la délimitation du contexte spatial.

Tableau 1: Indices in-situ pour le suivi de la sécheresse agricole

Indices	Données d'entrée	Avantages	Inconvénients	Auteurs
Palmer Drought Severity Index (PDSI)	Température, précipitations, humidité du sol, évapotranspiration	Fournit une meilleure analyse des conditions de sécheresse par rapport aux autres indices	Processus de calcul complexe	(Palmer, 1965)
Crop Moisture Index (CMI)	Température, précipitations	Facilement calculable	Moins sensible a des sécheresses de longue durée par rapport aux autres indices	(Palmer, 1968)
Standardized Precipitation Index (SPI)	Précipitations	Simple, mesure les conditions de sécheresse à différentes échelles du temps	Basé seulement sur les précipitations, difficiles à interpoler sur les grandes échelles	(McKee et al., 1993)
Soil Moisture index (SMI)	Humidité et Caractéristiques de sol	Capable de détecter les conditions de 'flash drought'	Disponibilité des mesures d'humidité et des caractéristiques du sol à grande échelle	(Hunt et al., 2009)
Crop Specific Drought Index (CSDI)	Température, précipitations, évapotranspiration	Permet d'estimer le contenu en eau du sol dans les différentes couches	Demande un nombre élevé de variables d'entrée	(Meyer et al., 1993)

I-2-2) Le suivi de la sécheresse agricole par télédétection

La télédétection est définie comme l'ensemble des connaissances et techniques utilisées pour déterminer des caractéristiques physiques et biologiques d'objets par des mesures effectuées à distance (Mulders, 1987). Ces caractéristiques sont déterminées après la mesure d'un signal électromagnétique émis ou réfléchi par l'objet dans un certain domaine de longueur d'onde. Les capteurs embarqués sur des missions d'observation de la terre ont pour rôle de mesurer le signal émis ou réfléchi par les surfaces terrestres et de le transmettre à des stations de contrôle au sol (Campbell, 1987). En raison de contraintes technologiques ou physiques, et notamment des propriétés de transparence de l'atmosphère, la télédétection spatiale n'utilise qu'une partie du spectre électromagnétique, on distingue les domaines visible ou solaire ($\lambda = 0.38$ à $3 \mu\text{m}$),

infrarouge thermique ($\lambda = 3$ à $1000 \mu\text{m}$), et micro-onde ($\lambda = 10^{-3}$ m à 0.3 m) (Aggarwal, 2004). Le rayonnement mesuré par un capteur est soit réfléchi par la surface dans le domaine solaire (optique), soit émis dans le domaine de l'infrarouge thermique, soit émis ou réfléchi dans le domaine des micro-ondes en fonction du caractère passif ou actif du capteur. Les systèmes de télédétection ne mesurent pas directement les paramètres d'intérêt de la surface terrestre (Mather, 1987). Au lieu de cela, les capteurs reçoivent un rayonnement électromagnétique et un algorithme d'inversion est nécessaire pour obtenir des paramètres de surface terrestre à partir des données de la télédétection (Elfarkh, 2021)

La télédétection offre l'une des rares approches capables de suivre l'évolution spatiale et temporelle des sécheresses à grande échelle (Jiao et al., 2021). L'utilisation de la télédétection pour le suivi de la sécheresse agricole repose sur le fait que la sécheresse peut affecter les propriétés biophysiques et chimiques du sol et de la végétation, telles que l'humidité du sol, la matière organique, la biomasse de la végétation, la chlorophylle, la température du couvert végétal et du sol. Ainsi, elle peut modifier les réponses spectrales et thermiques, qui peuvent être utilisées comme indicateurs de l'apparition de la sécheresse (Anjum et al., 2011; Ghulam et al., 2007; Tucker et Choudhury, 1987; Zargar et al., 2011). Afin de tenir compte de l'étendue spatiale de la sécheresse agricole, des indices basés sur la télédétection ont été largement utilisés pour le suivi de la sécheresse agricole (West et al., 2019). Ces indices peuvent être regroupés en quatre groupes : (i) Les indices basés sur la télédétection optique, (ii) thermique, (iii) micro-ondes, et (iv) sur la télédétection combinée (multi-capteurs). Il est intéressant de mentionner que la facilité d'utilisation des méthodes basées sur la télédétection pour le suivi de la sécheresse dépend des différents facteurs, notamment la disponibilité des données satellitaires, le coût, la qualité des données, les exigences de prétraitement et de post-traitement (West et al., 2019).

a) Suivi de la sécheresse par télédétection visible et proche infra-rouge

La télédétection optique permet la mesure du rayonnement d'origine solaire réfléchi par les surfaces dans les bandes de longueurs d'onde du visible (0.4 à $0.7 \mu\text{m}$), du proche-infrarouge (NIR) (0.7 à $1.30 \mu\text{m}$) et de l'infrarouge à ondes courtes (SWIR) (1.3 à $3.0 \mu\text{m}$). Cette mesure est fonction des caractéristiques de la surface observée et des conditions d'observation (Richards et Jia, 2006). Les caractéristiques de la surface décrivent la nature, l'état, la structure géométrique et l'agencement des éléments qui la constituent. Ces caractéristiques vont conditionner les propriétés de réflexion, d'absorption ou de transmission du rayonnement à l'interface sol-végétation-atmosphère (Myneni et al., 1995). La géométrie d'illumination et d'observation, ainsi que l'atmosphère (absorption et diffusion du rayonnement), vont également

influencer la mesure. Différents produits satellites dans ce domaine de longueur d'onde avec multiples résolutions spatiale et temporelle sont actuellement disponibles et gratuitement accessibles. Les produits les plus utilisés pour le suivi de la sécheresse selon [Jiao et al.\(2021\)](#) sont présentés dans le Tableau 2.

Tableau 2: Les principaux produits satellitaires couvrant l'ensemble du globe et utilisés pour le suivi de la sécheresse

	Satellite	Résolution temporelle	Résolution Spatial	Période de disponibilité	Référence
Végétation	AVHRR NDVI/EVI	16 jours	0.083°	1982 – présent	(Tucker et al., 2005)
	MODIS NDVI/EVI	16 jours	500 m	2000 – présent	(Beck et al., 2006)
	MODIS LAI	8 jours	500 m	2000 – présent	(Myneni et al., 2002)
	Landsat NDVI	16 jours	30 m	1972 – présent	(Beck et al., 2011)
	GOME-2 SIF	16 jours	0.5°	2004 – présent	(Joiner et al., 2011)
Température de surface	Landsat	16 jours	60 m	1999 – présent	(Sobrino et al., 2004)
	MODIS	Journalier	1 km	2000 – présent	(Wan en Li, 1997)
	ASTER	2 jours	90 m	1999 – présent	(Jiménez-Muñoz en Sobrino, 2010)
	AVHRR	16 jours	~1.1 km	1978 – présent	(Kerr et al., 1992)
	AATSR	35 days	~1 km	2004 – présent	(Prata, 2002)
Humidité du sol	AMSR-E	Journalier	25 km	2002 – 2011	(Paloscia et al., 2006)
	AMSR2	Journalier	25 km	2012 – présent	(Kim et al., 2015)
	SSM/I	Journalier	25 km	1987 – présent	(Paloscia et al., 2001)
	ASCAT	3 jours	12.5/25 km	2007 – présent	(Brocca et al., 2011)
	SMAP	2-3 jours	3/9/36 km	2015 – présent	(Das et al., 2011)
	SMOS	2-3 jours	35 km	2010 – présent	(Kerr et al., 2012)

Les propriétés spectrales des couverts végétaux dépendent à la fois de la nature de la végétation qui les composent, de leur état physiologique, de leur teneur en eau, mais aussi du sol sous-jacent ([Govender et al., 2009](#); [Myneni et al., 1995](#)). La végétation verte possède une signature spectrale spécifique dans ce domaine de longueur d'onde. En condition favorable, la chlorophylle présente dans la végétation verte, absorbe la portion rouge (R) du spectre électromagnétique. Par contraste, dans la portion du proche-infrarouge (NIR), les ondes sont fortement diffusées par la structure spongieuse du mésophylle des feuilles ([McVicar en](#)

Bierwirth, 2001; McVicar en Jupp, 1998; Rock et al., 1986). En situation de stress hydrique, la réflectance du NIR est plus faible alors que celui du R est plus élevé, la différence entre ces deux réflectances est donc plus faible en périodes de sécheresse (Nasser, 2020). Différentes combinaisons de ces deux bandes spectrales (R et NIR) ont été utilisées afin de développer plusieurs indices pour le suivi de la végétation (Xue en Su, 2017). Parmi tous ceux proposés, le Normalized Difference Vegetation Index (NDVI) (Tucker, 1979) est l'indice le plus utilisé pour la dynamique spatio-temporelle des couverts végétaux. Le NDVI a été utilisé pour le suivi, la classification de la végétation et la détermination de phénologie des cultures. De plus, il est également efficace pour surveiller les précipitations et la sécheresse, estimer les rendements des cultures, détecter les impacts météorologiques et anthropiques sur l'agriculture (Kogan, 1990; McVicar en Bierwirth, 2001; Tucker en Choudhury, 1987; Unganai en Kogan, 1998). Cependant le NDVI souffre (1) d'une saturation rapide quand la densité de végétation augmente ; (2) d'une ambiguïté liée à la contribution du sol qui peut rendre son interprétation douteuse dans les régions où le couvert est éparé (Kogan, 1995a, 1990). Kogan, (1990) a proposé le Vegetation Condition Index (VCI), qui utilise les valeurs extrêmes minimales, maximales calculées sur une période historique et les valeurs actuelles du NDVI afin de produire des anomalies normalisées et pour séparer les variations à court terme dans NDVI liées aux conditions météorologiques des variations à long terme de l'écosystème. Le VCI est une approximation de la composante météorologique dans le NDVI (Kogan en Sullivan, 1993). En ce sens, il est considéré comme l'un des meilleurs indicateurs de la distribution des précipitations que le NDVI (Kogan, 1990). Il permet aussi de comparer l'effet du climat sur des zones différentes. Le VCI apporte donc une amélioration par rapport à NDVI dans l'analyse de la condition de la végétation pour des zones non homogènes (Kogan, 1990). En premier lieu, le VCI a été créé pour suivre les conditions de la sécheresse du Mid-Ouest américain, le VCI a été utilisé dans plusieurs régions du globe afin de suivre la sécheresse à grande échelle. En Afrique du Sud (Unganai en Kogan, 1998), en Inde (Singh et al., 2003), en Chili (Zambrano et al., 2016) et en Chine (Jiao et al., 2016). Aussi, le VCI a été utilisé pour dériver le rendement du blé aux États-Unis et le rendement du soja au Brésil (Liu en Kogan, 2002; Salazar et al., 2007). Le VCI, tout comme les autres indices de domaine optique comporte les mêmes limitations associées à la méthode d'acquisition des données (comme les conditions atmosphériques). De plus, l'application du VCI est fortement liée au nombre d'images disponibles ainsi qu'à la qualité de ces images.

Le déficit de l'humidité du sol pendant la sécheresse agricole abaisse le potentiel hydrique de la plante et diminue la transpiration, ce qui entraîne une réduction de la turgescence cellulaire et de la teneur en eau relative (Rodriguez-Iturbe et al., 2001; Wang et al., 2008). Pour cette raison d'autres indices, dans le domaine optique, estiment le contenu en eau de la végétation grâce aux réflectances acquises dans le SWIR. Dans cette partie du spectre électromagnétique, la réflectance des plantes est sensible à la présence de l'eau dans les feuilles et la structure spongieuse du mésophylle des feuilles (Ceccato et al., 2001; Ghulam et al., 2008; Hunt en Rock, 1989; Rock et al., 1986). La différence entre la réflectance du SWIR et du NIR peut, de la même manière que pour le R et le NIR, être utilisée pour caractériser l'état de la végétation (Hunt en Rock, 1989). L'un des premiers indices utilisant ces deux bandes spectrales est le Moisture Stress Index (MSI) proposé par (Hunt en Rock, 1989) avec les bandes TM4 et TM5 de Landsat. Cet indice est fortement corrélé au contenu en eau de la végétation et donc aux conditions de sécheresse. Cependant le MI ne permet pas de détecter le stress hydrique précoce des plantes, il commence à détecter le stress que lorsque la plante perd la moitié de son contenu en eau (Hunt en Rock, 1989). Gao (1996) ont proposé un autre indice, le Normalized Water Difference Index (NDWI), pour la détection de l'eau contenue dans la végétation. Le NDWI a montré son efficacité pour le suivi de la sécheresse mais aussi pour l'estimation du rendement des cultures (Gu et al., 2008, 2007; Tuvdendorj et al., 2019; Wang et al., 2014). De même, le Shortwave Infrared Water Stress Index (SIWSI) dérivé des bandes NIR et SWIR, également sensible à la teneur en eau des feuilles, a montré une forte corrélation avec les estimations de l'humidité de surface au Sahel (Fensholt en Sandholt, 2003). Aussi en Sénégal, Fensholt et al. (2010) ont trouvé que le SWIR est corrélé avec le NDVI. En résumé, les principales limites de ces indices basés sur les réflectances acquises dans le domaine optique : (1) une sensibilité la masse volumique globale d'eau dans la végétation et non pas au contenu relatif qui pourrait renseigner sur un stress ou une sécheresse (Ceccato et al., 2002, 2001; Jackson et al., 2004). De même, l'utilisation de ces bandes ne permet pas d'éliminer complètement les effets du sol dans les zones à faible densité de végétation (Zhang et al., 2010).

Le Tableau 3 regroupe les indices dérivés de la télédétection optique qui sont largement utilisés pour le suivi de la sécheresse agricole avec leur formule et les données utilisées. Vu les avantages du VCI cité auparavant tels que sa simplicité dans le calcul et son applicabilité dans les différentes régions du globe, le VCI calculé par le NDVI dérivé de MODIS a été choisi pour caractériser la sécheresse dans notre étude.

Tableau 3: Indices dérivés de la télédétection optique pour le suivi de la sécheresse agricole

Indice		Formule	Satellite	Région	Auteur
Normalized Difference Vegetation Index (NDVI)		$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$	AVHRR	USA	(Tucker, 1987)
Moisture Index (MSI)	Stress	$MSI = \frac{\rho_{SWIR2}}{\rho_{NIR}}$	Landsat	USA	(Hunt et Rock, 1989)
Normalized Difference Water Index (NDWI)	Water Index	$NDWI = \frac{\rho_{NIR} - \rho_{SWIR2}}{\rho_{NIR} + \rho_{SWIR2}}$	AVIRIS	USA	(Gao, 1996)
Vegetation Condition Index (VCI)	Index	$VCI = \frac{NDVI_i - NDVI_{min}}{NDVI_{max} + NDVI_{min}}$	AVHRR	USA	(Kogan, 1995)
Visible Drought Index (VSDI)	Shortwave Index	$VSDI = 1 - [(\rho_{SWIR2} - \rho_B) + (\rho_R - \rho_B)]$	MODIS	USA	(Zhang et al., 2013)

* ρ est la valeur de réflectance de la surface des bandes bleu B, rouge (R), proche infrarouge (NIR) et infrarouge à ondes courtes (SWIR1, SWIR2 et SWIR3 centrées à ~ 1.24 , ~ 1.64 et ~ 2.14 μm).

b) Suivi de la sécheresse par télédétection infrarouge thermique

La télédétection dans l'infrarouge thermique (IRT) diffère de la télédétection visible par l'origine du rayonnement. Dans le cas du visible il s'agit du soleil, et l'objet observé est une source secondaire. Dans le cas de l'infrarouge thermique l'objet observé est la source primaire de rayonnement. Les capteurs dans IRT sont des radiomètres mesurant l'énergie émise par la terre qui est directement reliée à la température de la surface (LST) par la loi de Stefan-Boltzmann. Lorsque la demande en eau des plantes est plus grande que l'eau disponible dans le sol, un stress hydrique se produit. Afin de conserver l'humidité, les stomates des feuilles ferment afin de minimiser les pertes par transpiration. Comme le bilan énergétique doit demeurer équilibré, une partie de l'énergie qui est normalement utilisée pour l'évapotranspiration est alors répartie entre le flux de chaleur dans le sol et le flux de chaleur sensible dans l'atmosphère. Il y a alors une hausse de la température apparente du couvert végétal (Anderson et al., 2015, 2013; Crago, 1996; McVicar en Jupp, 1998; Rahimzadeh-

[Bajgiran et al., 2012](#)). Les indices de suivi de la sécheresse agricole basés sur la LST sont potentiellement de meilleurs indicateurs pour détecter les ‘flash Drought’ en raison de la réaction rapide de la LST aux conditions de stress hydrique que ceux dérivés des données du domaine visible-PIR ([Anderson et al., 2016, 2015, 2013](#)). Différents produits satellitaires fournissent des mesures de la LST à des résolutions spatiale et temporelle différentes et sont actuellement disponibles et gratuitement accessibles. Les produits les plus utilisés pour le suivi de la sécheresse sont présentés dans le Tableau 2.

Le Temperature Condition Index (TCI) est un indice de suivi de la sécheresse proposé par ([Kogan, 1997](#)), il est basé sur la température de surface et a été initialement dérivé des images du capteur AVHRR. Comme pour les indices de végétation, il est applicable à l'échelle régionale ou continentale. Le TCI est un indice simple et il ne nécessite qu'une série temporelle de données de la température de surface. Plusieurs études ont montré que le TCI est un indice efficace pour le suivi de la sécheresse dans différentes régions du globe ([Bento et al., 2018b; García-León et al., 2019; Kogan, 1995a; Tuvdendorj et al., 2019](#)). Il a aussi été indirectement utilisé pour l'estimation du rendement des cultures ([Liu en Kogan, 2002; Anup K. Prasad et al., 2006; Salazar et al., 2007](#)). Un autre indice a été développé par [McVicar et Jupp, \(1998\)](#), le Normalized Difference Temperature Index (NDTI). Le NDTI a des bases physiques plus solides que le TCI, mais le calcul, un peu plus complexe, présenté dans le tableau 4, demande l'utilisation d'un modèle de bilan d'énergie forcé par des observations météorologiques (la température de l'air, le rayonnement solaire, l'humidité et la vitesse du vent) au moment du passage du satellite ([McVicar et Jupp, 1998](#)). Récemment [Hu et al. \(2020\)](#) ont proposé le Temperature Rise Index (TRI) basé sur les mesures horaires de la LST dérivées des données acquises des satellites géostationnaires comme celui utilisé dans cette étude (MTSAT-2), pour le suivi de la sécheresse agricole en Australie. Le principe sous-jacent du TRI est que le taux d'augmentation de la LST entre 1.5 et 3.5 heures après le lever du soleil, est approximativement linéaire et se produit plus rapidement dans des conditions sèches que dans des conditions humides sur des surfaces végétalisées ([Hu et al., 2020](#)). Le Tableau 4 présente les indices de sécheresse agricole basés sur les données thermiques les plus couramment utilisées.

Tableau 4: Indices dérivés de la télédétection thermique pour le suivi de la sécheresse agricole.

Indice	Formule	Satellite	Région	Auteur
Temperature Condition Index (TCI)	$TCI = \frac{LST_{max} - LST_i}{LST_{max} - LST_{min}}$	AVHRR	USA	(Kogan, 1995a)
Normalized Difference Temperature Index (NDTI)	$NDTI = \frac{LST_{\infty} - LST_s}{LST_{\infty} + LST_0}$	AVHRR	Australie	(McVicar et Jupp, 1998)
Temperature Rise Index (TRI)	$TRI = \frac{\frac{dT}{dt_{p,max}} - \frac{dT}{dt_{p,y}}}{\frac{dT}{dt_{p,max}} + \frac{dT}{dt_{p,y}}}$	MTSAT-2	Australie	(Hu et al., 2020)

LST_{max} et LST_{min} sont les valeurs maximale et minimale de la température de surface sur une période de temps donnée ; LST_{∞} et LST_0 sont les températures de surface correspondant à, respectivement, ET=0 et à ET=ETp, respectivement. $\frac{dT}{dt_p}$ représente le taux d'augmentation de la LST le matin.

c) Suivi de la sécheresse par télédétection micro-ondes

Les systèmes de télédétection par micro-ondes fonctionnent généralement dans la bande de longueur d'onde comprise entre 1 à 136 cm. Le rayonnement micro-ondes peut pénétrer à travers les nuages, la brume et la poussière, ce qui fait de la télédétection par micro-ondes une technique indépendante des conditions météorologiques, et permet donc l'acquisition de données en tout temps. Dans le domaine des micro-ondes, deux types de capteurs se distinguent, les capteurs actifs ou les capteurs passifs (Campbell, 1987). Les capteurs passifs (radiomètres) détectent une partie du signal naturellement émis par la surface. Cette énergie est fonction de la température et surtout du contenu en eau de la surface (du sol et de la végétation) car l'humidité gouverne les propriétés diélectriques des cibles à ces domaines de fréquences. Les capteurs actifs (radar), fournissent leur propre source de rayonnement pour illuminer la cible (Karthikeyan et al., 2017). Ils transmettent vers la cible un signal dans les hyperfréquences et détectent la partie rétrodiffusée du signal. L'intensité du signal rétrodiffusé mesurée est également fortement influencé par l'humidité de surface, par la configuration d'observation (angle de visée) mais aussi par certaines propriétés géométriques de surface dont la rugosité de surface et la structure de la végétation (Dobson en Ulaby, 1986; Karthikeyan et al., 2017).

L'estimation de l'humidité du sol à partir des données des capteurs passifs se base sur des modèles empiriques ou physiques (Jackson et al., 1982; Theis et al., 1983; Wigneron et al., 2003). Les micro-ondes passives ont une base physique solide pour la récupération de l'humidité du sol et les capteurs en orbite propose une bonne résolution temporelle de l'ordre de 3 jours. Cependant, la résolution spatiale (>10 km) n'est pas toujours compatible avec les attentes des utilisateurs tels que les agriculteurs dont les parcelles ont une taille typique de l'ordre de l'ha dans certaines régions du monde comme la Méditerranée. Ces données partagent aussi une limite commune avec les produits d'humidité dérivés des données radar : ces produits sont représentatifs de la teneur en eau des 1ers cms du sol et non de la zone racinaire qui est plus étroitement liée au fonctionnement du couvert (Wigneron et al., 2003). Plusieurs produits d'humidité du sol issue de différents capteurs ont été proposés par la communauté: Le Scanning Multichannel Microwave Radiometer (SMMR , Paloscia et al., 2001), le Soil Moisture and Ocean Salinity (SMOS, Kerr et al., 2012), et le Soil Moisture Active and Passive (SMAP, Entekhabi et al., 2010).

Pour la télédétection micro-onde active ou télédétection radar, le coefficient de rétrodiffusion mesuré par les radar sont aussi utiliser pour inverser la teneur en eau du sol et de la végétation à des résolutions spatiales plus élevées (Dubois et Engman, 1995).

Les produits satellitaires d'humidité les plus utilisés pour le suivi de la sécheresse sont présentés dans le Tableau 2. Dans le cadre de l'Initiative sur le Changement Climatique (CCI) de l'Agence Spatiale Européenne (ESA) (<https://www.esa-soilmoisture-cci.org/>), l'une des plus longues séries temporelles d'humidité du sol à l'échelle mondiale a été développée. Ces produits sont disponibles depuis 1978 avec une résolution spatiale de 25 km et une résolution temporelle de 1 jour. Plus précisément, 3 produits sont disponibles (i) un produit basé sur les micro-ondes actives uniquement (diffusiomètres-vent), (ii) un produit basé sur les micro-ondes passives et (iii) un produit combiné actif-passif (Dorigo et al., 2017; Gruber et al., 2019).

Parmi les indices de suivi de la sécheresse agricole basé sur ces produits d'humidité du sol, on trouve le Soil Moisture Condition Index (SMCI) proposé par Zhang and Jia, (2013) pour le suivi de la sécheresse en Chine. Le SMCI est calculé de manière similaire au VCI et au TCI, il s'agit d'une anomalie normalisée de l'humidité du sol qui permet de suivre les conditions de sécheresse indépendamment des données météorologiques. Le Moisture Anomaly Index (MAI) proposé par Amri et al. (2012) peut fournir une représentation quantitative de l'intensité de la sécheresse et de l'importance d'une période de sécheresse, sur la base du profil de la teneur en eau du sol estimé grâce au Soil Water Index (SWI). Le MAI a été utilisé pour le suivi de la

sécheresse en Tunisie, et il a montré une forte corrélation avec le SPI (Amri et al., 2012). Le Tableau 5 présente les formules de calcul de ces deux indices.

Tableau 5: Indices dérivés de la télédétection micro-ondes pour le suivi de la sécheresse agricole

Indice	Formule	Satellite	Région	Auteur
Soil Moisture Condition Index (SMCI)	$SMCI = \frac{SM_t - SM_{min}}{SM_{max} - SM_{min}}$	AMSR-E Soil moisture	Chine	(Zhang et al., 2013)
Moisture Anomaly Index (MAI)	$MAI = \frac{SWI_t - SWI_{t\ mean}}{\sigma_t}$	ASCAT	Tunisie	(Amri et al., 2012)

SM_{min} , SM_{max} les valeurs minimale et maximale d'humidité de surface du pixel pendant la période d'étude. $SWI_{t\ mean}$, σ_t sont la moyenne et l'écart type de SWI pendant la période d'étude.

d) Suivi de la sécheresse par télédétection multi-capteurs

La sécheresse présente des aspects multiples : un déficit de précipitation, une température élevée, une faible humidité du sol accompagnée ou pas d'une altération prématurée du fonctionnement des cultures. Tous ces éléments peuvent se produire indépendamment ou simultanément (Wilhite, 2007). Un indice unique élaboré à partir d'une variable particulière a une faible capacité à rendre compte des nombreux processus complexes de la sécheresse (Jiao et al., 2021). Par exemple, un indice de sécheresse basé sur les précipitations ne peut pas caractériser le stress hydrique des plantes lié à l'augmentation du déficit de pression de vapeur pendant une vague de chaleur.(Stocker et al., 2018). De même, un indice lié à la végétation (domaine optique) ne permet pas de détecter la sécheresse précocement. En effet, quand l'altération du couvert est avérée, des dommages irrémediables peuvent avoir affecté les cultures. La sécheresse agricole est principalement due au manque d'humidité du sol qu'il faut détecter le plus précocement possible grâce à la température du couvert ou du contenu en eau dans la zone racinaire avant qu'elle ne cause des dommages irréversibles sur la végétation, notamment son activité photosynthétique. Les indices dérivés des données multi-capteurs qui fournissent des informations complémentaires ont une capacité plus fortes que les indices dérivés d'un seul domaine de longueur d'onde pour une détection plus précoce de la sécheresse agricole qui considère l'ensemble des impacts d'une sécheresse agricole sur le couvert (AghaKouchak et al., 2015; Jiao et al., 2021, 2019; L. Zhang et al., 2017).

Il existe une grande diversité d'indices qui exploitent les données de télédétection multi-capteurs (AghaKouchak et al., 2015; West et al., 2019). Les approches basées sur les données sont celles qui sont les plus couramment utilisés pour le développement des indices de sécheresses multi-capteurs (Jiao et al., 2021). La stratégie principale de ces approches est basée sur la combinaison des indices mono-capteurs. Quelques exemples de ces indices sont présentés dans le Tableau 6. Ces indices peuvent être classés en 3 catégories : (i) les indices basés sur une combinaison linéaire d'indices dérivés des différents domaines de longueur d'onde, (ii) les indices basés sur une synthèse des informations multi-longueur d'onde grâce à l'analyse en composantes principales (ACP), et (iii) les indices basés sur des méthodes de machine learning (Jiao et al., 2021).

Un des approches la plus couramment utilisée pour développer les indices multi capteurs de suivi de la sécheresse est la combinaison linéaire simple. Plusieurs indices de sécheresse multi-capteurs ont été développés sur la base d'une somme pondérée des indices mono-capteur en assignant des poids empiriques aux indices de sécheresse individuels, parmi ces indices, on distingue le Vegetation Health Index (VHI) proposé par Kogan, (1997). Plusieurs études ont utilisé le VHI pour différentes applications telles que le suivi de la sécheresse (Bento et al., 2018a; Kogan, 1997) et l'estimation du rendement des cultures (Kogan et al., 2004; Rahman et al., 2009; Tuvdendorj et al., 2019). Pour le suivi de la sécheresse, Rojas et al. (2011) ont utilisé le VHI pour identifier les principales sécheresses historiques sur la période (1981-2009), ainsi que pour identifier l'impact de ces événements sur les zones agricoles sur l'ensemble du continent africain. Le VHI est conçu comme la somme pondérée du VCI et du TCI. La pratique courante de calcul du VHI est une simple pondération égale à 0.5 pour le VCI et le TCI (Kogan, 1997). Cependant, Bento et al. (2020) ont montré que la contribution relative des composantes VCI et TCI peut être ajustée grâce à l'indice de sécheresse SPEI considéré dans cette étude comme une référence. Leurs résultats montrent que dans les régions sèches, où la croissance de la végétation est principalement limitée par le manque d'eau, le VCI est le terme dominant, c'est-à-dire que le poids associé à VCI est supérieur à 0.5. Par contraste, dans les régions plus humides, où la température et le rayonnement (énergie solaire) sont les facteurs limitant de la croissance de la végétation, l'indice TCI est le terme dominant. Rhee et al., (2010) ont proposé le Scaled Drought Condition Index (SDCI) pour évaluer les conditions de sécheresse dans le Sud-Est des États-Unis. Le SDCI est une combinaison de trois indices de sécheresse, une composante de température (TCI) avec un poids de 0.25, une composante de végétation (VCI) avec un poids de 0.25, et une composante de précipitation (PCI) avec un poids de 0.5. Le SDCI

a donné lieu à des corrélations relativement élevées avec les indices de sécheresse in situ tels que le PDSI et le SPI. La performance du SDCI peut également être améliorée si les pondérations des indices sont optimisées (Rhee et al., 2010). L'avantage des indices basés sur la combinaison linéaire simple est qu'ils sont relativement faciles à calculer et simples à mettre en œuvre. De même, ils présentent de bonnes performances pour le suivi de la sécheresse à l'échelle locale (Zhang et al., 2017). Cependant, ces indices ont des limites pour une mise en œuvre à grande échelle. Par exemple, ils supposent souvent que les sous-zones d'une zone d'étude contribuent au même poids pour chaque variable. En outre, les poids attribués à chaque variable de sécheresse sont susceptibles de varier dans différentes régions climatiques, et peuvent donc conduire à une mauvaise performance lorsqu'ils sont appliqués à diverses conditions climatiques (Bento et al., 2020, 2018b, 2018a; Jiao et al., 2021).

D'autres indices ont été développés avec l'analyse en composante principale (ACP ou Principal Component Analysis -PCA- en anglais). L'ACP est une transformation linéaire orthogonale qui convertit un ensemble d'observations de variables éventuellement corrélées en un nouveau système de coordonnées qui peut être représenté sans corrélation (Wold et al., 1987). L'ACP est largement utilisée dans l'analyse de la sécheresse (Santos et al., 2010; Vicente-Serrano et al., 2006). Parmi les indices basés sur l'ACP, le Synthesized Drought index (SDI ; Du et al., 2013) qui est développé sur la base de l'ACP du VCI, du TCI et du PCI. Les résultats de Du et al. (2013) ont notamment montré que le SDI est non seulement fortement corrélé avec le SPI, mais aussi avec le rendement des cultures et avec les zones de cultures touchées par la sécheresse en Chine. L'une des limitations principales des indices basés sur l'ACP est l'hypothèse de linéarité des variables d'entrée et l'hypothèse que l'information maximale des variables d'entrée est orientée dans la direction de la variance maximale (Wold et al., 1987).

Enfin, des études récentes ont utilisé plusieurs algorithmes de machine learning pour intégrer des informations de télédétection multi-capteurs afin de développer des indices de suivi de la sécheresse à l'échelle régionale (Crocetti et al., 2020; Feng et al., 2019; Han et al., 2019; Park et al., 2017; Shen et al., 2019). L'apparition de la sécheresse est liée à des interactions complexes entre de nombreux facteurs, telles que les précipitations, la température, l'évapotranspiration et la végétation. Wu et al. (2013) ont proposé le Integrated Surface Drought Index (ISDI). Le ISDI examine les relations entre la sécheresse et la précipitation (PCI), la température (TCI), la végétation (VCI) et l'évapotranspiration (anomalies de ET). Il est basé sur une approche Random Forest (RF). Leurs résultats montrent que le ISDI est davantage corrélé avec le SPI et les anomalies d'humidité du sol mesurée, que les quatre indices considérés séparément. De

plus, concernant les distributions spatiales de la sécheresse, celles du ISDI et de l'humidité du sol sont similaires dans leur région d'étude (en Chine). L'avantage principal des indices basés sur le machine learning pour le suivi de la sécheresse est que ces approches sont adaptées pour traiter des données multidimensionnelles et multi-variables dans différents environnements (Crocetti et al., 2020; Han et al., 2019; Jiao et al., 2021; Park et al., 2017). Cependant, comme toute méthode d'apprentissage, la performance de ces indices repose fortement sur la sélection des données d'entraînement. Ils ont également besoin de jeux de données massifs pour être entraîné (Ali et al., 2015; Lary et al., 2016).

Tableau 6: Indices dérivés de la télédétection multi-capteurs pour le suivi de la sécheresse agricole

Indice		Données	Formule	Auteur
Vegetation Health Index (VHI)		NDVI, (BT) AVHRR	$VHI = 0.5 VCI + 0.5 TCI$	(Kogan, 1997)
Microwave Integrated Drought Index (MIDI)		Précipitation (TRMM), SM (AMSR-E), LST (AMSR-E)	$MIDI = \alpha PCI + \beta SMCI + (1 - \alpha - \beta) TCI$	(Zhang et al., 2013)
Scaled Condition Index (SDCI)	Drought Index	Précipitation (TRMM), NDVI, LST (MODIS)	$SDCI = \frac{1}{4} TCI + \frac{1}{4} VCI + \frac{2}{4} PCI$	(Rhee et al., 2010)
Synthesized Drought Index (SDI)		Précipitation (TRMM), LST (MODIS), Vegetation (MODIS NDVI)	ACP	(Du et al., 2013b)
Integrated Condition Index (IDCI)	Drought Index	Précipitation (TRMM), LST (MODIS), Vegetation (MODIS NDVI)	ACP	(Meng et al., 2016)
High resolution Soil Moisture Drought Index (HSMDI)		Précipitation (TRMM), LST, NDVI, EVI, LAI, ET (MODIS), SM (AMSR-E)	Machine learning	(Park et al., 2017)
Combined Drought Monitoring Index		Précipitation (TRMM), LST, NDVI, ET (MODIS)	Machine learning	(Han et al., 2019)
Integrated Drought Index	Surface	NDVI, LST (MODIS), Land cover (IGBP)	Machine learning	(Wu et al., 2013)

I-2-3) Les Land Data Assimilation Systèmes

a) Généralités

Les satellites d'observation actuellement disponibles ont une précision incertaine pour l'estimation de l'humidité du sol ainsi qu'une faible profondeur de détection (quelques centimètres dans la partie supérieure) (Beck et al., 2021; Han et al., 2014; Spennemann et al., 2017). Ces défis ont encouragé l'utilisation conjointe de modèles de surface terrestre (ou Land surface model -LSM- en anglais) et d'observations satellitaires à l'aide de techniques d'assimilation de données pour obtenir des estimations plus précises de l'humidité de la zone racinaire qui est un facteur clé pour le suivi de la sécheresse agricole (Han et al., 2014; Li et al., 2010). Les techniques d'assimilation de données permettent d'intégrer de manière cohérente les observations in-situ ou par satellites dans des LSMs (Albergel et al., 2017; Reichle et al., 2007). Les Land Data Assimilation System (LDAS) font référence au cadre dans lequel les LSMs sont pilotés et/ou ingèrent de telles observations, générant des estimations améliorées des variables de surface terrestre (Kumar et al., 2019).

b) Le LDAS du CNRM

Le LDAS développé par le Centre National de Recherches Météorologiques en France (CNRM) (Albergel et al., 2018; Mahfouf et al., 2009) permet d'intégrer des produits satellitaires (LAI, SM) dans le modèle de surface ISBA-A-gs (Calvet et al., 1998) par un algorithme d'assimilation séquentielle (filtre de Kalman simplifié). Les produits satellitaires utilisés dans ce LDAS, appelé LDAS-monde, incluent (i) le LAI dérivé des satellites SPOT/VGT (Satellite Pour l'Observation de la Terre / VEGETATION) et PROBA-V (Project for On-Board Autonomy satellite, the V standing for vegetation.) de 1999 à maintenant avec une résolution spatiale de 1 km et une résolution temporelle de 10 jours (<https://land.copernicus.eu/global/products/lai>); (ii) l'humidité du sol dérivée du produit de l'ESA CCI Soil Moisture (SM) « combined » avec une résolution spatiale de 25 km et un pas du temps journalier (<https://www.esa-soilmoisture-cci.org/>). Le modèle ISBA est un modèle générique capable de représenter le cycle diurne des flux de surface ainsi que la variabilité saisonnière, interannuelle et décennale de la biomasse de la végétation. Le modèle ISBA-A-gs est une composante de la plateforme de modélisation SURFEX (Masson et al., 2013). Les sorties du LDAS que nous avons utilisées pour identifier la sécheresse sont : le LAI, la transpiration (Tr), l'évaporation du sol (E), l'évapotranspiration (ETR) et le SM à différentes profondeurs : WG2 (0 à 4 cm), WG4 (10 à 20 cm), WG6 (40 à 60 cm) et WG8 (80 à 100 cm). En outre, les mêmes variables dérivées du modèle ISBA-A-gs (sans assimilation de données)

sont utilisées pour analyser la valeur ajoutée de l'assimilation de données par rapport au modèle sans assimilation. Pour le suivi de la sécheresse nous avons calculé les anomalies de toutes ces variables.

II) La prévision saisonnière des rendements des cultures

Dans le contexte actuel du changement climatique et de son impact sur l'homme et son environnement, l'estimation précoce de la production agricole aux échelles nationales ou régionales est plus que jamais au cœur d'enjeux économiques, géostratégiques et humanitaires très importants (van Ittersum et al., 2008). La prévision du rendement est différente de l'estimation du rendement. La prévision est effectuée au cours de la saison avant la récolte, tandis que l'estimation du rendement est effectuée après la récolte. Il existe plusieurs méthodes de prévision du rendement. La méthode traditionnelle de prévision du rendement est basée sur l'évaluation de l'état des cultures par des experts. Des observations et des mesures sont effectuées tout au long de la saison de croissance des cultures, telles que l'indice de tallage, l'indice d'épillets et leur pourcentage de fertilité, le pourcentage de dégâts causés par les parasites et les champignons, le pourcentage d'infestation de mauvaises herbes, etc. Les données obtenues de cette manière permettent de prévoir le rendement à l'aide de méthodes de régression, ou grâce aux connaissances des experts locaux (Basso en Liu, 2019). Les deux autres méthodes utilisées pour prévoir le rendement des cultures sont : (i) L'utilisation de modèles empiriques reliant les rendements historiques et des variables ou indicateurs des conditions environnementales (données agrométéorologiques et/ou de télédétection), (ii) L'utilisation de modèles de croissance des cultures forcés par les prévisions météorologiques (Basso en Liu, 2019).

II-1) Prévision du rendement des cultures à l'aide des modèles agronomiques

Les modèles de croissance des cultures utilisent les informations liées à la météo, au sol, aux cultures et aux pratiques agricoles pour simuler le développement et la croissance des cultures (Whisler et al., 1986). La biomasse et le rendement en grains sont les principales variables de sortie de ces modèles. Les modèles de croissance des cultures consistent en une série d'équations mathématiques décrivant le processus de développement et de croissance des cultures, sous l'effet du climat et des pratiques (irrigation, fertilisation, date de semis ...) (Dumont et al., 2012).

Les modèles de croissance des cultures alimentés par les prévisions météorologiques entre la date de prévision et la date de récolte ont été utilisés pour la prévision précoce des rendements

des cultures au cours de la saison. Différentes méthodes ont été utilisées dans le but de faire la prévision des variables climatiques (température, précipitation ...), entre la date de prévision et la date de récolte pour alimenter les modèles de croissance des cultures. Parmi ces méthodes : (1) l'utilisation des moyennes météorologiques historiques (la climatologie), (2) les données météorologiques provenant des générateurs météorologiques, (3) et les prévisions saisonnières issues de modèles climatiques. Comme les prévisions météorologiques précises ne peuvent être établies que sur quelques jours, l'analyse des données météorologiques historiques permet d'obtenir de nombreuses informations. Le principe de la première méthode peut être décrite comme suit : A un instant donné t du cycle de croissance d'une culture, la série temporelle climatique est composée des données météorologiques mesurées, du semis à l'instant t , et de la moyenne journalière d'une base de données climatique historique couvrant la période de t à la récolte. [Dumont et al. \(2014\)](#) ont utilisé le modèle STICS (simulateur multidisciplinaire pour les cultures standard) pour la prévision précoce du rendement du blé en Belgique. Le forçage météorologique (température, précipitations, rayonnement solaire, vitesse du vent) à partir de la date de prévision était renseigné par une climatologie établie sur 30 ans d'observations. Leurs résultats montrent que la capacité de prédiction était faible en début de saison, lorsque la période de simulation basée sur les observations réelles était courte et que la dépendance aux données climatiques était élevée. Cependant, au fur et à mesure que la saison de croissance des cultures avançait, les effets de la variabilité climatique réellement observée jouaient un rôle plus important et la fiabilité des prédictions augmente. Avec un délai de prédiction d'environ 1 mois avant la récolte, une prédiction du rendement avec une probabilité de 85% et un intervalle de confiance de 10% autour de la valeur observée a été obtenue ([Dumont et al., 2014](#)). La méthode utilisée dans cette étude est simple, elle demande seulement les observations historiques. Cependant l'augmentation de la fréquence des événements extrêmes, telle que l'augmentation de la température et la forte variabilité des précipitations dans le futur peut être une limitation à l'utilisation de cette méthode. Aussi, en raison de la nature non uniforme des conditions météorologiques et de la réponse non linéaire des modèles de croissance des cultures aux données météorologiques, les prévisions météorologiques ne peuvent pas simplement être une série météorologique unique (la première méthode), mais doivent être un ensemble de séries météorologiques, incorporant la variabilité climatique spécifique au site. Pour rendre compte de l'incertitude météorologique, la deuxième méthode consiste à utiliser des générateurs stochastiques de données météorologiques qui sont des outils qui permettent de reproduire les propriétés des distributions statistiques de variables climatiques basés sur l'analyse des données historiques observées. [Lawless and Semenov, \(2005\)](#) ont utilisé le modèle SIRIUS ([Jamieson](#)

et al., 1998) pour la prévision précoce du rendement du blé au Royaume-Uni. Le forçage météorologique utilisé était basé sur les observations météorologiques pour la première partie de la saison de croissance jusqu'à la date de prévision et sur 300 ensembles de données générés par le générateur stochastique Long Ashton Research Station Weather Generator (LARS-WG) (Semenov en Barrow, 1997) pour le reste de la saison. Les séries de données météorologiques générées par LARSWG sont représentatives des conditions locales et sont donc spécifiques au site d'étude. Grâce à cette approche, les auteurs ont pu prédire les rendements avec une probabilité de 90% entre 39 et 61 jours avant la récolte. Cependant, comme pour l'utilisation d'une climatologie, la fréquence et l'ampleur des événements météorologiques extrêmes sont susceptibles de changer en raison du changement climatique, des travaux de recherche sont nécessaires pour mieux représenter ces extrêmes météorologiques dans ces générateurs (Senapati et al., 2021). De plus, l'utilisation de ces générateurs en combinaison avec des modèles de culture nécessite des ressources de calculs importantes (Dumont et al., 2015). Enfin, la dernière méthode consiste à utiliser les prévisions saisonnières des modèles climatiques. Ces prévisions peuvent améliorer la précision des estimations du rendement des cultures en début de saison et influencer les décisions saisonnières de gestion des cultures (Schepen et al., 2020). Les centres de prévisions climatiques utilisent désormais régulièrement des modèles climatiques globaux pour fournir des prévisions. Cependant, les prévisions brutes des General Circulation Model (GCMs) nécessitent un post-traitement pour améliorer leur fiabilité et permettre une intégration systématique avec les modèles de culture. Le post-traitement pour répondre aux exigences d'entrée des modèles de croissance des cultures est très difficile et les méthodes simples de correction de biais peuvent être peu performantes (Dumont et al., 2014). Schepen et al., (2020) ont utilisé le modèle APSIM-sugar et les sorties du GCM de l'ECMWF System4 (Sys4 ; Molteni et al., 2011) pour prédire la production en biomasse de canne à sucre en Australie, jusqu'à 12 mois à l'avance. Leurs résultats montrent que la prévision de la biomasse avec les sorties de CGM est très fortement liée à la méthode utilisée pour la réduction d'échelle de ces sorties.

En conclusion, les modèles de croissance des cultures sont un outil efficace pour l'estimation des rendements en fin de saison. Cependant les défis de l'utilisation de ces modèles pour la prévision précoce du rendement au cours de la saison sont liés au nombre important de données d'entrée qui sont difficiles à renseigner à grande échelle (caractéristique du sol, date de semis, fertilisation ...) ainsi qu'à l'incertitude liée aux prévisions météorologiques saisonnières entre la date de prévision et la date de récolte.

II-2) Prédiction du rendement des cultures avec la méthode statistique

Les premiers modèles utilisés pour la prédiction du rendement à grande échelle sont généralement des modèles statistiques (Thompson, 1969). Les modèles statistiques pour la prédiction du rendement relient les rendements historiques à des indicateurs des conditions agro-environnementales (température, précipitations, indices de végétation ...). L'application de ces modèles pour la prédiction du rendement des cultures repose sur le principe que les liens entre les conditions agro-environnementales de l'année de prédiction seraient identiques aux liens historiques utilisés pour l'élaboration du modèle, et que le rendement prévu dans les conditions de l'année de prédiction serait expliqué par le même ensemble de variables indépendantes lorsque le modèle a été élaboré à partir des données des années précédentes (Basso et al., 2013). Par conséquent, de longues séries temporelles de bonne qualité sur le rendement et les conditions agrométéorologiques et environnementales sont nécessaires pour élaborer des modèles statistiques de prédiction du rendement. Les modèles statistiques sont simples dans leur utilisation et moins paramétrés que les modèles de croissance des cultures, mais ils sont limités dans les informations qu'ils peuvent fournir en dehors des conditions dans lesquelles les modèles ont été établis, notamment pour les années extrêmes (Basso et Liu, 2019).

Les données météorologiques sont utilisées depuis longtemps pour expliquer la variabilité du rendement des cultures (Basso et al., 2013; Dumont et al., 2015; Mathieu en Aires, 2018). Dans ce contexte, le cumul des précipitations a été utilisé comme variable indépendante dans les modèles linéaires développés dans plusieurs régions en Inde pour la prédiction du rendement du blé (Manjunath et al., 2002). De même, les précipitations cumulées entre la date de semis et le début de développement ont été utilisées pour prévoir le rendement du blé au Canada (Qian et al., 2009). La température et les précipitations intégrés sur les stades critiques de croissance du blé ont été utilisées dans des modèles de régression pour prévoir le rendement du blé en Argentine (Scian, 2004). Des combinaisons de diverses variables météorologiques, notamment les températures minimales et maximales, l'humidité relative du matin et du soir, et les précipitations, ont été utilisées comme prédicteurs du rendement du maïs, du blé et du riz en Inde (Giri et al., 2017; Gurung et al., 2017).

Les réseaux météorologiques sont souvent épars dans plusieurs régions du globe qui ne disposent pas d'un réseau opérationnel dense tels que celui que l'on peut trouver en Amérique du Nord ou en Europe. Plusieurs études ont montré l'impact des pseudo-oscillations climatiques à grande échelle (ENSO -El Nino Southern Oscillation-, ONA -Oscillation Nord Atlantique-...) sur de nombreuses composantes des écosystèmes continentaux y compris les systèmes

agricoles, et les précipitations futures (Ceglar et al., 2017; Flaounas et al., 2013; Nguyen-Huy et al., 2017; Trambly et al., 2013; Wang et al., 2020). Les indices dérivés de variables atmosphériques tels que l'ONA, ou océaniques tels que l'ENSO sont donc utilisés comme proxy des conditions météorologiques locales. Aussi, Ray et al. (2015) ont montré que les oscillations climatiques influencent sur la production des cultures en modulant les conditions de croissance des cultures. À l'échelle mondiale, les oscillations climatiques contribuent à un tiers de la variabilité annuelle du rendement des cultures, variant selon les types de cultures et les régions (Ray et al., 2015). Dans ce contexte, en Australie, les indices climatiques à grande échelle liés à ENSO ont été incorporés dans des modèles empiriques pour prévoir le rendement du blé jusqu'à 3 mois avant la récolte (Wang et al., 2020). De même, Lehmann et al., (2020) ont utilisé des données de température de surface des océans (Sea Surface Temperature ou SST en anglais) et de l'ONA pour prévoir les anomalies du rendement du blé au Maroc à l'échelon nationale.

Enfin, les données de télédétection dans les différentes longueurs d'ondes fournissent des informations sur la végétation et sur l'état du sol à grande échelle spatiale. La régression entre le NDVI à partir de début de développement et le rendement final des cultures est le modèle statistique le plus largement utilisé à partir de données de télédétection (Basso et Liu, 2019). Plusieurs chercheurs ont extrait le NDVI à partir de MODIS de 2 à 3 mois avant la récolte et ont développé des modèles de régression linéaire pour prévoir le rendement du maïs, du blé et du riz (Belaqziz et al., 2013; Kogan et al., 2013; Skakun et al., 2016; Wang et al., 2014). Le NDVI a également été combiné à d'autres informations fournis par la télédétection pour prévoir le rendement. Johnson, (2014) a utilisé le NDVI et la LST de MODIS pour la prévision du rendement du maïs et du soja aux États-Unis. De même, Torino et al. (2014) ont étudié la capacité des modèles linéaires basés sur un indice similaire au NDVI qui est le Normalized Difference Red Edge index, (NDRE) à différents stades de développement pour prévoir le rendement du maïs à l'échelle du champ. Liu et Kogan, (2002) et Salazar et al., 2007 ont dérivé le VCI et TCI des données du satellite AVHRR et ont ensuite développé des modèles de régression pour prévoir le rendement du soja et du blé. Les coefficients de rétrodiffusion dérivés des capteurs radar à ouverture synthétique (SAR) ont été également utilisés pour développer des modèles statistiques afin de prévoir le rendement des cultures. Chen et al. (2011), par exemple, ont utilisé des données ScanSAR de Radarsat-1 pour prévoir le rendement du riz au niveau régional au Philippines. Balaghi et al. (2008) ont également combiné des données météorologiques (précipitation et température) et des observations issues de la télédétection

(NDVI) pour la prévision du rendement du blé, 2 mois avant la récolte, à l'échelle des provinces au Maroc. En termes de méthodologie de régression, on peut distinguer deux approches, l'approche linéaire et l'approche non-linéaire, qui sont détaillées ci-dessous.

II-2-1) Les approches linéaires

L'approche linéaire pour la prévision du rendement des cultures est basée sur l'utilisation de la régression linéaire multiple entre les variables indépendantes (données agrométéorologiques, de télédétection ...) et la variable dépendante (pour nous, le rendement final en grain). Plusieurs études ont utilisé cette méthode pour la prévision des rendements de cultures dans différentes régions de monde (Balaghi et al., 2008; Becker-Reshef et al., 2010; Bolton and Friedl, 2013; Franch et al., 2015; Kogan et al., 2005; Liu and Kogan, 2002; López-Lozano et al., 2015; Prasad et al., 2006; Quiring and Papakryiakou, 2003; Salazar et al., 2007)

$$y_t = \sum_{i=1}^n a_i x_{i,t} + \varepsilon_t \text{ (Eq. 1)}$$

Avec $x_{i,t}$ représente le prédicteur ou la variable indépendante i (température, précipitation NDVI, ONA...) pendant l'année t , ε_t le résidu et y_t représente le rendement prédit. a_i Sont les paramètres du modèle estimés par la méthode des moindres carrés qui consiste à rechercher les valeurs des paramètres qui minimisent la somme des carrés des résidus.

II-2-2) Les approches non-linéaires

Le machine learning est un champ d'études de l'intelligence artificielle qui a émergé avec les technologies de « big data » et la haute performance de calcul (Liakos et al., 2018). Entre autres définitions, le machine learning est défini comme le domaine scientifique qui donne aux machines la capacité d'apprendre sans être strictement programmées (Samuel, 1959). Une machine intelligente apprend et extrait des connaissances à partir des données, construit un modèle pour faire des prédictions. Ainsi, le processus de machine learning est divisé en trois étapes clés comme illustré dans la Figure 3, ces processus sont : le prétraitement des données, la construction du modèle, et finalement la généralisation : le processus qui permet de prédire la sortie compte tenu des entrées avec lesquelles l'algorithme n'a pas été entraîné auparavant (Sharma et al., 2021). L'un des principaux avantages de machine learning est la capacité de résoudre de manière autonome des problèmes non linéaires en utilisant des données de sources multiples (Chlingaryan et al., 2018). Durant ces dernières années, différents algorithmes de machine learning ont été mis en œuvre pour la prévision du rendement de différentes cultures et ces algorithmes ont montré une meilleure performance que la régression linéaire multiple (Cai et al., 2019 ; Feng et al., 2019 ; Filippi et al., 2019 ; Khaki and Wang, 2019 ; Shahhosseini

et al., 2019 ; Wolanin et al., 2020). Selon une review de littérature de van Klompenburg et al. (2020), le Support Vector Machine (SVM), le Random Forest (RF) and le eXtreme Gradient Boost (XGBoost) sont les algorithmes les plus utilisés dans différents domaines et, en particulier, pour la prévision du rendement des cultures.




Figure 3: le processus du Machine learning

a) Machines à vecteurs de support

Les Machines à Vecteurs de Support (Support Vector Machine SVM) ont été développées initialement pour résoudre les problèmes de classification (Sain en Vapnik, 1996). Cependant, leur nature permet de résoudre également des problèmes de régression. Pour un ensemble de données de N vecteurs $\{x_i, y_i\}$, ($i = 1, 2, \dots, N$), $x_i \in \mathbb{R}^d$ chaque vecteur des prédicteurs x_i a une dimension d et y_i représente la valeur cible, l'objectif de Machines à Vecteurs de Supports pour la Régression (SVR) est de trouver une fonction $f(x)$ qui rapproche le plus possible toutes les paires $(f(x_i), y_i)$ avec une précision de ε et qui soit en même temps aussi plate que possible (Smola en Schölkopf, 2004) (Figure 4). La fonction $f(x)$ peut-être écrite comme suit dans le cas de problème linéaire :

$$f(x) = \langle w, x \rangle + b \quad (\text{Eq. 2})$$

Où la fonction \langle, \rangle est un produit scalaire, w sont les poids du vecteur support et b un terme de biais. Une façon pour assurer la platitude de la fonction $f(x)$ est de minimiser le $\|w\|$ On peut décrire ce problème comme un problème d'optimisation convexe (Smola en Schölkopf, 2004). L'objectif du SVR est alors de minimiser le "risque" R exprimé comme suit :

$$R = \min \frac{1}{2} \|w\|^2 \text{ sujet à } \begin{cases} y_i - f(x_i) \leq \varepsilon \\ f(x_i) - y_i \leq \varepsilon \end{cases} \quad (\text{Eq.3})$$

L'hypothèse implicite dans (Eq. 3), est que le problème d'optimisation convexe est réalisable. Cependant, il arrive parfois que ce ne soit pas le cas, ou que l'on souhaite tenir compte de certaines erreurs. Afin d'autoriser certaines erreurs (plus grande de ε), des variables d'écart

(ξ^+, ξ^-) ont été introduit par (Sain en Vapnik, 1996) (Eq.4) pour adoucir la marge avec le paramètre de régulation C qui fait le compromis entre les erreurs et le terme de régularisation $\frac{1}{2} \|\mathbf{w}\|^2$ (Smola en Schölkopf, 2004).

$$R = \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n |y_i - f(\mathbf{x}_i)|_\varepsilon, \text{ sujet à } \begin{cases} y_i - f(\mathbf{x}_i) < \varepsilon + \xi^+ \\ f(\mathbf{x}_i) + y_i < \varepsilon + \xi^- \\ \xi^+, \xi^- > 0 \end{cases} \text{ (Eq. 4)}$$

En général, la plupart des problèmes de régression sont non linéaires, dans ce contexte les fonctions noyau (Kernel function en anglais) ont été introduites pour résoudre le problème en projetons les données d'origine dans un nouvel espace à haute dimension (Cheng et al., 2017). La fonction de base radiale (RBF) est de loin le choix le plus populaire pour le noyau car elle s'est avérée efficace pour une grande variété d'applications (Han et al., 2012). Elle prend la forme suivante :

$$K(x_i, x_j) = \exp \left[-\frac{1}{2} \left(\frac{\|x_i - x_j\|^2}{\sigma} \right) \right] \text{ (Eq. 5)}$$

Avec σ est la largeur de la fonction RBF.

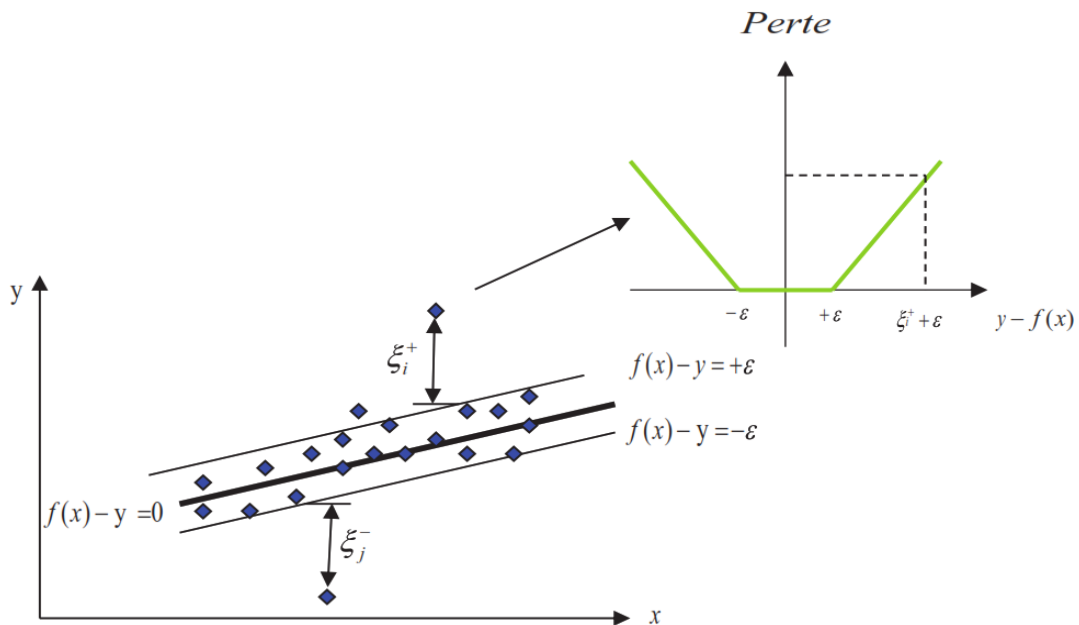


Figure 4: Le principe de SVM

b) Random forest

Random forest (RF) introduite par Breiman, (2001) est un sous-ensemble des arbres de classification et de régression (Classification And Regression Tress CART) qui sont basés sur

le bagging (Breiman, 1996). Le bagging a pour but de réduire la variance de l'estimateur (Breiman, 1996). Pour ce faire, à l'aide de la technique de bootstrap, des sous-ensembles de données d'entraînement par tirage aléatoire au sein de l'ensemble complet est créé. L'algorithme, l'arbre de décision par exemple, est entraîné sur ces sous-ensembles de données indépendamment pour construire plusieurs estimateurs. Ensuite, les estimateurs obtenus sont moyennés (lorsque les données sont quantitatives, cas d'un arbre de régression).

L'algorithme de Random Forest est basé sur un apprentissage en parallèle de multiples arbres de décision construits aléatoirement et entraînés sur des sous-ensembles de données différents. Le modèle de régression basé sur le RF suit trois étapes pour fournir des prédictions optimales. Dans la première étape, l'ensemble de données est divisé en sous-ensemble par la technique du bootstrap. Dans la deuxième étape, chaque sous-ensemble de données est utilisé pour construire un seul arbre de régression qui donne sa propre prédiction (Figure 5). Dans la dernière étape, les prédictions des arbres individuels $T_n(x_i)$ sont moyennées pour générer la prédiction finale du modèle RF (Figure 5), comme indiqué dans l'équation (6).

$$\hat{y}(x_i) = \frac{1}{K} \sum_{n=1}^K T_n(x_i) \quad (\text{Eq. 6})$$




Figure 5: Le principe de l'algorithme RF.

c) Extrem Gradient Boosting

Extrem Gradient Boosting (XGBoost) est un algorithme du machine learning proposé par Chen et Guestrin, (2016), Cet algorithme est une implémentation de GBM (Gradient Boosting Machines) (Friedman, 2001). Le boosting est une technique qui consiste à agréger des

estimateurs élaborés séquentiellement sur un échantillon d'apprentissage dont les poids des individus sont corrigés au fur et à mesure. Les estimateurs sont pondérés selon leurs performance et ils sont construits de manière récursive : chaque estimateur est une version adaptative du précédent en donnant plus de poids aux observations mal prédites (Freund en Schapire, 1996; Friedman, 2001; Genuer en Poggi, 2017). Le XGBoost est un algorithme ensembliste qui agrège des arbres de régression. À chaque itération, le nouvel arbre apprend de l'erreur commise par l'arbre précédent. Le principe de XGBoost est présenté dans la Figure 6.

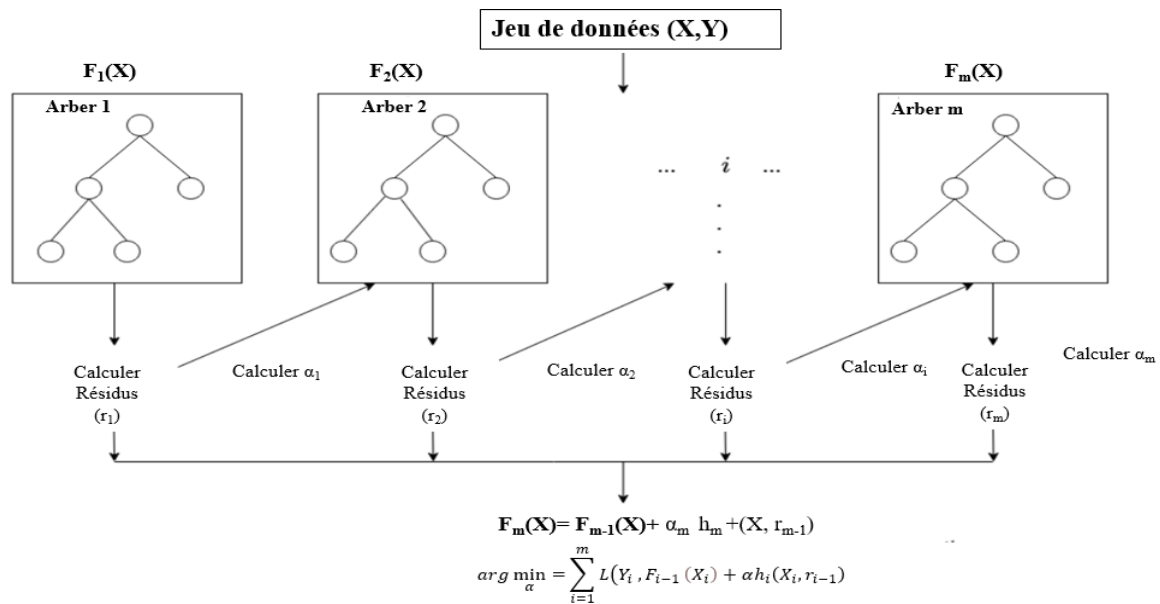


Figure 6: Le principe d'algorithme XGBoost.

Avec α_i et r_i , respectivement, le paramètre de régularisation et le résidu de l'arbre de régression i respectivement, et h_m la fonction utilisée pour calculer le résidu avec les variables indépendantes X pour l'arbre i . $(Y, F(X))$ est la fonction de perte.

III) Etude de l'impact du changement climatique sur la production

III-1) Le changement climatique

Durant ces dernières années, un changement climatique a été constaté au niveau du globe. Ce changement se traduit par une augmentation de la température moyenne, une plus forte variabilité de la pluviométrie et l'augmentation de l'occurrence de conditions extrêmes telles que les inondations, les sécheresses, les tsunamis ... (Giorgi, 2006; Giorgi en Lionello, 2008; IPCC, 2019; Orłowsky en Seneviratne, 2012; Seneviratne et al., 2016; Vogel et al., 2020)

III-1-1) Définition et enjeux

Le changement climatique est une problématique majeure. Le climat de notre planète n'a certes jamais été stable, mais les experts qui composent le « Groupe d'experts Intergouvernemental

sur l'Evolution du Climat » (GIEC) confirment sans équivoque le phénomène du réchauffement global et le lien avec les émissions des gaz à effet de serre d'origine humaine. Presque partout sur terre, la température a augmenté sensiblement (IPCC, 2014) (Figure 7). Pour comprendre le changement climatique et ses projections, il est nécessaire de faire la différence entre quatre termes clés : la météo, le climat, la variabilité climatique et le changement climatique. Par définition, la météo est un état de l'atmosphère à un moment donné. L'état de l'atmosphère est généralement déterminé en termes de température, de composition de l'atmosphère (par exemple, vapeur d'eau ou teneur en dioxyde de carbone), de vitesse et de direction des vents, de précipitations, de pression et de densité, en plus de l'intensité du rayonnement solaire et terrestre émis. Le climat est la moyenne des conditions météorologiques au fil du temps, il est représenté en termes de moyenne et de variance des principaux paramètres météorologiques pour une période donnée, généralement 30 ans (OMM, 2018). La variation des paramètres climatiques pour une durée spécifique ayant la même variance que le climat est appelé la variabilité climatique. On appelle changement climatique l'évolution du climat dans le temps lorsque la moyenne et d'autres paramètres statistiques sont également modifiés (IPCC, 2014). Le changement climatique se produit en raison de l'interaction entre les éléments constitutifs du système climatique tels que l'atmosphère, l'océan, la terre et la glace. Le changement climatique est évalué à partir des données observées dans le passé et projeté à l'aide des modèles climatiques (IPCC, 2014).




Figure 7: Carte de l'évolution des températures en surface observée entre 1901 et 2012 (Ipcc, 2013).

III-1-2) Projections et scénarios climatiques

Le climat futur est notamment fonction des émissions ou des concentrations de gaz à effet de serre (GES) et d'aérosols dues aux activités humaines. Or, les émissions humaines dépendent de notre consommation énergétique : chauffage et climatisation, transports, production de biens de consommation, activités agricoles, etc. Pour réaliser des projections climatiques, il faut donc émettre des hypothèses sur l'évolution de la démographie mondiale et des modes de vie à travers la planète. Il résulte de ces hypothèses des scénarios d'émission de GES, qui sont décrits dans les rapports du GIEC, (IPCC, 2014).

a) Les scénarios RCPs

Dans le 5^{ème} Rapport du GIEC les experts du GIEC ont défini quatre trajectoires d'émissions et de concentrations de gaz à effet de serre, d'ozone et d'aérosols, ainsi que d'occupation des sols, qui sont appelés les RCPs (Representative Concentration Pathways) (IPCC, 2014) (Figure 8). Ces RCPs sont utilisés par les différentes équipes d'experts (climatologues, hydrologues, agronomes, économistes ...). Les climatologues en déduisent des projections climatiques globales ou régionales (Figure 9). Les économistes établissent des scénarios qui explorent toutes les possibilités d'évolutions technologiques et socio-économiques compatibles avec les RCPs. Ces RCPs ont été traduits en termes de forçage radiatif, c'est-à-dire de modification du bilan radiatif de la planète (Moss et al., 2008). Le bilan radiatif représente la différence entre le rayonnement solaire reçu et le rayonnement infrarouge réémis par la planète. Il est calculé au sommet de la troposphère (entre 10 et 16 km d'altitude). Les 4 profils RCPs (RCP2.6, RCP4.5, RCP6.0 et RCP8.5) correspondent chacun à une évolution différente de ce forçage à l'horizon 2100, par exemple pour RCP4.5 = 4 W/m² et RCP8.6 8.5 W/m², plus cette valeur est élevée, plus le système terre-atmosphère gagne en énergie et se réchauffe (Moss et al., 2008).




Figure 8: Émissions de dioxyde de carbone (CO_2) selon les profils représentatifs d'évolution de concentration (RCP) uniquement (traits de couleur) et catégories de scénarios associées utilisées par le GIII (ombrages en couleur représentant la fourchette de 5 à 95 %). Les catégories de scénarios utilisées par le GIII condensent le vaste ensemble de scénarios d'émissions décrits dans les publications scientifiques ; leurs définitions se basent sur les niveaux de concentration en équivalent CO_2 (en ppm) en 2100 (IPCC, 2014).




Figure 9: Évolution de la température moyenne en surface (a) et évolution des précipitations moyennes (b) fondées sur des projections multi-modèles moyennes pour la période 2081–2100 par rapport à la période 1986–2005, selon les scénarios RCP2,6 (à gauche) et RCP8,5 (à droite). Le nombre de modèles utilisés pour calculer la moyenne multi-modèle figure dans l'angle supérieur droit de chaque image. Les pointillés signalent les régions dans lesquelles le changement projeté est grand par rapport à la variabilité naturelle interne et dans lesquelles 90 % au moins des modèles s'accordent sur le signe du changement. Les hachures signalent les régions dans lesquelles le changement projeté est inférieur à un écart type de la variabilité naturelle interne (IPCC, 2014).

b) Etablissement des projections climatiques à grande échelle

- Modèles de circulation générale

Un modèle de circulation générale, (General Circulation Model, GCM) est un modèle climatique. Il s'appuie sur les équations de Navier-Stokes, appliquées à une sphère en rotation ainsi que sur des équations d'équilibre de la thermodynamique pour inclure les sources d'énergie (rayonnement, changement de phase). Les GCMs simulent la météo (température, précipitation, vitesse de vent,) en fonction de la concentration atmosphérique de gaz à effet de serre, dérivées des scénarios futurs. Les GCMs ont une résolution spatiale grossière (généralement de 100 à 300 km environ) et comportent un certain nombre d'incertitudes dues aux conditions initiales et aux conditions limites, aux observations, aux paramètres du modèle et à sa structure (Wigley et al., 1990). En raison de ces incertitudes, certains processus du système climatique restent ambigus. Ces incertitudes peuvent être minimisées en utilisant des simulations d'ensemble dans lesquelles la moyenne des différents modèles est calculée. Les GCMs présentent une grande variabilité à la fois à l'échelle spatiale et temporelle et ne sont pas appropriés pour évaluer les impacts du changement climatique sur les systèmes agricoles par exemple en raison des caractéristiques topographiques locales (Wilby et Wigley, 1997). Pour évaluer les impacts possibles sur l'agriculture au niveau régional et l'intégration des caractéristiques locales, les projections des GCM doivent subir une descente d'échelle statistique ou dynamique. Toutefois, les données réduites peuvent présenter des incohérences en termes d'ampleur et de tendances temporelles, ce qui nécessite l'application de méthodes de correction des biais pour limiter l'écart entre les données observées et modélisées.

c) Descente d'échelle (Downscaling)

Etant donné que les GCMs ont généralement des résolutions spatiales de l'ordre de 100 à 300 km, ils ne permettent pas d'accéder aux échelles spatiales locales. Leurs sorties ne peuvent pas être directement utilisées pour alimenter les modèles d'impacts agronomiques ou hydrologiques (Wilby et Wigley, 1997). En effet, les forçages et les circulations qui modifient le climat régional se produisent généralement à des échelles spatiales plus fines et peuvent conduire à des conditions climatiques régionales bien différentes de ce que présuppose l'état climatique global (Giorgi, 2002). Les techniques de descente d'échelle spatiale (réduction d'échelle, downscaling ou désagrégation) servent notamment à élaborer des scénarios du changement climatique à des échelles spatiales fines à partir de sorties des GCMs. Classiquement, les méthodes de désagrégation sont rangées en deux classes : la désagrégation statistique et la désagrégation dynamique. Une brève description de ces méthodes est donnée ci-dessous.

- Descente d'échelle dynamique

Les méthodes de descente d'échelle dynamiques permettent d'affiner l'information climatique produite avec les GCMs en utilisant des modèles climatiques régionaux (Regional Climate Model –RCM) (Giorgi et Mearns, 1991; Wang et al., 2004). Selon Somot (2005), il existe trois types de modèles régionaux : (i) les AGCMs (Atmospheric General Circulation Model) à très haute résolution et couvrant tout le globe (Cubasch et al., 1995), (ii) L'utilisation d'un modèle global avec un zoom régional sur la zone d'intérêt. Par exemple le modèle ARPEGE-Climat (Déqué et al., 1994; Driouech et al., 2009) peut être utilisé dans ce type de configuration. Les performances de ce type de modèle sont similaires aux GCMs standards dans les régions en dehors du zoom, par contre, dans la zone d'intérêt, les performances y sont plus meilleures (Déqué et al., 2005), (iii) L'utilisation des modèles à aire limitée (Limited Area Model, LAM) initialisées et forcés aux bords par des GCMs à plus basse résolution (Giorgi et al., 2004; Giorgi et Mearns, 1999). Ces modèles sont résolus dans un domaine très réduit permettant d'atteindre des résolutions allant jusqu'à 12 km, en conservant des coûts de calculs numériques accessibles. Ces modèles ont donné naissance à de nombreux projets de modélisation régionale comme PRUDENCE (Christensen et al., 2002), ENSEMBLES (Hewitt et Griggs, 2004) en Europe, NARCCAP (Mearns et al., 2013) en Amérique du nord et plus récemment MED-CORDEX (Ruti et al., 2016) en zone méditerranéenne. Afin de préserver la cohérence entre le climat global et le climat local, les LAMs sont contraints à leurs frontières par des GCMs, afin de prendre en compte les conditions synoptiques de l'atmosphère et de l'océan. Par conséquent, les LAMs peuvent être impactés par les biais des GCMs forceurs : des erreurs systématiques peuvent être transmises aux frontières latérales. Aussi, d'importantes incohérences peuvent apparaître entre le climat global et régional sans possibilité de correction car il n'y a pas de rétroaction du LAM vers le GCM (Colmet-daage et Les, 2019).

- Descente d'échelle statistique

La descente d'échelle statistique repose sur l'hypothèse que le climat régional est conditionné à la fois par les caractéristiques à grande échelle et les propriétés locales (topographie, occupation des sols, ...). L'approche statistique repose donc sur la recherche d'une relation statistique entre les paramètres atmosphériques de grande échelle et les variables locales (Wilby et Wigley, 1997). Cette méthode repose sur 3 grandes hypothèses :

- La variable prédictive doit être fortement liée au climat local et simulée de façon réaliste par le modèle climatique global.

- La relation entre la variable prédictive et le climat local est supposée constante dans le temps.
- La variable prédictive doit être sensible aux changements climatiques.

La seconde hypothèse, dite de « stationnarité » est problématique, car elle n'est pas vérifiable dans le cadre des études sur le changement climatique. C'est-à-dire qu'il n'est pas garanti que dans un climat futur, la variable prédictive et le climat local soient liés de la même façon. Idéalement, les données observées devraient couvrir une large palette de conditions climatiques incluant les modifications futures des prédicteurs climatiques (Wilby et Wigley, 1997).

- La méthode de Quantile-Quantile pour la correction de biais

Afin de combler l'écart entre les informations nécessaires pour alimenter les modèles d'étude d'impact et les données des modèles régionaux du climat disponible, des méthodes de correction de biais sont mises en œuvre pour corriger les sorties des modèles, et rendre la distribution statistique des données simulées identiques à la distribution des données observées. Parmi ces méthodes, la méthode quantile-quantile (Déqué, 2007) qui consiste à élaborer une fonction de correction pour que la distribution des variables simulées par le modèle dans le climat futur tienne compte des erreurs sur les distributions statistiques de la période de référence (Ricard et al., 2009). Cette méthode non paramétrique revient à considérer que le modèle est capable de prédire la distribution des variables climatiques mais pas la valeur exacte de chaque quantile, et, comme pour la descente d'échelle statistique, elle repose sur une hypothèse forte selon laquelle la fonction de transfert calibrée sur une période du passé reste valable dans le futur (Déqué, 2007). Pour chaque variable météorologique, les fonctions de densité de probabilités (PDF) sont calculées en chaque point des séries temporelles de la simulation et d'observation. La fonction de transfert consiste à associer chaque centile du modèle au centile observé. Ces fonctions sont ensuite utilisées pour corriger les projections futures. Cette méthode permet de corriger les plus gros défauts des modèles, notamment en termes d'intensité des phénomènes extrêmes ou de fréquence des jours pluvieux (Déqué, 2007).

d) Initiative Med-CORDEX

L'initiative de Med-CORDEX (<http://www.medcordex.eu/>) vise à produire pour la région méditerranéenne un ensemble de simulations à différentes résolutions prenant en compte la spécificité du climat Méditerranéen avec l'utilisation de plusieurs GCM et RCM issus de différentes institutions (Tableur 7) (Ruti et al., 2016). Plusieurs études ont déjà utilisé les données de Med-CORDEX pour évaluer l'impact du changement climatique sur les ressources

en eau et l'agriculture dans la région méditerranéenne (Hajhouji et al., 2020; Marchane et al., 2017; Moucha et al., 2021; Raymond et al., 2019; Trambly et al., 2018, 2013b).

Tableau 7: Simulations disponibles à 50 km de résolution (grille MED44)

Institut	Modèle RCM	Résolution	Modèle GCM	Eval	HIST	RCP4.5	RCP8.5
GUF	CCLM	50 km	MPIESM	x	x	x	x
IPSL	LMDZ	50 km	IPSL	x	x	x	x
CNRM	ALADIN	50 km	CNRM	x	x	x	x
ICTP	RegCM4	50 km	HAD	x	x	x	x
CMCC	CCLM	50 km	CMCC	x	x	x	x

Noms des simulations :

Eval : Simulations en période de contrôle, 1979-2005, avec les modèles RCM forcés par des réanalyses ERA-Interim (permet de valider les RCM avec la comparaison avec les données observées)

HIST : Simulations en période de contrôle (1950-2005, selon les modèles) avec les RCM forcés par les GCM indiqués dans les tables

RCP4.5 / RCP8.5 : Simulations en période future (2005-2100) des RCM forcés par les différents GCM selon le scénario d'émission RCP4.5 ou RCP8.5.

Noms des instituts :

Goethe University Frankfurt (GUF); Institut Pierre Simon Laplace (IPSL); Centre National de Recherches Météorologiques (CNRM); International Centre for Theoretical Physics (ICTP); Centro Euro-Mediterraneo sui Cambiales Climatici (CMCC).

III-2) La modélisation des agrosystèmes

III-2-1) Généralités

Depuis les années 1960, la modélisation de la croissance des cultures a évolué avec les progrès de la technologie informatique, soutenant la simulation des processus physiologiques des plantes ainsi que la croissance et le développement des cultures. Les modèles de culture décrivent la croissance et le développement de cultures en interaction avec leurs conditions agro-environnementales (sol, climat et les pratiques de gestion) (Dumont et al., 2012). Au cœur du modèle de croissance des cultures, il y a un ensemble d'équations qui estime le taux de production de la biomasse à partir des ressources capturées telles que le dioxyde de carbone, le rayonnement solaire et l'eau (Monteith et al., 1994). Selon la ressource capturée, on peut

distinguer entre trois principaux types, des modèles qui se basent sur (i) le carbone, (ii) le rayonnement et (iii) l'eau (Todorovic et al., 2009).

Les modèles basés sur le carbone simulent la croissance des cultures et se basent sur l'assimilation du carbone par les feuilles grâce au processus de photosynthèse. Cette approche a été développée initialement par (de Wit, 1965). Ces modèles sont basés sur une description hiérarchique du système, où les réponses de niveau supérieur résultent de l'intégration des processus sous-jacents de niveau inférieur. Les processus de croissance simulés et le développement phénologique sont régulés par la température, le rayonnement et la teneur en CO₂ atmosphérique et sont limités par la disponibilité en eau. La structure de ces modèles est complexe et un grand nombre de paramètres d'entrée est nécessaire. Parmi ces modèles, on peut citer le modèle WOFOST (WOrld FOod STudies, van Diepen et al., 1989).

Les modèles basés sur le rayonnement, dérivent la biomasse directement du rayonnement solaire intercepté grâce à un coefficient de conversion, appelé efficacité d'utilisation du rayonnement (Radiation Use Efficiency, RUE), comme décrit par Monteith, (1977). Dans ces modèles, la production de biomasse aérienne est décrite comme une fonction linéaire du rayonnement intercepté et suit la loi de Monteith définie comme le produit entre l'absorption de rayonnement solaire incidente et RUE. Les processus hiérarchiques inférieurs exprimant les étapes intermédiaires nécessaires à l'accumulation de la biomasse sont incorporés synthétiquement dans le RUE (Monteith, 1977). De ce fait, la complexité et le nombre de variables d'entrée sont réduits par rapport aux modèles basés sur le carbone. Le modèle CERES (Crop Environment REsources Synthesis, Ritchie, 1985) est basé sur une approche de type efficience.

Dans les modèles de croissance des cultures basés sur l'eau, le taux de croissance de la biomasse est linéairement proportionnel à la transpiration par un paramètre appelé productivité de l'eau (Water Productivity, WP) (de Wit, 1965; Hanks, 1983; Hsiao, 1973; Steduto en Albrizio, 2005). Comme pour les modèles basés sur le rayonnement solaire, ces modèles ont une paramétrisation parcimonieuse et un nombre plus faible de paramètres d'entrée que les modèles basés sur le carbone (Steduto en Albrizio, 2005; Todorovic et al., 2009). L'un des principaux avantages des modèles basés sur l'eau, par rapport aux approche de type efficience, réside dans la possibilité de normaliser le paramètre WP en fonction du climat (à la fois la demande évaporative et la concentration atmosphérique en CO₂), ce qui permet une généralité plus forte dans l'espace et dans le temps (Hsiao et al., 2007; Steduto en Albrizio, 2005; Todorovic et al., 2009). Ce groupe de modèles inclut le modèle conçu par la FAO AquaCrop (Raes et al., 2009;

P. Steduto et al., 2009). AquaCrop a été développé pour fournir un outil de modélisation facile à utiliser à un large éventail d'utilisateurs (agriculteurs, consultants agricoles, gestionnaires de l'eau et décideurs politiques) intéressés par la biomasse des cultures et le rendement des récoltes dans le cadre de différents scénarios d'irrigation et de fertilisation. AquaCrop permet aussi d'analyser les impacts du changement climatique sur la production des cultures (Raes et al., 2009; P. Steduto et al., 2009). De plus, Todorovic et al. (2009) ont comparé la performance de modèle AquaCrop par rapport à deux modèles plus complexes WOFOST et CropSyst : ils ont montré que AquaCrop présente des simplifications notables et nécessite moins de paramètres d'entrée que les deux autres modèles, sans que cela affecte négativement ses performances en termes d'estimation de biomasse finale et de rendement.

Les modèles de croissance des cultures forcées par les projections futures du climat ont été utilisés pour étudier l'impact du changement climatique sur le développement, le rendement et les besoins en eau des cultures (Ahmed et al., 2017; Bocchiola, 2015; Wang et al., 2009; White et al., 2011). Dans notre étude nous avons choisi le modèle AquaCrop, en tenant compte des avantages des modèles mentionnés précédemment, et du fait qu' AquaCrop est déjà calibré et validé dans notre zone d'étude (Toumi et al., 2016). De plus, plusieurs études ont utilisé ce modèle pour étudier les impacts du changement climatique sur la production des cultures et les besoins en eau dans différentes régions de monde (Akumaga et al., 2018; Bird et al., 2016a; Voloudakis et al., 2015). Dans la section suivante, nous allons décrire en détail le modèle AquaCrop.

III-2-2) Model AquaCrop

a) Description du modèle AquaCrop

AquaCrop est un modèle de productivité des cultures et de l'eau, développé par la division des terres et des eaux de la FAO depuis 2008 (Raes et al., 2009). Ce modèle simule le comportement du système sol-plante-atmosphère durant une ou plusieurs saisons agricoles. Ce système est, d'une part, limité supérieurement par l'atmosphère, caractérisée par les variables climatiques standards (la température maximale et minimale de l'air, le rayonnement net, la pluie, la vitesse du vent et l'évapotranspiration de référence) et d'autre part, il est limité inférieurement par l'interface sol/sous-sol. Au lieu de l'indice foliaire (LAI), AquaCrop utilise la couverture de canopée verte (CC) pour exprimer le développement du feuillage. CC est la fraction de la surface du sol couverte par la canopée verte (en %). Le sol est considéré comme une succession de couches horizontales caractérisé par leur teneur en eau, les points de

flétrissement et les capacités au champ. Les racines, qui assurent l'interaction plante-sol, sont définies par leur distribution au sein du profil de sol (Raes et al., 2009).

En le comparant avec les autres modèles, AquaCrop est un outil simple, convivial et facile à utiliser. Les caractéristiques qui différencient AquaCrop des autres modèles de croissances des cultures sont :

- La focalisation sur l'eau ;
- L'utilisation de la couverture de canopée au lieu de l'indice foliaire ;
- L'utilisation de valeurs normalisées de productivité de l'eau (WP) pour des demandes évaporatoires et des concentrations de CO₂, qui confèrent au modèle une grande capacité d'extrapolation pour divers emplacements, saisons et climats, et y inclus des scénarios de climats futur ;
- Le nombre relativement réduit de paramètres d'entrée ;
- L'interface facile à manipuler ;
- La possibilité de l'appliquer dans des divers systèmes agricoles existants à travers le monde.

b) De l'approche Ky au modèle AquaCrop

La réponse du rendement à l'eau décrit la relation entre le rendement d'une culture et le stress hydrique à la suite d'une pluie trop faible ou d'une dose d'irrigation insuffisante durant la période de croissance. Doorenbos et al., (1980) ont utilisé une fonction de production empirique pour l'estimation de la réponse du rendement à l'eau :

$$\left(1 - \frac{Y}{Y_x}\right) = k_y \left(1 - \frac{ET}{ET_x}\right) \text{ (Eq. 7)}$$

Où Y_x et Y sont le rendement maximal et réel, $(1 - Y/Y_x)$ est le déclin relatif du rendement, ET_x et ET sont respectivement l'évapotranspiration maximale et réelle, $(1 - ET/ET_x)$ le stress hydrique relatif, et K_y un facteur de proportionnalité entre le déclin relatif du rendement et la réduction relative de l'évapotranspiration.

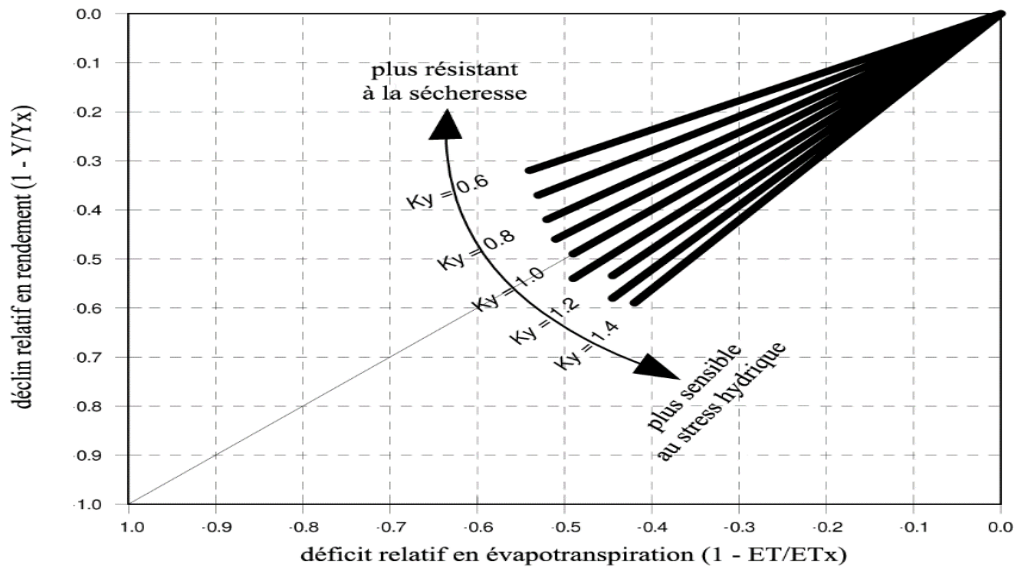


Figure 10: La relation entre le déclin relatif du rendement ($1 - Y/Y_x$) et le déficit relatif en évapotranspiration ($1 - ET/ET_x$) (Raes et al., 2009).

La figure 10 présente la relation entre le déclin relatif du rendement ($1 - Y/Y_x$) et le déficit relatif en évapotranspiration ($1 - ET/ET_x$) pour une période de croissance et pour les différents facteurs de réponse du rendement (K_y). Le modèle AquaCrop (Hsiao et al., 2009; Raes et al., 2009; Steduto et al., 2009) fait évoluer cette approche basée sur la réponse du rendement, K_y , en distinguant :

a) Dans l'évapotranspiration réelle (ET), l'évaporation du sol (E) et la transpiration de la culture (Tr) :

$$ET = E + Tr \quad (\text{Eq. 8})$$

La séparation d'ET en évaporation du sol et transpiration de la culture permet de distinguer la consommation en eau productive (transpiration) et non productive (évaporation du sol). Ceci est surtout important quand la couverture du sol est faible en début de saison ou si la culture est éparse.

b) le rendement final (Y), s'exprime comme le produit de la biomasse (B) et d'un indice empirique, l'indice de récolte (HI) :

$$Y = HI * B \quad (\text{Eq. 9})$$

La séparation dans le calcul du rendement entre la biomasse et l'indice de récolte, permet la partition des relations fonctionnelles correspondantes, en réponses aux conditions environnementales.

Ces changements mènent à l'équation suivante, qui est au cœur du moteur de croissance d'AquaCrop :

$$B = WP * \sum Tr \quad (\text{Eq. 10})$$

Où Tr est la transpiration de la culture (en mm) et WP est le paramètre de productivité de l'eau (kg de biomasse par m^2 et par mm d'eau de transpiration cumulée durant la période de production de biomasse). Cette démarche utilisant les équations 6 à 9 a une implication fondamentale sur la robustesse du modèle en raison du caractère conservateur de WP (Raes et al., 2009). Il est important de remarquer que les deux équations ont l'eau comme force motrice pour la croissance des cultures.

Afin d'être fonctionnelle, l'équation 10 a été placée dans un modèle comprenant des composantes sol, avec son bilan en eau, la culture, avec ses processus de développement, de croissance et de constitution du rendement et l'atmosphère, avec son régime thermique, la pluviométrie, la demande évaporative et la concentration en dioxyde de carbone. De plus, quelques aspects de gestion ont été considérés explicitement (ex. l'irrigation, la fertilisation, etc.), vu qu'ils affecteront le bilan d'eau du sol, le développement de la culture, et de cette manière la production finale. L'impact des ravageurs, maladies et mauvaises herbes n'est pas considéré.

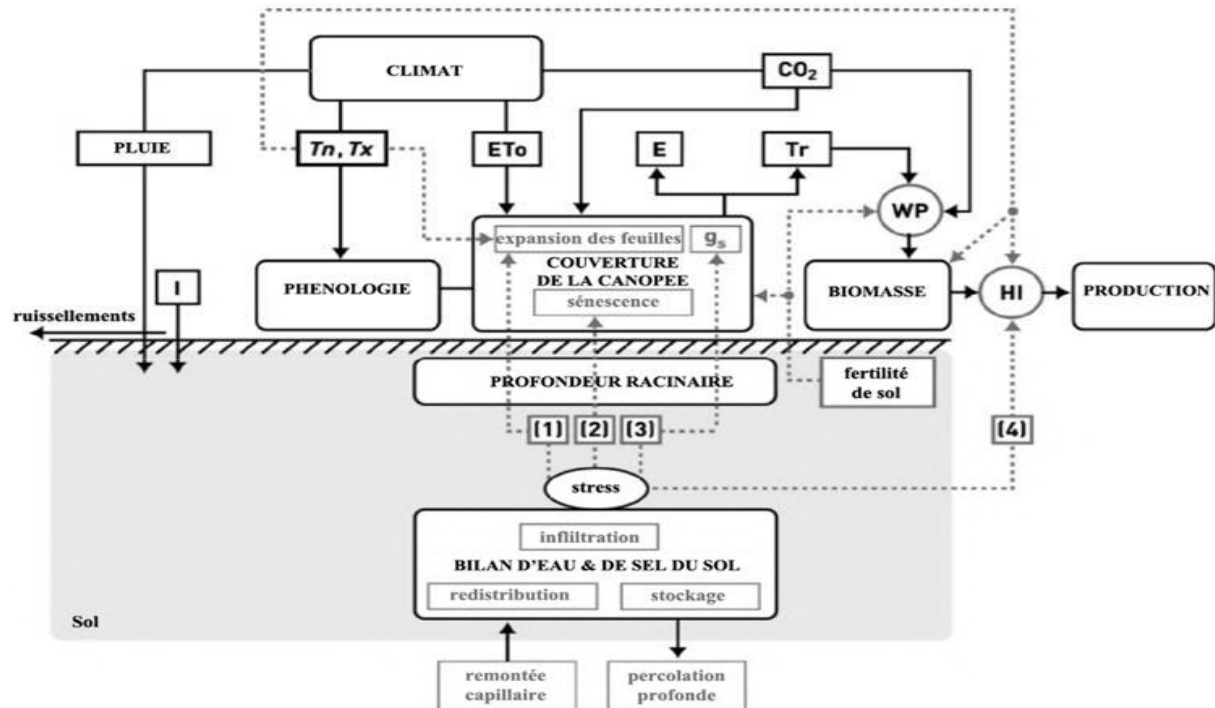


Figure 11: composantes principales du continuum sol-plante- atmosphère et les paramètres caractérisant la phénologie, la couverture de la canopée, la transpiration, la production de biomasse et le rendement final. (I, irrigation ; T_n , température minimale de l'air ; T_x , température maximale de l'air ; ET_0 , évapotranspiration de référence ; E , évaporation du sol ; Tr , transpiration de la canopée ; g_s , conductance stomatique ; WP , productivité de l'eau ; HI , indice de récolte ; CO_2 , concentration atmosphérique en dioxyde de carbone ; (1), (2), (3), (4), fonctions de réponse au stress hydrique sur : l'expansion des feuilles, la sénescence, la conductance stomatique et l'indice de récolte) Les traits continus indiquent les liens directs entre les variables et les processus. Les traits interrompus indiquent les feedbacks

c) Schéma de calcul

Un schéma de calcul d'AquaCrop est présenté dans la figure 12. A un pas du temps journalier, le modèle simule successivement les processus suivants :

1. Le bilan d'eau du sol : La quantité d'eau stockée dans la zone racinaire est simulée en comptabilisant les flux d'eau entrants et sortant à ses frontières. L'épuisement de la réserve en eau dans la zone racinaire détermine la magnitude d'une série de coefficients de stress en eau (K_s), affectant : (a) l'expansion de la canopée verte (CC), (b) la conductance stomatique et par conséquent la transpiration (Tr) par unité de CC, (c) la sénescence et le déclin de la canopée, (d) l'indice de récolte et (e) le taux d'enracinement dans la zone racinaire.

2. Le développement de la culture : pour la simulation du développement de la culture, l'expansion de la canopée est séparée de l'expansion de la zone racinaire. L'interdépendance entre ces deux expansions est indirecte via le stress hydrique. AquaCrop utilise la couverture de la canopée pour la description du développement de la culture. La canopée est une caractéristique cruciale d'AquaCrop. A travers son expansion, son vieillissement, sa conductance et sa sénescence, il détermine la quantité d'eau transpirée (Tr), qui en retour détermine la quantité de la biomasse (B) produite et le rendement final (Y). Si un stress hydrique se produit, l'expansion de la canopée verte simulée sera inférieure à la couverture potentielle de la canopée (CC_{pot}) pour des conditions sans stress, et la profondeur maximale des racines ne pourra pas être atteinte.

3. Transpiration de la culture (Tr) : La transpiration d'une culture est obtenue en multipliant la force évaporatoire de l'atmosphère (ET_o) par un coefficient cultural. Le coefficient cultural (K_{cb}) est proportionnel à CC, et est en conséquence continuellement modifié. La force évaporatoire est exprimée par l'évapotranspiration de référence (ET_o), déterminée selon l'équation de Penman-Monteith. Si un stress hydrique provoque une fermeture de stomates, le coefficient de stress lié à la conductance stomatique (K_s) diminuera et, par-là, la transpiration. La couverture de la canopée verte et la durée représentent les sources pour la transpiration, la conductance stomatique représente l'intensité de transpiration.

4. Biomasse au-dessus du sol (B) : Le cumul de la quantité d'eau transpirée (Tr) se traduit en une quantité proportionnelle de biomasse, produite à travers la productivité de l'eau (Eq.10). Dans le modèle AquaCrop, la productivité normalisée de l'eau (WP^*) pour la demande atmosphérique et les concentrations en CO_2 de l'air est utilisée. Elle exprime une forte relation

entre l'assimilation photosynthétique de CO₂ ou la production de biomasse, et la transpiration, indépendamment des conditions climatiques (Raes et al., 2009).




Figure 12 : Schéma de calcul d'AquaCrop indiquant (en flèches pointillées) les processus affectés par le stress hydrique (a à e). CC est la couverture de canopée simulée, CC_p la couverture potentielle de canopée, K_s le coefficient de stress en eau, K_{cb} le coefficient de culture, E_{To} l'évapotranspiration de référence, WP* la productivité de l'eau pour une culture normalisée, et HI l'indice de récolte (Sieduto et al., 2011).

d) Données d'entrées requises

Les données d'entrée du modèle AquaCrop sont : des données climatiques, des caractéristiques culturales et du sol, et des pratiques de gestion, qui définissent l'environnement dans lequel la culture se développera (Figure 13). Les données d'entrée sont stockées dans des fichiers du climat, de culture, du sol et de gestion. Elles peuvent être facilement changées à travers l'interface utilisateur.

- **Caractéristiques culturales**

Bien que basé sur des processus biophysiques basiques et complexes, le modèle AquaCrop utilise des paramètres de culture pour décrire les caractéristiques culturales. Une distinction est faite entre des paramètres conservateurs, spécifiques à la variété, et moins conservateurs :

- Les paramètres de culture conservateurs ne sont matériellement pas affectés par le temps, les pratiques de gestion ou l'emplacement géographique. Ils ont été calibrés avec des données d'une culture cultivée dans des conditions favorables et non-limitantes. Ils restent applicables dans des conditions de stress à travers les fonctions de réponse aux stress. De cette manière, les paramètres conservateurs ne nécessitent pas d'ajustement aux conditions locales et peuvent être directement utilisées dans les simulations.

- Les paramètres de culture spécifiques à une variété peuvent nécessiter un ajustement quand on sélectionne une variété différente de celle utilisée pour la calibration. Les paramètres de culture sont influencés par la gestion de la parcelle, les conditions dans le profil du sol ou le climat (surtout quand on simule en mode jour calendrier). Ces paramètres pourraient nécessiter des ajustements afin de tenir compte de la variété locale et/ou des conditions environnementales locales.

- **Caractéristiques du sol**

Le profil du sol peut comprendre jusqu'à cinq horizons différents de profondeur variable, ayant chacun ses propres caractéristiques physiques. Les caractéristiques hydrauliques considérées sont : la conductivité hydraulique à saturation (K_{sat}), les teneurs en eau du sol à saturation (θ_{sat}), à la capacité au champ (θ_{FC}) et au point de flétrissement permanent (θ_{PWP}).

- **Pratiques de gestion**

Les pratiques de gestion sont divisées en deux catégories : gestion à la parcelle, et gestion des pratiques d'irrigation :

- Les pratiques de gestion à la parcelle qui peuvent être choisis sont : des niveaux de fertilité du sol et les pratiques affectant le bilan hydrique.

- Quant à la gestion d'irrigation, l'utilisateur peut choisir entre culture pluviale et culture irriguée. En cas d'irrigation, on peut choisir la méthode d'irrigation (aspersion, goutte-à-goutte ou gravitaire), la fraction de la surface mouillée est spécifiée pour chaque irrigation, la qualité d'eau, la durée et la dose appliquée. Il y a également des options pour estimer les besoins nets en irrigation, et pour générer des calendriers d'irrigation, basés sur des critères de temps et de profondeur spécifiés. Comme les critères peuvent changer durant la saison, le programme offre la possibilité d'essayer des stratégies d'irrigation déficitaire en appliquant différentes doses d'eau durant les divers stades du développement de la culture (Raes et al., 2009).




Figure 13: Données d'entrée du modèle AquaCrop

- **Le degré jour de croissance**

Le degré jour de croissance est une mesure empirique utilisée pour calculer l'accumulation de la chaleur qui sert à estimer la durée d'un développement biologique tel que la croissance d'une plante. Les degrés-jours de croissance (DJC) sont calculés en soustrayant la température de base de la température moyenne de l'air (Tavg) :

$$DJC = T_{avg} - T_{base} \text{ (Eq. 11)}$$

La température de base (Tbase) est la température minimale à partir de laquelle une plante se développe. Dans AquaCrop, une température du seuil supérieure (Tupper) est également considérée. Tupper est la température maximale à partir de laquelle une plante ne se développe pas.

Il existe 3 méthodes de calcul de Tavg qui sont :

Méthode 1

La température moyenne de l'air est donnée par :

$$T_{avg} = \left(\frac{T_x + T_n}{2} \right) \text{ (Eq. 12)}$$

Où T_x : la température maximale de l'air T_n : la température minimale de l'air. Une fois que la T_{avg} est calculée, on vérifie si la température moyenne de l'air est comprise entre T_{base} et T_{upper} . Il existe deux cas de figures, dans le premier cas, si T_{avg} est inférieur à T_{base} , T_{avg} est prise égale à T_{base} (résultant en 0 ° C jour pour ce jour), Le deuxième cas, si T_{avg} est supérieur à T_{upper} , T_{avg} est prise égal à T_{upper} (Les degrés croissants maximaux).

Méthode 2

Dans cette méthode, la comparaison à T_{base} et T_{upper} se produit avant le calcul de la température moyenne. T_n et T_x sont ajustés s'ils tombent sous T_{base} ou dépassent T_{upper} .

Avant que T_{avg} ne soit calculé. La température moyenne est donnée par :

$$T_{avg} = \left(\frac{T_{x^*} + T_{n^*}}{2} \right) \text{ (Eq. 13)}$$

Où T_{x^*} et T_{n^*} sont les températures maximales et minimales de l'air ajustées.

Les règles suivantes s'appliquent : T_x est la température maximale de l'air ($T_{x^*} = T_x$) si T_x est supérieur à T_{upper} , alors $T_{x^*} = T_{upper}$, si T_x est inférieur à T_{base} , alors $T_{x^*} = T_{base}$. T_n est la température minimale de l'air ($T_{n^*} = T_n$), si T_n est supérieur à T_{upper} , alors $T_{n^*} = T_{upper}$, si T_n est inférieur à T_{base} , alors $T_{n^*} = T_{base}$.

Méthode 3

Comme dans la méthode 2, la comparaison avec T_{base} et T_{upper} se produit avant le calcul de la température moyenne. Cependant, la vérification ne concerne que la température maximale de l'air. La température moyenne est donnée par :

$$T_{avg} = \left(\frac{T_{x^*} + T_n}{2} \right) \text{ (Eq. 14)}$$

Où T_{x^*} est la température maximale de l'air ajusté et T_n la température minimale de l'air. Les règles suivantes s'appliquent : T_x est la température maximale de l'air ($T_{x^*} = T_x$), si T_x est supérieur à T_{upper} , alors $T_{x^*} = T_{upper}$, si T_x est inférieur à T_{base} , alors $T_{x^*} = T_{base}$. T_n n'est pas ajusté. Cependant, si T_n dépasse T_{upper} , T_n sera égal à T_{upper} . Une fois la T_{avg} calculée, on vérifie si la température moyenne de l'air est supérieure à la

température de base. Si T_{avg} est inférieur à T_{base} , alors T_{avg} est pris comme base (résultant en $0^{\circ}C$ jour ce jour).

- **Les stades phénologiques du développement sous AquaCrop**

Le cycle de développement d'une céréale comprend trois grandes périodes : (i) La période végétative, de la germination aux premières manifestations de l'allongement de la tige principale (début de la montaison) ; (ii) La période reproductrice, du tallage herbacé à la fécondation ; (iii) La période de maturation, de la fécondation à la maturité complète du grain. A chacune de ces périodes correspondent des exigences particulières de la plante vis-à-vis des facteurs et conditions du milieu. Il est donc important de pouvoir les repérer pour raisonner le choix des techniques culturales. La figure 13 montre les stades phénologiques de développement sous AquaCrop, les stades sont : **L'émergence** : C'est le temps requis à partir du semis pour atteindre 90% d'émergence. **Couverture maximale de canopée** : la couverture maximale de la canopée est dépendante de la densité des plantes, de la canopée cover par les jeunes plants à 90% d'émergence. **Temps de démarrage de la sénescence** : période à laquelle la sénescence de la canopée commence dans les conditions optimales. **Temps de maturité** : Quand la culture est récoltée plus tard, il est supposé que la production ne change plus.

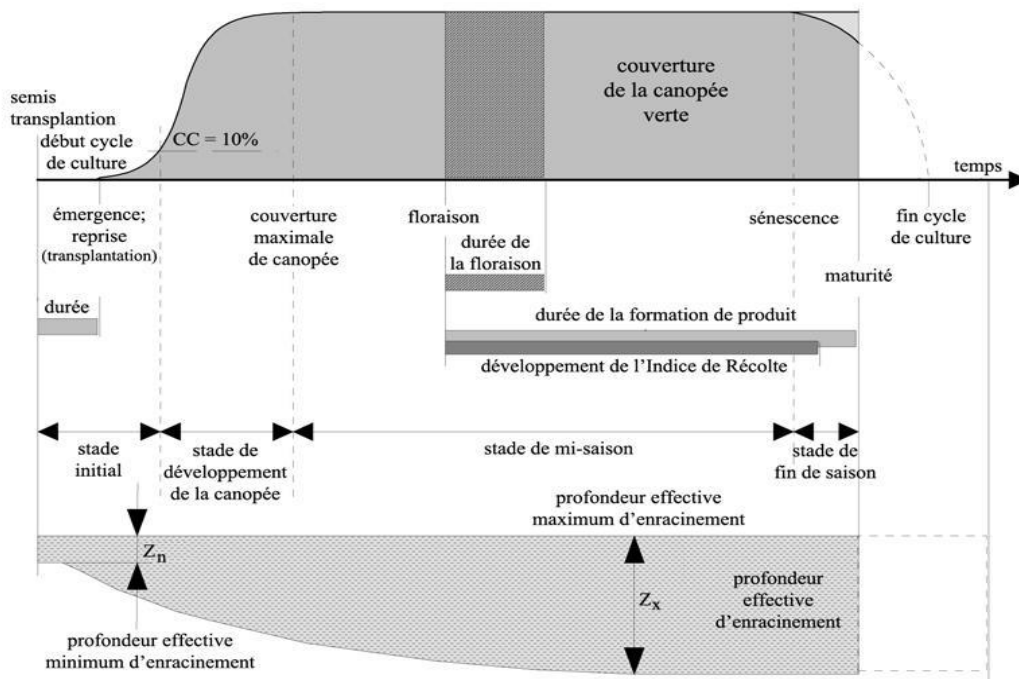


Figure 14: Les stades phénologiques de développement d'une culture (Raes et al., 2011).

III-3) Impact du changement climatique sur la production des cultures

La météorologie et l'agriculture sont très corrélées. Au-delà de la variabilité naturelle qui contrôle une partie de la variance des rendements agricoles, le changement climatique va affecter sur le long terme l'agriculture à l'échelle mondiale (Asseng et al., 2015). En effet, le changement climatique affecte la moyenne et la variabilité des conditions météorologiques et la fréquence des événements extrêmes, qui déterminent en grande partie la variabilité de la production et des rendements (Deschênes en Greenstone, 2007; Kukal en Irmak, 2018; Wang et al., 2020). Ces effets devront conduire à une variabilité de la production encore plus forte qu'aujourd'hui, entraînant à son tour une volatilité des prix des production agricole dans le marché mondial (Kogan et al., 2020; Lobell et al., 2008). L'étude de l'impact du changement climatique est importante pour les stratégies d'adaptation et d'atténuation (Ahmed et al., 2017). Les différents aspects du changement climatique, notamment l'augmentation de la concentration de dioxyde de carbone (CO₂) dans l'atmosphère, le réchauffement des températures, la modification du rayonnement solaire de surface et la variabilité des précipitations, devraient avoir un effet important sur le développement et la production des cultures (Asseng et al., 2013; Monteith, 1981; Wang et al., 2011). Les impacts probables du changement climatique sur le rendement des cultures peuvent être déterminés soit par des données expérimentales, soit par des modèles statistiques ou des modèles de croissance des cultures. Pour prévoir les impacts futurs sur le rendement des cultures, les modèles de culture présentent des approches intéressantes (Kang et al., 2009). Un certain nombre de modèles de croissance des cultures, tels que CERES-Maize (Crop Environment Resource Synthesis), CERES-Wheat, SWAP (Soil Water-Atmosphere-Plant), AquaCrop et STICS (Simulateur multIdisciplinaire for Standard Crops), ont été largement utilisés pour évaluer les impacts du changement climatique sur la production des cultures, en particulier pour analyser la sensibilité du rendement des cultures au climat selon différents scénarios climatiques (Ahmed et al., 2017; Bouras et al., 2019; Dettori et al., 2017; White et al., 2011; Yano et al., 2007).

III-3-1) Impact d'augmentation de CO₂

Les concentrations de CO₂ sont aujourd'hui plus élevées qu'au cours des années précédentes et elles ont augmenté de manière continue et rapide (Siegenthaler et al., 2005). L'augmentation de la concentration de CO₂ dans l'atmosphère a un l'effet sur le carbone du sol, la structure du sol et l'acquisition/la disponibilité des éléments nutritifs (Freeman et al., 2004). Les effets directs de l'augmentation du CO₂ sur les plantes comprennent des modifications quantitatives et qualitatives de leurs production (Norby, 1994). Un taux élevé de CO₂ affecte la photosynthèse,

la respiration, l'évapotranspiration, l'efficacité de l'utilisation de l'eau, le développement phénologique, finalement, le rendement des cultures (Jalota et al., 2018; Lawlor et Mitchell, 2000). Des expériences expérimentales ont démontré qu'une augmentation du CO₂ de 350-380 à 680-700 ppm augmentait le taux net de photosynthèse de 30-50%, entraînant une augmentation de 15-30% de la production totale de matière sèche et du rendement en grains du blé (Amthor, 2001; Mulholland et al., 1998, 1997). En plus de stimuler la photosynthèse et la croissance, l'augmentation de CO₂ entraîne également une réduction de la conductance stomatique de 19 à 22% (Ewert et al., 2002; Manderscheid et al., 2016; Purcell et al., 2018) et une diminution de la transpiration des cultures. Cela entraîne une diminution de l'évapotranspiration des cultures, comme le montre la réduction moyenne de 10 % de l'ET dans les expériences FACE (Free-air concentration enrichment) pour toutes les cultures étudiées y compris le blé (Kimball, 2016). L'amélioration de l'efficacité de l'utilisation de l'eau sous l'effet de l'augmentation de CO₂ peut permettre aux cultures de mieux tolérer la sécheresse (Toreti et al., 2020). Une combinaison de ces réponses de niveau de CO₂ plus élevé signifierait que toutes les cultures peuvent avoir un meilleur rendement (Hatfield et al., 2011; Izaurralde et al., 2011). La biomasse et le rendement ont tendance à augmenter de manière significative dans toutes les plantes, en particulier les plantes en C3 (de Graaff et al., 2006; Long et al., 2006); Dans la partie Nord-Ouest de l'Inde, le riz et le blé ont montré une augmentation du rendement de 15% et 28%, respectivement, à des concentrations élevées de CO₂ de 660 ppm (Lal et al., 1998). Il ne fait aucun doute que l'augmentation du CO₂ a des effets bénéfiques sur la photosynthèse, l'efficacité de l'utilisation de l'eau et la fixation symbiotique de l'azote dans les cultures de légumineuses et le rendement dans toutes les cultures, mais le mode par lequel un CO₂ élevé augmente le rendement est spécifique à la culture et à la voie de la photosynthèse (Jalota et al., 2018).

III-3-2) Impact de la hausse de température

La température est l'un des facteurs principaux qui gouverne la productivité des cultures (Wheeler et al., 2000). Contrairement au CO₂, l'augmentation de la température a un effet négatif sur la production agricole. Pour chaque augmentation de 1°C de la température, la production mondiale de blé diminue de 6% (Asseng et al., 2013). Même une augmentation de 1°C de la température par rapport à la température moyenne pendant la phase de reproduction peut entraîner une perte plus importante du rendement en grains (Bennett et al., 2012; Yu et al., 2014). La température influe sur la respiration et le métabolisme, ce qui affecte le taux de croissance et la production des cultures (Asseng et al., 2004; You et al., 2009). Les réponses

physiologiques aux changements de température dans les plantes peuvent se produire à court ou à long terme. Les effets à court terme impliquent une altération de l'expression des gènes, comme la synthèse des protéines par choc thermique. Les réponses à long terme comprennent des modifications du taux d'assimilation du CO₂, et de la répartition du C et du N au sein des organes et entre eux. La modification de la disponibilité du C provoquée par ces événements affecte l'absorption, le transport et l'assimilation des nutriments, ce qui entraîne des changements dans les taux de croissance et le rendement (Jalota et al., 2018). Les réponses à la température pour des processus physiologiques spécifiques ne sont pas toujours directement liées à la croissance, car celle-ci est une intégration des effets de la température sur le métabolisme total. Cependant, il est important de comprendre l'effet de la température sur les processus physiologiques comme la photosynthèse, la respiration, la transpiration, les développements phénologiques des plantes, et par conséquent la production et le rendement de la biomasse. La réponse de la température à la photosynthèse est sigmoïde. La photosynthèse nette est inférieure à l'optimum à des températures plus basses et plus élevées (Todd, 1982). La température optimale pour la photosynthèse est différente selon les cultures, 25°C pour le blé, 21-27°C pour le coton, 20-37°C pour le riz, 32°C pour le maïs et 34°C pour le soja (Todd, 1982). L'augmentation des températures accélère la maturation et la sénescence des feuilles, ce qui réduit la durée de la photosynthèse. L'efficacité de la photosynthèse diminue lorsque la température dépasse 35-40°C. La température optimale pour la photosynthèse varie en fonction de la concentration en CO₂ (Jalota et al., 2018).

IV) Conclusion

Dans ce chapitre nous avons présenté les différents indices utilisés pour le suivi de la sécheresse agricole. Les indices basés sur les mesures in-situ sont les plus précis car ils sont représentatifs des conditions locales mais les réseaux épars dans certaines régions du globe limitent leur utilisation pour le suivi de la sécheresse à grande échelle. Les indices dérivés de la télédétection dans les trois principaux domaines de longueur d'onde exploités en télédétection offrent la possibilité de suivre la sécheresse à grande échelle. Schématiquement, les indices issus des domaines visibles et proche infrarouge sont liés à l'état de végétation. Dans le domaine IRT, ils sont liés au stress thermo-hydrique et dans les micro-ondes au contenu en eau du sol et du couvert végétal. Dans un 2^{ème} temps, nous avons présenté les différentes méthodes utilisées pour la prévision des rendements des cultures avec un focus sur les méthodes empiriques basées sur la donnée plus facile à mettre en œuvre à grande échelle car moins gourmandes en paramètre d'entrée que les approches basées sur les modèles de croissance des cultures qui de plus

nécessite des prévisions saisonnières du climat de qualité. Finalement nous avons réalisé un état de l'art sur l'impact du changement climatique sur la production des cultures.

Dans le chapitre suivant, nous allons évaluer la relation entre la sécheresse agricole et le rendement des céréales au Maroc.

Chapitre II : La sécheresse agricole et la production des céréales au Maroc.

Les résultats de ce chapitre sont présentés dans l'article suivant : Bouras, E., Jarlan, L., Er-Raki, S., Albergel, C., Richard, B., Balaghi, R., Khabba, S., 2020. Linkages between rainfed cereal production and agricultural drought through remote sensing indices and a land data assimilation system: A case study in Morocco. Remote Sens. 12, 1–35.

<https://doi.org/10.3390/rs12244018>

I) Introduction

La sécheresse agricole, qui est principalement causée par un déficit d'humidité du sol, est un risque naturel majeur pour la production agricole (Ciais et al., 2005; Páscoa et al., 2017; Ribeiro et al., 2019). Elle cause jusqu'à 80% des pertes des rendements agricoles dans le monde (FAO, 2017). Dans la zone Sud de Méditerranée les impacts de la sécheresse agricole sur les systèmes agricoles et la production des cultures sont sévères (Tramblay et al., 2020) à cause de la dominance des cultures pluviales (80%) (Schilling et al., 2020). Nous évaluons dans ce chapitre le lien entre la sécheresse agricole, identifiée par des indices dérivés des observations de télédétection dans trois domaines de longueur d'onde et par les anomalies des sorties du LDAS de Météo-France, et le rendement des céréales au Maroc. Dans notre étude nous avons focalisé sur les 15 provinces les plus productives au Maroc (plus de 90% de la production nationale).

II) Résumé de l'article

L'objectif de ce travail est de caractériser le lien entre la sécheresse agricole et la production des céréales au Maroc. La sécheresse est identifiée à l'aide : (1) Des indices dérivés de données de télédétection dans différents domaines de longueur d'ondes qui sont : le vegetation condition index (VCI) calculé à partir du NDVI du MODIS (MOD13A2) avec une résolution spatiale de 1 km. Le Temperature Condition Index (TCI), calculé à partir du LST de produit MOD11A1 qui a une résolution temporelle journalière et spatiale de 1 km. Le Vegetation Health Index (VHI) qui est une combinaison linéaire de VCI et TCI. Le Soil Moisture Condition Index (SMCI) calculé à partir d'humidité du sol de produit de ESA CCI et le Soil Water Index (SWI) pour les différentes couches du sol à partir de ASCAT. (2) Des variables clés de la surface terrestre (Indice de surface foliaire -LAI-, l'humidité du sol à différentes profondeurs, l'évaporation du sol et la transpiration des plantes) provenant d'un système d'assimilation des données (LDAS) sur la période 2000-2017.

Les données sur la production et la superficie cultivée à l'échelle provinciale ont été obtenues auprès du service économique du Ministère de l'Agriculture au Maroc. Nous avons sélectionné les 15 provinces les plus productives au Maroc où leur production représente plus que 90% de la production nationale (Figure 15). Ces 15 provinces ont été regroupées en 4 groupes selon la variabilité temporelle du rendement sur la période d'étude avec l'utilisation de K-mean. Les statistiques sur le rendement, la production ainsi que les conditions météorologiques (température et précipitations) sont présentées dans le Tableau 8. Le premier groupe nommé "Zone 1" située au Sud de la zone d'étude couvre les provinces de Settat, El Jadida, Safi, Kelaa

des Sraghnas, Haouz et Beni Mellal. En raison du fort gradient pluviométrique Nord-Sud au Maroc, la zone du groupe 1 est caractérisée par une faible précipitation et des températures élevées, elle est par conséquent considérée comme une zone moins productive avec un rendement d'environ 1.5 t. ha^{-1} en moyenne sur la période 2000-2017. Il faut noter que la province de Safi reçoit une grande quantité de précipitations (355 mm de novembre à mai en moyenne sur la période d'étude selon les données ERA5) car elle est située le long de l'océan Atlantique. Cependant, les rendements sont faibles (0.7 t. ha^{-1}), ce qui peut être dû à la pauvreté des sols dans cette province. En outre, une grande zone pluviale de la province de Beni Mellal est située dans le piémont des montagnes de l'Atlas, où les conditions sont plus froides que dans les plaines. Le deuxième groupe nommé "Zone 2" couvre les provinces de Ben Slimane, Khenifra, El Hajeb, Khemisset et Meknès. Elles sont situées au centre de la région d'étude avec des conditions pluviométriques favorables (environ 600 mm en moyenne du novembre à mai). Cela explique les rendements, plus élevés que ceux du groupe 1, avec un rendement moyen d'environ 1.9 t. ha^{-1} . Le troisième groupe, appelé "Zone 3", couvre les provinces de Taza, Taounat et Fès. La zone 3 est située au Nord du Maroc, et elle est caractérisée par une pluviométrie également élevée (environ 680 mm/an). Le rendement moyen dans cette zone est d'environ 1.5 t. ha^{-1} . Le dernier groupe nommé "Zone 4" comprend uniquement la province de Kenitra. Cette province est située dans la partie nord-est du pays. La zone 4 est dominée par les zones irriguées où les céréales représentent plus de 60% des surfaces cultivées ; les rendements sont élevés (2.1 t. ha^{-1}).




Figure 15: Les 15 provinces les plus productives considérées dans l'étude et résultats des quatre classifications

Tableau 8: Les statistiques de production, précipitations moyennes et température pour chaque province.

	Province	Surface cultivée (1000 ha)	Ratio de la surface cultivée (%)	Production totale (1000 t)	Rendement (t. ha ⁻¹)	Cumul de précipitations (mm)	Température (°C)
Zone 1	Settat (ST)	414.8	43%	540.8	1.3	420.3	15.1
	El Jadida (JD)	330.4	47%	613.9	1.9	419.5	15.6
	Beni Mellal (BM)	173.7	26%	252.4	1.5	555.1	11.8
	Kelaa Sraghna (KS)	260.0	37%	272.3	1.0	340	15.9
	Safi (SF)	125.7	13%	90	0.7	355.2	15.2
	Haouz (HZ)	90.3	15%	78.2	0.9	381.1	9.9
	Total	1394.9	30%	1847.6	1.2	411.9	13.9
Zone 2	Ben Slimane (BS)	83.1	34%	156.4	1.9	518	14.7
	Khemisset (KM)	328.3	40%	490.2	1.5	589.9	13.7
	Meknes (MK)	80.8	45%	181	2.2	671.7	14.6
	El Hajeb (HJ)	70.4	28%	148.5	2.1	688.7	12.2
	Khenifra (KN)	184.0	16%	338.7	1.8	525.6	9.7
	Total	746.6	33%	1314.8	1.9	598.78	12.98
Zone 3	Fes (FS)	91.8	45%	156.7	1.7	667.1	14.8
	Taounat (TN)	140.6	27%	209	1.5	900.9	13.7
	Taza (TZ)	231.8	18%	296.4	1.3	471.9	12.4
	Total	464.1	30%	662.1	1.5	680.0	13.6
Zone 4	Kenitra (KT)	105.0	22%	204	2.1	748.6	15.4

Dans un premier temps, à l'échelle des zones, les séries temporelles des indices de sécheresse dérivés de la télédétection (VCI, TCI, VHI, et SMCI), dont la moyenne a été calculée pendant la saison de croissance des céréales (de novembre à mai), sont superposées aux anomalies de rendement. Les résultats montrent que la variation temporelle des indices est en accord avec la variabilité interannuelle des rendements et les grandes pertes du rendement durant les saisons 2006-2007 et 2015-2016 sont marquantes. De même, la saison céréalière exceptionnelle de 2014-2015 est bien reflétée par ces indices. Dans un 2^{ème} temps, une analyse de corrélation a été menée à l'échelle provinciale pour évaluer les relations entre les indices de sécheresse et le rendement céréalier à des échelles du temps mensuels. Les liens principaux entre rendements et indices de sécheresse sont résumés dans le tableau. Les résultats montrent que le VCI et le LAI dérivé du LDAS sont fortement liés au rendement pour toutes les provinces ($R = 0.94$ pour

la province de Khemisset) autour de stade de développement maximal des céréales (mars-avril), tandis qu'un lien élevé est observé pour le TCI pendant la phase de développement plus tôt dans la saison en janvier-février ($R = 0.83$ pour la province de Beni Mellal). Concernant, les indices liés à l'humidité du sol des couches superficielle (SMCI, SWI), ils sont corrélés avec le rendement très tôt dans la saison autour de l'émergence (Décembre). Les résultats démontrent aussi la valeur ajoutée de l'utilisation d'un LDAS par rapport à l'utilisation des produits de télédétection seuls, notamment en ce qui concerne l'humidité du sol dans la zone racinaire, considérée comme une variable clé pour le suivi de la sécheresse agricole et pour la production des céréales, qui n'est pas directement observable par la télédétection. L'échelle de temps de l'intégration de ces indices est également discutée dans notre étude. En intégrant les indices sur les principaux stades phénologiques du blé au lieu de l'échelle mensuelle, la corrélation entre les indices et le rendement augmente jusqu'à 14%.

Tableau 9: Synthèse des liens entre les indices de sécheresse dérivés de la télédétection, les sorties du LDAS et les rendements céréaliers pendant la saison agricole (++ corrélation significative, +++ corrélation hautement significative)

		Emergence	Tallage	Elongation	Epiaison	Anthèse
		Décembre	Janvier	Février	Mars	Avril
Indices de sécheresse dérivés de la télédétection	VCI			++	+++	++
	TCI		++	+++		
	VHI		++	++	++	++
	SMCI	+++	++			
	SWI10	+++				
	SWI40	++	+++			
	SWI60	++	++	+++		
les sorties du LDAS	LAI		++	++	+++	
	Tr		++	++	+++	
	Ev	+++	++			
	WG2	+++	++			
	WG4	++	+++			
	WG6	++	+++			
	WG8	++	+++			

III) Article

Article

Linkages between Rainfed Cereal Production and Agricultural Drought through Remote Sensing Indices and a Land Data Assimilation System: A Case Study in Morocco

El houssaine Bouras ^{1,2,*}, Lionel Jarlan ² , Salah Er-Raki ^{1,3} , Clément Albergel ^{4,†} , Bastien Richard ⁵, Riad Balaghi ⁶ and Saïd Khabba ^{3,7} 

¹ ProcEDE, Department of Applied Physique, Faculty of Sciences and Technologies, Cadi Ayyad University, Marrakech 40000, Morocco; s.erraki@uca.ma

² CESBIO, University of Toulouse, IRD/CNRS/UPS/CNES, 31400 Toulouse, France; lionel.jarlan@ird.fr

³ Center for Remote Sensing Applications (CRSA), University Mohammed VI Polytechnic (UM6P), Benguerir 43150, Morocco; khabba@uca.ma

⁴ CNRM UMR 3589, Météo-France/CNRS, 75016 Toulouse, France; clement.albergel@esa.int

⁵ G-EAU, University Montpellier, AgroParisTech, CIRAD, IRD, INRAE, Institut Agro, 34000 Montpellier, France; bastien.richard@irstea.fr

⁶ National Institute for Agronomic Research (INRA), Rabat 10000, Morocco; Riad.balaghi@inra.ma

⁷ LMFE, Department of Physics, Faculty of Sciences Semlalia, Cadi Ayyad University, Marrakech 40000, Morocco

* Correspondence: elhoussaine.bouras@ced.uca.ma; Tel.: +212-(0)-5-2443-3404 or +212-(0)-6-0136-8700

† Now at European Space Agency Climate Office, ECSAT, Harwell Campus, Oxfordshire, Didcot OX11 0FD, UK.

Received: 20 October 2020; Accepted: 27 November 2020; Published: 8 December 2020



Abstract: In Morocco, cereal production shows high interannual variability due to uncertain rainfall and recurrent drought periods. Considering the socioeconomic importance of cereal for the country, there is a serious need to characterize the impact of drought on cereal yields. In this study, drought is assessed through (1) indices derived from remote sensing data (the vegetation condition index (VCI), temperature condition index (TCI), vegetation health index (VHI), soil moisture condition index (SMCI) and soil water index for different soil layers (SWI)) and (2) key land surface variables (Leaf Area Index (LAI), soil moisture (SM) at different depths, soil evaporation and plant transpiration) from a Land Data Assimilation System (LDAS) over 2000–2017. A lagged correlation analysis was conducted to assess the relationships between the drought indices and cereal yield at monthly time scales. The VCI and LAI around the heading stage (March–April) are highly linked to yield for all provinces ($R = 0.94$ for the Khemisset province), while a high link for TCI occurs during the development stage in January–February ($R = 0.83$ for the Beni Mellal province). Interestingly, indices related to soil moisture in the superficial soil layer are correlated with yield earlier in the season around the emergence stage (December). The results demonstrate the clear added value of using an LDAS compared with using a remote sensing product alone, particularly concerning the soil moisture in the root-zone, considered a key variable for yield production, that is not directly observable from space. The time scale of integration is also discussed. By integrating the indices on the main phenological stages of wheat using a dynamic threshold approach instead of the monthly time scale, the correlation between indices and yield increased by up to 14%. In addition, the contributions of VCI and TCI to VHI were optimized by using yield anomalies as proxies for drought. This study opens perspectives for the development of drought early warning systems in Morocco and over North Africa, as well as for seasonal crop yield forecasting.

Keywords: agricultural drought; cereal yield; remote sensing; land data assimilation systems; semiarid region

1. Introduction

Agronomical drought, which is mainly caused by a deficit in water supply, is a major natural hazard to rainfed agricultural systems [1–3], causing up to 80% of yield losses worldwide [4]. In the semiarid regions of the south Mediterranean, 80% of arable lands are rainfed, enhancing the vulnerability of agriculture to drought events [5–7]. As a consequence, agricultural production, and cereal yields in particular, which are critical for food security [8], shows a very high interannual variability in these regions owing to uncertain rainfall and drought periods [9–11]. Drought frequencies have already risen in the Mediterranean area. In Morocco, the frequency changed from one event every 10 years at the beginning of the 20th century to 5 or 6 events every 10 years at the beginning of the 21st century [12,13]. In addition, climate change is expected to increase the frequency and severity of drought in Europe and Mediterranean countries [14–18]. For some countries such as Morocco, national cereal production does not cover the country's needs due to low productivity, even during sufficiently rainy years with a coverage rate for the country's needs ranging between 30 and 80% [19]. The first step towards drought mitigation is drought monitoring; thus, it is highly important to develop an early warning system for drought monitoring and to evaluate its linkages with yields regarding the dramatic socioeconomic consequences of a failure of cereal production [20].

Wilhite and Glantz (1985) classified drought by characterizing the cascade of impacts of a rainfall deficit (i.e., the meteorological drought) on water resources (hydrological drought), on the agricultural sector (agricultural drought) and on the country's economy (socioeconomic drought) [21]. Agricultural drought is related to a persistent lack of moisture in the root zone [22], affecting crop health and production. Thus, assessments of agricultural droughts should rely on a complex combination of variables related to water inputs, climate factors impacting the atmospheric evaporative demand, such as temperature or incoming radiation, soil factors and factors related to crops such as its leaf area index [23]. In addition, the timing of drought occurrence during the crop season, potentially associated with temperature and biotic stresses, is of prime importance to determine the impact on yields [24], because even a short water deficit occurs during the most sensitive phenological stages of cereals can drastically decrease production [25,26]. Thus, an early warning system for drought in terms of anticipating wheat production should also be able to deliver timely and accurate information at specific growth stages throughout the crop season.

The first systems for drought monitoring were mainly based directly on rainfall amount [1] or on related indices, such as the Standardized Precipitation Index (SPI; McKee et al., 1993 [27]). Considering the complex features of agricultural drought already highlighted, several authors considered other variables for drought monitoring [10,28–30]. In particular, air temperature is both a governing variable in the atmospheric evaporative demand and crop evapotranspiration and a limiting factor of wheat production when strong anomalies (negative during the early stage of winter or positive around the heading stages) negatively impact yield [31,32]. The same reason also motivated the development of an extended SPI called the Standardized Precipitation Evapotranspiration Index (SPEI; Vicente-Serrano et al., 2010 [33]) to consider the effect of atmospheric evaporative demand. Nevertheless, considering that the lack of station data is often an obstacle in semiarid areas, several drought indicators derived from remote sensing observations, which are now freely available on a global scale, were quickly considered to monitor the severity and intensity of drought conditions [34–37]. Drought might affect vegetation and soil properties, such as vegetation biomass and development, canopy and soil temperature and soil moisture [38]. Remote sensing can provide information on vegetation vigor thanks to vegetation indices acquired in the optical domain, such as the normalized difference vegetation index (NDVI), land surface temperature (LST) derived from

thermal infrared data and soil moisture (SM) retrieved from active or passive microwave observations. Most of the remote sensing drought indices are based on normalized anomalies of these products. For instance, Kogan (1995) developed the vegetation condition index (VCI) based on NDVI and the temperature conditions index (TCI) based on LST, which have been shown to be two useful tools for monitoring drought on regional or global scales [39]. VCI was also shown to be strongly correlated with crop yield [40–43]. In addition, some studies found that a joint consideration of VCI and TCI together through the vegetation health index (VHI; computed as a weighted sum of TCI and VCI) was better suited for drought monitoring than considering both indices separately [39,42,44]. As there is no a priori knowledge of the actual contribution of the chlorophyll tissues and of the temperature conditions for the vegetation health in a given region, the value of α as proposed by Kogan (1995) was 0.7, as VCI already considers the temperature effect on vegetation, but, more recently, a value of 0.5 was used by several authors, including Kogan (1997). Several recent studies questioned the value of 0.5 and proposed some new approaches for optimizing the values of this index [45–47]. In addition to temperature and vegetation conditions, some indices related to the SM conditions have also been proposed, as several surface SM products, mainly derived from microwave sensors with several dedicated missions (Soil Moisture and Ocean Salinity (SMOS), Advanced Microwave Scanning Radiometer (AMSR), and Soil Moisture Active Passive (SMAP)), are now available. The soil moisture condition index (SMCI) was developed by Zhang and Jia (2013) to describe drought conditions from a soil moisture perspective, which does not consider meteorological factors [48]. Table 1 displays a non-exhaustive list of studies based on different drought indices.

Nonetheless, the shallow sensing depth and the uncertain accuracy of currently available satellite SM retrievals fostered the integration of land surface models and surface SM observations or the leaf area index from satellites using data assimilation techniques to obtain more accurate root-zone SM estimates. Data assimilation techniques allow for the integration of spatially and temporally observed information into land surface models (LSMs) in a coherent way [49,50]. The Land Data Assimilation System (LDAS) refers to the framework where LSMs are driven by and/or ingest such observations, generating enhanced estimates of the land surface variables (LSVs) [51]. Recently, several operational land data assimilation systems (LDAS) have emerged, such as the coupled land vegetation LDAS (CLVLDAS, [52]) and the famine early warning systems network (FEWSNET) LDAS (FLDAS, [53]). SM data assimilation has also been actively investigated as a tool for improving operational drought monitoring [51,54,55]. Previous studies have demonstrated that the assimilation of surface SM retrievals can improve the estimation of root-zone SM by a land surface model [50,54,56–61]. In particular, for agricultural drought monitoring, Bolten and Crow (2012) described the benefit of assimilating surface SM retrievals from the Advanced Microwave Scanning Radiometer for Earth Observing System (EOS; AMSR-E) into the modified Palmer SM model developed by the U.S. Department of Agriculture (USDA) [62]. In addition, they demonstrated that the assimilation of AMSR-E surface SM retrievals substantially improves the performance of a global drought monitoring system, especially for instrumented areas of the world where high-quality rainfall observations are unavailable. Additionally, Albergel et al. (2018) noted that the LDAS-monde (the land data assimilation system developed in the research department of the French meteorological service) is better able to characterize agricultural droughts than an open-loop counterpart (i.e., a model without any assimilation of satellite-derived measurements) [63].

Within this context, the main objective of this work is to evaluate the impact of agricultural drought on cereal yields in Morocco. Drought is assessed with extensively used remote sensing indices as well as outputs of an LDAS.

Table 1. Summary of remote sensing drought indices.

Authors	Index Name	Data	Region	Period
Kogan, 1995 [64]	Vegetation condition index (VCI)	NDVI AVHRR	United States	1985–1990
Kogan, 1995 [64]	Temperature condition index (TCI)	bright temperature (BT) AVHRR	United States	1985–1990
Kogan, 1997 [44]	Vegetation health index (VHI)	NDVI AVHRR bright temperature (BT) AVHRR	United States	1990–1994
Gao, 1996 [65]	Normalized difference waterindex (NDWI)	AVIRIS	United States	1995
Wang et al., 2001 [66]	Temperature vegetation condition index (TVCI)	AVHRR	Northwest China	2000
Peters et al., 2002 [67]	Standardized vegetation index (SVI)	NDVI AVHRR	United States	1989–2000
Gu et al., 2007 [68]	normalized difference drought index (NDDI)	MODIS	United States	2001–2005
Wang and Qu, 2007 [69]	Normalized multiband drought index (NMDI)	MODIS	United States	2001–2005
Ghulam et al., 2008 [70]	Vegetation water stress index (VWSI)	LANDSAT	China	2001–2004
Rhee et al., 2010 [71]	Precipitation condition index (PCI)	TRMM	United States	2000–2009
Zhang and Jia, 2013 [48]	Soil moisture condition index (SMCI)	AMSR-E Soil moisture	China	2003–2010
Anderson et al., 2016 [72]	Evaporative stress index (ESI)	MODIS LAI; MODIS LST; MERRA; TRMM	Brazil	2003–2013
Zhang et al., 2017a [73]	Process-based accumulated drought index (PADI)	GPCP precipitation; GLDAS SM; AVHRR NDVI;	China	2000–2011
Jiao et al., 2019 [74]	Geographically independent integrated drought index (GIIDI)	MODISL ST; AMSR-E; TRMM; SM;	China	2002–2011
Le Page and Zribi, 2019 [36]	Temperature anomaly index (TAI) Vegetation anomaly index (VAI) Moisture anomaly index (MAI)	MODIS LST; MODIS NDVI; ASCAT SWI	Northwest Africa	2007–2017
Hu et al., 2020 [75]	temperature rise index (TRI)	(MTSAT-2)	Australia	2010–2014

2. Materials and Methods

2.1. Study Area

Morocco is located at the southern edge of the mid-latitude storm track with a semiarid climate [76] (Figure 1). The climate is influenced by the Atlantic Ocean, the Mediterranean Sea and the Sahara Desert, together with the very steep orography in the Atlas region [77]. Most of the precipitation falls during winter and spring, which is from the beginning of November until the end of April [13]. Winter cereals occupy more than 55% of the country's agricultural areas; common and durum wheat account for approximately 75% of these cereals (MAPMDREF, 2019). This wheat is cultivated both in rainfed and irrigated fields, depending on access to water supply and climate conditions. Wheat production is mainly rainfed and represents more than 80% of total cereal production [78]. Cereals can be sown as early as November 1st if significant rainfall occurs, while a persistent drought at this time can delay seeding until 15 January. Late seeding is often associated with production loss through a decrease in wheat crop areas. Indeed, many farmers are accustomed to waiting for regular rainfall events to seed

at the beginning of the season. Harvests occur in June–July of the following calendar year, starting in the south and steadily progressing towards the north and mountainous areas.




Figure 1. Maps of the 15 most productive provinces considered in the study in terms of cereal yields and results of the four classifications (see text). The agricultural areas identified as rainfed cereal are shaded.

2.2. Data

The dataset is composed of the remote sensing drought index and the output of an LDAS described below and of the cereal yield statistics on the agricultural provincial scale. In addition, cumulative rainfall amounts and the SPEI, which is considered to be a reference for drought monitoring in several studies [79–82], were extracted from ERA5 reanalysis surface variables.

2.2.1. ERA5 Data and the SPEI

Data used for computing SPEI and rainfall amounts were downloaded from the ERA5 database, which is the fifth generation of European reanalyses produced by the ECMWF and a key element of the EU-funded Copernicus Climate Change Service (C3S) (<https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5>). Important changes in ERA5 relative to the ERA-interim's former ECMWF atmospheric reanalysis include (i) a higher spatial and temporal resolution, as well as (ii) a more recent version of the ECMWF Earth system model physics and data assimilation system [83]. In this study, the SPEI was computed using the SPEI R package version 1.7 [84], and reference evapotranspiration (ET₀) was computed using the FAO Penman-Monteith (FAO-PM) equation [85]. However, there is some debate over the use of ET₀ or actual evapotranspiration (ET_a) in calculating the SPEI. Begueria et al. (2014) showed the advantages of using ET₀ instead of ET_a for calculating the SPEI: inclusion of ET₀ in the SPEI formulation is valid for both humid and arid climates, producing reliable estimations of drought severity [79]. In addition, the SPEI was computed on several time scales (SPEI 1, 3, 6, and 12 months) to consider the effect of an accumulating precipitation deficit and high evapotranspiration, which are critical parameters for crop growth.

In addition, Figure 2 shows the cumulative rainfall during the crop season (from November to May) derived from ERA5 data. The monthly mean temperature is displayed in Figure A1 in Appendix A. There are high spatial variations in rainfall and temperature, as noticed in previous studies [24]. Higher amounts of rainfall are observed in the northern part of the country: the cumulative rainfall reached more than 900 mm in the Taounat province. In contrast, the center of the country is characterized by low rainfall: Kelaa des Sraghna province exhibited approximately 340 mm less rainfall than Taounat (approximately 63%). Concerning temperature, areas located at high elevation (high Atlas, middle Atlas and Rif Mountains) are characterized by low temperatures compared with the other regions. In February, the mean air temperature in Khenifra and Haouz is approximately 6 °C, while it reached 15 °C in the Safi province, which is located along the Atlantic Ocean.

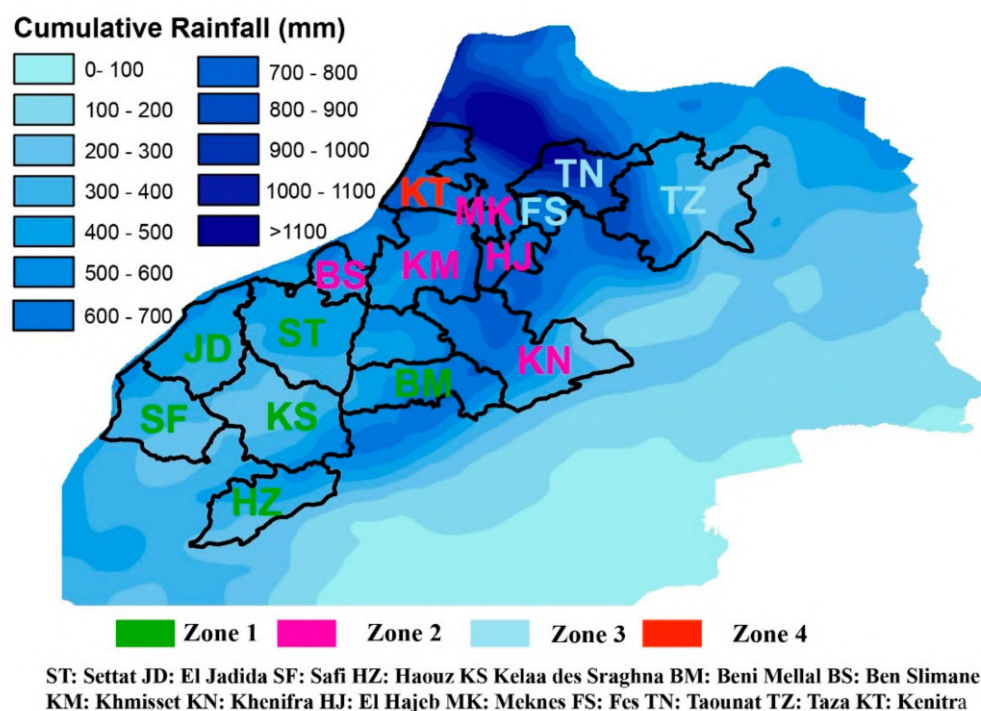


Figure 2. Average rainfall derived from ERA5 (2000–2017) accumulated during the cereal crop season (from November to May).

2.2.2. Yield Data

The main types of cropped cereals in Morocco are bread wheat, barley and durum wheat. Rainfed wheat yield data were acquired from the Economic Services of the Ministry of Agriculture. The dataset contains the crop production and harvested areas for 14 crop seasons between 2000 and 2017 on the administrative province scale (2001–2002, 2004–2005 and 2005–2006 were not available). These data are compiled from subprovince sample surveys and released in official documents as provincial averages. The annual values of rainfed cereal yields in tons per hectare ($\text{t}\cdot\text{ha}^{-1}$) were calculated as the ratio between crop production (tons) and harvested area (hectares) for each province. In this study, focus is placed on the main cereal crop regions in Morocco. For this objective, the 15 most productive provinces (more than 90% of national production) were selected for analysis. Table 2 provides the average cropped areas, ratio between cropped area and total province area in percentage, average total production and average yields during the study period, coefficient of variation (standard deviation divided by the average, in percentage), cumulative total rainfall, and average air temperature during the crop season. Cereal yields are low compared with potential yields in all provinces, which can reach 7.5 to 8.0 $\text{t}\cdot\text{ha}^{-1}$ in rainfed areas when adequate technologies and practices are used [86,87]. This low yield is attributed to water stress, heat stress and poor soil, as well as to traditional agricultural practices that may lead to inappropriate crop rotation, insufficient nitrogen and fertilization and late sowing [88,89].

To enable interpretation of the results, groups of provinces with similar cereal yield interannual variability are identified through a classification using the kmeans based on the correlative distance ($d_c = \sqrt{\frac{1-r}{2}}$ with r being the Pearson correlation coefficient between two time series [90]). d_c was preferred to classic Euclidian or Manhattan distances, as time series with similar interannual patterns are sought.

The classification results are mapped in Figure 1. Time series corresponding to the standardized anomalies of yields for each group of provinces are presented in Figure 3. Four groups of provinces are isolated:

- The first group named “Zone 1” covers the southern province of the study area: Settat, El Jadida, Safi, Kelaa des Sraghnas, Haouz and Beni Mellal provinces. Because of the strong north-south rainfall gradient in Morocco, the group 1 area is characterized by low rainfall and high temperature and is consequently considered to be a less productive area. Please note that the Safi province receives a large amount of rainfall (355 mm from November to May on average over the study period using the ERA5 dataset) as it is located along the Atlantic Ocean. However, yields are low, which may be due to poor soils. In addition, a large rainfed area in the Beni Mellal province is located in the foothills of the Atlas Mountains, which has colder conditions than in the plains; yields are also quite low (1.5 t/ha on average over 2000–2017).
- The second group named “Zone 2” covers the Ben Slimane, Khenifra, El Hajeb, Khemisset and Meknes provinces. They are located in the center of the study region with relatively high rainfall conditions (approximately 600 mm on average during the crop season), showing higher yields than those for group 1, with an average yield of approximately 1.9 t/ha.
- The third group named “Zone 3” covers the provinces of Taza, Taounat, and Fes. Zone 3 is located north of Morocco, and it is characterized by higher rainfall compared with the other groups (approximately 680 mm). The average yield in this zone is approximately 1.5 t/ha.
- The last group named “Zone 4” includes only the province of Kenitra. This province is located in the northeastern part of the country. Zone 4 is dominated by irrigated areas where cereals represent more than 60% of crops, including the Gharb plain. Although rainfed yields are only considered in this study, it is likely that any rainfed fields neighboring irrigated areas benefit from the supplementary water supply. The combined high rainfall amount and high coastal air moisture may justify the high yield observed in this province compared with the other zones.

Table 2. Cereal yields and production statistics, average rainfall and air temperature for each province. Colors correspond to the four groups of agricultural provinces (see text).

	Province	Cropped Areas (1000 ha)	Ratio of Cropped Area (%)	Total Production (1000 t)	Yield (t/ha)	Variation Coefficient (SD/mean %)	Cumulative Rainfall (mm)	Temperature (°C)
Zone 1	Settat (ST)	414.8	43%	540.8	1.3	64.9%	420.3	15.1
	El Jadida (JD)	330.4	47%	613.9	1.9	39.4%	419.5	15.6
	Beni Mellal (BM)	173.7	26%	252.4	1.5	57.8%	555.1	11.8
	Kelaa Sraghna (KS)	260.0	37%	272.3	1.0	59.9%	340	15.9
	Safi (SF)	125.7	13%	90	0.7	72.1%	355.2	15.2
	Haouz (HZ)	90.3	15%	78.2	0.9	65.9%	381.1	9.9
	Total	1394.9	30%	1847.6	1.2	60.0%	411.9	13.9
Zone 2	Ben Slimane (BS)	83.1	34%	156.4	1.9	50.8%	518	14.7
	Khemisset (KM)	328.3	40%	490.2	1.5	50.2%	589.9	13.7
	Meknes (MK)	80.8	45%	181	2.2	48.9%	671.7	14.6
	El Hajeb (HJ)	70.4	28%	148.5	2.1	31.9%	688.7	12.2
	Khenifra (KN)	184.0	16%	338.7	1.8	40.9%	525.6	9.7
	Total	746.6	33%	1314.8	1.9	44.5%	598.78	12.98
Zone 3	Fes (FS)	91.8	45%	156.7	1.7	51.7%	667.1	14.8
	Taounat (TN)	140.6	27%	209	1.5	42.1%	900.9	13.7
	Taza (TZ)	231.8	18%	296.4	1.3	39.6%	471.9	12.4
	Total	464.1	30%	662.1	1.5	44.5%	680.0	13.6
Zone 4	Kenitra (KT)	105.0	22%	204	2.1	31.7%	748.6	15.4

2.2.3. Remote Sensing-Based Drought Indices

In this study, five satellite-based drought indices were selected, and their potentials to detect agricultural drought were assessed. These indices are based on the normalized anomalies of NDVI, LST and SM. The dataset characteristics are summarized in Table 3.

The Vegetation Condition Index (VCI)

Changes in the NDVI index related to weather conditions (precipitation, temperature and wind) are lower than those related to the ecosystem (climate, soil, topography and vegetation type) for agricultural regions. Thus, drought impacts on crops are difficult to detect directly from NDVI data [39,64,91]. Therefore, Kogan (1995) developed the VCI to control local differences in ecosystem productivity [92]:

$$VCI_t = \frac{NDVI_t - NDVI_{min}}{NDVI_{max} - NDVI_{min}} * 100 \quad (1)$$

$NDVI_{min}$ and $NDVI_{max}$ are the maximum and minimum values, respectively, at each desired time step over the study period, and $NDVI_t$ represents the NDVI value in month “t”. Thus, the VCI is a pixel-based normalization of the NDVI in which the short-term climate signal of the NDVI was filtered by separating it from the long-term ecological signal. In this study, the temporal composite series of MODIS NDVI (MOD13A2 collection 6; available at (<https://lpdaac.usgs.gov/>)) from 2000 to 2017 with a spatial resolution of 1 km are used. The NDVI value is based on the maximum value composite method (MVC) [93] using a sliding 16-day period.

The Temperature Condition Index (TCI)

The TCI is based on LST. For the region where incoming radiation is not limiting vegetation growth, LST is related to the plant water stress when water is limited, as a higher LST should be related to a lack of available water for evaporation and transpiration and to more energy being used for sensible heat flux. Thus, the index is related to changes in vegetation health due to thermal effects. The TCI is computed as follows (Kogan, 1995):

$$TCI_t = \frac{LST_{max} - LST_t}{LST_{max} - LST_{min}} * 100 \quad (2)$$

LST_{max} and LST_{min} are the maximum and minimum values, respectively, at each desired time step over the study period, and LST_t represents the LST in month “t”. In contrast with NDVI, high LST during the growing season indicates unfavorable or drought conditions, while low LST indicates generally favorable conditions [39]. Therefore, the low TCI value indicates an unfavorable climatic condition (high temperature), while higher values mainly reflect favorable conditions (low temperature). The daily 1 km resolution LST (version 6) MOD11A1 product available through the U.S. Land Processes Distributed Active Archive Center (LP DAAC, <https://lpdaac.usgs.gov/>) from 2000 to 2017 is used in this study. The LST is derived from the generalized split-window algorithm [94].

The Vegetation Health Index (VHI)

To combine the weather and thermal condition impacts on vegetation response, several authors proposed the VHI as a combination of VCI and TCI:

$$VHI_t = \alpha VCI_t + (1 - \alpha) TCI_t \quad (3)$$

Parameter α describes the weights of VCI and TCI in VHI, and the α value ranges between 0 and 1. A value of $\alpha = 0.5$ is considered in this study following Kogan (1997), and part of the discussion is dedicated to the assessment of optimal α values.

The Soil Water Index (SWI)

The SWI is related to the SM content. It is not considered to be a drought index; however, when integrated over time, the SWI is useful for monitoring the variation in the SM in rainfed agricultural areas. In particular, [95] highlighted the importance of SM for drought monitoring. However, SWI from the surface layer that can be inferred from microwave active (radar) and passive sensors has been shown to be well correlated with vertically integrated SM estimates derived from both in situ observations and water balance modeling [96–98]. Lagged correlations have also been highlighted with vegetation growth conditions on a monthly time scale [99].

The SWI algorithm is based on a two-layer infiltration model describing the relationship between the surface SM and vertical SM profile as a function of time [100]. The SWI is formulated as follows:

$$SWI(t_n) = \frac{\sum_{i=1}^n SSM(t_i) e^{-\frac{t_n-t_i}{T}}}{\sum_{i=1}^n e^{-\frac{t_n-t_i}{T}}} \quad (4)$$

where for $t_i \leq t_n$, t_n is the observation time of the current measurement and t_i represents the observation times of the previous measurements (both given in Julian days). This model assumes that the water content of the deeper layer is controlled by the past moisture conditions in the surface layer and thus the precipitation history [96]. The parameter T , called the characteristic time length, represents the time scale of SM variations in units of time $T = L/C$, where L is the depth of the reservoir layer and C is an area-representative pseudodiffusivity constant [101]. An increased T value is either due to an increase in reservoir depth or a decreased pseudodiffusivity coefficient, which means that, for a fixed pseudodiffusivity constant, an increased T value represents a deeper soil layer [102], meaning that a high (low) T describes a deeper (shallower) soil layer [97]. Giving a general rule on how to translate a given T value to a certain soil depth is currently not possible since it strongly depends on the application and soil composition of the area of interest [101]. Ceballos et al. (2005) found that, for their study region in Spain, the best T -values were 40, 50 and 60 for layer depths of 0–25, 0–100 and 50–100 cm, respectively [96].

The surface SM product is retrieved from the C-band ASCAT radar onboard the METOP satellites [103]. The product is distributed by the Copernicus Global Land Service (<http://land.copernicus.eu/global/products/swi>) with a daily time step and a 12.5 km resolution.

The Soil Moisture Condition Index (SMCI)

Agricultural drought is characterized by low SM levels that negatively affect agricultural production [104]. The SMCI [48] is a normalization of soil moisture values relative to the absolute maximum (SM_{max}) and the absolute minimum (SM_{min}) of the time series to obtain normalized SM ranging from 0 (very dry, unfavorable conditions) to 100 (very wet, favorable conditions). SMCI can describe drought conditions from a soil moisture perspective without considering meteorological factors, such as precipitation.

$$SMCI_t = \frac{SM_t - SM_{min}}{SM_{max} - SM_{min}} * 100 \quad (5)$$

where SM_{min} and SM_{max} are the historical minimum and maximum values, respectively, at each desired time step over the study period, and SM_t is the SM in month t .

The data used for computing SMCI are derived from the European Space Agency Climate Change Initiative (European Space Agency (ESA) CCI) SM COMBINED version 04.2 (<https://www.esa-soilmoisture-cci.org/>), which merges SM observations from seven microwave radiometers (SMMR, SSM/I, TMI, ASMR-E, WindSat, AMSR2, SMOS) and four scatterometers (ERS-1 and 2 AMI and MetOp-A and B ASCAT) into a harmonious dataset [105]. This product had a daily temporal resolution and a 25 km spatial resolution.

2.2.4. Land Data Assimilation System (LDAS) Outputs

Within the SURFEX modeling platform of Météo-France [106], the LDAS [63,107,108] developed in the research department of Météo-France, the CNRM (Centre National de Recherches Météorologiques) permits integration of satellite products (leaf area index (LAI) and soil moisture (SM)) into the ISBA (Interaction between Soil Biosphere and Atmosphere) LSM [109,110] using a data assimilation scheme. The satellite product used in LDAS is the GEOV1 LAI, which is produced by the European Copernicus Global Land Service project (<http://land.copernicus.eu/global/>). The LAI observations are retrieved from the SPOTVGT and PROBA-V (from 1999 to present) with a 1 km resolution and a temporal frequency of 10 days. Surface soil moisture was obtained from ESA CCI SM COMBINED (v4.7) as described above.

The algorithm of this data assimilation system permits the trajectory of the ISBA model to be optimally corrected each time an observation is available. Indeed, unlike the approaches conventionally used in crop models or carbon flux models, phenology in the CO₂-responsive version of ISBA, ISBA-A-gs [110,111] is not constrained by degree-day submodels. The dynamic evolution of the vegetation biomass and LAI variables are entirely controlled by photosynthesis in response to atmospheric and climate conditions. Photosynthesis enables vegetation growth resulting from CO₂ uptake and responds directly or indirectly to all atmospheric variables, as well as SM and canopy density.

The outputs of LDAS used in this study are the LAI, plant transpiration (Tr), soil evaporation (E), evapotranspiration (ETR) and SM at different depths: WG2 (0 to 4 cm), WG4 (10 to 20 cm), WG6 (40 to 60 cm) and WG8 (80 to 100 cm). In addition, the same variables derived from the open-loop run of the ISBA-A-gs model (without data assimilation) are considered to analyze the added value of data assimilation with regard to the model predictions alone. For all variables, a standardized time series anomaly was computed based on Equation (6).

$$Y_t = \frac{X_t - \bar{X}}{\sigma} \quad (6)$$

where Y_t is the standardized anomaly, X_t is the actual value of the variable (LAI, Tr...) for month t , and \bar{X} and σ are the mean and standard deviation of the time series.

Table 3. Summary of the dataset used in this study.

Product	Temporal Resolution	Spatial Resolution	Variable	Source
MODIS (MOD13A2)	16-Day	1 km	NDVI	https://lpdaac.usgs.gov/
MODIS (MOD11A1)	Daily	1 km	LST	https://lpdaac.usgs.gov/
ASCAT SWI	Daily	12.5 km	SWI10, SWI40 SWI60	http://land.copernicus.eu/global/products/swi
ESA CCI SM COMBINED	Daily	SSM	SSM	https://www.esa-soilmoisture-cci.org/
ERA5	Daily	30 km	Rainfall, Air temperature, Relative humidity, Wind speed, Solar radiation	https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5
LDAS	Daily	25 km	Leaf area index, Evaporation, Transpiration, Soil moisture	

2.3. Methods

2.3.1. Identification of Rainfed Cereal Areas

The identification of areas where rainfed cereal fields are cropped is important to assess the linkage between remote sensing indices and cereal production because rainfed crops are more sensitive to drought [2,3]. Genovese et al. (2001) found that the application of a cropland mask to select the NDVI value corresponding to wheat in a crop yield model significantly improved the accuracy of crop yield forecasts [112]. For this reason, the identification of rainfed cereal areas is carried out using a two-step approach:

- (a) ECOCLIMAP-II land cover [113,114] developed by CNRM at a 1 km resolution (<https://opensource.umr-cnrm.fr/projects/ecoclimap/wiki>) was used to select the pixels corresponding to C3 crops, including both irrigated and rainfed fields.
- (b) The land cover map at a 300 m resolution provided by the Climate Change Initiative land cover project of the ESA (<https://www.esa-landcover-cci.org/>) was used to distinguish between irrigated and rainfed crops.

The rainfed cereal areas were identified through the combination of ESA land cover and ECOCLIMAP-II.

2.3.2. Identification of Major Phenological Stage

The linkages between drought variables, including remote sensing indices and LDAS outputs, are first evaluated at the seasonal and monthly time scales, but the use of a time period that is in close agreement with crop functioning is discussed. For this objective, detection of the phenological scale is described in this section. Indeed, phenology detection is of prime importance for crop growth and yield [115]. A dynamic threshold method was used to detect phenology in this study following Bradley et al. (2007), Li et al. (2014) and Viña et al. (2004) [116–118]. As a preliminary step, the NDVI data were smoothed using the Savitzky–Golay filter to reduce noise. Then, the three main phenological stages [115] that can be easily determined from NDVI time series were detected from the smoothed NDVI curves as follows (see Figure A2 for an example of the smoothed NDVI profile, Settat province, season 2016/2017):

- Emergence stage: The emergence stage starts when the NDVI reaches 30% of the difference between NDVI max and NDVI min.
- Development stage: A drastic increase in the NDVI is observed at the start of the season. The development stage was defined as starting when the NDVI value reached 30% of the difference between the maximum and minimum of the NDVI values. The stage ends at the heading stage (see below).
- Heading stage: The heading stage starts when the NDVI reaches its maximum value and ends at the harvesting stage.

2.3.3. Correlation Analysis between Drought Indices and Rainfed Cereal Yield

As reported by previous studies [2,72,73,119–121], a correlation analysis between the indices and cereal yield was performed to investigate the link between drought indices and crop production. Pearson's correlation coefficient (R) between all indices and rainfed cereal yields was calculated on a monthly scale during the growing season, from November to May for the most productive province in Morocco for 2000–2017 using the following equation (Equation (7)). Pearson's correlation coefficient

(R) represents the degree and direction of the linear regression between two continuous variables that are measured at the equal interval.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

where x_i and y_i represent drought indices and the value of rainfed cereal yields, respectively, n is the number of samples, and \bar{x} and \bar{y} are the average values of x_i and y_i , respectively.

3. Results

3.1. Satellite Drought Indices and Yield Time Series

3.1.1. Seasonal Scale

The time series of remote sensing drought indices (VCI, TCI, VHI, and SMCI) averaged during the cereal growing season from November to May are superimposed with the yield anomalies and the standardized anomalies of the cumulative rainfall amount for each agricultural zone in Figure 3. Correlations between rainfall, drought indices and yields are reported in Table 4.

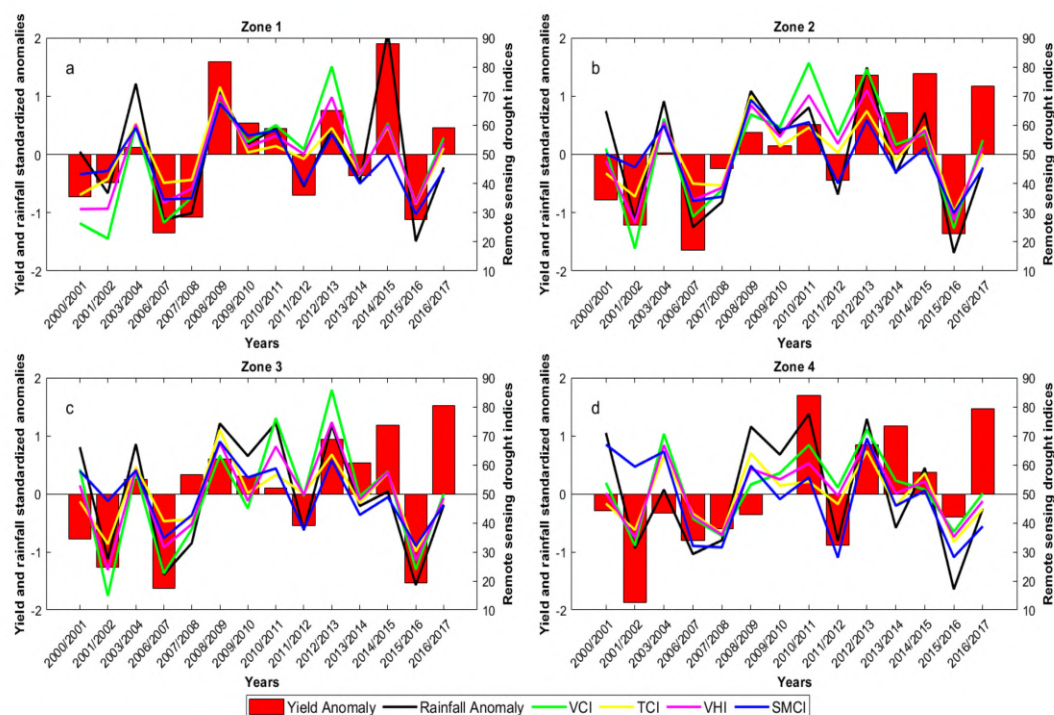


Figure 3. Temporal variations in the drought index and standardized yield and the rainfall anomalies for zone 1 (a), zone 2 (b), zone 3 (c) and zone 4 (d) during the study period from 2000 to 2017.

The seasonal averages of drought indices and standardized anomalies of rainfall capture the interannual variability in yields well, particularly for zones 1 to 3, as most of the correlation coefficients are significant at the 99% level. The major crop failures of the 2006–2007 and 2015–2016 seasons are prominent in the first three zones. Likewise, the exceptional cereal season of 2014–2015 is well reflected by both the yield and drought index time series. Indeed, 2014–2015 was characterized by above-normal rainfall of approximately 18%, which was accompanied by a steady distribution of events throughout the season (MAPMDREF, 2015). The specific behavior of zone 4 is probably related

to the presence of the largest irrigated area of Morocco (the Gharb region is more than 105,000 hectares) and/or high coastal air moisture. Indeed, the crop mask used to identify rainfed cereal suffers from uncertainties, and irrigated cereal may also be considered in the analysis. This finding may explain the significantly lower correlation coefficient with yields than those for the first 3 zones, as reported in Table 4. In addition to the low spatial resolution of some products, the correlation of yields and SMCI is particularly low ($R = 0.14$), as the ASCAT data used to compute SMCI have a 25 km resolution that may favor observations of mixed pixels containing both rainfed and irrigated fields. The 2007–2008 crop season for the latter zone exhibits a production deficit, while an average to above-normal production is recorded for the other zones. This result is because the Kenitra region faced severe flooding in autumn 2008 that hampered the crops in the region. The above-normal rainfall that watered the country at this time favored cereal production in regions that did not experience any flooding, such as the agricultural provinces located in zone 1 in the center of the country. Winter 2009/2010 is well known for an exceptional and persistent negative phase of the North Atlantic Oscillation [122], but unfortunately, it did not trigger above-normal rainfall in North Africa, as could be expected [77], leading to average production for the four zones. Finally, another striking feature is that all drought indices match well with each other while they depict very different crop characteristics, such as surface temperature (TCI), surface soil moisture (SMCI) or vegetation vigor (VCI). It is probable that the integration over the crop season and on the scale of the agricultural zone masks some specific seasonal and geographical features, which will be analyzed in the next section.

Table 4. Correlation between remote sensing drought indices (VCI, TCI, SMCI and VHI), rainfall amounts during the crop season and crop yield anomalies for the four zones (*, **, *** = significant at 5/1/0.1% probability levels).

	VCI	TCI	SMCI	VHI	Rainfall
Zone 1	0.79 ***	0.86 ***	0.80 ***	0.85 ***	0.88 ***
Zone 2	0.77 ***	0.75 ***	0.59 **	0.78 ***	0.70 ***
Zone 3	0.67 ***	0.66 ***	0.49 *	0.69 ***	0.58 **
Zone 4	0.59 **	0.36	0.14	0.51 *	0.48 *

3.1.2. Monthly Scale

To further understand the linkage between drought and cereal crop yield, lagged correlations between drought indices and yields are carried out separately on the monthly time scale and for each agricultural province. Figure 3 displays the lagged correlation results from November to May. Only correlation coefficients significant at the 99% level are displayed. In addition, Figure A3 displays the lagged correlation between yields and cumulative rainfall and average temperature (both average since the beginning of the season in November and monthly values are considered) for comparison purposes, as those variables that are measured by meteorological stations in the synoptic network have been used for a long time for drought assessments.

The correlation between yields and rainfall and temperature (Figure A3) corresponds to well-known patterns [9,24]: (1) a significant positive correlation with monthly rainfall early in the crop season in November or December. It is obvious that seeding in a well-watered soil will speed up plant emergence. In addition, the farmers practice opportunistic agriculture by seeding when the soil has been well watered thanks to well-distributed rainfall events at the beginning of the season; (2) a significant positive correlation with cumulative rainfall during the entire season with a maximum correlation occurring in February or in March around the vegetation peak; (3) for temperature, the correlation is much more scattered, but the monthly temperature appears to be significantly negatively correlated with yields in January during the tillering phase for most of the provinces, meaning that mild temperatures during this time are favorable for crop production due to the prevention of heat stress. Wheat is well known to be highly sensitive to air temperature during the developmental

stages [123] when the crop is photosynthetically active and when high biomass accumulation occurs. Mild temperatures at this time favor long culms, large flag leaves and more potentially fertile florets in each spikelet [124].

For the VCI (Figure 4a), the correlation with cereal yield is high during the end of winter and in early spring (from February to April), which corresponds to development stages from late tillering to grain filling. The higher correlation for each province ranges between 0.61 and 0.94 (significant at the 99% level). Higher correlation coefficient values are observed for the provinces of Ben Slimane, Khenifra, Haouz, Settat, Khemisset and Taounat (0.89, 0.90, 0.92, 0.94, 0.93 and 0.85, respectively). These provinces are distributed within the first three zones, meaning that a differentiated analysis by zone is not relevant for the linkages between the VCI and grain yields. This finding could be attributed to the mechanisms explaining the linkages between the VCI and yields that are not related to climate or soil types. Indeed, the LAI is highly linked to the NDVI, and, thus, the LAI is also linked to the VCI. The LAI for cereals is a proxy for biomass accumulation; high aboveground biomass is also often related to high grain yield apart from late water or heat stresses that could prevent good grain filling, particularly during the pollination stage [125]. A high LAI also reduces soil evaporation through shielding and may improve the water use efficiency of the field. The lowest correlations are observed for Beni Mellal, Safi and Taza. The Safi province is known to have poor soil, which explains this area having the lowest yield of the 15 provinces (Table 2) with regard to cumulative rainfall amount. The only difference observed apart from the strength of the correlations is related to the timing at which the correlation is at the maximum, which slightly differs among provinces. Eighty percent of the 15 provinces exhibit a maximum correlation in March, which is the typical timing of the maximum green LAI for wheat in Morocco, while, for the Khenifra and Haouz provinces, the highest correlation was found in April. This finding may be attributed to slightly lower temperatures during the growing season, meaning low cumulative growing degree days and longer crop seasons. Indeed, these two provinces present the two lowest average temperatures during the crop season (see Table 2). Our results are in line with the work of Salazar et al. (2007) that was carried out on wheat cropped in Kansas, and these researchers highlighted a maximum correlation between wheat yield and the VCI during the maximum development of wheat [42]. Likewise, Unganai and Kogan (1998) in south Africa also found a similar timing of maximum correlation but for corn yield [41]. In addition, Zhang et al. (2017b) found a high correlation between VCI and wheat yield during the anthesis stage (February and March) in the Indo-Gangetic Plain (IGP) region of India [119].

Concerning TCI, as presented in Figure 4b, high correlation coefficients significant at the 99% level are also observed, ranging from 0.61 to 0.82. The positive correlation values found with the yields means that lower than normal LSTs are favorable for grain yield production during the development stages, including tillering and stem extension. In contrast with the VCI, the higher correlation values are found earlier in the season by an average of approximately 1 month, around January or February for 14 out of the 15 provinces. The main rationale of the TCI is that when water is a limiting factor, transpiration decreases drastically or even stops in the more extreme cases, and vegetation temperature, which may represent the LST when the canopy is adequately developed to shield the soil, increases. Stated differently, water stress should be avoided during wheat growth. In line with our results, several authors have already highlighted a positive correlation between cereal yields and the TCI during the growth stages of wheat in the United States [42], Mongolia [126] and Austral [75], and, as well as in Unganai and Kogan (1998) in South Africa for corn and others. The lowest correlation is found for the Kenitra province. For this province, irrigated cereal extending over more than 60% of the agricultural areas can be considered in the analysis because of the land use map uncertainty, as already highlighted. Irrigated cereals are well known to be less sensitive to air temperature than rainfed fields [127] because irrigation water inputs limit the water stress period and introduce thermal inertia to the soil. This finding could explain the lower correlation found for the Kenitra province.

The correlation between yield and VHI (Figure 4c) is significantly positive during all stages of development (tillering and stem extension) until anthesis, apart from the Kenitra province.

The correlation values with the VHI are generally stronger than those with the VCI and TCI taken separately. The most striking feature is that the spatiotemporal patterns are very similar to the correlation obtained with the VCI (Figure 4a), as already expressed by Bachmair et al. (2018) [128]. Likewise, the correlations exhibit a peak during late spring, which is in line with the results obtained with the VCI. This result means that the contribution of the VCI to the VHI dominates over the effect of the thermal conditions seen with the TCI. Several authors already underlined high positive correlation values with yields during the development stages of cereals, such as Ribeiro et al. (2019) on the Iberian Peninsula (IP), who found that the correlation between the cereal yield and VHI was the strongest during the heading stage of cereal [3].

The correlations between the SMCI and rainfed cereal yield are displayed in Figure 4d, and the correlations between the SWIs at different depths and yields are displayed in Figure 5. Please note that the SMCI is highly linked to the SWI that is representative of the upper soil layer (approximately 5 cm). In contrast with the other indices, the highest correlation values are between the SMCI and the SWI10 on the one hand, and on the other hand, yields are observed at the beginning of the growing season around seeding and/or the emergence stage, occurring as early as November for three of the provinces. Positive correlations that are significant at 99% are obtained with a maximum either in December (11 provinces for the SMCI) or January (three provinces for the SMCI); the only exception is Kenitra, which has already been shown to behave differently than the other provinces. The highest correlations of $R = 0.88$ for the SMCI and $R = 0.95$ for the SWI10 were observed for the Settat province. This positive correlation means that above-normal moisture conditions are favorable for high yields at this time. This finding is consistent with that of Modanesi et al. (2020), who found a high correlation between the standardized SM index (SSI) derived from the satellite SM observations of the ESA Climate Change Initiative (CCI) and the Modern-Era Retrospective Analysis for Research and Applications, version 2 (MERRA-2) SM dataset and wheat production in November and December in India [120]. Additionally, Zhang et al. (2017b) found a significant correlation between the SSI and wheat during the emergence stage (October and November) in the IGP, which is the northern region that separates the Peninsula from the Himalayan chain [119]. SM is another indicator that is highly suitable for assessing agricultural drought, as plants start to wilt when sufficient soil water is not available to meet the evapotranspiration demand. A deficit of SM during the development stages will affect crop growth, and finally, a decrease in final crop yield will be expected. This finding is well reflected by the correlation obtained with the SWI, which represents the deeper layers (SWI40 and SWI60). Indeed, as the roots develop during the crop season, deeper layers of soil undergo water extraction by the plant. The observed differences among provinces in terms of correlation could be attributed to differences in rainfall distribution or/and soil type, as computation of the SWI of the deeper layers was carried out using the time constant T for a specific type of soil. In line with our study, Modanesi et al. (2020) already showed that SM is a suitable indicator for representing agricultural drought, as SM correlates more closely with reduced crop yield than precipitation [120]. Zribi et al. (2010) illustrated a tight link between rainfall and the SWI in a semiarid area of Tunisia [99]. In addition, the researchers found that the SWI is strongly related to the NDVI during the early season ($R = 0.81$ in December). Likewise, a high correlation is also observed between the NDVI and the SWI in the more productive region of Northwest Africa [36]. Additionally, the SWI anomaly showed a strong correlation with the SPI index over the central region of Tunisia [129].

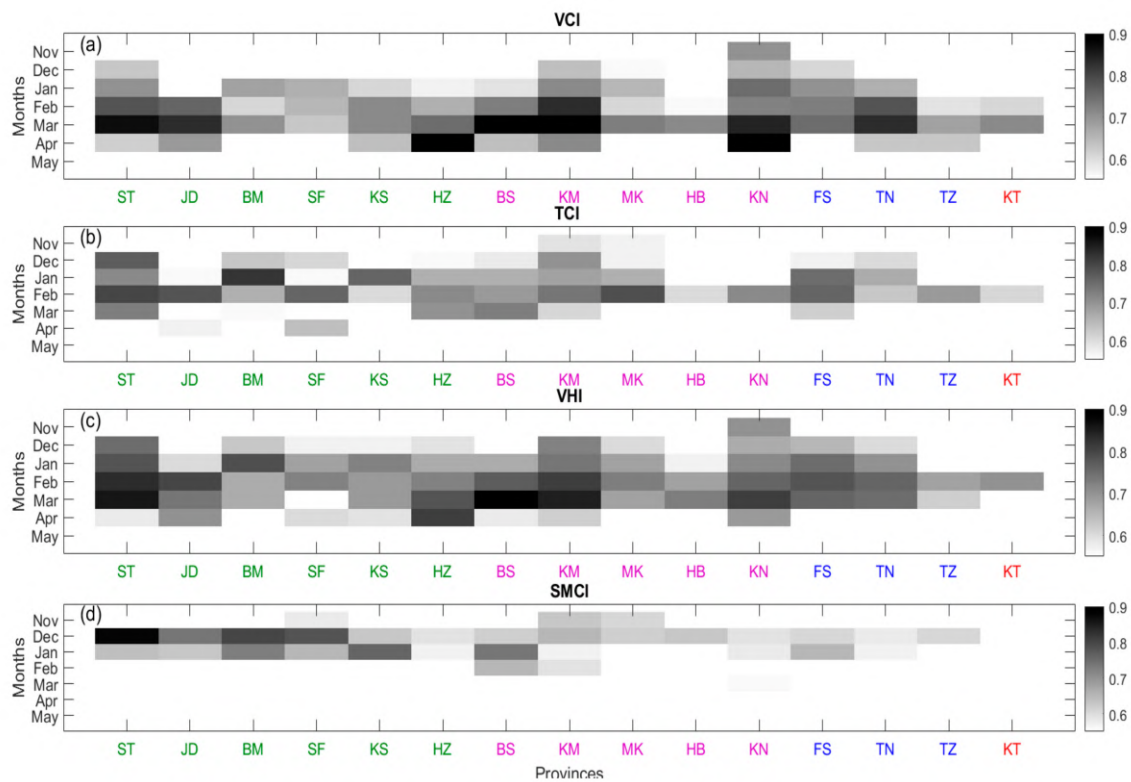


Figure 4. Correlations between the VCI (a), TCI (b), VHI (c), SMCI (d) and cereal yields on the province scale. ST: Settat, JD: El Jadida, BM: Beni Mellal, SF: Safi, KS: Kelaa des Sraghna, HZ: Haouz, BS: Ben Slimane, KM: Khemisset, MK: Meknes, HB: El Hajeb, KN: Khenifra, FS: Fes, TN: Taounat, TZ: Taza, KT: Kenitra. All the correlations are significant at the 99% level.




Figure 5. Correlation between the SWI 10 (a), SWI 40 (b), SWI 60 (c) and cereal yield at the province scale: Settat, JD: El Jadida, BM: Beni Mellal, SF: Safi, KS: Kelaa des Sraghna, HZ: Haouz, BS: Ben Slimane, KM: Khemisset, MK: Meknes, HB: El Hajeb, KN: Khenifra, FS: Fes, TN: Taounat, TZ: Taza, KT: Kenitra. All the correlations are significant at the 99% level.

3.2. LDAS Outputs and Yields Time Series

In this section, the results of the relationships between anomalies of the LDAS outputs and the cereal yields are investigated (Figure 6). In contrast with the remote sensing drought indices, the results are summarized by group instead of considering each province separately because correlation patterns similar to those of the remote sensing drought indices are observed. Indeed, the LAI provides information close to that of the VCI; SM in the root zone is related to the SWI of the deeper layer, while upper profile SM mainly governs soil evaporation; the TCI is closely related to the transpiration and evapotranspiration processes.




Figure 6. Lagged correlation between the LDAS output anomalies of the LAI (a), transpiration (b), soil evaporation (c), evapotranspiration (d), SM at (0 to 4 cm) (e), SM at (10 to 20 cm) (f), SM at (40 to 60 cm) (g), SM at (80 to 100 cm) (h) and the cereal yield for all zones.

For the LAI, the correlation reaches its maximum around the heading stage, as is the case for the VCI, which is in March for groups 1, 3 and 4 and in February for group 2. The strength of the correlation reached approximately 0.91, 0.89 and 0.90 for groups 1, 2 and 3, respectively. This result is in

line with that of Sawada et al. (2019), who highlighted a similar correlation between the LAI analyzed within an LDAS system and wheat production at the national level in Morocco [130]. Transpiration (Tr) and cereal yield are significantly correlated from at approximately the maximum development stage and the heading stage. Higher transpiration is expected when the root zone is well watered and when the leaf area index is high, explaining the same timing (March) of the high correlation that was already observed with the VCI. The correlation also reaches higher values than the correlations with the VCI and the TCI, at least for zones 1, 2 and 3 (0.87, 0.78, and 0.88, during March, respectively). In contrast, monthly soil evaporation is significantly correlated at the start of the season, from sowing to emergence (November–December) for zones 1, 2 and 3. Again, zone 4 is different from the others, with a correlation peak occurring in February. Higher evaporation means higher soil water content, and this result is in line with the correlation pattern found with the soil moisture indices for the upper soil layers (SMCI and SWI10).

For the deeper layers (40 to 60 and 80 to 100 cm), the correlation is significantly positive later in the season, during the development stage of cereal, because of the progressive root development, as already highlighted for the SWI.

3.3. Case Study: 2015/2016

The 2015/2016 season is characterized by a high negative production anomaly that strongly affected the country's economy. In particular, more than 90% of the national territory of Morocco experienced droughts during December 2015 and January 2016 [34]. The cereal yield decrease reached 55%, 58%, 67%, and 13% of the long-term mean for zone 1, zone 2, zone 3 and zone 4, respectively. Figure 7 shows the 2015/2016 time series of drought indices and anomalies of LDAS outputs for all zones from September 2015 to July 2016. Figure A4 in Appendix A is the same for 2011–2012, which is also characterized by below normal yields. The first striking feature is a close correspondence between the drought indices and LDAS outputs, although a contrasted behavior can be highlighted between the first three zones and zone 4, as already discussed, particularly for the VCI and the LAI, as well as for the superficial soil moisture-related variables (SMCI and WG2). More discrepancies can be observed for root-zone soil moisture-related variables (SWI60 and WG6). This result is probably related to the uncertain soil depth for the SWI (the choice of the time scale T —Equation (4)—is related to the soil type). The TCI and Tr also follow the same dynamic, at least for zones 1 and 2. Zone 3 is the most affected zone, while zone 4 exhibited nearly normal production, probably because of the large irrigated areas, as already mentioned. This season faced a severe rainfall deficit (meteorological drought) as early as December in the four zones, as reflected by the below normal conditions in terms of the SMCI and the SPEI3, while the VCI and the SWI60 were still indicative of the average vegetation and root-zone moisture conditions at this time. Likewise, the air temperature was 2.7° above average during the growing stages (MAPMDREF, 2016), which is in line with the TCI dynamic whose negative anomalies peak in January for all four zones. In January and February, during the development stage of cereal, the persistence of the precipitation deficit is associated with the continuation of adverse conditions in terms of the surface soil moisture described here by the SMCI. In March, during the heading stage of cereal, rainfall was still in short supply, and then, the VCI dropped for zone 1, zone 2 and zone 3, indicating that crops were severely affected by the continuous deficit of rainfall and above-normal temperatures. In contrast, the VCI for zone 4 still indicated good conditions even if precipitation remained in short supply, which shows the resilience of irrigation systems facing a rainfall deficit. Interestingly, 2011–2012 (Figure A4) exhibited a different seasonal pattern of drought. Indeed, while the first part of the season until January exhibited average (for the SPEI) to above-normal conditions (for the VCI and the SMCI), the drastic drop in rainfall during the core of wheat development (February and March) had a major impact on grain yields, and the recovery of good soil moisture conditions occurred too late, probably after the grain filling stage in April. This contrasting behavior reveals that the different remote sensing drought indices related to vegetation, temperature and SM conditions can be used to anticipate drought impacts on yields in a timely manner throughout the crop season.




Figure 7. Monthly evolution of the remote sensing drought index anomalies VCI, TCI, VHI, SMCI, SWI60, and LDAS outputs standardized anomalies LAI, Tr, WG2 (0–4 cm), WG6 (40–60 cm) and SPEI3 for zone 1 (a), zone 2 (b), zone 3 (c) and zone 4 (d) during the 2015/2016 dry cropping season.

4. Discussion

Linkages between monthly drought indices and the outputs of land data assimilation with cereal yields have been highlighted at different times during wheat growth throughout the crop season. Several questions arising from these results are discussed below: (1) What is the added value of using LDAS to monitor drought with regard to the much higher expertise and computing time needed for the implementation of such a complex system? (2) Remote sensing drought indices are usually computed at a monthly time scale in the literature, but would an averaging time that is closer to the functioning of the crops, such as the phenological stages, be more relevant? (3) Finally, could an empirical choice of the α coefficient for VHI computation equal to 0.5 be revisited as a function of climate?

4.1. The Added Value of an LDAS

In terms of providing a drought monitoring dashboard to stakeholders, among which include managers on the catchment scale or ministries on the country scale, the complexity of implementation is a key question. Indeed, the LDAS, combining physically based LSMs with remote sensing variables through complex techniques of filtering, parameter identification and data assimilation, are difficult for local managers to implement without intense and continuous training sessions. This question is assessed in two different ways. As a preliminary step, the added value of assimilating remote sensing variables in a land surface model is assessed by comparing the correlation with the cereal yields of the LDAS output with and without data assimilation (the “open-loop” runs). Then, the correlation values between drought indices and LDAS outputs and cereal yields are compared at the group scale.

Table 5 shows the correlation between the outputs of the LSM without assimilation (open loop) and with assimilation (analysis) and cereal yields. The analysis improves the correlation compared with the open loop for all variables. For example, the assimilation improved the correlation between the LAI and yield by approximately 6% for zones 1 and 3 and by 7% for zone 2. Concerning Tr, the correlation improved by approximately 1 to 2%, depending on the study zone. Conversely, the improvement is higher for the surface SM (WG2) when compared with the root-zone SM (WG6), as the variable is more difficult to predict because (1) the vertical profile of soil hydraulic properties is uncertain

and (2) the analysis increments (i.e., correction of the variables) for the deeper layers may be lower than those for the superficial layer. Our results are in line with the work of Albergel et al. (2019), who highlighted the ability of the LDAS-monde to better characterize agricultural droughts than its open-loop counterpart over the continental United States of America [55]. Sawada et al. (2019) used the Coupled Land and Vegetation Data Assimilation System (CLVDAS) based on the EcoHydro-SiB land surface model to show that the simulated LAI at the end of the growing season is well correlated with wheat production over North Africa, including Morocco. Data assimilation also improved the skill of an LSM to reproduce the satellite-derived phenology so that the LDAS can reproduce the nationwide crop production of this water-limited region.

Table 5. Correlation between output of the LSM with and without data assimilation and cereal yields at the group scale. Only the maximum correlation time already identified in Section 3 is displayed. All correlation coefficients are significant at the 99% level.

		LAI	Tr	Ev	WG 2	WG 6
Group 1	Month	March	March	December	December	January
	Open loop	0.88	0.84	0.73	0.82	0.72
	Analysis	0.91	0.87	0.78	0.84	0.85
Group 2	Month	February	March	January	December	December
	Open loop	0.89	0.70	0.53	0.64	0.63
	Analysis	0.91	0.78	0.65	0.70	0.78
Group 3	Month	March	March	December	December	January
	Open loop	0.82	0.71	0.71	0.71	0.72
	Analysis	0.90	0.88	0.82	0.76	0.75
Group 4	Month	March	March	December	December	January
	Open loop	0.62	0.6	-	-	-
	Analysis	0.64	0.65	-	0.69	0.59

Finally, Table 6 reports the correlation of the LDAS outputs and the remote sensing indices with cereal yields at the correlation peak. The LDAS and remote sensing indices provide comparable correlations with yields for vegetation characteristic variables (VCI and LAI) and to a lesser extent, for the TCI and Tr. In contrast, one striking feature is the added value of the LDAS outputs for variables related to the SM vertical profile. The correlations are always higher with the LDAS outputs than the indices derived from remote sensing products. This result could be related to the shielding effect of the canopy for the microwave observations used to derive the soil moisture-related indices. Indeed, the C-band backscattering coefficient acquired by the ASCAT sensor is used to compute the SWIs at different depths. The penetration depth of the C-band signal is low. In addition, Sigma0 is highly sensitive to surface roughness, which may change significantly during the crop season in response to soil workings and rainfall events. Brightness temperatures measured by microwave radiometers used to derive the SMCI are also highly sensitive to the canopy optical depth. Within this context, a mechanistic-based model predicting the processes involved in the SM dynamic (water interception by the canopy, surface layer evaporation, root water extraction, water diffusion between the different layers and deep drainage, etc.) appears to be better suited than using the remote sensing-derived SM products that could be contaminated with errors, especially when the crop canopy is fully developed.

Table 6. Correlation of the LDAS outputs and the remote sensing indices with cereal yields at the correlation peak. The best correlation coefficients R are reported in bold.

	Group 1		Group 2		Group 3		Group 4	
	Month	R	Month	R	Month	R	Month	R
VCI	March	0.84	March	0.87	March	0.80	March	0.71
LAI	March	0.91	February	0.91	March	0.90	March	0.64
TCI	February	0.78	February	0.80	February	0.75	February	0.61
Tr	March	0.87	March	0.78	March	0.88	March	0.65
SMCI	December	0.81	January	0.63	February	0.58	December	0.31
WG2	December	0.82	December	0.70	December	0.77	December	0.69
SWI60	January	0.79	December	0.75	December	0.57	December	0.47
WG6	January	0.85	December	0.78	January	0.75	January	0.59

4.2. Phenological Stages Versus Monthly Scale

Drought influences crop production differently depending on the development stage at the time of its occurrence [131–133]. The correlation of yields with the drought indices averaged over the main phenological stages described above is assessed in this section. Figure 8 shows the correlations between the VCI, TCI, SMCI and SWI60 and rainfed cereal yield at the key phenological stages; all correlation coefficients are significant at the 99% level. Table 7 displays the improvement in the maximum correlation with regard to the correlation obtained by integrating the drought indices on the monthly time scale. In line with the results described above, the correlation between the VCI and yields is the strongest during the heading stage, corresponding to the development peak, while the TCI is highly correlated during the development stage (Figure 8). The correlation by integrating across the main phenological stages is slightly higher than that using the monthly time scale, but the correlation improvement is limited, remaining below 15% for the VCI and the TCI and can even decrease by up to 14% (Kenitra province for the VCI). This finding means that, in view of implementing an early warning system of drought or for choosing predictors for the development of a model for the seasonal prediction of wheat yields, the monthly time scale is adequate regarding the additional data processing needed to identify the phenological stages. The behavior is quite similar for SWI60, except for some provinces in which the maximum correlation increase can reach 31%. For the index related to the soil moisture of the superficial layer SMCI, the maximum correlation is obtained around emergence during the early stage of wheat growth. It is striking that (1) the correlation is improved for all the provinces and (2) the correlation increase is significantly higher than that for the other indices and can reach 49%. The seeding dates are very variable from one province to another and even from field to field depending on the farming practices and the rainfall distribution. Thus, it is better suited to choose an integrating time in accordance with the observed emergence of the crop detected in this study using NDVI. It is more substantial at this time than during the following stages when the crops are well developed. The main conclusion is that the monthly time scale is adequate for the drought indices related to yields during the development and heading stages, while integration during the observed emergence stage should be preferred for the superficial moisture conditions impacting yields the earliest in the crop season.




Figure 8. Correlation between VCI (a), TCI (b), SMCI (c), SWI60 (d) and cereal yield for key phenological stages. ST: Settat, JD: El Jadida, BM: Beni Mellal, SF: Safi, KS: Kelaa des Sraghna, HZ: Haouz, BS: Ben Slimane, KH: Khemisset, MK: Meknes, HB: El Hajeb, KN: Khenifra, FS: Fes, TN: Taounat, TZ: Taza, KT: Kenitra. All the correlations are significant at the 99% level.

Table 7. Improvement in the maximum correlation coefficient obtained between yields and the drought indices integrated over the phenological stages with regard to the monthly scale. Colors correspond to the four groups of agricultural provinces (see text).

	ST	JD	BM	SF	KS	HZ	BS	KM	MK	HJ	KN	FS	TN	TZ	KT
VCI	5%	1%	12%	8%	4%	1%	2%	0%	9%	8%	2%	4%	3%	11%	−14%
TCI	3%	3%	0%	8%	5%	10%	9%	2%	4%	14%	5%	3%	3%	5%	12%
SMCI	3%	20%	6%	1%	4%	23%	7%	14%	12%	4%	46%	15%	49%	31%	35%
SWI60	2%	4%	7%	5%	1%	3%	1%	7%	31%	3%	18%	−3%	6%	16%	−10%

4.3. Alpha Value for the Computation of VHI

It is well known that the LST and NDVI contributions through the α value (Equation (3)) to the VHI are not equal during the growing season or for different climate conditions [121]. As pointed out by [46], who used the SPEI as a reference drought index, it is possible and recommended to estimate an optimal value of α to assess the relative contributions of VCI and TCI for different regions during each phenological stage. The objective of this section is twofold: (1) to propose optimal values of α for each province and (2) to discuss the factors impacting these values. For this objective, α is optimized to maximize the VHI correlation with yields (α_{Yield}), which is expected to reflect the agricultural drought conditions during the entire growing season. The optimization method is a simple brute force approach to sampling the space of the α value (from 0 to 1) with a step of 0.001. For ease of interpretation, optimization at the scale of the phenological stages is preferred to the monthly time scale, and the development and heading stages are chosen, as the VCI and the TCI have been shown to be correlated with yields at these times of the crop season. As yield values are not available on the province scale everywhere in the world, optimization is also performed based on the SPEI 1, 3 and 6 from January to April (α_{SPEI}), which can be computed from widely available observations of temperature and precipitation following Bento et al. (2018). Then, the correlation of the VHI with the α_{SPEI} values and cereal yields is computed. The retained results are those maximizing the latter for the 15 provinces on average; the correlation corresponds to the SPEI6 in March around the vegetation peak,

which is in agreement with Bento et al. (2020). Table 8 displays the correlation of the VHI with yields before and after optimization for both strategies (optimization with the yields and with the SPEI) and the optimized values of α based on the cereal yields. Only the best results (with the SPEI6 in March) are provided for optimization on the SPEI.

The results show that more weight should obviously be given to TCI during the development stage (optimized $\alpha < 0.5$) and to VCI during the heading stage (optimized $\alpha > 0.5$) for all provinces, which is in line with the correlation obtained between the TCI/VHI and the yields described above. The correlation between the yields and the VHI is obviously significantly improved when considering the optimized values based on yields, but the correlation values also increase when optimization is performed on the SPEI 6 in March. This result means that (1) the optimized value of α should be preferred to the widely used value corresponding to an equal weight to properly reflect the drought conditions of a specific region; and (2) it is possible to find a better value than the equal weight based on ancillary data when the yields are not available. This result has already been shown by Bento et al. (2018) for Europe [46]. Interestingly, a close link is found between the α values and the seasonal rainfall amount during the development stage (positive correlation of 0.65) and to a lesser extent ($r = 0.56$) during the heading stage (no relationship with the average temperature was found; Table 2). Stated differently, the VCI contribution increases with the annual rainfall amount, which is in apparent conflict with the results of Bento et al. (2020), who showed that, on the global scale, the optimized α values increase with aridity [47]. Nevertheless, all ecoclimatic regions of the globe are of concern in the study of Bento et al. (2020), while only the semiarid and subhumid parts of Morocco are studied here. In addition, non-wheat areas are masked in this study, while mixed pixels are analyzed using the 8-km AVHRR data in Bento et al. (2020) [47]. For our interpretation, more weight should be given to the TCI, as the heat stress drastically impacts yields during the development and heading stages in the semiarid areas that are likely to face more severe temperatures than in the more humid regions located north of the country.

Table 8. Correlation between the VHI proposed by Kogan and the VHI with optimization with yield and the SPEI6 and yield. The value of α was optimized at the key phenological stage for all provinces. All correlation coefficients are significant at the 99% level. Colors correspond to the four groups of agricultural provinces (see text).

	VHI (Kogan)		VHI		VHI		Alpha Values	
			(Optimization with Yield)		(Optimization with SPEI 6)		(Optimization with Yield)	
	Development	Heading	Development	Heading	Development	Heading	Development	Heading
ST	0.72	0.87	0.84	0.93	0.81	0.88	0.12	0.67
JD	0.45	0.79	0.83	0.86	0.82	0.80	0.02	0.60
BM	0.60	0.85	0.82	0.86	0.79	0.79	0.01	0.38
SF	0.48	0.74	0.82	0.76	0.80	0.71	0.02	0.67
KS	0.49	0.76	0.79	0.77	0.78	0.76	0.01	0.52
HZ	0.64	0.86	0.79	0.93	0.79	0.92	0.01	0.60
BS	0.45	0.82	0.79	0.86	0.79	0.77	0.02	0.54
KM	0.68	0.85	0.76	0.89	0.75	0.78	0.16	0.98
MK	0.72	0.73	0.84	0.79	0.82	0.76	0.34	0.92
HJ	0.68	0.74	0.74	0.88	0.71	0.77	0.42	1.00
KN	0.78	0.90	0.83	0.94	0.80	0.92	0.47	0.90
FS	0.72	0.78	0.72	0.80	0.70	0.78	0.50	0.70
TN	0.58	0.75	0.68	0.85	0.64	0.78	0.38	0.89
TZ	0.47	0.63	0.73	0.75	0.63	0.72	0.01	0.88
KT	0.50	0.61	0.68	0.63	0.58	0.52	0.10	0.93

5. Conclusions

The main objective of this study was to assess the linkages between rainfed cereal production and agricultural drought in Morocco through remote sensing indices and an LDAS over the most productive province. This assessment was carried out using a simple lagged correlation analysis between the different variables and remote sensing indices and the wheat yields on the agricultural province scale. The main results, which are schematically summarized in Table 9, are biophysically sound and in line with the rich literature existing on this subject: the SMCI, SWI10, WG2 and Ev (soil evaporation), as proxies of surface soil moisture conditions, are closely linked to the yields for the early stage of wheat development, while the yields are correlated with moisture in the deeper layers later in the season as the roots develop (WG4 to WG8, SWI40 and SWI60); temperature conditions provided by the TCI and indirectly by the Tr mainly impact the yields during the development stage, while the vegetation conditions (the VCI and the LAI) are a good proxy of production around the vegetation peak in March or April depending on the provinces. Then, the case studies of the 2011–2012 and 2015–2016 droughts are analyzed in detail, showing the propagation from the deficit of rainfall until the drop in vegetation conditions through the SM anomalies and adverse temperature conditions occurring early in the season for 2015–2016, while the yield losses for 2011–2012 can be attributed to a drastic drop in moisture conditions during the core of the season in February and March.

Table 9. Summary of the linkages between the remote sensing drought indices, the LDAS output variables and the cereal yields during the crop season (++ significant correlation, +++ highly significant correlation).

		Emergence		Tillering	Elongation	Booting	Anthesis
		December	January	February	March	April	
Remote sensing Drought indices	VCI			++	+++	++	
	TCI		++	+++			
	VHI		++	++	++	++	
	SMCI	+++	++				
	SWI10	+++					
	SWI40	++	+++				
	SWI60	++	++	+++			
LDAS outputs	LAI		++	++	+++		
	Tr		++	++	+++		
	Ev	+++	++				
	WG2	+++	++				
	WG4	++	+++				
	WG6	++	+++				
	WG8	++	+++				

Then, several questions arising from the obtained results are discussed. First, the added value of using an LDAS requiring strong expertise and computational power regarding simple drought indices freely available from remote sensing is analyzed to provide a drought monitoring dashboard to stakeholders. The main result is that a clear added value can be evidenced for all variables and in particular for the variables related to the SM profile that are not directly observable from space for the deeper layers. This result is interesting for stakeholders in the view of an operational monitoring of drought as, with the development of LDAS systems, surface analysis of moisture, temperature and vegetation conditions will be available freely in a near future, thus limiting the need for expertise and computing facilities. Indeed, vegetation is an interfering element for the retrieval of SM from active

and microwave sensors. Thus, surface SM products have the worst quality when the vegetation is fully developed. Second, the typical integration time scale for the drought indices chosen within the literature is the monthly time scale. Therefore, the correlation by integrating over the main phenological stages that should be closer to plant functioning is computed. Higher correlations are obtained, but the correlation improvement is limited, apart from the index related to the soil moisture of the superficial layer SMCI, meaning that the monthly time scale is adequate for the drought indices related to the yields during the development and heading stages, while integration during the observed emergence stage are preferred for the superficial moisture conditions that most impact the yields early in the crop season. Finally, the VHI is an extensively used drought index combining the temperature conditions through the TCI and the vegetation conditions through the VCI, and the relative weight of both indices for computation of the VHI is questioned following Bento et al. (2020) [47]. The optimal value of the weight (α) in terms of mapping drought in relation to wheat production is computed by maximizing the correlation between the VHI and the yields. As an alternative way to identify α values better than the equal weight, α is also optimized, but it is optimized on the SPEI that can be computed from freely available data. The main results are that (1) the optimized value of α should be preferred to the widely used value corresponding to an equal weight to properly reflect the drought conditions of a specific region; and (2) it is possible to find a better value than the equal weight based on ancillary data when the yields are not available.

This study opens doors for the development of early warning systems for agronomic drought in North Africa as well as for the seasonal forecasting of yields. To this objective, our on-going work is twofold: (1) estimating threshold values triggering a warning as well as quantifying the potential drop of yields as a function of the warning level; (2) early forecasting of yields production. Finally, considering the small dimensions of Mediterranean fields, the Copernicus constellation providing high-resolution data with a high revisit time will significantly improve the drought monitoring capability from space and should be considered in future studies.

Author Contributions: Conceptualization L.J., E.h.B., S.K. and S.E.-R.; writing—original draft preparation, E.h.B., L.J.; review and editing L.J., S.E.-R., S.K., C.A., R.B., and B.R. All authors have read and agreed to the published version of the manuscript.

Funding: This work was carried out within the framework of the Joint International Laboratory TREMA (<http://lmi-trema.ma>) (IRD, UCAM, DMN, CNESTEN, ABHT, and ORMVAH) and the ERANETMED03–62 CHAAMS ‘global CHange: Assessment and Adaptation to Mediterranean region water Scarcity’ project. The European Commission Horizon 2020 Programme for Research and Innovation (H2020) in the context of the Marie Skłodowska-Curie Research and Innovation Staff Exchange (RISE) action (REC project, grant agreement no. 645642), followed by the ACCWA project, grant agreement no. 823965) and by SAGESSE PPR/2015/48 ‘Système d’Aide à la décision pour la GEstion des reSSources en Eau’ are acknowledged for the mobility grants of E. Bouras. The H2020 PRIMA ALTOS project, MISTRALS/SICMED2 and PHC Toubkal #39064WG/2018 are also acknowledged for additional funding. E. Bouras was supported by a fellowship from the ARTS program from IRD, France.

Acknowledgments: The authors acknowledge the Economic Services of the Ministry of Agriculture of Morocco for providing the crop production statistics. Additionally, the Copernicus Global Land Service (CGLS), the European Space Agency Climate Change Initiative (ESA CCI), the Copernicus Climate Change Service (C3S) and NASA’s Land Processes Distributed Active Archive Center (LP DAAC) provided the free satellite data.

Conflicts of Interest: The authors declare that they have no conflicts of interest.

Appendix A

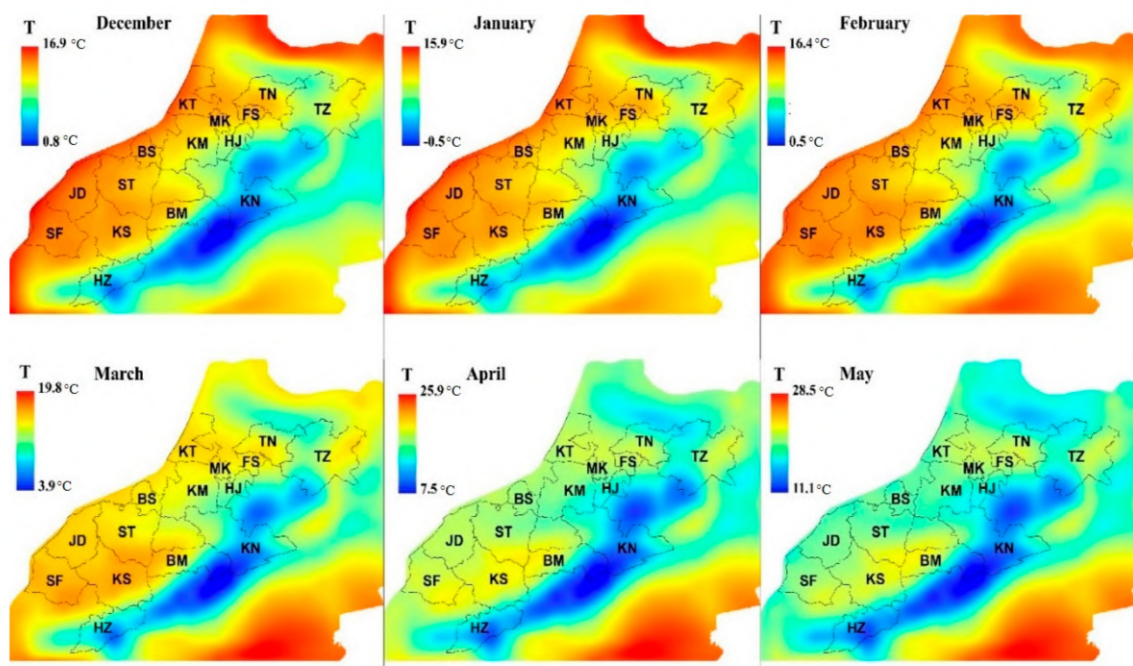


Figure A1. Mean air temperature derived from ERA5 during the cereal crop season from 2000 to 2017.




Figure A2. NDVI profile with key phenological stages during the 2016–2017 season for the Settat province.




Figure A3. Correlation between the cumulative rainfall (a), monthly rainfall (b), average temperature (c), monthly temperature (d) and cereal yields on the province scale. ST: Settat, JD: El Jadida, BM: Beni Mellal, SF: Safi, KS: Kelaia des Sraghna, HZ: Haouz, BS: Ben Slimane, KM: Khemisset, MK: Meknes, HB: El Hajeb, KN: Khenifra, FS: Fes, TN: Taounat, TZ: Taza, KT: Kenitra. All the correlations are significant at the 99% level.




Figure A4. Monthly evolution of the remote sensing drought index anomalies VCI, TCI, VHI, SMCI, SWI60, and LDAS output standardized anomalies LAI, Tr, WG2 (0–4 cm), WG6 (40–60 cm) and SPEI3 for zone 1 (a), zone 2 (b), zone 3 (c) and zone 4 (d) during the 2011/2012 dry crop season.

References

1. Kumar, V. An early warning system for agricultural drought in an arid region using limited data. *J. Arid Environ.* **1998**. [CrossRef]
2. Páscoa, P.; Gouveia, C.M.; Russo, A.; Trigo, R.M. The role of drought on wheat yield interannual variability in the Iberian Peninsula from 1929 to 2012. *Int. J. Biometeorol.* **2017**. [CrossRef]
3. Ribeiro, A.F.S.; Russo, A.; Gouveia, C.M.; Páscoa, P. Modelling drought-related yield losses in Iberia using remote sensing and multiscalar indices. *Theor. Appl. Climatol.* **2019**. [CrossRef]
4. FAO. *The Impact of of Natural Hazards and Disasters on Agriculture, Food Security and Nutrition*; FAO: Rome, Italy, 2017; ISBN 978-92-5-130359-7.
5. Schilling, J.; Freier, K.P.; Hertig, E.; Scheffran, J. Climate change, vulnerability and adaptation in North Africa with focus on Morocco. *Agric. Ecosyst. Environ.* **2012**. [CrossRef]
6. Schilling, J.; Hertig, E.; Trambly, Y.; Scheffran, J. Climate change vulnerability, water resources and social implications in North Africa. *Reg. Environ. Chang.* **2020**. [CrossRef]
7. Tigkas, D.; Tsakiris, G. Early Estimation of Drought Impacts on Rainfed Wheat Yield in Mediterranean Climate. *Environ. Process.* **2015**. [CrossRef]
8. Karrou, M.; Oweis, T. Water and land productivities of wheat and food legumes with deficit supplemental irrigation in a Mediterranean environment. *Agric. Water Manag.* **2012**. [CrossRef]
9. Jarlan, L.; Abaoui, J.; Duchemin, B.; Ouldbba, A.; Tourre, Y.M.; Khabba, S.; Le Page, M.; Balaghi, R.; Mokssit, A.; Chehbouni, G. Linkages between common wheat yields and climate in Morocco (1982–2008). *Int. J. Biometeorol.* **2014**, *58*, 1489–1502. [CrossRef]
10. Balaghi, R.; Tychon, B.; Eerens, H.; Jlibene, M. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. *Int. J. Appl. Earth Obs. Geoinf.* **2008**. [CrossRef]
11. Latiri, K.; Lhomme, J.P.; Annabi, M.; Setter, T.L. Wheat production in Tunisia: Progress, inter-annual variability and relation to rainfall. *Eur. J. Agron.* **2010**, *33*, 33–42. [CrossRef]
12. Agoumi, A. *Vulnerability of North African Countries to Climatic Changes*; International Institute for Sustainable Development: Winnipeg, MB, Canada, 2003.
13. Driouech, F.; Déqué, M.; Mokssit, A. Numerical simulation of the probability distribution function of precipitation over Morocco. *Clim. Dyn.* **2009**. [CrossRef]
14. IPCC. Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. Available online: <https://www.ipcc.ch/report/managing-the-risks-of-extreme-events-and-disasters-to-advance-climate-change-adaptation/> (accessed on 27 November 2020).
15. Hertig, E.; Trambly, Y. Regional downscaling of Mediterranean droughts under past and future climatic conditions. *Glob. Planet. Chang.* **2017**. [CrossRef]
16. Lehner, F.; Coats, S.; Stocker, T.F.; Pendergrass, A.G.; Sanderson, B.M.; Raible, C.C.; Smerdon, J.E. Projected drought risk in 1.5 °C and 2 °C warmer climates. *Geophys. Res. Lett.* **2017**. [CrossRef]
17. Dai, A. Drought under global warming: A review. *Wiley Interdiscip. Rev. Clim. Chang.* **2011**. [CrossRef]
18. Vogel, M.M.; Hauser, M.; Seneviratne, S.I. Projected changes in hot, dry and wet extreme events' clusters in CMIP6 multi-model ensemble. *Environ. Res. Lett.* **2020**. [CrossRef]
19. Ministère de l'Agriculture, de la Pêche Maritime, Développement Rural et des eaux et Forêts, Agriculture en chiffre au Maroc. Available online: <https://www.agriculture.gov.ma/pages/publications/agriculture-en-chiffres-2018-edition-2019> (accessed on 27 November 2020).
20. Vicente-Serrano, S.; Cuadrat-Prats, J.M.; Romo, A. Early prediction of crop production using drought indices at different time-scales and remote sensing data: Application in the Ebro Valley (north-east Spain). *Int. J. Remote Sens.* **2006**. [CrossRef]
21. Wilhite, D.A.; Glantz, M.H. Water International Understanding: The Drought Phenomenon: The Role of Definitions Understanding: The Drought Phenomenon: The Role of Definitions. *Water Int.* **1985**, *10*, 111–120. [CrossRef]
22. Ciais, P.; Reichstein, M.; Viovy, N.; Granier, A.; Ogée, J.; Allard, V.; Aubinet, M.; Buchmann, N.; Bernhofer, C.; Carrara, A.; et al. Europe-wide reduction in primary productivity caused by the heat and drought in 2003. *Nature* **2005**. [CrossRef]
23. Mishra, A.K.; Singh, V.P. A review of drought concepts. *J. Hydrol.* **2010**. [CrossRef]

24. Balaghi, R.; Jlibene, M.; Tychon, B.; Eerens, H. *Agrometeorological Cereal Yield Forecasting in Morocco*; Institut National de la Recherche Agronomique: Rabat, Morocco, 2013; ISBN 978-9954-0-6683-6.
25. Ewert, F.; Rodriguez, D.; Jamieson, P.; Semenov, M.A.; Mitchell, R.A.C.; Goudriaan, J.; Porter, J.R.; Kimball, B.A.; Pinter, P.J.; Manderscheid, R.; et al. Effects of elevated CO₂ and drought on wheat: Testing crop simulation models for different experimental and climatic conditions. *Agric. Ecosyst. Environ.* **2002**, *93*, 249–266. [[CrossRef](#)]
26. Van Herwaarden, A.F.; Farquhar, G.D.; Angus, J.F.; Richards, R.A.; Howe, G.N. “Haying-off”, the negative grain yield response of dryland wheat to nitrogen fertiliser. I. Biomass, grain yield, and water use. *Aust. J. Agric. Res.* **1998**, *49*, 1067. [[CrossRef](#)]
27. McKee, T.B.; Nolan, J.; Kleist, J. The relationship of drought frequency and duration to time scales. *Prepr. Eighth Conf. Appl. Climatol. Am. Meteor. Soc.* **1993**, *17*, 179–184.
28. Kazmi, D.H.; Rasul, G. Agrometeorological wheat yield prediction in rainfed Potohar region of Pakistan. *Agric. Sci.* **2012**. [[CrossRef](#)]
29. Salman, A.Z.; Al-Karablieh, E.K. An early warning system for wheat production in low rainfall areas of Jordan. *J. Arid Environ.* **2001**. [[CrossRef](#)]
30. Kumar, V.; Panu, U. Predictive assessment of severity of agricultural droughts based on agro-climatic factors. *J. Am. Water Resour. Assoc.* **1997**. [[CrossRef](#)]
31. Heng, L.K.; Asseng, S.; Mejahed, K.; Rusan, M. Optimizing wheat productivity in two rain-fed environments of the West Asia-North Africa region using a simulation model. *Eur. J. Agron.* **2007**, *26*, 121–129. [[CrossRef](#)]
32. Timmermans, B.G.H.; Vos, J.; van Nieuwburg, J.; Stomph, T.J.; van der Putten, P.E.L. Germination rates of *Solanum sisymbriifolium*: Temperature response models, effects of temperature fluctuations and soil water potential. *Seed Sci. Res.* **2007**, *17*, 221–231. [[CrossRef](#)]
33. Vicente-Serrano, S.M.; Beguería, S.; López-Moreno, J.I. A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *J. Clim.* **2010**. [[CrossRef](#)]
34. Bijaber, N.; El Hadani, D.; Saidi, M.; Svoboda, M.D.; Wardlow, B.D.; Hain, C.R.; Poulsen, C.C.; Yessaf, M.; Rochdi, A. Developing a remotely sensed drought monitoring indicator for Morocco. *Geosciences* **2018**, *8*, 55. [[CrossRef](#)]
35. Hayes, M.J.; Svoboda, M.D.; Wardlow, B.D.; Anderson, M.C.; Kogan, F. Drought Monitoring: Historical and Current Perspectives. Available online: <https://digitalcommons.unl.edu/droughtfacpub/94/> (accessed on 27 November 2020).
36. Le Page, M.; Zribi, M. Analysis and Predictability of Drought In Northwest Africa Using Optical and Microwave Satellite Remote Sensing Products. *Sci. Rep.* **2019**. [[CrossRef](#)]
37. Zargar, A.; Sadiq, R.; Naser, B.; Khan, F.I. A review of drought indices. *Environ. Rev.* **2011**, *19*, 333–349. [[CrossRef](#)]
38. Hazaymeh, K.; Hassan, Q.K. Remote sensing of agricultural drought monitoring: A state of art review. *AIMS Environ. Sci.* **2016**. [[CrossRef](#)]
39. Singh, R.P.; Roy, S.; Kogan, F. Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. *Int. J. Remote Sens.* **2003**. [[CrossRef](#)]
40. Liu, W.T.; Kogan, F.N. Monitoring regional drought using the vegetation condition index. *Int. J. Remote Sens.* **1996**. [[CrossRef](#)]
41. Unganai, L.S.; Kogan, F.N. Drought monitoring and corn yield estimation in southern Africa from AVHRR data. *Remote Sens. Environ.* **1998**. [[CrossRef](#)]
42. Salazar, L.; Kogan, F.; Roytman, L. Use of remote sensing data for estimation of winter wheat yield in the United States. *Int. J. Remote Sens.* **2007**. [[CrossRef](#)]
43. Vicente-Serrano, S.M. Evaluating the impact of drought using remote sensing in a Mediterranean, Semi-arid Region. *Nat. Hazards* **2007**. [[CrossRef](#)]
44. Kogan, F.N. Global Drought Watch from Space. *Bull. Am. Meteorol. Soc.* **1997**. [[CrossRef](#)]
45. Bento, V.A.; Trigo, I.F.; Gouveia, C.M.; DaCamara, C.C. Contribution of Land Surface Temperature (TCI) to Vegetation Health Index: A comparative study using clear sky and all-weather climate data records. *Remote Sens.* **2018**, *9*, 1324. [[CrossRef](#)]
46. Bento, V.A.; Gouveia, C.M.; DaCamara, C.C.; Trigo, I.F. A climatological assessment of drought impact on vegetation health index. *Agric. For. Meteorol.* **2018**. [[CrossRef](#)]

47. Bento, V.A.; Gouveia, C.M.; DaCamara, C.C.; Libonati, R.; Trigo, I.F. The roles of NDVI and Land Surface Temperature when using the Vegetation Health Index over dry regions. *Glob. Planet. Chang.* **2020**, *190*, 103198. [[CrossRef](#)]
48. Zhang, A.; Jia, G. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. *Remote Sens. Environ.* **2013**, *134*, 12–23. [[CrossRef](#)]
49. Reichle, R.H.; Koster, R.D.; Liu, P.; Mahanama, S.P.P.; Njoku, E.G.; Owe, M. Comparison and assimilation of global soil moisture retrievals from the Advanced Microwave Scanning Radiometer for the Earth Observing System (AMSR-E) and the Scanning Multichannel Microwave Radiometer (SMMR). *J. Geophys. Res.* **2007**, *112*, 1–14. [[CrossRef](#)]
50. Albergel, C.; Munier, S.; Jennifer Leroux, D.; Dewaele, H.; Fairbairn, D.; Lavinia Barbu, A.; Gelati, E.; Dorigo, W.; Faroux, S.; Meurey, C.; et al. Sequential assimilation of satellite-derived vegetation and soil moisture products using SURFEX-v8.0: LDAS-Monde assessment over the Euro-Mediterranean area. *Geosci. Model Dev.* **2017**. [[CrossRef](#)]
51. Kumar, S.V.; Jasinski, M.; Mocko, D.M.; Rodell, M.; Borak, J.; Li, B.; Beaudoin, H.K.; Peters-Lidard, C.D. NCA-LDAS Land Analysis: Development and Performance of a Multisensor, Multivariate Land Data Assimilation System for the National Climate Assessment. *J. Hydrometeorol.* **2019**. [[CrossRef](#)]
52. Sawada, Y.; Koike, T.; Walker, J.P. A land data assimilation system for simultaneous simulation of soil moisture and vegetation dynamics. *J. Geophys. Res.* **2015**. [[CrossRef](#)]
53. McNally, A.; Arsenault, K.; Kumar, S.; Shukla, S.; Peterson, P.; Wang, S.; Funk, C.; Peters-Lidard, C.D.; Verdin, J.P. A land data assimilation system for sub-Saharan Africa food and water security applications. *Sci. Data* **2017**. [[CrossRef](#)]
54. Han, E.; Crow, W.T.; Holmes, T.; Bolten, J. Benchmarking a soil moisture data assimilation system for agricultural drought monitoring. *J. Hydrometeorol.* **2014**, *15*, 1117–1134. [[CrossRef](#)]
55. Blyverket, J.; Hamer, P.D.; Schneider, P.; Albergel, C.; Lahoz, W.A. Monitoring soil moisture drought over northern high latitudes from space. *Remote Sens.* **2019**, *10*, 1200. [[CrossRef](#)]
56. Bolten, J.D.; Crow, W.T.; Jackson, T.J.; Zhan, X.; Reynolds, C.A. Evaluating the Utility of Remotely Sensed Soil Moisture Retrievals for Operational Agricultural Drought Monitoring. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2010**. [[CrossRef](#)]
57. Renzullo, L.J.; van Dijk, A.I.J.M.; Perraud, J.M.; Collins, D.; Henderson, B.; Jin, H.; Smith, A.B.; McJannet, D.L. Continental satellite soil moisture data assimilation improves root-zone moisture analysis for water resources assessment. *J. Hydrol.* **2014**. [[CrossRef](#)]
58. Draper, C.S.; Mahfouf, J.F.; Walker, J.P. An EKF assimilation of AMSR-E soil moisture into the ISBA land surface scheme. *J. Geophys. Res. Atmos.* **2009**. [[CrossRef](#)]
59. Albergel, C.; Calvet, J.C.; Mahfouf, J.F.; Rüdiger, C.; Barbu, A.L.; Lafont, S.; Roujean, J.L.; Walker, J.P.; Crapeau, M.; Wigneron, J.P. Monitoring of water and carbon fluxes using a land data assimilation system: A case study for southwestern France. *Hydrol. Earth Syst. Sci.* **2010**. [[CrossRef](#)]
60. Ragab, R. Towards a continuous operational system to estimate the root-zone soil moisture from intermittent remotely sensed surface moisture. *J. Hydrol.* **1995**. [[CrossRef](#)]
61. Walker, J.P.; Willgoose, G.R.; Kalma, J.D. One-dimensional soil moisture profile retrieval by assimilation of near-surface measurements: A simplified soil moisture model and field application. *J. Hydrometeorol.* **2001**. [[CrossRef](#)]
62. Bolten, J.D.; Crow, W.T. Improved prediction of quasi-global vegetation conditions using remotely-sensed surface soil moisture. *Geophys. Res. Lett.* **2012**. [[CrossRef](#)]
63. Albergel, C.; Munier, S.; Bocher, A.; Bonan, B.; Zheng, Y.; Draper, C.; Leroux, D.J.; Calvet, J.C. LDAS-Monde sequential assimilation of satellite derived observations applied to the contiguous US: An ERA-5 driven reanalysis of the land surface variables. *Remote Sens.* **2018**, *10*, 1627. [[CrossRef](#)]
64. Kogan, F.N. Application of vegetation index and brightness temperature for drought detection. *Adv. Sp. Res.* **1995**. [[CrossRef](#)]
65. Gao, B.C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* **1996**. [[CrossRef](#)]
66. Wang, P.X.; Li, X.W.; Gong, J.Y.; Song, C. Vegetation temperature condition index and its application for drought monitoring. In Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS), Sydney, Australia, 9–13 July 2001.

67. Peters, A.J.; Walter-Shea, E.A.; Ji, L.; Viña, A.; Hayes, M.; Svoboda, M.D. Drought monitoring with NDVI-based Standardized Vegetation Index. *Photogramm. Eng. Remote Sens.* **2002**, *68*, 71–75.
68. Gu, Y.; Brown, J.F.; Verdin, J.P.; Wardlow, B. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. *Geophys. Res. Lett.* **2007**. [[CrossRef](#)]
69. Wang, L.; Qu, J.J. NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. *Geophys. Res. Lett.* **2007**. [[CrossRef](#)]
70. Ghulam, A.; Li, Z.L.; Qin, Q.; Yimit, H.; Wang, J. Estimating crop water stress with ETM+ NIR and SWIR data. *Agric. For. Meteorol.* **2008**. [[CrossRef](#)]
71. Rhee, J.; Im, J.; Carbone, G.J. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sens. Environ.* **2010**, *114*, 2875–2887. [[CrossRef](#)]
72. Anderson, M.C.; Zolin, C.A.; Sentelhas, P.C.; Hain, C.R.; Semmens, K.; Tugrul Yilmaz, M.; Gao, F.; Otkin, J.A.; Tetrault, R. The Evaporative Stress Index as an indicator of agricultural drought in Brazil: An assessment based on crop yield impacts. *Remote Sens. Environ.* **2016**, *174*, 82–99. [[CrossRef](#)]
73. Zhang, X.; Chen, N.; Li, J.; Chen, Z.; Niyogi, D. Multi-sensor integrated framework and index for agricultural drought monitoring. *Remote Sens. Environ.* **2017**, *188*, 141–163. [[CrossRef](#)]
74. Jiao, W.; Tian, C.; Chang, Q.; Novick, K.A.; Wang, L. Agricultural and Forest Meteorology A new multi-sensor integrated index for drought monitoring. *Agric. For. Meteorol.* **2019**, *268*, 74–85. [[CrossRef](#)]
75. Hu, T.; Renzullo, L.J.; van Dijk, A.I.J.M.; He, J.; Tian, S.; Xu, Z.; Zhou, J.; Liu, T.; Liu, Q. Monitoring agricultural drought in Australia using MTSAT-2 land surface temperature retrievals. *Remote Sens. Environ.* **2020**, *236*. [[CrossRef](#)]
76. Driouech, F.; Déqué, M.; Sánchez-Gómez, E. Weather regimes-Moroccan precipitation link in a regional climate change simulation. *Glob. Planet. Chang.* **2010**, *72*, 1–10. [[CrossRef](#)]
77. Knippertz, P.; Christoph, M.; Speth, P. Long-term precipitation variability in Morocco and the link to the large-scale circulation in recent and future climates. *Meteorol. Atmos. Phys.* **2003**. [[CrossRef](#)]
78. Balaghi, R.; Jlibene, M.; Tychon, B.; Mrabet, R. Gestion du risque de sécheresse agricole au Maroc. *Sci. Chang. Planét. Sécheresse* **2007**, *18*, 169–176. [[CrossRef](#)]
79. Beguería, S.; Vicente-Serrano, S.M.; Reig, F.; Latorre, B. Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *Int. J. Climatol.* **2014**. [[CrossRef](#)]
80. Abbasi, A.; Khalili, K.; Behmanesh, J.; Shirzad, A. Drought monitoring and prediction using SPEI index and gene expression programming model in the west of Urmia Lake. *Theor. Appl. Climatol.* **2019**, *138*, 553–567. [[CrossRef](#)]
81. Tirivarombo, S.; Osupile, D.; Eliasson, P. Drought monitoring and analysis: Standardised Precipitation Evapotranspiration Index (SPEI) and Standardised Precipitation Index (SPI). *Phys. Chem. Earth* **2018**, *106*, 1–10. [[CrossRef](#)]
82. Wang, F.; Yang, H.; Wang, Z.; Zhang, Z.; Li, Z. Drought evaluation with CMORPH satellite precipitation data in the Yellow River basin by using Gridded Standardized Precipitation Evapotranspiration Index. *Remote Sens.* **2019**, *11*, 485. [[CrossRef](#)]
83. Hersbach, H.; Bell, B.; Berrisford, P.; Hirahara, S.; Horányi, A.; Muñoz-Sabater, J.; Nicolas, J.; Peubey, C.; Radu, R.; Schepers, D.; et al. The ERA5 global reanalysis. *Q. J. R. Meteorol. Soc.* **2020**. [[CrossRef](#)]
84. Begueria, S.; Serrano, V.; Sawasawa, H. SPEI: Calculation of Standardised Precipitation-Evapotranspiration Index. R Package Version 1.7. Available online: <https://cran.r-project.org/web/packages/SPEI/SPEI.pdf> (accessed on 27 November 2020).
85. Allen, R.G.; Pereira, L.S.; Raes, D.; Smith, M. Crop Evapotranspiration—Guidelines for Computing Crop Water Requirements—FAO Irrigation and Drainage Paper 56. Available online: https://appgeodb.nancy.inra.fr/biljou/pdf/Allen_FAO1998.pdf (accessed on 27 November 2020).
86. Jlibene, M. Options Génétiques D’adaptation du Blé Tendre au Changement Climatique. Prix Hassan II pour L’innovation et la Recherche, Édition 2009. Available online: <https://www.inra.org.ma/sites/default/files/publications/ouvrages/jlibene11.pdf> (accessed on 27 November 2020).
87. Bouras, E.; Jarlan, L.; Khabba, S.; Er-Raki, S.; Dezetter, A.; Sghir, F.; Tramblay, Y. Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco. *Sci. Rep.* **2019**, *9*. [[CrossRef](#)]

88. Ryan, J.; Monem, M.A.; Amri, A. Nitrogen fertilizer response of some barley varieties in semi-arid conditions in Morocco. *J. Agric. Sci. Technol.* **2009**, *11*, 227–236.
89. Duchemin, B.; Fieuzal, R.; Rivera, M.; Ezzahar, J.; Jarlan, L.; Rodriguez, J.; Hagolle, O.; Watts, C. Impact of Sowing Date on Yield and Water Use Efficiency of Wheat Analyzed through Spatial Modeling and FORMOSAT-2 Images. *Remote Sens.* **2015**, *7*, 5951–5979. [[CrossRef](#)]
90. Kaufman, L.; Rousseeuw, P.J. Finding Groups in Data: An Introduction to Cluster Analysis (Wiley Series in Probability and Statistics). Available online: <https://www.wiley.com/en-us/Finding+Groups+in+Data%3A+An+Introduction+to+Cluster+Analysis-p-9780470317488> (accessed on 27 November 2020).
91. Du, L.; Tian, Q.; Yu, T.; Meng, Q.; Jancso, T.; Udvardy, P.; Huang, Y. A comprehensive drought monitoring method integrating MODIS and TRMM data. *Int. J. Appl. Earth Obs. Geoinf.* **2013**. [[CrossRef](#)]
92. Kogan, F.N. Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bull. Am. Meteorol. Soc.* **1995**. [[CrossRef](#)]
93. Holben, B.N. Characteristics of maximum-value composite images from temporal AVHRR data. *Int. J. Remote Sens.* **1986**. [[CrossRef](#)]
94. Wan, Z. A generalized split-window algorithm for retrieving land-surface temperature from space. *IEEE Trans. Geosci. Remote Sens.* **1996**. [[CrossRef](#)]
95. Qiu, J.; Crow, W.T.; Nearing, G.S.; Mo, X.; Liu, S. The impact of vertical measurement depth on the information content of soil moisture times series data. *Geophys. Res. Lett.* **2014**. [[CrossRef](#)]
96. Ceballos, A.; Scipal, K.; Wagner, W.; Martínez-Fernández, J. Validation of ERS scatterometer-derived soil moisture data in the central part of the Duero Basin, Spain. *Hydrol. Process.* **2005**. [[CrossRef](#)]
97. Albergel, C.; Rüdiger, C.; Pellarin, T.; Calvet, J.C.; Fritz, N.; Froissard, F.; Suquia, D.; Petitpa, A.; Piguet, B.; Martin, E. From near-surface to root-zone soil moisture using an exponential filter: An assessment of the method based on in-situ observations and model simulations. *Hydrol. Earth Syst. Sci.* **2008**. [[CrossRef](#)]
98. Brocca, L.; Hasenauer, S.; Lacava, T.; Melone, F.; Moramarco, T.; Wagner, W.; Dorigo, W.; Matgen, P.; Martínez-Fernández, J.; Llorens, P.; et al. Soil moisture estimation through ASCAT and AMSR-E sensors: An intercomparison and validation study across Europe. *Remote Sens. Environ.* **2011**. [[CrossRef](#)]
99. Zribi, M.; Paris Anguela, T.; Duchemin, B.; Lili, Z.; Wagner, W.; Hasenauer, S.; Chehbouni, A. Relationship between soil moisture and vegetation in the Kairouan plain region of Tunisia using low spatial resolution satellite data. *Water Resour. Res.* **2010**. [[CrossRef](#)]
100. Wagner, W.; Lemoine, G.; Rott, H. A method for estimating soil moisture from ERS Scatterometer and soil data. *Remote Sens. Environ.* **1999**. [[CrossRef](#)]
101. Bauer-Marschallinger, B. Copernicus Global Land Operations “Vegetation and Energy”. *Copernicus Publ. Prod. User Man.* **2018**, *51*, 1–85.
102. Paulik, C.; Dorigo, W.; Wagner, W.; Kidd, R. Validation of the ASCAT soil water index using in situ data from the International Soil moisture network. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *30*, 1–8. [[CrossRef](#)]
103. Bartalis, Z.; Naeimi, V.; Wagner, W. *ASCAT Soil Moisture Product Handbook*; ASCAT Soil Moisture Report Series, No. 15; Institute of Photogrammetry and Remote Sensing, Vienna University of Technology: Vienna, Austria, 2008.
104. Krueger, E.S.; Ochsner, T.E.; Quiring, S.M. Development and evaluation of soil moisture-based indices for agricultural drought monitoring. *Agron. J.* **2019**, *111*, 1392–1406. [[CrossRef](#)]
105. Dorigo, W.; Wagner, W.; Albergel, C.; Albrecht, F.; Balsamo, G.; Brocca, L.; Chung, D.; Ertl, M.; Forkel, M.; Gruber, A.; et al. ESA CCI Soil Moisture for improved Earth system understanding: State-of-the art and future directions. *Remote Sens. Environ.* **2017**, *203*, 185–215. [[CrossRef](#)]
106. Masson, V.; Le Moigne, P.; Martin, E.; Faroux, S.; Alias, A.; Alkama, R.; Belamari, S.; Barbu, A.; Boone, A.; Bouyssel, F.; et al. The SURFEXv7.2 land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geosci. Model Dev.* **2013**. [[CrossRef](#)]
107. Fairbairn, D.; Lavinia Barbu, A.; Napoly, A.; Albergel, C.; Mahfouf, J.F.; Calvet, J.C. The effect of satellite-derived surface soil moisture and leaf area index land data assimilation on streamflow simulations over France. *Hydrol. Earth Syst. Sci.* **2017**. [[CrossRef](#)]
108. Mahfouf, J.F.; Bergaoui, K.; Draper, C.; Bouyssel, F.; Taillefer, F.; Taseva, L. A comparison of two off-line soil analysis schemes for assimilation of screen level observations. *J. Geophys. Res. Atmos.* **2009**. [[CrossRef](#)]
109. Noilhan, J.; Mahfouf, J.F. The ISBA land surface parameterisation scheme. *Glob. Planet. Chang.* **1996**. [[CrossRef](#)]

110. Calvet, J.C.; Noilhan, J.; Roujean, J.L.; Bessemoulin, P.; Cabelguenne, M.; Olioso, A.; Wigneron, J.P. An interactive vegetation SVAT model tested against data from six contrasting sites. *Agric. For. Meteorol.* **1998**. [[CrossRef](#)]
111. Gibelin, A.L.; Calvet, J.C.; Roujean, J.L.; Jarlan, L.; Los, S.O. Ability of the land surface model ISBA-A-gs to simulate leaf area index at the global scale: Comparison with satellites products. *J. Geophys. Res. Atmos.* **2006**. [[CrossRef](#)]
112. Genovese, G.; Vignolles, C.; Nègre, T.; Passera, G. A methodology for a combined use of normalised difference vegetation index and CORINE land cover data for crop yield monitoring and forecasting. A case study on Spain. *Agronomie* **2001**. [[CrossRef](#)]
113. Faroux, S.; Kaptué Tchuenté, A.T.; Roujean, J.-L.; Masson, V.; Martin, E.; Le Moigne, P. ECOCLIMAP-II/Europe: A twofold database of ecosystems and surface parameters at 1 km resolution based on satellite information for use in land surface, meteorological and climate models. *Geosci. Model Dev.* **2013**. [[CrossRef](#)]
114. Masson, V.; Champeaux, J.L.; Chauvin, F.; Meriguet, C.; Lacaze, R. A global database of land surface parameters at 1-km resolution in meteorological and climate models. *J. Clim.* **2003**. [[CrossRef](#)]
115. Chu, L.; Liu, G.H.; Huang, C.; Liu, Q.S. Phenology detection of winter wheat in the Yellow River delta using MODIS NDVI time-series data. In Proceedings of the 2014 3rd Int. Conf. Agro-Geoinformatics, Agro-Geoinformatics 2014, Beijing, China, 11–14 August 2014. [[CrossRef](#)]
116. Bradley, B.A.; Jacob, R.W.; Hermance, J.F.; Mustard, J.F. A curve fitting procedure to derive inter-annual phenologies from time series of noisy satellite NDVI data. *Remote Sens. Environ.* **2007**. [[CrossRef](#)]
117. Viña, A.; Gitelson, A.A.; Rundquist, D.C.; Keydan, G.; Leavitt, B.; Schepers, J. Monitoring maize (*Zea mays* L.) phenology with remote sensing. *Agron. J.* **2004**, *96*, 1139–1147.
118. Li, L.; Friedl, M.A.; Xin, Q.; Gray, J.; Pan, Y.; Frolking, S. Mapping crop cycles in China using MODIS-EVI time series. *Remote Sens.* **2014**, *11*, 2473–2493. [[CrossRef](#)]
119. Zhang, X.; Obringer, R.; Wei, C.; Chen, N.; Niyogi, D. Droughts in India from 1981 to 2013 and Implications to Wheat Production. *Sci. Rep.* **2017**. [[CrossRef](#)]
120. Modanesi, S.; Massari, C.; Camici, S.; Brocca, L.; Amarnath, G. Do Satellite Surface Soil Moisture Observations Better Retain Information About Crop-Yield Variability in Drought Conditions? *Water Resour. Res.* **2020**. [[CrossRef](#)]
121. Kogan, F.; Yang, B.; Guo, W.; Pei, Z.; Jiao, X. Modelling corn production in China using AVHRR-based vegetation health indices. *Int. J. Remote Sens.* **2005**. [[CrossRef](#)]
122. Jung, T.; Vitart, F.; Ferranti, L.; Morcrette, J.J. Origin and predictability of the extreme negative NAO winter of 2009/10. *Geophys. Res. Lett.* **2011**, *38*. [[CrossRef](#)]
123. Savin, R.; Slafer, G.A. Shading effects on the yield of an Argentinian wheat cultivar. *J. Agric. Sci.* **1991**. [[CrossRef](#)]
124. Warrington, I.J.; Dunstone, R.L.; Green, L.M. Temperature effects at three development stages on the yield of the wheat ear. *Aust. J. Agric. Res.* **1977**. [[CrossRef](#)]
125. Ritchie, J.T.; Singh, U.; Godwin, D.C.; Bowen, W.T. Cereal Growth, Development and Yield. 1998. Available online: https://link.springer.com/chapter/10.1007/978-94-017-3624-4_5 (accessed on 27 November 2020).
126. Tuvdendorj, B.; Wu, B.; Zeng, H.; Batdelger, G.; Nanzad, L. Determination of appropriate remote sensing indices for spring wheat yield estimation in Mongolia. *Remote Sens.* **2019**, *11*, 568. [[CrossRef](#)]
127. Li, X.; Troy, T.J. Changes in rainfed and irrigated crop yield response to climate in the western US. *Environ. Res. Lett.* **2018**. [[CrossRef](#)]
128. Bachmair, S.; Tanguy, M.; Hannaford, J.; Stahl, K. How well do meteorological indicators represent agricultural and forest drought across Europe? *Environ. Res. Lett.* **2018**, *13*. [[CrossRef](#)]
129. Amri, R.; Zribi, M.; Lili-Chabaane, Z.; Wagner, W.; Hasenauer, S. Analysis of C-band scatterometer moisture estimations derived over a semiarid region. *IEEE Trans. Geosci. Remote Sens.* **2012**. [[CrossRef](#)]
130. Sawada, Y.; Koike, T.; Ikoma, E.; Kitsuregawa, M. Monitoring and Predicting Agricultural Droughts for a Water-Limited Subcontinental Region by Integrating a Land Surface Model and Microwave Remote Sensing. *IEEE Trans. Geosci. Remote Sens.* **2019**. [[CrossRef](#)]
131. Sarto, M.V.M.; Sarto, J.R.W.; Rampim, L.; Bassegio, D.; da Costa, P.F.; Inagaki, A.M. Wheat phenology and yield under drought: A review. *Aust. J. Crop Sci.* **2017**. [[CrossRef](#)]
132. Mavromatis, T. Drought index evaluation for assessing future wheat production in Greece. *Int. J. Climatol.* **2007**, *27*, 911–924. [[CrossRef](#)]

133. Wu, H.; Hubbard, K.G.; Wilhite, D.A. An agricultural drought risk-assessment model for corn and soybeans. *Int. J. Climatol.* **2004**, *24*, 723–741. [[CrossRef](#)]

Publisher’s Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

IV) Conclusion

L'objectif de ce chapitre était d'évaluer le lien entre le rendement des céréales et la sécheresse agricole au Maroc. La sécheresse agricole a été identifiée à travers des indices de télédétection et les anomalies des sorties du LDAS. L'évaluation de lien entre le rendement et la sécheresse agricole a été réalisée à l'aide d'une analyse de corrélation entre les différentes variables et indices de télédétection et le rendement à l'échelle de la province agricole. Les principaux résultats obtenus montrent que, le SMCI, SWI10, WG2 et Ev (évaporation du sol), en tant qu'indicateurs des conditions d'humidité superficielle, sont fortement liés aux rendements pendant le début de saison agricole autour de l'émergence, tandis que les rendements sont corrélés à l'humidité dans les couches plus profondes, plus tard dans la saison à cause de développement des racines (WG4 à WG8, SWI40 et SWI60). En outre, les conditions de température de surface fournies par le TCI et indirectement par la transpiration influencent principalement les rendements pendant le stade de développement, tandis que les indices de végétation (VCI et LAI) sont fortement corrélés au rendement autour du pic de développement des céréales aux mois de mars-avril. Les résultats ont aussi montré que les sorties du LDAS de Météo-France sont fortement corrélés au rendement par rapport aux indices de télédétection, pour toutes les variables et en particulier pour les variables liées au profil humidité du sol. L'échelle de temps mensuelle est la plus utilisée dans la littérature pour le calcul des indices de sécheresse. Dans notre étude, nous avons intégré ces indices à l'échelle des principaux stades phénologiques. Les résultats ont montré des corrélations plus élevées avec l'intégration sur l'échelle des stades phénologique, mais l'amélioration est limitée, sauf pour l'indice lié à l'humidité superficielle pendant le stade de l'émergence. Dans le chapitre suivant, ces résultats sont exploités pour le développement de modèles de prévisions saisonnières des rendements en blé sur le Maroc à l'échelle de la province agricole.

Chapitre III : Prévision saisonnière des rendements des céréales au Maroc

Les résultats de ce chapitre sont présentés dans l'article suivant : Bouras, E., Jarlan, L., Er-Raki, Balaghi, R., Amazirh, A., Richard, B., and Khabba, S., 2021. Cereal Yield Forecasting with Satellite Drought-Based Indices, Weather Data and Regional Climate Indices Using Machine Learning in Morocco. Remote Sens. 2021, 13(16), 3101; <https://doi.org/10.3390/rs13163101>

I) Introduction

Le changement climatique va affecter la production agricole mondiale dans le futur (Asseng et al., 2015; FAO, 2016) et il va menacer la sécurité alimentaire dans plusieurs régions du globe dont les zones méditerranéennes qui sont identifiées depuis longtemps comme un « hotspot » du changement climatique (Giorgi, 2006; Lionello en Scarascia, 2018). En plus du changement attendu des caractéristiques moyennes du climat, notamment la température et les précipitations, l'augmentation de la fréquence des événements extrêmes peuvent réduire encore davantage la production agricole. En effet, la sécheresse peut être responsable d'une perte de la production agricole de 10 à 35% selon son intensité, sa durée, et son étendue spatiale (Kogan et al., 2019). La fréquence et l'intensité des périodes de sécheresse vont augmenter dans le futur (Vicente-Serrano et al., 2020). Dans ce contexte, la prévision saisonnière précise des rendements des cultures est un outil important d'aide à la décision, afin de prévoir le plus tôt possible les besoins d'importation. De plus, elle fournit des informations essentielles permettant aux agriculteurs de prendre des décisions rapides pour augmenter les rendements en améliorant les pratiques agricoles pendant la saison de croissance (Peng et al., 2016). L'objectif de ce chapitre est de développer des modèles empiriques de prévision saisonnière du rendement des céréales au Maroc à l'échelle provinciale en utilisant différentes approches de machine learning.

II) Résumé de l'article

Dans cette partie, nous visons à développer des modèles de prévision saisonnière du rendement des céréales pour les 15 provinces les plus productives au Maroc. Pour ce faire, nous nous sommes appuyés sur les résultats du chapitre précédent où nous avons trouvé une forte corrélation entre les indices de sécheresse issus des observations satellitaires à différentes longueurs d'onde et le rendement des céréales. En outre, nous nous sommes également appuyés sur les résultats de Jarlan et al. (2014) qui ont montré une relation entre les rendements et des variables et indices témoignant des phénomènes pseudo-oscillatoire du climat à grande échelle (indices dérivés de variables atmosphérique notamment les principaux modes de variabilité de l'atmosphère de l'hémisphère nord : ONA et -Scandinavian Pattern -SCA-, SST et dérivés des températures de surface des océans : le mode équatorial ou Niño Atlantique et le mode Tripôle Atlantique). Dans notre étude, nous avons évalué la performance de la combinaison entre indices de télédétection, les observations météorologiques et les indices climatiques pour prédire le rendement des céréales au Maroc. Afin de construire les modèles de prévision avec ces données, nous avons utilisé une approche linéaire (régression linéaire multiple) et plusieurs approches non-linéaire basées sur les algorithmes de machine learning les plus utilisés dans la

littérature. Ces algorithmes sont SVM, RF et XGBoost. Nos résultats montrent que la combinaison de données provenant de plusieurs sources a donné de meilleures performances que les modèles basés sur un seul ensemble de données. Nous avons trouvé également que le XGBoost est le meilleur outil avec un $R^2 = 0.88$ et un RMSE d'environ 0.22 t. ha^{-1} en janvier par exemple. Nos résultats montrent également que la précision des prévisions augmente à mesure que l'on se rapproche de la date de la récolte. Les indices de sécheresse de télédétection sont des prédictors potentiels du rendement des céréales lorsque la prévision est effectuée à proximité de la récolte (au mois de mars), tandis que les données météorologiques et, les indices climatiques, sont des variables clés pour la prévision précoce du rendement dès le mois de janvier.

III) Article



Article

Cereal Yield Forecasting with Satellite Drought-Based Indices, Weather Data and Regional Climate Indices Using Machine Learning in Morocco

El houssaine Bouras ^{1,2,*}, Lionel Jarlan ², Salah Er-Raki ^{1,3}, Riad Balaghi ⁴, Abdelhakim Amazirh ³, Bastien Richard ⁵ and Saïd Khabba ^{3,6}

- ¹ ProcEDE, Department of Applied Physique, Faculty of Sciences and Technologies, Cadi Ayyad University, Marrakech 40000, Morocco; s.erraki@uca.ma
- ² CESBIO, University of Toulouse, IRD/CNRS/UPS/CNES, 31400 Toulouse, France; lionel.jarlan@ird.fr
- ³ Center for Remote Sensing Applications (CRSA), University Mohammed VI Polytechnic (UM6P), Benguerir 43150, Morocco; abdelhakim.amazirh@um6p.ma (A.A.); khabba@uca.ma (S.K.)
- ⁴ National Institute for Agronomic Research (INRA), Rabat 10000, Morocco; riad.balaghi@inra.ma
- ⁵ G-EAU, University Montpellier, AgroParisTech, CIRAD, IRD, INRAE, Institut Agro, 34000 Montpellier, France; bastien.richard@irstea.fr
- ⁶ LMFE, Department of Physics, Faculty of Sciences Semlalia, Cadi Ayyad University, Marrakech 40000, Morocco
- * Correspondence: elhoussaine.bouras@ced.uca.ma; Tel.: +212-(0)-5-2443-3404 or +212-(0)-6-0136-8700



Citation: Bouras, E.h.; Jarlan, L.; Er-Raki, S.; Balaghi, R.; Amazirh, A.; Richard, B.; Khabba, S. Cereal Yield Forecasting with Satellite Drought-Based Indices, Weather Data and Regional Climate Indices Using Machine Learning in Morocco. *Remote Sens.* **2021**, *13*, 3101. <https://doi.org/10.3390/rs13163101>

Academic Editors: Bin Chen, Yufang Jin and Le Yu

Received: 4 June 2021
Accepted: 30 July 2021
Published: 6 August 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Accurate seasonal forecasting of cereal yields is an important decision support tool for countries, such as Morocco, that are not self-sufficient in order to predict, as early as possible, importation needs. This study aims to develop an early forecasting model of cereal yields (soft wheat, barley and durum wheat) at the scale of the agricultural province considering the 15 most productive over 2000–2017 (i.e., $15 \times 18 = 270$ yields values). To this objective, we built on previous works that showed a tight linkage between cereal yields and various datasets including weather data (rainfall and air temperature), regional climate indices (North Atlantic Oscillation in particular), and drought indices derived from satellite observations in different wavelengths. The combination of the latter three data sets is assessed to predict cereal yields using linear (Multiple Linear Regression, MLR) and non-linear (Support Vector Machine, SVM; Random Forest, RF, and eXtreme Gradient Boost, XGBoost) machine learning algorithms. The calibration of the algorithmic parameters of the different approaches are carried out using a 5-fold cross validation technique and a leave-one-out method is implemented for model validation. The statistical metrics of the models are first analyzed as a function of the input datasets that are used, and as a function of the lead times, from 4 months to 2 months before harvest. The results show that combining data from multiple sources outperformed models based on one dataset only. In addition, the satellite drought indices are a major source of information for cereal prediction when the forecasting is carried out close to harvest (2 months before), while weather data and, to a lesser extent, climate indices, are key variables for earlier predictions. The best models can accurately predict yield in January (4 months before harvest) with an $R^2 = 0.88$ and RMSE around 0.22 t. ha^{-1} . The XGBoost method exhibited the best metrics. Finally, training a specific model separately for each group of provinces, instead of one global model, improved the prediction performance by reducing the RMSE by 10% to 35% depending on the provinces. In conclusion, the results of this study pointed out that combining remote sensing drought indices with climate and weather variables using a machine learning technique is a promising approach for cereal yield forecasting.

Keywords: crop yield forecasting; machine learning; remote sensing drought indices; climate indices; weather data; semiarid region

1. Introduction

Climate change will affect global crop production [1,2] and threaten food security in several regions of the globe including the Mediterranean areas that have long been identified as a hot spot for climate change [3,4]. It has been shown that a 1 °C increase in temperature would lead to a drop of 6% in global wheat production for instance [1]. Besides the expected change of the average characteristics of climate, including temperature and precipitation, extreme events can further reduce crop production. Indeed, drought, the frequency of which is expected to increase in the future [5], can be responsible for a 10% to 35% loss depending on its intensity, timing and duration [6]. The southern Mediterranean countries and Morocco, in particular, are characterized by a strong interannual variability in precipitation amounts and distribution and recurrent droughts that mainly affect rainfed crops among which wheat dominates with more than 90% of cultivated areas [7]. Within this context, achieving food security, one of the key points of the Sustainable Development Goals [8], relies on a reliable monitoring system of wheat production [2]. An early and reliable forecast of the pre-harvest cereal yield in large areas would assist decision-makers in order to anticipate important needs, especially in countries such as Morocco that are not always self-sufficient [9–12]. It would also help to identify yield gaps and to better understand the wheat response to local climatic and edaphic conditions [9,13,14].

Besides the agricultural statistics based on sample observations in the field, the monitoring and forecasting of wheat yields are mainly carried out using empirical regression-based models or crop growth models based on biophysiological processes [15]. The latter is able to describe crop growth and yield response to weather conditions, soil, and management practices [16] and can provide a good estimate of final crop yield when accurate values of input parameters and meteorological forcing variables are available; a strong drawback for southern countries considering the sparsity of the ground-based networks. Another limitation arises for seasonal forecasting in relation to the forcing meteorological data during the period between the forecast date and harvest time [17]. Seasonal weather forecasts either based on historical weather observation [18–20], on weather generators [21] or on climate model outputs [22] remain very uncertain. Given these limitations, the majority of the national agriculture departments use empirical regression-based models to forecast yield over large areas. These models rely on the use of some selected variables or indicators of environmental conditions (agrometeorological, and/or remotely sensed data) as independent variables to forecast crop yield [12,23–26]. In addition, as the quantity and the quality of observed data have increased in recent years, these models forecast crop yield with reasonable accuracy [24,27].

Weather data have long been used to explain crop yield variability [27–29]. In this context, Sierra and Brynsztein [30] have used temperature and precipitation as predictors to forecast wheat yield up to 3 months before the harvest in Argentina; Giri et al. [31] have used several meteorological variables to predict wheat yield at the district scale in India. The models developed in this study had an R^2 range between 0.6 and 0.92, depending on district's location. Nevertheless, the performance of the models was lower for some districts, which may be due to other variables influencing yields such as the soil type or the practical management. More recently, many research works have focused on establishing a relationship between remote sensing indices and observed crop yield [10,32–34]. The main advantage of using remote sensing observations in crop yield forecasting is that they allow the obtaining of information on a large scale, independent of territorial boundaries. The Normalized Difference Vegetation Index (NDVI) is one of the most widely used variables to forecast the final crop yield at a large scale [15]. For instance, the Moderate Resolution Imaging Spectroradiometer (MODIS) and Advanced Very High-Resolution Radiometer (AVHRR) derived NDVI has been used to develop linear regression models to predict maize, wheat and rice yields up to 2 to 3 months before harvest [24,35,36]. Besides, other studies have used remote sensing drought indices, such as the Vegetation Condition Index (VCI) and the Temperature Condition Index (TCI) from AVHRR data, to forecast wheat yield in the United States [34], and soybean yield in Brazil, respectively [37]. Interestingly

enough, it has been shown that the use of these drought indices to forecast crop yields in Spain outperformed models based on precipitation anomalies only [38]. This can be explained by the accurate detection of local drought conditions provided by these indices integrating information on climate and biophysical conditions when compared to indices based only on precipitation. In addition, the high spatial resolution of satellite products with regards to meteorological data provided by a coarse network of weather stations [38] may be an advantage, in particular for southern countries often characterized by sparse meteorological networks. Finally, several studies have also shown the impact of large-scale climate pseudo-oscillations on many components of the continental ecosystems including agricultural systems [39–41], and on the future monthly precipitation [41,42]. In light of this, large-scale climate indices and data, including El Niño Southern Oscillation (ENSO), the North Atlantic Oscillation (NAO) and Sea Surface Temperature (SST) have been used as predictors of crop yield in different regions over the world [41,43–45]. In Morocco, in particular, wheat yields have been shown to be tightly linked to NAO value in December and to the leading mode of the SST in the tropical Atlantic [11]. In Australia, the large-scale climate indices related to ENSO have been incorporated into empirical models to predict wheat yield up to 3 months before the harvest [41]. Instead of using a single data source as predictors of crop yield, several studies have combined multi-source data to predict crop yield. For example, Cai and Sharma, [46] and Balaghi et al. [12] combined remote sensing data (NDVI) and weather data (rainfall and temperature) as predictors of rice and wheat yield in India and Morocco, respectively.

Most of the models developed in the previously cited studies are based on the classical Multiple Linear Regression (MLR) while the linkages between yields and potential predictors are likely to be non-linear. For this reason, non-linear machine learning algorithms have been employed to improve crop yield prediction [47]. Recently, several studies have examined the performance of machine learning algorithms such as Support Vector Machine (SVM), Random Forest (RF), eXtreme Gradient Boost (XGBoost), Artificial Neural Network (ANN) and Long-Short Term Memory (LSTM) for yield forecasting at county or province scales. They have used multi-source data as predictors, and they found that the non-linear machine learning methods showed a better performance for yield forecasting than the linear approach [48–54]. Schwalbert et al. [55] have used different machine learning algorithms (linear regression, RF and LSTM) to predict soybean yield at the municipality level in Brazil by using remote sensing data (NDVI, EVI, LST) and precipitation as predictors. They found that soybean yield can be forecasted with a mean absolute error of 0.42 t. ha⁻¹ around 2 months before harvesting. Cai et al. [56] have also forecasted wheat yield in Australia by incorporating various predictors into SVM, RF and ANN algorithms. In their study, they used the enhanced vegetation index (EVI) from MODIS, solar-induced chlorophyll fluorescence from GOME-2 and several climate variables and they found that combining climate and satellite data achieved a high performance of wheat prediction ($R^2 = 0.75$). For Morocco, the existing literature on seasonal yield forecasting is limited. Balaghi et al. [12] proposed empirical linear regression models to forecast wheat yields up to 2 months before the harvest at a provincial and national scale. NDVI from AVHRR, rainfall sums and average monthly air temperatures were used. More recently, Lehmann et al. [45] have used SST and causal precursors from geopotential height anomalies at 500 hPa to forecast wheat yield anomalies at the country scale. Several studies have used the combination of multi-source datasets and machine learning algorithms to forecast crop yield including cereals [48–54]. However, the combination between remote sensing drought indices, weather data and climate indices as predictors of cereals yield has not been assessed yet.

In this context, the aim of this study is to investigate the potential of using machine learning for developing dynamic decision support systems for cereal production in Morocco, combining satellite-based drought indices, weather and climate data. Our specific objective is to develop empirical models that can forecast cereal yield early in the crop season (up to 4 months before harvest). More specifically, this study builds on previous work carried out in Morocco that highlighted biophysically sound linkages between wheat

yields and weather data and climate indices (Jarlan et al. [11]) and between wheat yields and drought indices (Bouras et al. [10]). It also aimed to go further than Balaghi et al. [12] by analyzing the potential of climate and drought indices information to forecast yields earlier in the season and at a finer spatial scale than Lehmann et al. [45].

2. Materials and Methods

In this study, the target variable is cereal yield. The potential predictors are the satellite drought indices, weather data (rainfall and temperature) and climate indices derived from atmospheric and oceanic variables. In order to limit the number of agricultural provinces, a threshold of 90% of the national production was set: the 15 selected provinces corresponding to the most productive are displayed in Figure 1. The forecasting models are then built using the extensively used multi-linear regression approach and three non-linear machine learning methods. An overview of the methodology is represented in the flowchart of Figure 2. Table 1 lists all the raw datasets with their sources. Table 2 displays the predictor variables derived from these raw datasets together with the time span of the year considered in the model based on biophysically sound linkages highlighted by previous studies.

Table 1. Summary of the raw characteristics of the data sets used for yields prediction as well as yields “observations” information. All the datasets used for yields prediction are then averaged at the agricultural province and the monthly time scales (see text).

Category	Product	Variable	Spatial Resolution	Temporal Resolution	Source of Data
Crop Yield		Crop yield	Province level	Yearly	Ministry of agriculture of Morocco
Remote sensing	MOD13A2	NDVI	1 km	16-Day	https://lpdaac.usgs.gov (accessed on 31 July 2021)
	MOD11A1	LST	1 km	Daily	
	ESA CCI SM COMBINED	SM	25 km	Daily	
Weather	ERA5	Rainfall, Air temperature	30 km	Daily	https://www.ecmwf.int/en/forecasts/dataset/reanalysis-datasets/era5 (accessed on 31 July 2021)
Climate		NAO, SCA, SST		Monthly	https://psl.noaa.gov/data/climateindices/ (accessed on 31 July 2021)

Table 2. Input predictors for the forecasting model and time span of the year when these variables are considered based on previously highlighted biophysically sound linkages.

Predictor Variables	Raw Products	Time Span of the Year	Publication
VCI	NDVI	February–April	[10–12]
TCI	LST	January–February	[10]
SMCI	SM	October–November	[10]
Air temperature	ERA5 air temperature	December	[11,12]
Rainfall	ERA5 rainfall	October–November and January–March	[11,12]
NAO	Northern Hemispheric Teleconnection Patterns	December	[11]
SCA	Northern Hemispheric Teleconnection Patterns	January	[11]
Atlantic Tripole	SST	February	[11]
Atlantic Niño	SST	October	[11]

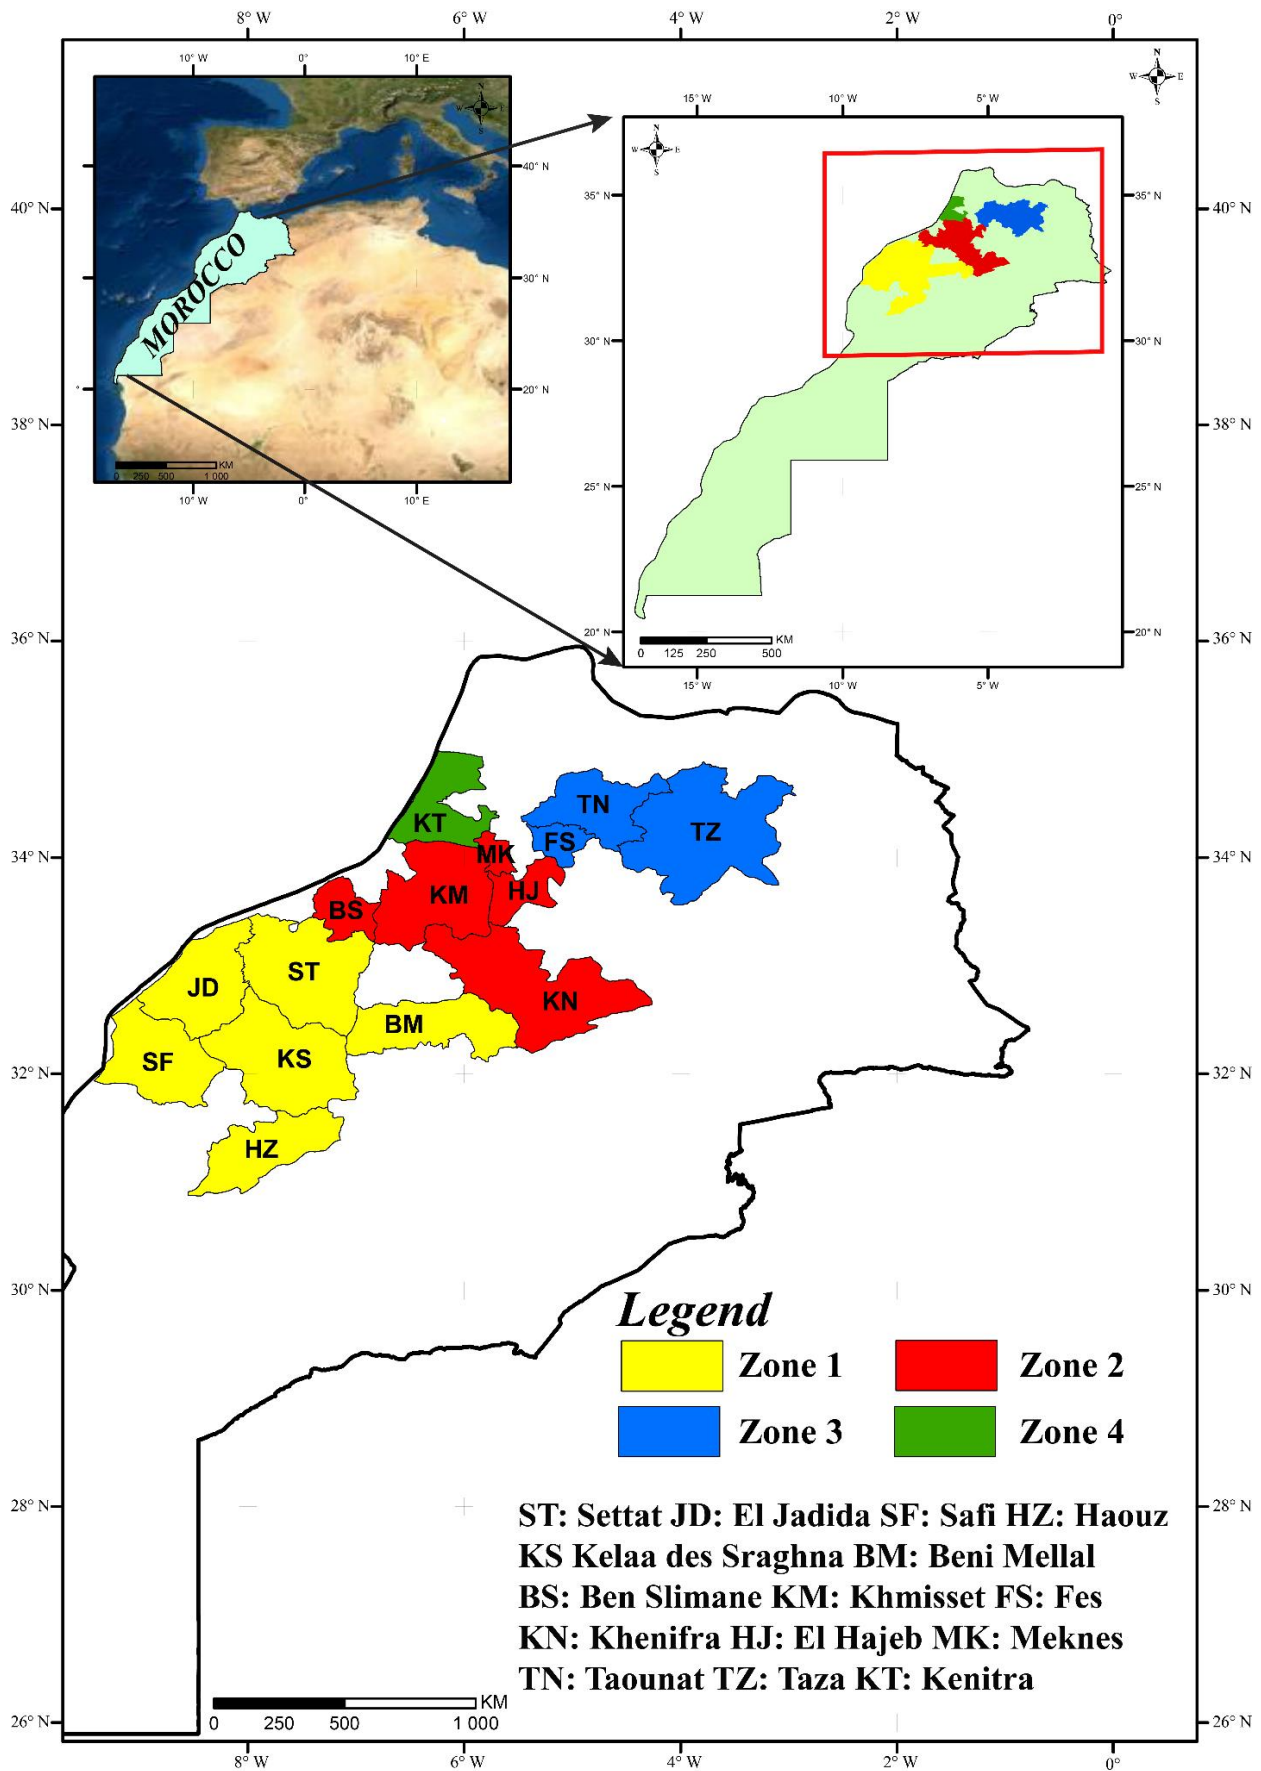


Figure 1. The study areas with the 15 provinces.

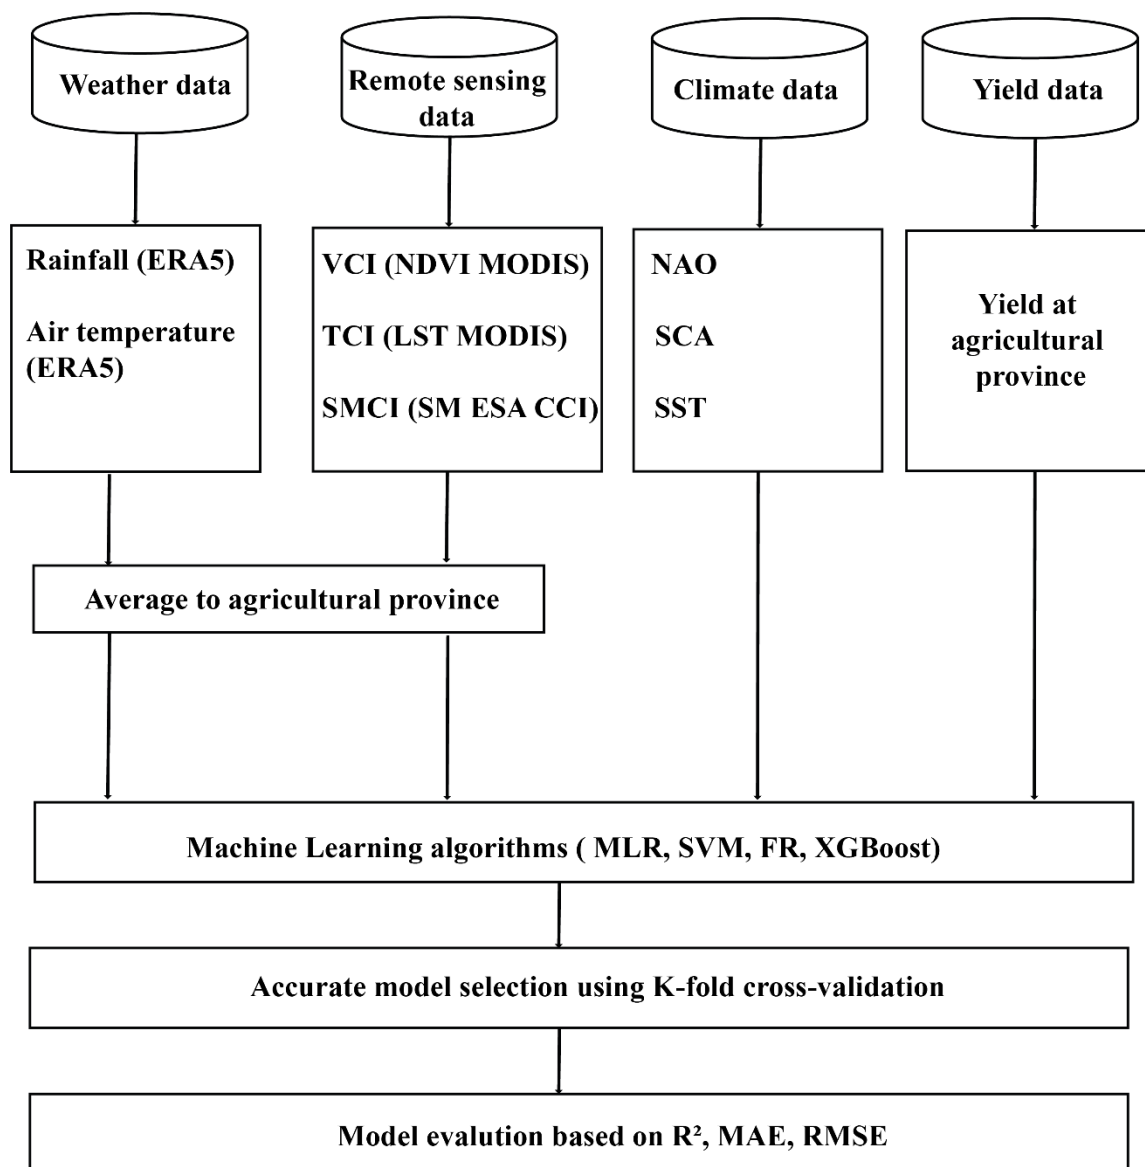


Figure 2. Schematic diagram presenting an overview of the main inputs data and the methodology proposed in this study.

2.1. Study Area

Morocco is a North African country (Figure 1) with a semi-arid climate influenced by the Atlantic Ocean, the Mediterranean Sea and the Sahara [42]. Precipitation in Morocco is characterized by its strong spatiotemporal variability and a rainfall season—extending through winter and spring from November to April, which coincides with the cereal growing season. The northern part of Morocco receives higher amounts of precipitation which can rise to 900 mm while the center of the country is marked by low amounts of precipitation below 350 mm. Similarly, the high spatial variability of the temperature is noted. The regions located at high elevation (the high Atlas Mountains) are marked by low temperatures when compared to other regions in the country [10,57]. Cereals are the main rainfed crop occupying up to 90% of the rainfed usable agricultural area in Morocco. The early sowing takes place in November if significant precipitation occurs at this time, while the sowing can be extended to January in the case of delays in precipitation. Late sowing usually leads to a lower production compared to early sowing, due to both a decrease of the cropped areas because a large part of farmers will not seed if precipitation arrives late in the season and because the last stage of

the season corresponds to periods of high temperature that may hamper yields [9]. Harvest takes place generally around the end of May.

2.2. Yield Data

Soft wheat, barley and durum wheat are the main types of cereals cropped in Morocco. Data on cereal crop productions and harvested areas over the study period 2000–2017 at the administrative provincial scale were gathered by the Economic Services of the Ministry of Agriculture in Morocco (<https://www.agriculture.gov.ma/>, accessed on 31 July 2021). The yearly cereal yield used in this study for each province was calculated as the ratio of the total crop production by the total harvest areas. The average cereal yield over the study period ranged from 0.7 t. ha⁻¹ to 2.2 t. ha⁻¹ depending on the province. The 15 selected provinces were classified into four groups with similar cereal yield interannual variability using a k-means algorithm based on the correlative distance [58]. More details about the cereal yield data and classification are provided in Bouras et al. [10].

2.3. Satellite-Based Drought Indices

Agricultural drought affects both vegetation and soil, the characteristics of which can be monitored by remote sensing observation [59]. We selected three extensively used satellite-based drought indices: the Vegetation Condition Index (VCI), the Temperature Condition Index (TCI) [60] and the Soil Moisture Condition Index (SMCI) [61]. The VCI, TCI and SMCI are the normalized anomalies of NDVI, Land Surface Temperature (LST) and soil moisture (SM), respectively. While the VCI is related to vegetation density and activity, the TCI is related to the thermal stress of vegetation and the SMCI describes soil moisture drought as it is based on soil moisture anomalies in the first centimeters. These indices were widely used in agricultural drought monitoring [10,38,62,63]. Bouras et al. [10] have analyzed the linkages between these indices and cereal yield at the provincial scale in Morocco. Their results have shown that the VCI in March and April during the heading stage of wheat is highly correlated to cereal yield. For TCI, the highest correlation with cereal yield was observed around the development stage in January–February. Finally, SMCI was found to be connected with cereal yield earlier at the beginning of crop season during the emergence stage (December–January).

The VCI was calculated with NDVI from MODIS (MOD13A2 collection 6). The VCI compares the currently observed value of NDVI to the minimum and maximum NDVI values observed during a study period. As such, the VCI lies between 0 and 100, with a low VCI value associated with below-normal vegetation development while above-normal vegetation development is indicated by a high VCI value. TCI was computed in a similar way to VCI but using the LST from MODIS LST (MOD11A1 collection 6). The high TCI values indicate low temperatures, then favorable climatic conditions, while lower values of TCI reflect unfavorable conditions with high temperatures. The SMCI is a normalization of soil moisture. SMCI lies between 0 and 100; the lower values indicate unfavorable soil moisture conditions (very dry), and the higher values indicate favorable conditions (very wet). In this study, we used the SM COMBINED version 4.2. product provided by the European Space Agency Climate Change Initiative (ESA CCI) [64].

2.4. Weather Data

The linkage between cereal yield and weather data, including rainfall and temperature over Morocco, has been analyzed in previous studies [10–12]. The main results of these studies are: for rainfall, a positive correlation with cereal yields was observed in November–December. When the rainfall is abundant during this period, it will speed up plant emergence and increase cropped areas as already highlighted. Concerning temperature, a positive correlation with cereal yields was observed in December and January during the early stage. Low temperatures during this period cause poor emergence and reduce the number of ears leading to lower yields. By contrast, a negative correlation with cereal yield was observed in March meaning that high temperatures should be avoided during the grain

filling stage occurring at this time of the year [65]. Weather data including air temperature at 2 m. above land surface and rainfall were extracted from the ERA5 re-analysis data set [66].

2.5. Climate Data

In a previous study, Jarlan et al. [11] have analyzed the relationship between provincial-scale wheat yields in Morocco and large-scale climate. Significant correlations have been found between yields and the NAO in December (negative sign), the Scandinavian Pattern (SCA) in January (positive sign) and the leading modes of SST on the northern hemisphere (“Atlantic tripole” mode) in February (negative sign) and on the equatorial Atlantic (the so-called “Atlantic Niño” mode) earlier in the season in October (positive sign). In this study, we evaluate the potentiality of introducing this climate information in addition to satellite drought indices and weather data to predict cereal yields. The NAO and the SCA are part of the Northern Hemisphere Teleconnection Patterns [67]. These indices are distributed with a monthly time scale by the Climate Prediction Center (<https://www.cpc.ncep.noaa.gov/>, accessed on 31 July 2021). In addition to these atmospheric indices, the monthly sea surface temperature (SST) leading modes are computed from monthly NOAA SST v2 at 0.25° resolution throughout the study on a North Atlantic window (20°N–70°N, 80°W–20°E) and an Equatorial Atlantic window (20°S–20°N, 80°W–20°E) for the “Atlantic tripole” and the “Atlantic Niño”, respectively, following Jarlan et al. [11].

2.6. Machine Learning Methods for Cereal Yield Forecasting

In order to build the seasonal forecasting models, we relied on Multiple Linear Regression, and three non-linear machine learning algorithms extensively used for crop yield prediction [47], which are: Support Vector Machine (SVM), Random Forest (RF) and eXtreme Gradient Boost (XGBoost). The scikit-learn package in Python 3.7 [68] was used in this study.

2.6.1. Multiple Linear Regression

In Multiple Linear Regression (MLR) [69], the dependent variable y is linearly related to multiple independent variables $x_i = 1, \dots, n$ as:

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n, \quad (1)$$

where y in this study is the predicted yield, x_i ($i = 0, \dots, n$) are the satellite-based drought indices, the weather data and/or the climate indices and a_i ($i = 0, \dots, n$) are the regression coefficients.

2.6.2. Random Forest (RF)

The RF algorithm was introduced by Breiman (2001) and is used for both classification and regression. RF for regression is an ensemble of multiple decision trees regression model; each tree provides its prediction and the optimal prediction of RF obtained by averaging the prediction of all decision trees regression in RF [70]. The RF-based model follows three steps to provide the optimal predictions. In the first step, the dataset is split into data subdivisions. In the second step, each data subdivision is used to develop a single decision tree representing a sub-regression model that gives its prediction. In the last step, predictions of all decision trees are averaged to provide the final prediction. The hyper-parameters that need to be tuned in the RF algorithm are the number of trees or the number of regression trees, the number of features to consider when looking for the best split, and the maximum depth of the tree. These hyper-parameters were tuned with a grid search method, described in Section 2.7.

2.6.3. Support Vector Machine (SVM)

The Support Vector Machine (SVM) was originally developed to solve classification problems and it was extended to solve regression problems, namely support vector regression (SVR) [71]. The SVM algorithm uses kernels [72]. By relying not only on the

minimization of the distance to training data (the training error or empirical risk) but also by trying to limit the model “complexity” (i.e., to search a function as flat as possible: the structural risk), SVR may have, a priori, better generalization capacity (i.e., for data not contained in the training set) than MLR. The SVM regression-based model passes through two steps. In the first step, by using the kernel function, which can be linear or non-linear depending on the relationship between the independent (=Crop yield in our case) and dependent variables, the independent variables (remote sensing drought indices, weather and/or climate indices in our case) are transformed from the original space to a high-dimensional feature space. In the last step, a linear model is built by the new derived feature space to minimize the errors [73]. The SVM algorithm based on the Radial Basis Function (RBF) (the most popular choice in the literature) had two hyper-parameters: the penalty factor C aiming to find a trade-off between the fitting error and the model “complexity”, and the kernel width gamma [74]. The SVM hyper-parameters were tuned with a grid search method.

2.6.4. eXtreme Gradient Boost (XGBoost)

eXtreme Gradient Boost (XGBoost) is a machine learning algorithm proposed by Chen and Guestrin (2016), derived from the Gradient Boosting Machines (GBM) [75,76]. The basic principle of the approach is to consider a set of weak learners (with high error) that are combined to develop a new stronger learner (with low error) through the introduction of training additive strategy. The main idea of boosting methods is to use the negative gradient direction of the model loss function, which was established previously, and then iteratively improves the accuracy of the model [77]. The hyper-parameters the number of gradients boosted trees, the maximum tree depth and the learning rate were tuned using the grid search method.

2.7. Model Evaluation

To select the best hyper-parameters of the ML algorithms, the comprehensive grid search (GS) was used in this study, to examine all possible combinations of the hyper-parameters, and cross-validation (CV) was used to assess the performance of the model [78]. In GS, a set of values was attributed for each hyper-parameter and a set of trials was formed by assembling every possible combination of values. The evaluation was performed using k-fold cross-validation. The CV is the most employed technique for algorithm selection and evaluation, due to its simplicity and ability to avoid over-fitting [79–82]. In k-fold cross-validation, the training data are randomly divided into k subsets and the hold-out method is repeated k times, such that each time, one of the k subsets is used as the validation set of the model constructed using (k – 1) subsets [82]. To evaluate the performance of the developed models, widely employed statistical metrics were used in this study. The coefficient of determination (R^2) reflects the degree of linear relationship between the observed and forecasted cereal yields. The mean absolute error (MAE) indicates the percentage of the average deviation of the forecasted yield from the observation. The Root Mean Square Error (RMSE) measures the discrepancy of forecasted yield around observations.

$$R^2 = \frac{(\sum_{i=1}^n ((O_i - \bar{O})(F_i - \bar{F})))^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (F_i - \bar{F})^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (3)$$

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (F_i - O_i)^2}, \quad (4)$$

where O_i is the observed yield, F_i is the forecasted yield by the machine learning algorithm, \bar{O} and \bar{F} are the averages of the observed and predicted yields and n is the number of samples used for the machine learning model.

2.8. Experiment Design

The identification of rainfed cereal areas is an important point in order to obtain values of the remote sensing drought indices representative of rainfed cereal conditions at the scale of the agricultural province. The identification of rainfed cereal areas was carried out based on the joint use of two land cover maps: ECOCLIMAP-II at a 1 km resolution [83] (<https://opensource.umr-cnrm.fr/projects/ecoclimap/wiki>, accessed on 31 July 2021) was used to determine the cereal areas and the land cover map provided by the Climate Change Initiative (CCI) land cover project of the ESA [84] (<https://www.esa-landcover-cci.org/>, accessed on 31 July 2021) at 300 m resolution was used to isolate the rainfed fields as described in Bouras et al. [10]. Remote sensing drought indices were then aggregated to the agricultural province by a simple average of these pixels identified as rainfed cereal areas. Weather data were also averaged at the scale of the agricultural province but without considering the rainfed cereal mask because of their coarse spatial resolution of about 25 km (Table 1).

Multicollinearity between the predictors variables is well known to increase the variance of the coefficients for MLR. This can limit the generalization capability of the MLR models as well as hamper the interpretation of the coefficients. In this study, no method to reduce data redundancy was applied because a pre-selection of the time span of the year considered for each predictor was carried out based on previous studies to limit collinearity. Nevertheless, the prediction metrics of the MLR models could probably be improved by applying methods to reduce collinearity such as Principal Component Analysis.

Four experiments were then designed. The first experiment was constructed to identify the best combinations of input datasets among the satellite-based drought indices, the weather data and the climate indices that will reach the high performance in forecasting final cereal yield in Morocco. For this reason, all machine learning algorithms were applied using the different combinations of available input data collected from October to April (see Table 2): (i) Satellite-based drought indices only; (ii) Satellite-based drought indices and weather data; and (iii) Satellite-based drought indices, weather and climate data. The second experiment was conducted in order to assess the performance of the models as a function of the lead time before harvest from 4 to 2 months. In this experiment, we used the best combination of inputs data, determined from the first experiment, and the input data were collected from October to January, October to February and from October to March, based on Table 2, to build the forecasting model in January, February and March, respectively. Then, the performance of machine learning models was evaluated in March, February and January which corresponds to 2, 3 and 4 months before the harvest. In addition, the importance of each input data point was computed using the best machine learning algorithm in order to assess the contribution of each input data point for each lead time of prediction. The third experiment was designed to test the practical performance of the developed models. For this reason, the predictions are performed using a “leave-one year-out” approach consisting in predicting the yield value of one year using all the other years data to train the model (for instance, yield in 2017 is predicted based on a model trained using the 2000–2016 database). Finally, the last experiment was designed to assess the performance of using specific models developed separately for each group of provinces with regards to one global model used in the previous experiments. In this experiment, the accuracy (RMSE) of the global model developed for all provinces was compared to the model developed at a regional level based on a leave-one province-out approach.

3. Results

Results are organized around three sections dedicated to: (1) the assessment of the best combination of predictor datasets; (2) the performance of the seasonal forecasting models as a function of the lead times before harvest; and (3) the evaluation of the added-value of developing a model separately for each group of provinces.

3.1. Choice of Input Data Sets

In order to identify the best combination of input data among the satellite-based drought indices, the weather data and the climate indices, the seasonal forecasting models of cereal yields were developed using the different combinations of input data within the season, about 1 month prior to harvest in April, by considering all available predictors from October to April (Table 2). All the provinces are considered to build a so-called global model. The statistical metrics for the different combinations of input datasets and for the different methods are reported in Table 3. The results presented in Table 3 show that the statistical metrics of the model improve with the increase of the number of datasets used for prediction. In addition, all statistical metrics are improved when adding a dataset and this is also true for all the tested methods. The results showed that the yield variability is reasonably explained with satellite-based drought indices only, with R^2 values ranging from 0.67 (for MLR) to 0.81 (for XGBoost) and RMSE from 0.66 t. ha⁻¹ (for MLR) to 0.44 t. ha⁻¹ (for XGBoost). By combining satellite-based drought indices and weather data, the performances of all models are improved by 2–7% for R^2 and by 25–30% for RMSE. The best statistical metrics are obtained by combining the three datasets with a further improvement of the statistical metrics by about 11–45% for RMSE and 4–10% for R^2 depending on the used method. This means that climate indices such as the Northern Hemisphere Teleconnection Patterns (NAO and SCA) and the main modes of SST variability in the Atlantic contributes to improving the model performances. In addition, when comparing the different methods, the non-linear machine learning approaches (RF, SVM and XGBoost), outperformed the linear approaches (MLR) as already shown by various authors when applied to seasonal predictions of yields [53] and streamflow [85]. This clearly reflects that most of the relationships between yield and the considered predictors are non-linear and that the non-linear methods can obviously better capture these relationships than the linear method. Finally, the best algorithm for yield forecasting in our study is XGBoost, which predicts the yield with $R^2 = 0.95$ and RMSE = 0.20 t. ha⁻¹. This finding was corroborated by several studies for seasonal yield forecasting that showed a better performance of XGBoost when compared to other non-linear machine learning approaches such as SVM and RF [52]. Interestingly enough, this model fits the forecasting error threshold usually accepted in European agro-statistics that is of about 0.20 t. ha⁻¹ [86]. In the next section, the combination of satellite drought indices, weather data and climate indices are considered to predict cereal yield for several lead times before harvest.

Table 3. Statistical metrics of the forecasting models for several input data combination and for the 4 methods in April (1 month before harvest). All available input data from October to April were used (see Table 2). The metrics are computed for the 15 provinces.

Input Data	Models	RMSE (t. ha ⁻¹)	MAE (t. ha ⁻¹)	R ²
Satellite-based drought indices only	MLR	0.66	0.57	0.67
	SVM	0.54	0.43	0.78
	RF	0.46	0.35	0.80
	XGBoost	0.45	0.34	0.81
Satellite-based drought indices and weather data	MLR	0.46	0.39	0.72
	SVM	0.40	0.31	0.80
	RF	0.34	0.24	0.84
	XGBoost	0.37	0.25	0.86
Satellite-based drought indices, weather data and climate indices	MLR	0.41	0.31	0.75
	SVM	0.25	0.21	0.88
	RF	0.22	0.19	0.92
	XGBoost	0.20	0.16	0.95

3.2. Model Performance as a Function of Lead Time before Harvest

In this section, the performance of the forecasting models using the three datasets are evaluated as a function of the leading time prior to harvest from January to March (from 4 to 2 months before harvest). The RMSEs and R^2 of the models are plotted as a function of the lead time in Figure 3 to investigate the prediction accuracy. In addition, the relative importance of each dataset is reported in Figure 4 using the XGBoost algorithm as the method providing the best statistical metrics for all lead times.

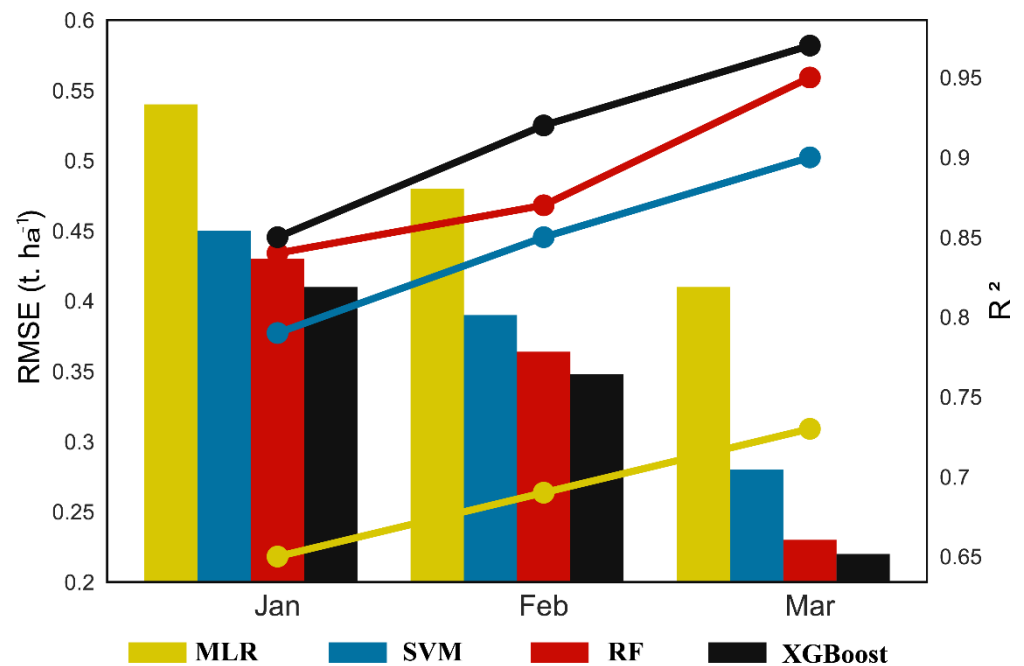


Figure 3. Model performance (R^2 -line- and RMSE -bar-) as a function of the lead time from 4 to 2 months before harvest (from January to March) for the four methods (MLR, SVM, RF and XGBoost). All the available predictor variables at the time of prediction were used (see Table 2).

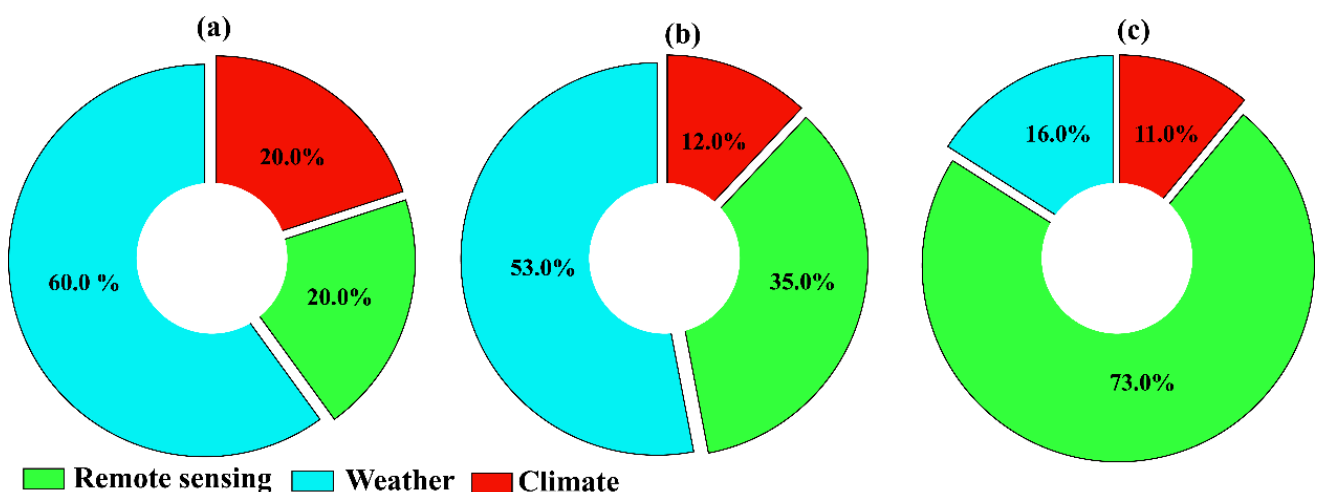


Figure 4. Importance of the different inputs datasets for yield prediction from January (a); February (b) and March (c). The considered predictors variables and their time span of the year for each model are reported in Table 2.

The closer to harvest the forecast is carried out, the better the performance metrics as shown by the increase of the correlation coefficient and the drop of RMSE when going from January to March at Figure 3. The best method whatever the lead time is XGBoost as

already shown, followed closely by RF based approaches. The models based on XGBoost explain 88%, 92% and 96% of yield variability (RMSE of 0.41, 0.34 and 0.22 t. ha⁻¹) for forecasting from January, February and March, respectively. By contrast, the poorest results are obtained with MLR with a strong gap of metrics with regards to the non-linear machine learning approaches (R^2 is below 0.75 for MLR while the correlations for the non-linear methods are above 0.90).

While a slight improvement of the model metrics is observed when going from January to February, considering predictors in March leads to a significant jump in the metrics with an RMSE close to the international standard of 0.20 t. ha⁻¹ for the XGBoost method and, to a lesser extent, for the RF model. This is probably related to the very high correlation between NDVI around the crop development peak in March and wheat yields that were already shown by various authors [11,87] giving a large weight to VCI at this time. The dominating importance of the satellite drought indices in March for the model based on XGBoost supports this assumption (Figure 4).

Other striking comments can be made by analyzing the importance of the three datasets (Figure 4): (1) the weather data dominates largely in January and, to a lesser extent, in February, while a strong shift is observed in March when satellite drought indices take the lead over the two other datasets. This is in agreement with the already observed high correlation between yields and precipitation around emergence in October and November and between yields and temperature in December during the tillering stage [11]; (2) Likewise, the importance of climate indices decreases with the lead time and their contribution is the lowest of the three datasets apart from in January when it contributes to 20% like the satellite drought indices. Indeed, the highest correlation with yields was found in December and January for NAO and SCA, respectively, while the correlations with the SST leading modes peak in October and February for Atlantic Niño and Atlantic Tripole modes, respectively. In addition, linkages between climate indices are, in particular, based on SST, and yields occur through teleconnection, meaning that the relationships are very indirect. This means that when good quality precipitation and temperature data are available, they should be preferred to climate indices as they provide more direct information on growing conditions; (3) satellite drought indices play a dominating role in early prediction in March only when they contribute up to 73% to the prediction accuracy. Nevertheless, a significant contribution is observed in February (35%) and in January (20%). This is because VCI and TCI were found to be significantly correlated to final yields in January and February and because SMCI is significantly related to yields as early as October around the emergence stage [10]. Indeed, the high moisture in the upper soil layers at this time facilitates the emergence and significant rainfall event during October–December promotes the farmer to seed, leading to an increase in cereal production [10,12].

In order to assess the practical performance of the developed models to predict yield in Morocco, a “leave-one-year-out” experiment, mimicking the practical forecasting conditions of a manager who wants to predict yields for the season to come based on the historical dataset, is tested. Figure 5 presents the average of the observed and the predicted yields using the three non-linear methods (MLR was excluded with regards to its poorest performance) for a lead time from 4 to 2 months before harvest. As already highlighted, the statistical metrics improve when going from January to March but the models predict yields with reasonable accuracy as early as January. Beyond the average statistical metrics, the ability of the forecasting models to predict extreme values is another important feature of seasonal prediction. Within this context, the ability of the models to predict classified anomalies instead of absolute value is analyzed by partitioning the production in terms of below normal (average minus one standard deviation), normal and above normal (average plus one standard deviation) production. Like the statistical metrics, the extreme anomalies are better predicted when the lead time decreases, as one anomaly is correctly detected by the models for a prediction from January (2006–2007) while all significant anomalies are properly reproduced by the three methods with a slightly better ability of the SVM

approach at the expense of some false detection (such as in 2008–2009 when SVM predicts above normal production).

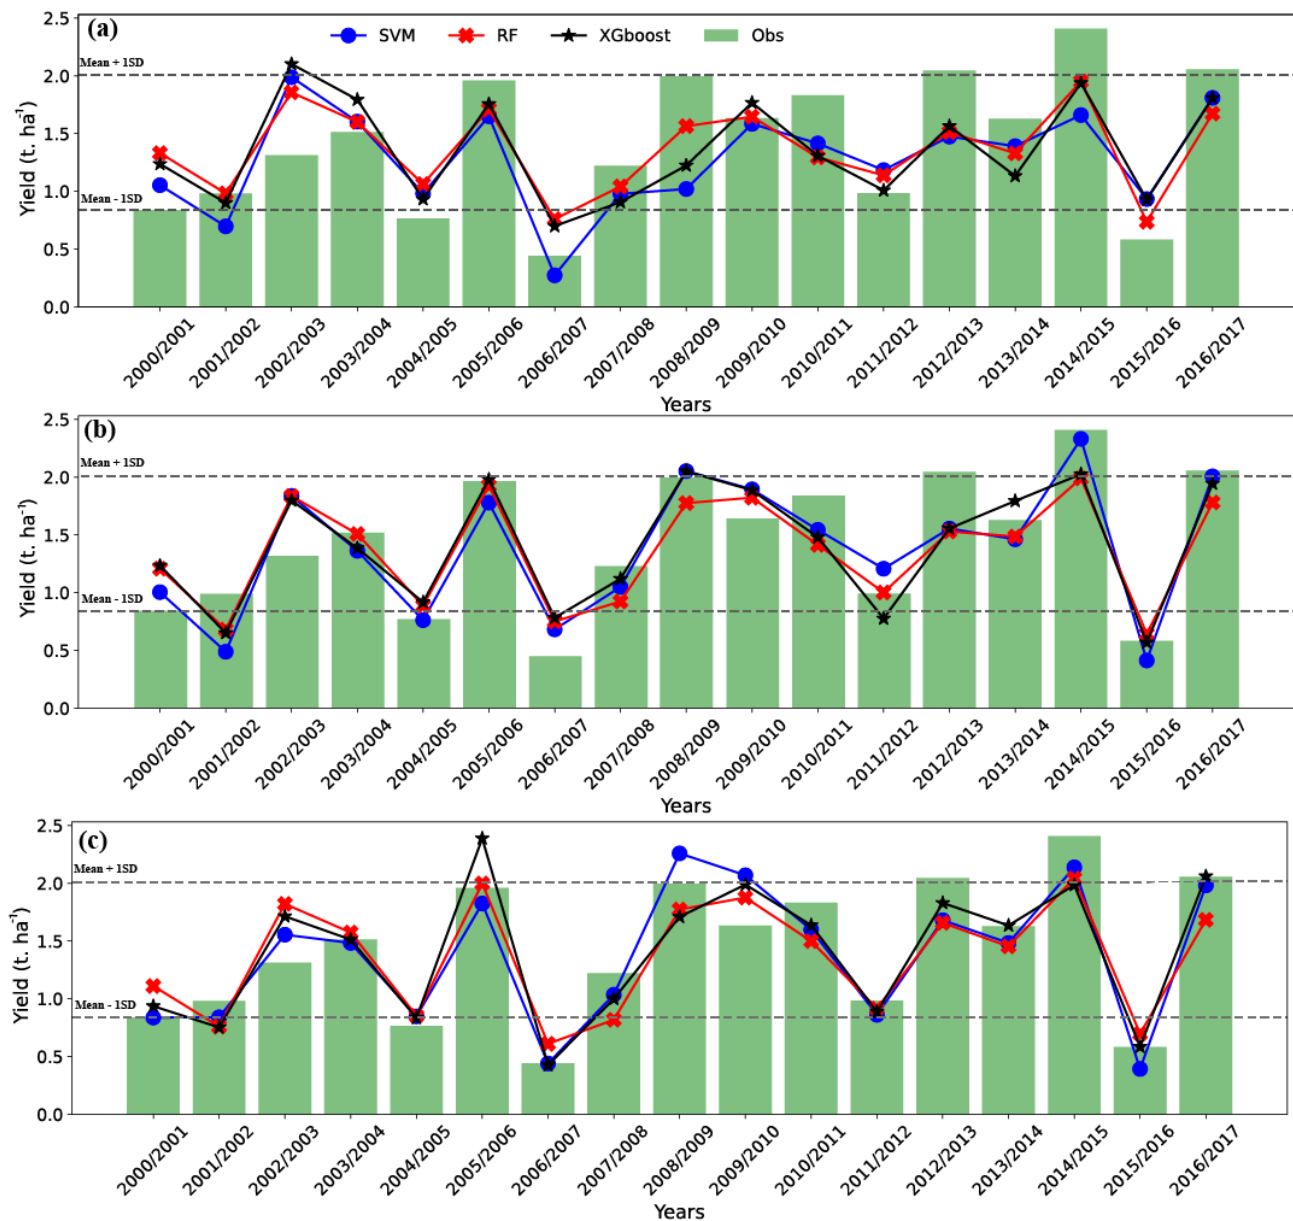


Figure 5. Average of observed and predicted yields using the “leave-one-year-out” technique at (a) January, (b) February and (c) March.

3.3. Model Performance at a Regional Scale

Cereal yields are dependent on many factors, such as weather conditions, local management and soil type, while the importance of each factor varies from one region to another [88]. Therefore, the high variability of crop yield from one season to another is also marked from province to province. To investigate the added value of developing a specific model for each group of provinces separately, Figure 6 compares the RMSE of the predicted yield using a global model and a local model with different lead times using a leave-one-out approach for each province. Only the XGBoost algorithm is retained as it exhibited the best metrics in the previous sections. The results illustrate that the performance of yield prediction improved when the lead time decreases, as already highlighted, and that the metrics show a high variability from one province to another. The use of a “regional”

model improved the RMSE whatever the provinces and the lead time: the RMSE values decrease in January by about 4% to 13% and by 12% to 32% in February and by 12% to 36% in March depending on the province. Interestingly enough, the better performances are obtained for some provinces that are known to be mostly covered by rainfed cereals, such as the ones located along the Atlantic coast (El Jadida JD, Settat ST and Khmisset KM), highlighting the problem of the scale mismatch between the typical size of the fields in the Mediterranean agriculture (<5 ha) and the coarse scale of the input predictor variables.

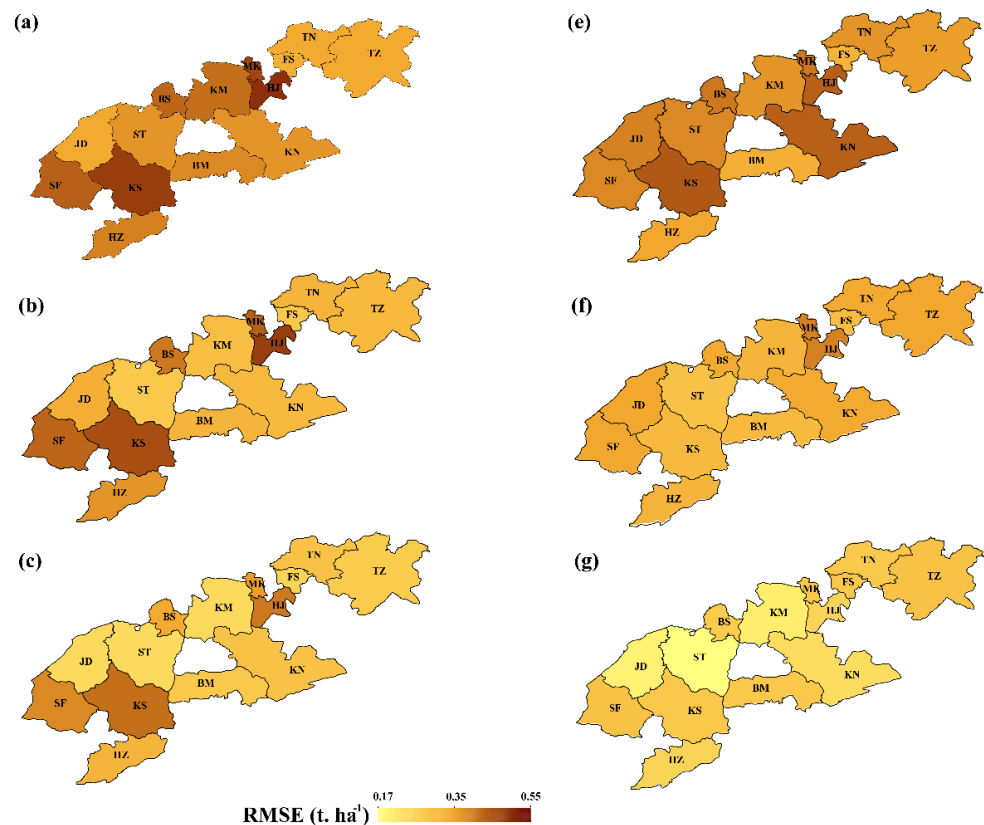


Figure 6. RMSE of global model at (a) January, (b) February, (c) March and regional models at (e) January, (f) February and (g) March.

4. Discussion

The proposed approach is based on a combination of three different datasets to forecast grain yields. From these datasets, the predictors were carefully selected based on statistically significant correlations with grain yields and biophysically sound mechanisms as explained in previous studies [10–12]. Atmospheric and oceanic indices are taken as proxies of local temperature and rainfall conditions. Interestingly enough, the impact of oceanic circulation on local weather can be not concomitant because of the remote nature of these phenomena occurring through teleconnections processes, such as for the Atlantic “El Niño” mode of SST variability. This explains why climate indices are important predictors for very early forecasting in January. Some authors have even based their modeling experiment on large scale climate information only to forecast yield, including Lehmann et al. [45] who showed that climate data (NAO, SST) could be used for the early forecasting (from December) of wheat yield anomaly at the country scale in Morocco. Nevertheless, the direct use of temperature and rainfall data should be preferred to these substitutes when gridded data of good quality exist, as shown by the dominating importance of weather variables for forecasting in January and February. Later in the season in March, when the crops are developed, drought indices providing a direct information on the cover density, health and hydric status obviously took the lead with regards to the other two data sets.

In brief, the satellite drought indices are a potential predictor of cereal yield when the forecasting is done close to harvest, while weather data and climate indices are the key variables for earlier forecasting of cereal yield. Other variables could also be considered to improve the models' skills. Soil type and management practices (water harvesting techniques, complementary irrigation, fertilizing inputs, planting dates etc.), for instance, are key factors for crop growth. While information on management practices is difficult to consider because of a strong variability from one farm to another (apart from the planting date, see below), large scale spatial patterns of soil type could be extracted from global soil maps such as soil grid [89]. For instance, considering information on the soil type could probably improve the performance metrics of the models on Safi, characterized by shallow and pebbly soils with a poor nutrient content, which are significantly lower than its surrounding coastal provinces, such as El Jadida and Settat (see for the global models Figure 4a–c).

The scale mismatch between the scale of the fields (lower than 5 ha) and the coarse resolution of the predictor variables (at best 1 km for the remote sensing drought index) is an important issue as already highlighted. The use of higher spatial and temporal resolution remote sensing data, such as Landsat and Sentinel, could thus improve the performance of the models developed in this study for those provinces with very heterogeneous land cover. For further studies at the field scale, higher resolution products, such as surface soil moisture derived from Sentinel-1 data [90,91] and Sentinel-2 NDVI, should be considered. In addition, cereal yields may be related to other factors that were not considered in our study, such as planting date, soil properties, local climate conditions and other management aspects [92]. In particular, the planting dates can shift the growing season with regards to the average growing period from November to May considered in this study. Local climate conditions can also shift the cereal season. For instance, the milder temperature conditions encountered in the Beni-Mellal province, located in the foothills of the Atlas, shift the cereal season by about one month with a harvest occurring in June on average while May is usually the harvest time for the provinces located in the plain (most of the provinces of our study area). This means that the considered time span of the year of the predictor variables (December for temperature, for instance, see Table 2) could not be optimal for all the provinces because of this time shift. A potential refinement of the models would thus be to consider the optimal time span of the predictor variables for each province or each group of provinces separately (for the last experiment considering a specific model for each group of provinces) instead of the same time period used in this study.

Finally, a last more general question arises about the model generalization to different crops and sites. In this study, the predictors were selected according to both the timing of the crop season and to the key phenological stages of wheat and companion cereals such as barley. As the timing of the crop season is similar for wheat that is usually cropped in winter in the whole north African area, it could be expected that the time span of local predictors, such as weather variables and drought indices, should be close for the other Maghreb countries. By contrast, the impact of oceanic and atmospheric indices on local climate may be different from one region to another. For instance, Trambly et al. [93] found NAO to be related to rainfall in Morocco and Algeria while Tunisian rainfall was more correlated to the Mediterranean Oscillation (MO; [94]). Ouachani et al. [95] highlighted that ENSO could be a driving pattern of precipitation in Tunisia through teleconnections. This means that the use of other indices, proxies of climate pseudo-oscillations, should be considered for the development of forecasting models for other sites. Likewise, the forecasting of yields for other crops will require a different choice of predictors and their associated time spans according to their key phenological stages. For instance, maize is known to be relatively drought tolerant during the grain filling stages on the contrary to wheat [96]. By contrast, water deficit early in the season around seedling may hamper maize from complete recovery, even with full irrigation, during the vegetative growth stages [97]. This may have critical implications for the choice of the time span of the remote sensing drought indices.

5. Conclusions

Crop yield forecasting provides critical and timely information to enable farmers to make quick decisions to increase yields through improving agricultural practices during the growing season. In addition, it allows the modeling of global and local market prices [98]. The main objective of our study was to develop an approach to forecasting cereal yield in Morocco based on multi-source data and machine learning techniques. To this objective, this study presents a methodology based on different machine learning approaches (MLR, SVM, RF and XGBoost) to predict the cereal yield over Morocco for several lead times prior to harvest using freely available datasets including satellite-based drought indices, weather data and climate indices. Our results show that combining satellite-based drought indices, weather and climate data as predictors of cereal yield provided a better forecasting accuracy than using any single data source. In line with our results, several studies pointed out that the use of multi-source data increases the accuracy of the machine learning model for yield prediction [52,54,56]. XGBoost outperformed the other machine learning techniques by explaining 93% of yield variation at the scale of the country (RMSE = 0.23 t. ha⁻¹). Interestingly enough, the value of RMSE is close to the acceptance threshold of 0.2 t. ha⁻¹ used in European agro-statistics [86]. It is also shown that the prediction accuracy increases as more observations along the growing season are added for all machine learning algorithms. Finally, the development of models at the regional level for each group of provinces improved the skills of yield prediction with regards to one “global” model applied to all provinces by decreasing the RMSE by about 4% to 36% depending on the province and the time of prediction, which is due to the high variability of cereal yield from one province to another.

The results presented in this study clearly showed that combining satellite-based drought indices, weather and climate data integrated into machine learning algorithms is a promising approach to forecasting cereal yields in Morocco. Moreover, the proposed approach provides a source of timely information needed for decision making during the growing season. In addition, this work could be used to map gain yield and yield gap at a provincial scale across Morocco. Then, the province with hotspots in terms of yield gap could be targeted for practice improvement and further research works.

Author Contributions: Conceptualization, E.h.B., L.J.; methodology, E.h.B., L.J.; software, E.h.B., L.J. and A.A.; Data curation, E.h.B., L.J. and R.B.; formal analysis, E.h.B. and L.J.; investigation, E.h.B. and L.J.; writing—original draft preparation, E.h.B.; writing—review and editing, L.J., S.E.-R., S.K., A.A., R.B. and B.R.; supervision, L.J. and S.E.-R. All authors have read and agreed to the published version of the manuscript.

Funding: This work was carried out within the framework of the Joint International Laboratory TREMA (<http://lmi-trema.ma>, accessed on 31 July 2021). This work was funded by the ERANETMED03–62 CHAAMS project, the ACCWA project, grant agreement no: 823965 and by SAGESSE PPR/2015/48. E. Bouras was supported by a fellowship from the ARTS program from IRD, France. The H2020 PRIMA ALTOS project, MISTRALS/SICMED2, PHC Toubkal #39064WG/2018 and PRIMA-IDEWA project are also acknowledged for additional funding.

Acknowledgments: The authors acknowledge the Economic Services of the Ministry of Agriculture of Morocco for providing the crop production statistics. The authors are also grateful for the valuable and constructive comments from the anonymous reviewers.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Asseng, S.; Ewert, F.; Martre, P.; Rötter, R.; Lobell, D.; Cammarano, D.; Kimball, B.A.; Ottman, M.J.; Wall, G.W.; White, J.W.; et al. Rising temperatures reduce global wheat production. *Nat. Clim. Chang.* **2015**, *5*, 143–147. [CrossRef]
2. FAO. *Climate Change and Food Security: Risks and Responses*; Food and Agriculture Organization of The United Nations: Rome, Italy, 2016; ISBN 9789251089989.
3. Giorgi, F. Climate change hot-spots. *Geophys. Res. Lett.* **2006**, *33*, 101029. [CrossRef]

4. Lionello, P.; Scarascia, L. The relation between climate change in the Mediterranean region and global warming. *Reg. Environ. Chang.* **2018**, *18*, 1481–1493. [[CrossRef](#)]
5. Vicente-Serrano, S.M.; Quiring, S.M.; Peña-Gallardo, M.; Yuan, S.; Domínguez-Castro, F. A review of environmental droughts: Increased risk under global warming? *Earth Sci. Rev.* **2020**, *201*, 1–23. [[CrossRef](#)]
6. Kogan, F.; Guo, W.; Yang, W. Drought and food security prediction from NOAA new generation of operational satellites. *Geomat. Nat. Hazards Risk* **2019**, *10*, 651–666. [[CrossRef](#)]
7. Schilling, J.; Hertig, E.; Trambly, Y.; Scheffran, J. Climate change vulnerability, water resources and social implications in North Africa. *Reg. Environ. Chang.* **2020**, *20*, 1–15. [[CrossRef](#)]
8. UN General Assembly. *Transforming Our World: The 2030 Agenda for Sustainable Development*; United Nations: New York, NY, USA, 2015.
9. Bouras, E.; Jarlan, L.; Khabba, S.; Er-Raki, S.; Dezetter, A.; Sghir, F.; Trambly, Y. Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco. *Sci. Rep.* **2019**, *9*, 1–14. [[CrossRef](#)]
10. Bouras, E.H.; Jarlan, L.; Er-Raki, S.; Albergel, C.; Richard, B.; Balaghi, R.; Khabba, S. Linkages between rainfed cereal production and agricultural drought through remote sensing indices and a land data assimilation system: A case study in Morocco. *Remote Sens.* **2020**, *12*, 4018. [[CrossRef](#)]
11. Jarlan, L.; Abaoui, J.; Duchemin, B.; Ouldbba, A.; Tourre, Y.M.; Khabba, S.; Le Page, M.; Balaghi, R.; Mokssit, A.; Chehbouni, G. Linkages between common wheat yields and climate in Morocco (1982–2008). *Int. J. Biometeorol.* **2014**, *58*, 1489–1502. [[CrossRef](#)]
12. Balaghi, R.; Tychon, B.; Eerens, H.; Jlibene, M. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. *Int. J. Appl. Earth Obs. Geoinf.* **2008**, *10*, 438–452. [[CrossRef](#)]
13. Lobell, D.B.; Burke, M.B.; Tebaldi, C.; Mastrandrea, M.D.; Falcon, W.P.; Naylor, R.L. Prioritizing climate change adaptation needs for food security in 2030. *Science* **2008**, *319*, 607–610. [[CrossRef](#)]
14. Sacks, W.J.; Kucharik, C.J. Crop management and phenology trends in the U.S. Corn Belt: Impacts on yields, evapotranspiration and energy balance. *Agric. For. Meteorol.* **2011**, *151*, 882–894. [[CrossRef](#)]
15. Basso, B.; Liu, L. Seasonal crop yield forecast: Methods, applications, and accuracies. *Adv. Agron.* **2019**, *54*, 201–255.
16. Jones, J.W.; Antle, J.M.; Basso, B.; Boote, K.J.; Conant, R.T.; Foster, I.; Godfray, H.C.J.; Herrero, M.; Howitt, R.E.; Janssen, S.; et al. Toward a new generation of agricultural system data, models, and knowledge products: State of agricultural systems science. *Agric. Syst.* **2017**, *155*, 269–288. [[CrossRef](#)]
17. Lawless, C.; Semenov, M.A. Assessing lead-time for predicting wheat growth using a crop simulation model. *Agric. For. Meteorol.* **2005**, *135*, 302–313. [[CrossRef](#)]
18. Wang, X.; Zhao, C.; Li, C.; Liu, L.; Huang, W.; Wang, P. Use of Ceres-wheat model for wheat yield forecast in Beijing. In *Proceedings of the IFIP Advances in Information and Communication Technology*; Springer: Boston, MA, USA, 2009.
19. Li, Z.; Song, M.; Feng, H.; Zhao, Y. Within-season yield prediction with different nitrogen inputs under rain-fed condition using CERES-Wheat model in the northwest of China. *J. Sci. Food Agric.* **2016**, *96*, 2906–2916. [[CrossRef](#)]
20. Dumont, B.; Leemans, V.; Ferrandis, S.; Bodson, B.; Destain, J.P.; Destain, M.F. Assessing the potential of an algorithm based on mean climatic data to predict wheat yield. *Precis. Agric.* **2014**, *15*, 255–272. [[CrossRef](#)]
21. Hansen, J.W.; Indeje, M. Linking dynamic seasonal climate forecasts with crop simulation for maize yield prediction in semi-arid Kenya. *Agric. For. Meteorol.* **2004**, *125*, 143–157. [[CrossRef](#)]
22. Mishra, A.; Hansen, J.W.; Dingkuhn, M.; Baron, C.; Traoré, S.B.; Ndiaye, O.; Ward, M.N. Sorghum yield prediction from seasonal rainfall forecasts in Burkina Faso. *Agric. For. Meteorol.* **2008**, *148*, 1798–1814. [[CrossRef](#)]
23. Kogan, F.; Yang, B.; Guo, W.; Pei, Z.; Jiao, X. Modelling corn production in China using AVHRR-based vegetation health indices. *Int. J. Remote Sens.* **2005**, *26*, 2325–2336. [[CrossRef](#)]
24. Kogan, F.; Kussul, N.; Adamenko, T.; Skakun, S.; Kravchenko, O.; Kryvobok, O.; Shelestov, A.; Kolotii, A.; Kussul, O.; Lavrenyuk, A. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *23*, 192–203. [[CrossRef](#)]
25. Johnson, D.M. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. *Remote Sens. Environ.* **2014**, *141*, 116–128. [[CrossRef](#)]
26. Meroni, M.; Fasbender, D.; Balaghi, R.; Dali, M.; Haffani, M.; Haythem, I.; Hooker, J.; Lahlou, M.; Lopez-Lozano, R.; Mahyou, H.; et al. Evaluating NDVI Data Continuity Between SPOT-VEGETATION and PROBA-V Missions for Operational Yield Forecasting in North African Countries. *IEEE Trans. Geosci. Remote Sens.* **2016**, *54*, 795–804. [[CrossRef](#)]
27. Mathieu, J.A.; Aires, F. Assessment of the agro-climatic indices to improve crop yield forecasting. *Agric. For. Meteorol.* **2018**, *253–254*, 15–30. [[CrossRef](#)]
28. Dumont, B.; Basso, B.; Leemans, V.; Bodson, B.; Destain, J.P.; Destain, M.F. A comparison of within-season yield prediction algorithms based on crop model behaviour analysis. *Agric. For. Meteorol.* **2015**, *204*, 10–21. [[CrossRef](#)]
29. Basso, B.; Cammarano, D.; Carfagna, E. Review of Crop Yield Forecasting Methods and Early Warning Systems. In *Proceedings of the First Meeting of the Scientific Advisory Committee of the Global Strategy to Improve Agricultural and Rural Statistics*, Rome, Italy, 18–19 July 2013.
30. Sierra, E.M.; Brynstein, S.M. Wheat yield variability in the S.E. of the Province of Buenos Aires. *Agric. For. Meteorol.* **1990**, *49*, 281–290. [[CrossRef](#)]

31. Giri, A.K.; Bhan, M.; Agrawal, K.K. Districtwise wheat and rice yield predictions using meteorological variables in eastern Madhya Pradesh. *J. Agrometeorol.* **2017**, *9*, 366–368.
32. Rembold, F.; Atzberger, C.; Savin, I.; Rojas, O. Using low resolution satellite imagery for yield prediction and yield anomaly detection. *Remote Sens.* **2013**, *1*, 5572–5573. [[CrossRef](#)]
33. Anderson, M.C.; Zolin, C.A.; Sentelhas, P.C.; Hain, C.R.; Semmens, K.; Tugrul Yilmaz, M.; Gao, F.; Otkin, J.A.; Tetrault, R. The Evaporative Stress Index as an indicator of agricultural drought in Brazil: An assessment based on crop yield impacts. *Remote Sens. Environ.* **2016**, *174*, 82–99. [[CrossRef](#)]
34. Salazar, L.; Kogan, F.; Roytman, L. Use of remote sensing data for estimation of winter wheat yield in the United States. *Int. J. Remote Sens.* **2007**, *28*, 3795–3811. [[CrossRef](#)]
35. Wang, M.; Tao, F.L.; Shi, W.J. Corn yield forecasting in northeast china using remotely sensed spectral indices and crop phenology metrics. *J. Integr. Agric.* **2014**, *13*, 1538–1545. [[CrossRef](#)]
36. Becker-Reshef, I.; Vermote, E.; Lindeman, M.; Justice, C. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sens. Environ.* **2010**, *114*, 1312–1323. [[CrossRef](#)]
37. Liu, W.T.; Kogan, F. Monitoring Brazilian soybean production using NOAA/AVHRR based vegetation condition indices. *Int. J. Remote Sens.* **2002**, *23*, 1161–1179. [[CrossRef](#)]
38. García-León, D.; Contreras, S.; Hunink, J. Comparison of meteorological and satellite-based drought indices as yield predictors of Spanish cereals. *Agric. Water Manag.* **2019**, *213*, 388–396. [[CrossRef](#)]
39. Nguyen-Huy, T.; Deo, R.C.; An-Vo, D.A.; Mushtaq, S.; Khan, S. Copula-statistical precipitation forecasting model in Australia's agro-ecological zones. *Agric. Water Manag.* **2017**, *191*, 153–172. [[CrossRef](#)]
40. Ceglar, A.; Turco, M.; Toreti, A.; Doblaz-Reyes, F.J. Linking crop yield anomalies to large-scale atmospheric circulation in Europe. *Agric. For. Meteorol.* **2017**, *240–241*, 35–45. [[CrossRef](#)]
41. Wang, B.; Feng, P.; Waters, C.; Cleverly, J.; Liu, D.L.; Yu, Q. Quantifying the impacts of pre-occurred ENSO signals on wheat yield variation using machine learning in Australia. *Agric. For. Meteorol.* **2020**, *291*, 108043. [[CrossRef](#)]
42. Knippertz, P.; Christoph, M.; Speth, P. Long-term precipitation variability in Morocco and the link to the large-scale circulation in recent and future climates. *Meteorol. Atmos. Phys.* **2003**, *83*, 67–88. [[CrossRef](#)]
43. Podestá, G.; Letson, D.; Messina, C.; Royce, F.; Ferreyra, R.A.; Jones, J.; Hansen, J.; Llovet, I.; Grondona, M.; O'Brien, J.J. Use of ENSO-related climate information in agricultural decision making in Argentina: A pilot experience. *Agric. Syst.* **2002**, *74*, 371–392. [[CrossRef](#)]
44. Martinez, C.J.; Baigorria, G.A.; Jones, J.W. Use of climate indices to predict corn yields in southeast USA. *Int. J. Climatol.* **2009**, *29*, 1680–1691. [[CrossRef](#)]
45. Lehmann, J.; Kretschmer, M.; Schauburger, B.; Wechsung, F. Potential for Early Forecast of Moroccan Wheat Yields Based on Climatic Drivers. *Geophys. Res. Lett.* **2020**, *41*, 1–10. [[CrossRef](#)]
46. Cai, X.L.; Sharma, B.R. Integrating remote sensing, census and weather data for an assessment of rice yield, water consumption and water productivity in the Indo-Gangetic river basin. *Agric. Water Manag.* **2010**, *97*, 309–316. [[CrossRef](#)]
47. Van Klompenburg, T.; Kassahun, A.; Catal, C. Crop yield prediction using machine learning: A systematic literature review. *Comput. Electron. Agric.* **2020**, *177*, 105709. [[CrossRef](#)]
48. Abbas, F.; Afzaal, H.; Farooque, A.A.; Tang, S. Crop yield prediction through proximal sensing and machine learning algorithms. *Agronomy* **2020**, *10*, 1046. [[CrossRef](#)]
49. Cao, J.; Zhang, Z.; Tao, F.; Zhang, L.; Luo, Y.; Han, J.; Li, Z. Identifying the contributions of multi-source data for winter wheat yield prediction in China. *Remote Sens.* **2020**, *12*, 750. [[CrossRef](#)]
50. Feng, P.; Wang, B.; Liu, D.L.; Waters, C.; Xiao, D.; Shi, L.; Yu, Q. Dynamic wheat yield forecasts are improved by a hybrid approach using a biophysical model and machine learning technique. *Agric. For. Meteorol.* **2020**, *285–286*, 107922. [[CrossRef](#)]
51. Kamir, E.; Waldner, F.; Hochman, Z. Estimating wheat yields in Australia using climate records, satellite image time series and machine learning methods. *ISPRS J. Photogramm. Remote Sens.* **2020**, *160*, 124–135. [[CrossRef](#)]
52. Kang, Y.; Ozdogan, M.; Zhu, X.; Ye, Z.; Hain, C.; Anderson, M. Comparative assessment of environmental variables and machine learning algorithms for maize yield prediction in the US Midwest. *Environ. Res. Lett.* **2020**, *15*, 064005. [[CrossRef](#)]
53. Mateo-Sanchis, A.; Piles, M.; Muñoz-Mari, J.; Adsua, J.E.; Pérez-Suay, A.; Camps-Valls, G. Synergistic integration of optical and microwave satellite data for crop yield estimation. *Remote Sens. Environ.* **2019**, *234*, 111460. [[CrossRef](#)]
54. Han, J.; Zhang, Z.; Cao, J.; Luo, Y.; Zhang, L.; Li, Z.; Zhang, J. Prediction of winter wheat yield based on multi-source data and machine learning in China. *Remote Sens.* **2020**, *12*, 236. [[CrossRef](#)]
55. Schwalbert, R.A.; Amado, T.; Corassa, G.; Pott, L.P.; Prasad, P.V.V.; Ciampitti, I.A. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agric. For. Meteorol.* **2020**, *284*, 107886. [[CrossRef](#)]
56. Cai, Y.; Guan, K.; Lobell, D.; Potgieter, A.B.; Wang, S.; Peng, J.; Xu, T.; Asseng, S.; Zhang, Y.; You, L.; et al. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agric. For. Meteorol.* **2019**, *274*, 144–159. [[CrossRef](#)]
57. Driouech, F.; Déqué, M.; Mokssit, A. Numerical simulation of the probability distribution function of precipitation over Morocco. *Clim. Dyn.* **2009**, *2*, 1055–1063. [[CrossRef](#)]

58. Kaufman, L.; Rousseeuw, P.J. *Finding Groups in Data: An Introduction to Cluster Analysis*; Wiley Series in Probability and Statistics; Wiley: Hoboken, NJ, USA, 1990; ISBN 0471735787.
59. West, H.; Quinn, N.; Horswell, M. Remote sensing for drought monitoring & impact assessment: Progress, past challenges and future opportunities. *Remote Sens. Environ.* **2019**, *232*, 111291. [[CrossRef](#)]
60. Kogan, F.N. Application of vegetation index and brightness temperature for drought detection. *Adv. Space Res.* **1995**, *15*, 91–100. [[CrossRef](#)]
61. Zhang, A.; Jia, G. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. *Remote Sens. Environ.* **2013**, *134*, 12–23. [[CrossRef](#)]
62. Jiao, W.; Tian, C.; Chang, Q.; Novick, K.A.; Wang, L. A new multi-sensor integrated index for drought monitoring. *Agric. For. Meteorol.* **2019**, *268*, 74–85. [[CrossRef](#)]
63. Bento, V.A.; Trigo, I.F.; Gouveia, C.M.; DaCamara, C.C. Contribution of Land Surface Temperature (TCI) to Vegetation Health Index: A comparative study using clear sky and all-weather climate data records. *Remote Sens.* **2018**, *10*, 1324. [[CrossRef](#)]
64. Dorigo, W.; Wagner, W.; Albergel, C.; Albrecht, F.; Balsamo, G.; Brocca, L.; Chung, D.; Ertl, M.; Forkel, M.; Gruber, A.; et al. ESA CCI Soil Moisture for improved Earth system understanding: State-of-the art and future directions. *Remote Sens. Environ.* **2017**, *203*, 185–215. [[CrossRef](#)]
65. Heng, L.K.; Asseng, S.; Mejahed, K.; Rusan, M. Optimizing wheat productivity in two rain-fed environments of the West Asia-North Africa region using a simulation model. *Eur. J. Agron.* **2007**, *26*, 121–129. [[CrossRef](#)]
66. Hersbach, H.; Bell, B.; Berrisford, P.; Hirahara, S.; Horányi, A.; Muñoz-Sabater, J.; Nicolas, J.; Peubey, C.; Radu, R.; Schepers, D.; et al. The ERA5 global reanalysis. *Q. J. R. Meteorol. Soc.* **2020**, *146*, 1999–2049. [[CrossRef](#)]
67. Barnston, A.G.; Livezey, R.E. Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. *Mon. Weather Rev.* **1987**, *115*, 1083–1126. [[CrossRef](#)]
68. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-learn: Machine learning in Python. *J. Mach. Learn. Res.* **2011**, *12*, 2825–2830.
69. Henry, N.W.; Cohen, J.; Cohen, P. Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences. *Contemp. Sociol.* **1977**, *6*, 320. [[CrossRef](#)]
70. Breiman, L. Random forests. *Mach. Learn.* **2001**, *45*, 5–32. [[CrossRef](#)]
71. Sain, S.R.; Vapnik, V.N. The Nature of Statistical Learning Theory. *Technometrics* **1996**, *38*, 409. [[CrossRef](#)]
72. Gunn, S. Support Vector Machines for classification and regression. *Analyst* **1998**, *135*, 230–267. [[CrossRef](#)]
73. Smola, A.J.; Schölkopf, B. A tutorial on support vector regression. *Stat. Comput.* **2004**, *14*, 199–222. [[CrossRef](#)]
74. Kuter, S. Completing the machine learning saga in fractional snow cover estimation from MODIS Terra reflectance data: Random forests versus support vector regression. *Remote Sens. Environ.* **2021**, *255*, 112294. [[CrossRef](#)]
75. Chen, T.; Guestrin, C. XGBoost: A scalable tree boosting system. In Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, CA, USA, 13–17 August 2016.
76. Friedman, J.H. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* **2001**, *29*, 1189–1232. [[CrossRef](#)]
77. Song, Y.; Liu, X.; Zhang, L.; Jiao, X.; Qiang, Y.; Qiao, Y.; Liu, Z. Prediction of double-high biochemical indicators based on lightGBM and XGBoost. In Proceedings of the ACM International Conference Proceeding Series, Wuhan, China, 12–13 July 2019.
78. Kaneko, H.; Funatsu, K. Fast optimization of hyperparameters for support vector regression models with highly predictive ability. *Chemom. Intell. Lab. Syst.* **2015**, *142*, 64–69. [[CrossRef](#)]
79. Picard, R.R.; Cook, R.D. Cross-validation of regression models. *J. Am. Stat. Assoc.* **1984**, *79*, 575–583. [[CrossRef](#)]
80. Kohavi, R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *Int. Jt. Conf. Artif. Intell.* **1995**, *2*, 1137–1143.
81. Arlot, S.; Celisse, A. A survey of cross-validation procedures for model selection. *Stat. Surv.* **2010**, *4*, 40–79. [[CrossRef](#)]
82. Baumann, K. Cross-validation as the objective function for variable-selection techniques. *TrAC Trends Anal. Chem.* **2003**, *22*, 395–406. [[CrossRef](#)]
83. Faroux, S.; Kaptué Tchuenté, A.T.; Roujean, J.-L.; Masson, V.; Martin, E.; Le Moigne, P. ECOCLIMAP-II/Europe: A twofold database of ecosystems and surface parameters at 1 km resolution based on satellite information for use in land surface, meteorological and climate models. *Geosci. Model. Dev.* **2013**, *6*, 563–582. [[CrossRef](#)]
84. ESA. *Land Cover CCI Product User Guide Version 2.0*; ESA: Paris, France, 2017. Available online: http://maps.elie.ucl.ac.be/CCI/viewer/download/ESACCI-LC-Ph2-PUGv2_2.0.pdf (accessed on 31 July 2021).
85. Rasouli, K.; Hsieh, W.W.; Cannon, A.J. Daily streamflow forecasting by machine learning methods with weather and climate inputs. *J. Hydrol.* **2012**, *414–415*, 284–293. [[CrossRef](#)]
86. Genovese, G.P.; Fritz, S.; Bettio, M. A comparison and evaluation of performances among crop yield forecasting models based on remote sensing: Results from the geoland observatory of food monitoring. *Int. Arch. Photogramm. Remote Sens. Spacial Inf. Sci.* **2006**, *36*, 71–77.
87. Belaqziz, S.; Khabba, S.; Er-Raki, S.; Jarlan, L.; Le Page, M.; Kharrou, M.H.; Adnani, M.E.; Chehbouni, A. A new irrigation priority index based on remote sensing data for assessing the networks irrigation scheduling. *Agric. Water Manag.* **2013**, *119*, 1–9. [[CrossRef](#)]
88. Satir, O.; Berberoglu, S. Crop yield prediction under soil salinity using satellite derived vegetation indices. *Field Crop. Res.* **2016**, *192*, 134–143. [[CrossRef](#)]

89. Hengl, T.; De Jesus, J.M.; Heuvelink, G.B.M.; Gonzalez, M.R.; Kilibarda, M.; Blagotić, A.; Shangguan, W.; Wright, M.N.; Geng, X.; Bauer-Marschallinger, B.; et al. SoilGrids250m: Global gridded soil information based on machine learning. *PLoS ONE* **2017**, *12*, e0169748. [[CrossRef](#)]
90. El Hajj, M.; Baghdadi, N.; Zribi, M.; Belaud, G.; Cheviron, B.; Courault, D.; Charron, F. Soil moisture retrieval over irrigated grassland using X-band SAR data. *Remote Sens. Environ.* **2016**, *176*, 202–218. [[CrossRef](#)]
91. Ouadi, N.; Jarlan, L.; Ezzahar, J.; Zribi, M.; Khabba, S.; Bouras, E.; Bousbih, S.; Frison, P.-L. Monitoring of wheat crops using the backscattering coefficient and the interferometric coherence derived from Sentinel-1 in semi-arid areas. *Remote Sens. Environ.* **2020**, *251*, 112050. [[CrossRef](#)]
92. Zhang, Z.; Jin, Y.; Chen, B.; Brown, P. California almond yield prediction at the orchard level with a machine learning approach. *Front. Plant. Sci.* **2019**, *10*, 809. [[CrossRef](#)] [[PubMed](#)]
93. Trambly, Y.; El Adlouni, S.; Servat, E. Trends and variability in extreme precipitation indices over maghreb countries. *Nat. Hazards Earth Syst. Sci.* **2013**, *13*, 3235–3248. [[CrossRef](#)]
94. Conte, M.; Giuffrida, A.; Tedesco, S. *The Mediterranean Oscillation. Impact on Precipitation and Hydrology in Italy Climate Water*; Academy of Finland: Helsinki, Finland, 1989.
95. Ouachani, R.; Bargaoui, Z.; Ouada, T. Power of teleconnection patterns on precipitation and streamflow variability of upper Medjerda Basin. *Int. J. Climatol.* **2013**, *33*, 58–76. [[CrossRef](#)]
96. Kang, S.; Shi, W.; Zhang, J. An improved water-use efficiency for maize grown under regulated deficit irrigation. *Field Crop. Res.* **2000**, *67*, 207–214. [[CrossRef](#)]
97. Song, L.; Jin, J.; He, J. Effects of severe water stress on maize growth processes in the field. *Sustainability* **2019**, *11*, 5086. [[CrossRef](#)]
98. Peng, Y.H.; Hsu, C.S.; Huang, P.C. Developing crop price forecasting service using open data from Taiwan markets. In Proceedings of the TAAI 2015—2015 Conference on Technologies and Applications of Artificial Intelligence, Tainan, Taiwan, 20–22 November 2015.

IV) Conclusion

Dans cette étude, nous avons développé des modèles empiriques de prévision du rendement du blé à l'échelle provinciale au Maroc avec l'utilisation des algorithmes de machine learning. Nos résultats montrent que la combinaison entre les indices de suivi de sécheresse par télédétection, les données météorologiques et les indices climatiques en tant que prédicteurs du rendement a fourni la meilleure précision, par rapport aux autres combinaisons ou à l'utilisation d'une seule source de données. En accord avec nos résultats, plusieurs études ont souligné que l'utilisation de données multi-sources augmente la précision des modèles du machine learning pour la prévision du rendement (Cai et al., 2019; Han et al., 2020; Kang et al., 2020) . Le XGBoost, en expliquant 93% de la variation du rendement à l'échelle du pays et $RMSE=0.21 \text{ t. ha}^{-1}$, a surpassé les autres algorithmes. Il est intéressant de noter que la valeur du RMSE reste proche du seuil d'acceptation de 0.2 t. ha^{-1} utilisé dans l'Agro-statistique européenne (Genovese et al., 2006). Nos résultats montrent que la précision de la prédiction augmente à mesure que l'on ajoute des observations le long de la saison de croissance pour tous les algorithmes de machine learning. Cependant, les conditions météorologiques et pédologiques pendant les premiers stades autour du semis ont des implications importantes pour la croissance ultérieure des cultures.

Les résultats présentés dans cette étude ont clairement montré que la combinaison des indices de sécheresse par satellite, des données météorologiques et climatiques est un meilleur prédicteur du rendement des céréales. L'intégration de ces données dans des algorithmes de machine learning peut fournir des outils utiles pour une prévision précoce du rendement des céréales au Maroc et peut être utilisée comme une source d'informations nécessaires à la prise de décision pendant la saison de croissance.

Dans le chapitre suivant nous allons quantifier l'impact du changement climatique dans le futur sur le rendement du blé et ses besoins en eau.

Chapitre IV : Impact du changement climatique sur les rendements et les besoins en eau du blé.

Les résultats de ce chapitre sont présentés dans l'article suivant : Bouras, E., Jarlan, L., Khabba, S., Er-Raki, S., Dezetter, A., Sghir, F., Trambly, Y., 2019. Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco. Sci. Rep. 9. <https://doi.org/10.1038/s41598-019-55251-2>

I) Introduction

Le changement climatique est une menace pour la sécurité alimentaire. L'objectif du présent travail est d'étudier l'impact du changement climatique, notamment l'augmentation de la concentration atmosphérique en CO₂, de la température, ainsi que les changements de précipitation, sur le rendement optimal en grain et les besoins en eau du blé irrigué dans la région de Tensift (Maroc). Le rendement optimal en grain se réfère à un rendement obtenu sous des conditions optimales d'irrigation et de fertilisation. Pour atteindre cet objectif, nous avons considéré deux scénarios (RCP4.5 et RCP8.5) et deux horizons (2041-2060 et 2081-2100). Nous avons également choisi trois dates de semis typiques de la région méditerranéenne : semis précoce (15 novembre), semis intermédiaire (15 Décembre) et semis tardif (15 janvier). Afin d'évaluer l'impact sur les rendements et les besoins en eau, nous avons opté pour le modèle AquaCrop (Pasquale Steduto et al., 2009) car (1) il a été calibré sur du blé dans notre zone d'étude (Toumi et al., 2016) ; (2) il a déjà été utilisé dans d'autres études sur l'impact du changement climatique sur le rendement (Abedinpour et al., 2014; Akumaga et al., 2018; Bird et al., 2016; Stevens and Madani, 2016); (3) l'effet fertilisant du CO₂ a été paramétré sur la base des résultats d'expérience FACE (Free-air concentration enrichment) (Vanuytrecht et al., 2011).

II) Résumé de l'article

Les projections des températures et des précipitations extraites des bases de données Med-CORDEX selon deux scénarios RCP4.5 et RCP8.5 et pour deux horizons 2050 et 2090, sont d'abord désagrégées avec la méthode quantile-quantile et évaluées. Les résultats montrent que pour tous les scénarios et horizons, une augmentation est prévue pour les températures maximales et minimales allant de 1°C (RCP4.5 2050) à 6°C (RCP8.5 2090). Ces augmentations sont particulièrement élevées pendant les mois d'hiver durant le cycle de développement du blé. Ces augmentations de températures auront également un impact sur l'évapotranspiration de référence (ET₀). Le cumul de l'ET₀ annuel devrait augmenter de 4.3, 7.5, 7.8 et 9.2% respectivement sous les scénarios RCP4.5 2050, RCP4.5 2090, RCP8.5 2050 et RCP8.5 2090. Une diminution des précipitations est également probable au milieu et à la fin de ce siècle au printemps (mars et avril) et en hiver (octobre à décembre). La baisse peut atteindre 12 mm et 10 mm par mois au printemps, par exemple, sous RCP8.5 en 2050 et 2090 respectivement. Cela correspond à 38% et 45% des précipitations mensuelles actuelles.

Ensuite, nous avons étudié l'impact du changement climatique sur la durée des principaux stades phénologiques de développement du blé, en se basant sur l'approche degrés-jours, pour

les trois dates de semis. Les résultats montrent une réduction de la durée totale de la saison de croissance de blé de 10 à 32% selon la date de semis, le scénario et l'horizon. Des petites différences sont observées entre les dates de semis. Par exemple, pour le semis précoce la réduction est autour de 11% (environ 17 jours) pour le RCP4.5 en 2050 et une réduction de 10% est attendue dans les mêmes conditions pour le semis tardif (environ 13 jours). Les mêmes tendances, mais avec des réductions plus fortes, sont observées pour les autres scénarios et horizons. Pour le scénario le plus extrême de la fin du siècle (RCP8.5 2090), la différence est plus importante mais reste limitée (32% de réduction pour le semis précoce contre 26% pour le semis tardif). Nous avons trouvé aussi que malgré une diminution de la durée totale de la durée de la saison avec un ordre de grandeur similaire pour toutes les dates de semis, les stades phénologiques sont affectés de manière différente. La hausse de température la plus importante attendue pendant les mois d'hiver affecte principalement la durée du stade d'émergence pour le semis tardif : une réduction de 14% est attendue pour le scénario RCP4.5 2050 pour le semis précoce alors qu'elle pourrait atteindre 27% pour le semis tardif. En revanche, le cycle du semis précoce est principalement impacté au printemps qui pourrait diminuer de 22% pour le RCP4.5 2050 contre une diminution de 14% pour le semis tardif.

Les impacts de l'augmentation de la température, de concentration du CO₂ atmosphérique et des diminutions de précipitations sur les rendements du blé et les besoins en eau et leur productivité sont ensuite évalués, sur la base du modèle AquaCrop selon 3 expériences : (i) avec l'augmentation de CO₂ uniquement, (ii) avec l'augmentation de la température et le changement de précipitations uniquement et (iii) avec l'augmentation de CO₂ de la température et le changement de précipitations. Dans un premier temps, le modèle AquaCrop alimenté par les observations sur la période historique (1991-2010) a été utilisé pour estimer les rendements optimaux en grain. Ces résultats ont ensuite été utilisés pour déterminer la référence du rendement, des besoins et la productivité de l'eau. Comme prévu, selon l'expérience qui ne prenait en compte que l'augmentation de la concentration de CO₂, les résultats indiquent une augmentation du rendement du blé pour tous les scénarios et pour toutes les périodes, en raison de taux de photosynthèse plus élevé due à l'augmentation de CO₂ qui entraîne une augmentation de la production végétale. Vers 2050, les rendements du blé pourraient ainsi augmenter de 21 à 26% pour les scénarios RCP4.5 et RCP8.5 respectivement. Vers 2090, les rendements pourraient augmenter de 52% pour toutes les dates de semis. Par contraste, en considérant l'augmentation de température uniquement, ces rendements pourraient diminuer de l'ordre de l'ordre de 7 à 30% selon les scénarios et les dates de semis. Un cycle de croissance plus court

lié à une température plus élevée réduit le rayonnement cumulé intercepté et donc diminue le rendement en biomasse et en grain. Par exemple, en 2050 pour les RCP4.5 et RCP8.5, les baisses des rendements prévues sont de 11 et 18% pour le semis précoce associé à raccourcissement du cycle de 12 et 17%. De même, pour le RCP4.5 en 2090, les rendements pourraient être réduits de 15, 7 et 11% pour, respectivement, les semis précoce, intermédiaire et tardif, sous une augmentation de la température moyenne annuelle de 2,3 °C. Évidemment, une baisse plus radicale est attendue en 2090 pour le scénario RCP8.5, mais avec les mêmes tendances en ce qui concerne la date de semis : pour le semis précoce par exemple, on note une diminution du rendement de 30% due à une augmentation de la température de 4,9°C (associée à une diminution de 30 % de la durée du cycle). En considérant l'augmentation du CO₂, de la température et le changement des précipitations, une augmentation du rendement est prévue pour tous les scénarios RCP et tous les horizons. Cela signifie que l'effet fertilisant du CO₂ pourrait compenser les pertes du rendement causées par la hausse de température. En 2050, le rendement pourrait augmenter de 7 et 12 % pour le semis précoce et intermédiaire, selon le scénario RCP. Et en 2090, les augmentations maximales des rendements sont attendues pour le semis tardif sous RCP8.5 (27%).

La diminution du cumul de la demande évaporative associée à un raccourcissement de la durée totale de cycle de développement du blé, entraîne une diminution de la transpiration et de l'évaporation. En conséquence, les résultats montrent une diminution des besoins en eau pour tous les scénarios et les horizons, cela indique que le raccourcissement du cycle de développement pourrait contrebalancer l'augmentation de la demande évaporative. Concernant les besoins en irrigation (BR), pour le semis précoce, les BRs actuels sont d'environ 160 mm répartis de décembre à mars avec un maximum en février (48 mm). En 2050, selon le scénario RCP4.5, les BRs devraient augmenter de 2% pour atteindre 164 mm, avec à nouveau un pic en février. En revanche, en 2090, selon le scénario RCP8.5, la demande en irrigation pourrait diminuer de 33 mm (20 %) de décembre à février, avec un maximum avancé d'un mois en janvier (49 mm). Pour le semis tardif et intermédiaire, le décalage du besoin maximal est d'environ 2 mois pour le semis tardif dans le scénario le plus extrême et pour l'horizon le plus lointain. Cela pourrait avoir des conséquences importantes pour la gestion de l'eau agricole dans la région.

III) Article

OPEN

Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco

Elhoussaine Bouras^{1,2,3}, Lionel Jarlan^{2,3*}, Said Khabba^{3,4,5}, Salah Er-Raki^{1,3,4}, Alain Dezetter^{3,6}, Fathallah Sghir^{3,7} & Yves Trambly^{3,6}

The present work aims to quantify the impact of climate change (CC) on the grain yields of irrigated cereals and their water requirements in the Tensift region of Morocco. The Med-CORDEX (MEDiterranean COordinated Regional Climate Downscaling EXperiment) ensemble runs under scenarios RCP4.5 (Representative Concentration Pathway) and RCP8.5 are first evaluated and disaggregated using the quantile-quantile approach. The impact of CC on the duration of the main wheat phenological stages based on the degree-day approach is then analyzed. The results show that the rise in air temperature causes a shortening of the development cycle of up to 50 days. The impacts of rising temperature and changes in precipitation on wheat yields are next evaluated, based on the AquaCrop model, both with and without taking into account the fertilizing effect of CO₂. As expected, optimal wheat yields will decrease on the order of 7 to 30% if CO₂ concentration rise is not considered. The fertilizing effect of CO₂ can counterbalance yield losses, since optimal yields could increase by 7% and 13% respectively at mid-century for the RCP4.5 and RCP8.5 scenarios. Finally, water requirements are expected to decrease by 13 to 42%, mainly in response to the shortening of the cycle. This decrease is associated with a change in temporal patterns, with the requirement peak coming two months earlier than under current conditions.

Climate changes (CC), mainly attributed to the human-induced increase of greenhouse gases, e.g., carbon dioxide CO₂, are expected to cause global warming in certain regions over the next century¹. In particular, the Mediterranean area has been identified as a hot spot of climate change². As a result, numerous key economic sectors, including agriculture, could be drastically impacted. In Morocco, winter cereals occupy more than 55% of the country's agricultural areas, common and durum wheat account for about 75%³. Although it represents only 19% of arable land, irrigated agriculture contributes 45% of added agricultural value. It consumes about 83% of the available resources⁴, but could be the main lever of water saving in the region as legislation remains permissive and irrigation efficiency is low. Climate change is expected to lead to an even stronger production variability leading than today in turn to price volatility⁵. Given this context, it becomes important to analyze the impact of future climate changes on wheat yield and irrigation water requirements in this region.

Higher atmospheric CO₂ concentration, and changes in temperature and rainfall may increase or decrease crop yield, and the net effect of CC on crop yield depends on the interaction between these various factors. Plant production and water-use efficiency are known to increase at higher atmospheric CO₂ concentrations, in particular for C3 plants such as wheat. This is due to higher rates of photosynthesis⁶ and an improved response to stress related to a reduced stomatal closure that better regulates plant transpiration⁷. On the other hand, higher atmospheric CO₂ can negatively affect grain quality by reducing the concentrations of plant nutrients⁸. Moreover,

¹LP2M2E, Département de Physique Appliquée, Faculté des Sciences et Techniques, Université Cadi Ayyad, (UCAM), Marrakech, Morocco. ²Centre d'Etudes Spatiales de la Biosphère (CESBIO), Institut de Recherche pour le Développement (IRD), Toulouse, France. ³Joint International Laboratory TREMA, Université Cadi Ayyad (UCAM), Marrakech, Morocco. ⁴Center for Remote Sensing Applications (CRSA), University Mohammed VI Polytechnic (UM6P), Benguerir, Morocco. ⁵LMME, Faculté des Sciences Semalia (FSS), Université Cadi Ayyad (UCAM), Marrakech, Morocco. ⁶Laboratoire HydroSciences Montpellier (HSM), Montpellier, France. ⁷Office Régional de Mise en Valeur Agricole du Haouz (ORMVAH), Marrakech, Morocco. *email: lionel.jarlan@cesbio.cnes.fr

increased temperature can negatively impact plant production because of the heat stress⁹. This is particularly the case if it occurs at sensitive phenological stages, e.g., pollination for wheat¹⁰ and because it reduces the length of the crop season, leading to less radiation intercepted by the plants¹¹. Another effect of higher temperatures is an increase in plant water demand due to increased transpiration¹². Obviously, a smaller rainfall during the wheat development cycle at emergence, tillering¹³ or during the grain-filling¹⁴ stages can drastically affect yield, especially for rainfed crops, owing to a deficit of crop water.

Several studies have employed crop models to study the impact of climate changes on agricultural production, e.g., Ludwig and Asseng¹⁵; Yang *et al.*¹⁶ among several others. Considering temperature increase and rainfall changes only, lower yields must inevitably be projected. By contrast, most of the simulation studies carried out on semi-arid Mediterranean environments suggest that fertilizing effects could offset the negative impacts of higher temperatures, resulting in increased yields^{15,17,18} and that this positive impact could be more pronounced in warm and dry locations¹⁹. Concerning water requirements, Saadi *et al.*¹⁷ demonstrate that under optimal conditions, the net irrigation requirements could decrease by 11% at the 2050 horizon in the southern Mediterranean region. Nevertheless, most studies instead suggest an increase in water requirements, Lovelli *et al.*²⁰ explained the rise of evaporative demand associated with rising temperature²¹ could not be compensated by reductions in phenological stages and partial stomatal closure²². Other studies attempt additionally to take into account the change in land-use associated with the major agricultural transformation that faces the Mediterranean regions (intensification, conversion to cash crops, and so on). Valverde *et al.*²³ and Rodriguez-Diaz *et al.*²⁴ in the Iberian Peninsula, both found a substantial increase in water requirements but without considering the potential reduction in the duration of the phenological stages. Likewise, the recent work of Fader *et al.*²⁵ also suggests a significant increase in gross irrigation that could reach 74% in the more extreme scenarios. To our knowledge, no studies has been designed for studying the potential changes in the seasonal irrigation patterns in south Mediterranean while a different timing of the irrigation season induced by changes in the phenological stages duration may have significant consequences for water management.

This literature review demonstrates the complex interactions between the various manifestations of climate change, and shows that the simulated impacts of their combined effects on yields and water requirements depend strongly on local conditions and also on the various process representations used in the modeling tools. In particular, the accuracy of the impact projections depends critically on the representation of the fertilization effect within the crop models²⁶. Crop models used in impact assessment studies simulate the effects of elevated CO₂ on growth and yield by a variety of methods (reviewed by Tubiello and Ewert²⁷). Some concerns have been expressed^{26,28,29} regarding the parameterizations that have been developed from earlier studies implemented in greenhouses. More recent Free Air Carbon dioxide Enrichment (FACE) experiments tend to demonstrate that fertilizing effects projected from enclosure studies may overestimate the fertilizing effect by up to 50%²⁶. In order to address this large uncertainty, impact projection studies of climate change on crop production are now usually based on two experiments: one taking into account the fertilizing effect and another that does not²⁵, in addition to considering several CO₂ emission scenarios.

The objective of the present work is to study the impact of climate change, including rising atmospheric CO₂ concentration and temperature, and changes in rainfall, on the optimal grain yield and water requirements of irrigated wheat in the Tensift region (Morocco). The optimal grain yield refers to a yield obtained under optimal irrigation scheduling and optimal fertilizer rates. To this objective, we considered two scenarios (RCP4.5 and RCP8.5) and two horizons (2041–2060 and 2081–2100). In order to assess the impact on yields, we choose the AquaCrop model³⁰ because (1) it was calibrated on wheat grown in the study region during a previous investigation³¹; (2) it has already been used in impact projection studies^{32–35}; (3) the CO₂ fertilizing effect has been parameterized based on FACE experiment results^{36,37}.

Results

Temperature and precipitation trends. Future changes in temperature and precipitation under the RCP4.5 and RCP8.5 scenarios between the historical period 1991–2010 and the two time horizons 2041–2060 (referred to hereafter as 2050) and 2081–2100 (hereafter 2090) were evaluated. For all scenarios, there is a systematic increase in maximum and minimum temperature ranging from 1 °C (RCP4.5 by 2050) to 6 °C (RCP8.5 by 2090) (Fig. 1a,b). Even considering the models' overall spread, there is no ambiguity concerning the sign of the change, which remains positive apart from RCP4.5 during September and October. The higher increase is logically observed for the most distant horizons and for the most pessimistic emission scenarios (Fig. 1a,b). Interestingly, the seasonal cycle of minimum and maximum temperature change is fairly marked, with a much stronger increase during the winter months. For instance, the average difference between the RCP4.5 2050 minimum temperature and observed values during December-January-February is 1.8 °C, while this difference for March-April-May is only 1.2 °C. These increased temperature will also affect reference evapotranspiration (ET_0). In our study, annual ET_0 is expected to increase by 4.3, 7.5, 7.8 and 9.2% respectively under RCP4.5 by 2050, RCP4.5 by 2090, RCP8.5 by 2050 and RCP8.5 by 2090 (not shown).

A decrease in precipitation (from the mean of the model ensemble) is expected for mostly all scenarios (Fig. 1c) and period. This lower precipitation is particularly prominent in spring (March and April) and winter (October to December) even when considering the model ensemble's spread. The drop may reach 12 mm and 10 mm per month in spring, for instance, under RCP8.5 in 2050 and 2090 respectively. This corresponds to 38% and 45% of the monthly rainfall.

Impact of CC on the duration of phenological stages. The impact of CC on the total duration of the cycle is first quantified starting by the variation of the cumulative degree days (CDD), a classic method for predicting wheat development³⁸. For the historical period (1991–2010), is equal to 2372 °C for the observations at the meteorological station of Marrakech; an increase is observed for all scenarios and horizons ranging from 3%




Figure 1. Projected maximum temperature (a), minimum temperature (b) and precipitation (c) according to RCP 4.5 and RCP 8.5 in 2050 and 2090. The line is the models mean and the colored section corresponds to Mean \pm SD standard deviation of the 5 RCM models.

(RCP4.5 2050) to 30% (RCP8.5 2090) (Fig. S1). For information, no specific effect of CO₂ has been observed on crop cycle duration, either from modeling studies^{39,40} or from FACE experiments⁴¹, implying that temperature rise explains the change in phenology.

In the AquaCrop model, the phenological stages are emergence, maximum canopy cover, senescence and maturity, the time from sowing to maturity corresponds to the length of the crop season (LCS). Actual phenological stage's durations are presented in Table 1. The results show a systematic reduction of the LCS from 10 to 32% (Fig. 2). Small differences are observed between the sowing dates as, for instance, the early-season LCS could be decreased by 11% (about 17 days) for RCP4.5 at 2050 and a 10% reduction is expected under the same conditions for late sowing (about 13 days). The same trends but with stronger reductions are observed for the other scenarios

Stage\Sowing date	Emergence (days)	Maximum canopy Cover (days)	Start of senescence (days)	Maturity* (days)
Early	7	83	112	152
Intermediate	9	83	106	141
Late	11	72	93	125

Table 1. Actual (year 2000) duration of the phenological stages for all sowing dates. *Corresponds to the length of the crop season (LCS).




Figure 2. Reduction of the duration of the phenological stages of wheat (in %) for different climatic scenarios and horizon: (a) early sowing (b) intermediate sowing and (c) late sowing. The error bars correspond to Mean \pm SD of the 5 RCM models.

and horizons. For the more extreme scenario at the end of the century (RCP8.5 2090), the difference is higher but remains limited (32% decrease for early sowing versus 26% decrease for late sowing). Considering the model ensemble's spread, the uncertainty can be high, in particular for RCP4.5 in 2050, but the phenological stage durations are always predicted to decrease whatever the scenarios and horizons.

More interestingly, despite a decrease in the total LCS of a similar order of magnitude for all sowing dates, the phenological stages are affected in a different way. The greater temperature rise expected in the winter months primarily affects the emergence stage for late sowing: a 14% reduction is expected for RCP4.5 2050 for early sowing while it could reach 27% for late sowing. By contrast, the early sowing cycle is mainly impacted during the period of maximum canopy cover, which will drop by 22% for RCP4.5 2050 versus a 14% decrease for late sowing.

Impact of CC on optimal grain yields of wheat. As a preliminary step, the AquaCrop model driven by meteorological observations from the historical period (1991–2010) has been used to compute the baseline optimum grain yields, which are equal to 7.5, 6.2 and 5.4 tons/ha for early, intermediate and late sowing, respectively.

Wheat yield under CO₂-only change ("CO₂" experiment). Experiments that considered only the rise of the CO₂ concentration predicted significant increases of wheat yield under all scenarios for all time periods (Fig. 3a) because of higher rates of photosynthesis leading to higher plant production and more efficient use of water^{6,7}. Around the year 2050 wheat yields could rise between 21 to 26% for RCP4.5 and RCP8.5 respectively. Around the year 2090, yields are expected to increase by as much as 52% for all sowing dates.

Wheat yield under temperature and precipitation changes only ("CC" experiment). When changes in temperature and precipitation only are taken into account, the optimal yields tend to decrease for all sowing dates and all RCPs scenarios and horizons (Fig. 3b). A shorter LCS related to warmer temperature reduces the cumulative intercepted radiation, and, *in fine*, the biomass and grain yields^{11,42}. For example, in 2050 for RCP4.5 and RCP8.5, projected yield decreases are 11 and 18% for early sowing associated with a decrease in LCS of 12 and 17%. Similarly, for RCP4.5 in 2090, yields could be reduced by 15, 7 and 11% for early, intermediate and late sowing respectively, under an increase in yearly average temperature of 2.3 °C. Obviously, a more drastic drop is expected in 2090 for




Figure 3. Relative change in yields for early, intermediate and late sowing date corresponding to: (a) CO₂ change only “CO₂” experiment, (b) Temperature and precipitation changes only “CC” experiment and (c) temperature, precipitation and CO₂ changes “CCO₂” experiment. The error bars correspond to Mean ± SD of the 5 RCM models.

the RCP8.5 scenario but with the same trends with respect to the sowing date: for early sowing, a 30% loss of yield due to an increase in temperature of 4.9 °C is projected (associated with a 30% decrease in LCS). The uncertainties of changes in yield for “CC” experiments are lower for intermediate sowing compared to other sowing dates, especially for RCP8.5 2050. For late and intermediate sowing, yield reduction is smaller (9 and 11%) than for early sowing. This is probably because of an already warmer “baseline” temperature during the growth cycle and also because the reduction of the emergence stage for this sowing dates probably has less impact on yields than the larger reduction in the phenological stages related to the maximum canopy cover, which could affect early-sowing wheat. Indeed, Jarlan *et al.*⁴³ found a negative correlation between yields and temperature in February and at the end of the cycle in March, corresponding to the high temperatures generally prevailing during the grain-filling stage in early spring. This could explain the larger drop in yield for early sowing because the grain-filling phase would coincide with the months of February and March. Pre- and post-anthesis high temperatures and heating are known to have huge impacts upon wheat growth, since heat stress reduces the photosynthetic efficiency of crops⁴⁴. In particular, Wardlaw and Dunstone⁴⁵ have observed that photosynthesis is optimal for wheat at temperatures between 20 and 30 °C and decreases steeply at temperatures above 30 °C. High temperatures (above 30 °C) are particularly harmful for yields of all crops during the pollination phase⁴⁶. Interestingly enough, this effect is represented in AquaCrop. In our study, the 30 °C threshold is never reached for none of the scenarios tested but the corruption of extremes values by the Q-Q approach as underlined previously precludes from drawing any definitive conclusion on this point.

Wheat yields under temperature, precipitation and CO₂ changes (“CCO₂” experiment). With a dual increase of temperature and of atmospheric CO₂ concentration caused by CC, optimal grain yields should rise for all RCPs scenarios and horizons (Fig. 3c). This means that, based on our simulation study, the fertilizing effect might be able to offset the yield loss. In 2050 yield could increase by 7 and 12% for early and intermediate sowing, depending on the RCP scenario. And in 2090 maximum increases in yields are expected for late sowing under RCP8.5 (27%). Taking into account the ensemble’s spread, the sign of the change appears uncertain for early-sowing wheat, which combines a moderate expected average increase of wheat yields and a high uncertainty.

Impact of CC on water requirements and water productivity. In order to study wheat’s water requirements (including both irrigation and precipitation) and water productivity, we examined the anticipated combined effects of the potential increase in evaporative demand and shortening of the phenological cycle on future water requirements and productivity.

Impact of CC on water requirements (WR). Decrease in cumulative evaporative demand (computed from the Hargreaves formula) associated with a shorter growing season, leads to a decrease in transpiration and evaporation (Fig. S2). Current seasonal cumulative evapotranspiration for early, intermediate and late sowings are 353 ($E = 72$ mm $Tr = 281$ mm), 382 (83, 299) and 404 mm (92, 312 mm) respectively. The partition of evapotranspiration is in accordance with the measured values in the region, showing a dominant transpiration^{47–51}. In 2050, according to RCP4.5, transpiration is expected to decrease by 57, 48 and 38 mm (20, 16, and 12%) and evaporation also decreases by 16, 9 and 16 mm (22, 11, and 17%) for early, intermediate and late sowing respectively. This

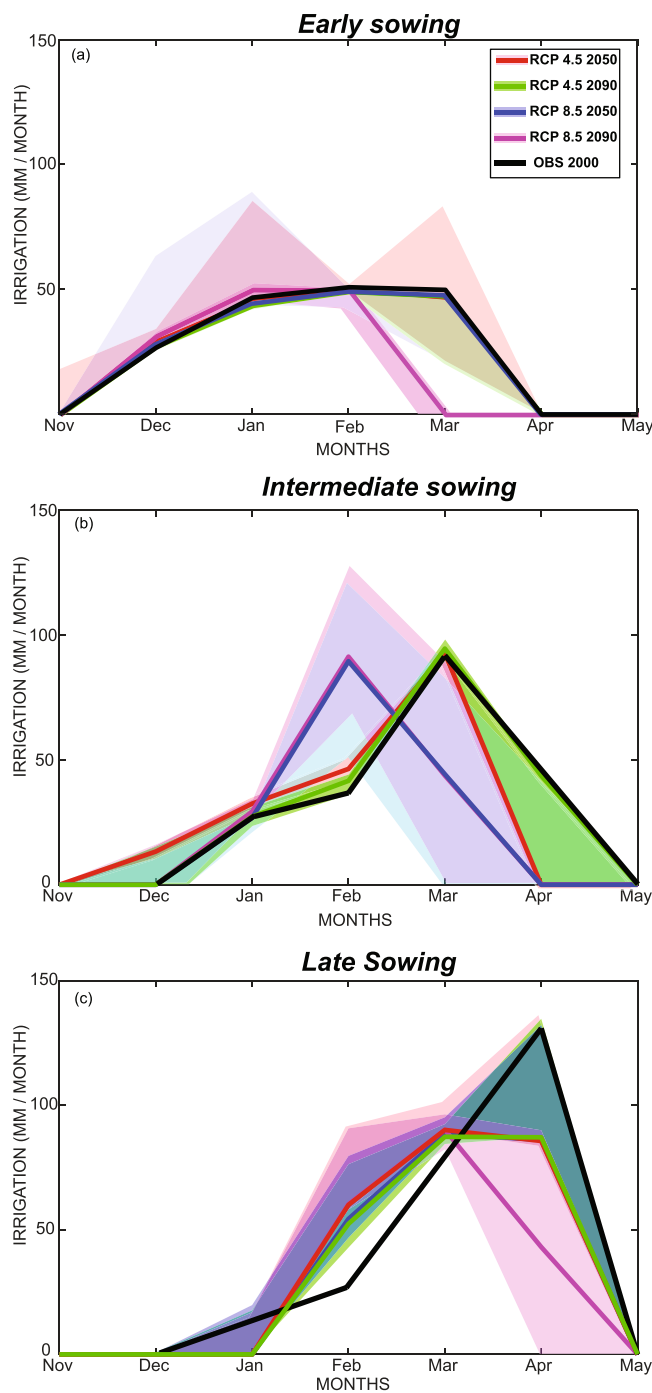


Figure 4. Irrigation for (a) early, (b) intermediate and (c) late sowing (“CCO₂” experiment). The line is the model mean and the colored section correspond to Mean \pm SD of the 5 RCM models.

corresponds to an evapotranspiration drop of 21, 15 and 13% for the three sowing dates. Also, according to RCP8.5 in 2090, the decrease in evapotranspiration reaches 43% for early sowing. This decrease in evapotranspiration may decrease WR for the various climate scenarios and horizons (Fig. S2). The actual WRs are 353, 382 and 404 mm for early, intermediate and late sowing respectively. These values are consistent with those obtained by Hadria *et al.*⁵², Kharrou *et al.*⁵³ and Toumi *et al.*⁵¹ for wheat in the same region of study. WR was then projected for the CO₂ and climate change scenarios. Results show a systematic decrease of WR independent of the sowing date and of the scenarios and horizons, indicating that the joint shortening of the LCS and the improved stomatal regulation associated with rising temperature and CO₂ are able to counterbalance the increase in evaporative demand.

Figure 4 displays irrigation requirements (IR) only, for the three sowing date and for all scenarios and horizons. For early sowing, current IRs are about 160 mm distributed from December to March with a maximum in February (48 mm). In 2050 according to the RCP4.5 scenario, IR requirements should increase by 2% to

164 mm, again with a peak in February. By contrast in 2090, according to RCP8.5, IR should decrease of 33 mm or 20% from December to February, with the maximum advanced by one month to January (49 mm). For late and intermediate sowing, the projections of IR follow the same decreasing trend in irrigation. The shift in peak requirement is about 2 months for late sowing in the more extreme scenario and for the later horizon. Decreases in the maximum are due to decreases in the temperature and reference evapotranspiration in February as compared to April. Decrease of evapotranspiration is due both to a shorter growing season and to improved stomatal regulation.

Impact of CC on water productivity (WP). Water productivity (WP) is expressed as the dry matter above ground (gr or kg) produced per unit of transpired water (mm). Since the fertilizing effect in AquaCrop consists of modulating the Water Productivity parameter, an increase in the efficiency of water use is obviously expected (Fig. S3). The results show that actual WPs are 2.1, 1.6 and 1.3 kg/m³ for early, intermediate and late sowing respectively. With a rise in CO₂ concentration plus a temperature increase, WPs are expected to increase for all climate scenarios up to 93% for RCP8.5 at the 2090 horizon, depending on the sowing dates. Hunsaker *et al.*⁵⁴ demonstrated that the water productivity of wheat could increase by 50 to 60% depending on the water conditions under a doubled CO₂ concentration. This increase in WP is due to increased photosynthesis⁵⁵ and thus increased grain production per unit of transpired water⁵⁶.

Discussion and Conclusion

A systematic increase in maximum and minimum temperature for all scenarios and horizons is observed. This temperature rise ranges from 1 °C (RCP4.5 by 2050) to 6 °C (RCP8.5 by 2090) for yearly averages. The changes in temperature and precipitation are in agreement with several studies signalling (1) a significant temperature rise for the entire Mediterranean region^{2,57} or for the Tensift catchment⁵⁸ and (2) a decrease in annual precipitation in the northern Mediterranean ranging from 16% in 2036–2065 for the RCP4.5 scenario to 30% in 2066–2095 for RCP8.5²¹. Likewise, the associated increase of the reference evapotranspiration ET₀ was also highlighted in line with the results of Saadi *et al.*¹⁷ and Trambly *et al.*²¹. The seasonality of the changes points out several implications for wheat growth and production. The decrease in precipitation is particularly prominent in spring (March and April) during the grain filling stage and autumn (October to December) around emergence. Early-sowing wheat could be particularly impacted by the temperature rise because of a greater warming in winter than in autumn and spring. The decrease of cycle duration could reach 32% (50 days) in 2090 according to scenario RCP8.5. This value is closed to the work of Saadi *et al.*¹⁷ and Wang *et al.*⁴⁴ who have previously shown that temperature rise predicted in Mediterranean regions could induce a reduction of the LCS ranging from 22 to 41 days as a consequence of 2.3–3.8 °C increases in air temperature.

Higher atmospheric CO₂ concentrations increased yield for all climate scenarios and horizons. This strongly positive effect was expected as CO₂ fertilization has been proven to be maximized on warm and dry environments⁵⁹. Similar trends have already been reported from modeling studies by Ludwig and Asseng¹⁵ and Wang *et al.*⁶⁰ who have shown that doubling atmospheric CO₂ could increase yields by up to 48% using the APSIM-wheat. Interestingly, increases of the same order of magnitude have been obtained from experimental studies such as Amthor⁶¹, who obtained almost 31% higher grain yields by doubling the CO₂ concentration value under laboratory conditions or Fitzgerald *et al.*⁶² who measured a CO₂ stimulation of wheat production ranging from 24% to 53% in FACE experiments. By contrast, temperature rise at constant atmospheric CO₂ concentration result in lower yields for all climate scenarios and sowing dates. In line with our results, Ludwig and Asseng¹⁵ found that a rise of 4 °C decreased the potential yield by as much as 32% and that an increase of 6 °C decreased the yield a further 50%. Also, You *et al.*⁶³ observed a significant reduction in yield in China owing to a rise in temperature and it was concluded that a 1.8 °C rise could cause a 3–10% reduction in wheat yields. Early sowing could be significantly more heavily impacted by temperature rise. When considering climate change and rising CO₂ concentration, it appears that whatever the scenario and the horizon, the fertilizing effect of atmospheric CO₂ concentration might offset the losses induced by rising temperatures. Interestingly, the resulting increase of yields is higher for intermediate and late sowing. The simulated positive interaction between elevated CO₂ concentration and temperature was also observed in several experimental studies⁶¹. Wheeler *et al.*⁶⁴ have grown winter wheat (*Triticum aestivum*) in a field inside polyethylene-covered tunnels at a range of temperatures from about 1–2 °C below to about 2–3 °C above ambient, and at CO₂ concentrations of 380 and 684 ppm. They found that grain yield was reduced by warmer temperatures but increased by CO₂ enrichment at all temperatures. The grain-filling rate could also be impacted by the combined effects of temperature and CO₂ increase. Wheeler *et al.*⁶⁴ again found that the rate of increase in the dry weight of grain per ear was 8.0 mg/day greater at 684 ppm than at 380 ppm CO₂ concentration for a given temperature, but that this higher filling rate was not able to compensate for the reduction of the grain-filling rate caused by increased temperature.

Water requirements decrease for all scenarios and horizons taking into account temperature and precipitation change and the CO₂ fertilizing effect. This results from a drop in both cumulative evaporation and transpiration because of the shortening of the wheat cycle and improved stomatal closure respectively. Atkinson *et al.*⁶⁵ and Hendrey *et al.*⁶⁶ observed a decrease of stomatal conductance of 30%–40% although there are large differences between species. Woodward⁶⁷ has also highlighted a decline in stomatal density and concluded from these changes that the efficiency of water use has improved significantly. Hunsaker *et al.*⁵⁴ demonstrated that the water productivity of wheat could increase by 50 to 60% depending on the water conditions under a doubled CO₂ concentration. This increase in WP is due to increased photosynthesis⁵⁵ and thus increased grain production per unit of transpired water⁵⁶. The irrigation requirement decreases by 11 to 31% depending on the scenario and horizon. Interestingly, the decrease in the cycle's duration could also impact the temporal pattern of irrigation, with a possible shift of the season towards a requirement peak as much as two months earlier for the most extreme case.

Despite a number of studies^{39,68} showing that rising CO₂ concentration negates the adverse effects of rising temperatures in semi-arid climates, it is important to reemphasize that the uncertainties remain high. In fact, the sign of change is reversed whether or not the rise in CO₂ concentration is taken into account. “Reality” will certainly lie in between. The first issue to be addressed⁶⁹ is the parameterization of detailed, process-based photosynthetic models such as that of Farquhar *et al.*⁷⁰ for C3 plants. This might better represent the complex interaction between CO₂ and the meteorological environment in plant physiology than semi-empirical approaches such as AquaCrop's. In addition, several factors that have not been considered in this study. Another important aspect is related to the soil type, which may alter wheat production via the soil's holding capacity. Larger negative impacts from rising temperatures are usually expected on light soils with lower water-holding capacities^{15,16}. This means in particular that wheat in the Tensift region seems to bring together a number of favorable conditions favoring yield increase in a changing climate (heavy soils, a warm and dry climate favoring a positive reaction to CO₂ rise).

The results could have direct implication for agricultural practices and water management in the region. First, considering water requirement, the seasonal pattern of irrigation demand could be significantly modified, with a peak requirement that might be advanced for wheat by about two months. This change in the temporal pattern of irrigation requirement could affect water managers, who could reap more benefit from surface water for irrigating cereals in winter while spring inputs, partially originating from snow melt in snowfed catchments such as the Tensift, could be retained to water perennials during the summer. This point is important within the context of the current extension and intensification of tree crops in the Mediterranean area, which further constrain agricultural water demand, especially during the hottest months^{71,72}. The precipitation decrease in autumn could also foster a later sowing and shift the season by up to two months as farmers usually seed after the first rainfall, even for irrigated areas. While early sowing has been found to have a positive impact on final production for Mediterranean areas⁷³ by avoiding coincidence between the pollination and period of high temperature¹⁴, our study suggest that in a changing climate later sowing could be preferable. Another question that arises from the shortening of the growth cycle is related to the optimal choice of wheat cultivars. Long-duration wheat varieties are not well suited to the semi-arid Mediterranean region at the present time because the grain-filling phase coincides with the severe temperatures occurring in late spring. In view of the shortening of the crop cycle, longer duration and drought-tolerant varieties that may prove more productive⁷⁴ could become increasingly rewarding in a changing climate.

Finally, we evaluated only the impact of climate change on the optimal wheat yields and crop water needs without considering constraints in terms of water availability, agricultural practices and socio-economic conditions. In practice, the potential yield increase under climate change shown in this study under optimal conditions in terms of irrigation and fertilizer could never be reached because of several practical constraints. First, nitrogen is a major limiting factor for agricultural production. FACE experiments conducted on wheat by Long *et al.*²⁶ with N inputs of 15 to 70 kg ha⁻¹, which is considered to be low by all agricultural standards but exceeds the typical farm inputs in the study region, resulted in a yield increase of 9% only, about a third of what was expected²⁶. To reach the simulated increase in yield, a nitrogen amount may be needed, well beyond the financial capacity of most small-scale farmers cropping wheat in the region. Another main constraint will be the availability of water resource in the future, due to reduced rainfall and increased evaporation demand. In a recent study, Trambly *et al.*²¹ highlighted a potential decrease of surface water availability in Morocco (dams are the principal source of irrigation) that could reach 40% around 2066–2095 under RCP8.5 scenario. Within this context, water allocated to irrigation could decrease in the future considering the numerous competing demands (industry, tourism, drinking water ...). In reality, irrigation efficiency is also far from optimal. Taking into account leakage within the network, bad irrigation scheduling and water losses by drainage and soil evaporation, irrigation efficiency barely exceed 50%⁷⁵. Considering only irrigation technics and farmers practices, several studies carried out in Morocco^{76–79} based on experimental data (mainly eddy-covariance stations, lysimeters and soil moisture profile) showed very different results in terms of water lost by the plant either through soil evaporation or deep drainage. The main conclusion is that the conversion to drip irrigation that is fostered in several north african countries through ambitious public policy does not necessary lead to the expected water savings with regards to more traditional method such as flooding. The reason are numerous: bad use of the technic by the farmers, soil washout because of a high level of salinity, extension of irrigation to the surrounding field that were not previously irrigated because of an easier access to water thanks to the drip system, intensification of crops (inter-cropping) for the same reason ... By contrast, irrigation scheduling could also be modified towards deficit irrigation consisting in a trade-off between water saving while maintaining acceptable level of yields in order to save water.

This study points out the need (1) for more field experiments in order to better understand how temperature, water and CO₂ concentration interact to impact wheat yields; (2) for considering agricultural practices in future studies.

Methods

Study site and meteorological data. The Tensift-Haouz region, located in the center of Morocco (Fig. 5), covers some 20,000 km² and is characterized by a semi-arid Mediterranean climate. The atmosphere is dry, with an average relative humidity of 56%^{15,47,48}. The annual average evaporation demand is very high (around 1600 mm/year), based on the reference evapotranspiration ET_0 ⁸⁰, greatly exceeding the annual rainfall which ranges from 190 to 250 mm/year⁸¹. Most of the precipitation falls during winter and spring from the beginning of November until the end of April^{15,47,48}. Common wheat is one of the region's main crops. It is cultivated both in rainfed and irrigated fields, depending on access to water supply and climate conditions. Cereals can be sown as early as November 1st if significant rainfall occurs, but a persistent drought at the beginning of the growing season can delay seeding until January 15th. Harvesting usually takes place around the end of May. Precipitation, minimum and maximum temperature data were acquired by the synoptic station at Marrakech airport located at 8°W/31°30'N from 1991 to 2010.




Figure 5. Location of the Tensift watershed.

Climate data and bias corrected scenarios. Five regional climate model (RCM) simulations with a horizontal resolution of 50 km were extracted from the Med-CORDEX experiment⁸², which aims to produce a set of simulations at various resolutions, taking into account the specificity of the Mediterranean climate. The main characteristics of each simulation are presented in Table S1.

Two climate scenarios were selected for comparison: the representative concentration pathways (RCP) 4.5 and 8.5. Emissions in the RCP4.5 peak around 2040, then decline, while in RCP8.5, emissions continue to rise throughout the 21st century. These RCPs scenarios and their associated atmospheric CO₂ concentrations are listed in Table S2. Finally, two time horizons are considered (2041–2060 and 2081–2100) and compared to the so-called “historical” period (1991–2010).

For each model, the following climate simulations were selected:

- Historical runs (HIST): simulations for the control period available from 1950–2005 depending on the model, with RCMs forced by the various GCMs indicated in Table S1.
- Scenario runs: simulations for future projections (2005–2100) with RCMs forced by various GCMs according to emission scenarios RCP4.5 and RCP8.5.

Extracted variables correspond to the meteorological inputs of the AquaCrop model at a daily time step: minimum temperature (Tmin), maximum temperature (Tmax) and precipitation (pr). Reference evapotranspiration was estimated using the empirical method Hargreaves–Samani which requires only air temperature⁸³. Er-Raki *et al.*⁸¹ have shown the good performance of this formula in Tensift region. Although the RCM simulations have been found to match the main patterns of climates encountered in Mediterranean countries^{84,85}, some significant and systematic discrepancies with observed data have been highlighted. For this reason, bias correction of climate runs is unavoidable for hydrological and agronomical impact studies. The five Med-CORDEX runs corresponding to the grid point centered on the synoptic station at Marrakech (8°W/31°30'N) are thus bias corrected based on the daily data acquired by the station using the quantile-quantile approach described below. Only temperature and precipitation are bias corrected in this study.

The bias correction method aims to correct the large discrepancies usually observed between model predictions and local observations that are attributed to parameterization problem or to orography representation. The quantile-quantile method has the advantage of correcting skews of the considered model. It is a non-linear method which consists in correcting the values of the quantiles of the model by those calculated from the observations⁸⁶. In each point of the model, for each weather variable, the 99 percentiles of the daily series are then calculated as well as the minimum and maximum values and the same is done from the series of daily observations. The correction function consists of associating each percentile of the model with the observed percentile, and, thus, of matching the distribution of observations to the simulations. For any model value between two percentiles, a linear interpolation is carried out⁸⁶. The software used in this study has been developed by Giuliani *et al.*⁸⁷. Within this study, the bias correction of daily temperature and precipitation has been applied to all models separately in order to assess the ensemble spread. In addition, it was independently applied season by season (January-February-March, April-May-June, July-August-September, October-November-December). This was




Figure 6. Flowchart of the proposed methodology to study the impact of climate change on grain yield (Y), water requirements (WR) and water productivity (WP).

done because of the strong seasonal contrast of rainfall distribution between the rainy season (from November to May) and the dry season during the summer. In order to assess the impact of the climate scenarios spread on yields and water requirements projections, three simulations of the Aquacrop model were carried out using the Mean and Mean \pm SD of the 5 RCM models.

A literature review suggests that bias correction methods including the quantile-quantile used in this study suffer from different caveats^{88,89}: (1) it does not always preserve trends of the raw GCM runs⁹⁰; (2) it tends to overestimate the spread of the ensemble runs of climate models for future projected variables⁹¹; (3) it can also corrupts the extremes (lower and higher percentiles)^{92,93}. As these limitations could have some implications for the conclusion of our study, it has been checked that the trends of the raw climate runs together with the spread of the ensemble is not significantly modified by the application of the quantile-quantile approach (not shown). Finally, the corruption of very extreme lower and higher percentiles is a common feature of bias correction method. For our study, it precludes from studying the impact of threshold processes such as during the pollination stage when very high temperature (above 30 °C for daily average) lead to a drastic drop of wheat (cf. description of the Aquacrop model in the supplementary material).

The Aquacrop model. AquaCrop, developed by the Land and Water Division of the Food and Agriculture Organization of the United Nations (FAO), is a crop model to simulate yield response to water use as a decision support tool for agricultural planning and scenario analysis including future climate scenario^{30,94,95}. AquaCrop includes the following sub-model components: soil, crop, atmosphere and management⁹⁶. The impact of climate change can be evaluated in AquaCrop by: (i) adjusting the precipitation data, (ii) adjusting the temperature data, (iii) enhancing the CO₂ levels. The first two options are performed in this study through the Med-CORDEX ensemble runs described above. In addition, the CO₂ rise scenarios from RCP4.5 and RCP4.8 were applied (Table S2). The basic concepts and fundamental calculation procedures of AquaCrop are presented in Steduto *et al.*³⁰ and further described as supplementary materials (section S1).

Implementation of AquaCrop and experiments. The FAO offers calibrated crop parameter values for most agricultural crops and provides them as default values in the model. In particular, a distinction is made between conservative, and non-conservative parameter:

- Conservative crop parameters are not materially affected by time, management practices or geographic location (for example: base temperature, upper temperature and initial canopy cover). They were calibrated using data from crops grown under favorable and non-limiting conditions³⁰.

- Non-conservative crop parameters (Calibrated parameter) may require adjustment when selecting a different variety from that used for calibration (for example: time from sowing to emergence, maximum canopy cover, start of senescence). Non-conservative crop parameters are influenced by plot management, soil profile conditions, and climate.

In our study, the generic variety of wheat is *Triticum durum* and the sowing density is 150 kg/ha. Both parameters were kept identical for each experiment (see below). The soil is homogeneous, characterized by a clay-loamy texture typical of the region of study: the values of field capacity (Fc), permanent wilting point (PWP), saturation (Sat) and hydraulic conductivity (Ksat) were 0.32, 0.17, 0.45 m³/m³ and 100 mm/day respectively. In addition, non-conservative calibrated parameters for winter wheat crop in the Tensift region were obtained from Toumi *et al.*³¹ (Table S3). Various parameters affecting canopy cover (FC), evapotranspiration, total water content (TWC) and yield were calibrated and validated on the basis of a comparison between measurements and the results of simulations³¹. The average values of the Mean Bias Error (MBE) between observed and measured CC, evapotranspiration and GY were 7.89%, -0.01 mm/day and 0.06 t/ha for the validation fields, respectively. Finally, since the focus is on irrigated wheat, irrigation is planned automatically by the model to avoid water stress. The AquaCrop model calculates the quantity of water required to avoid water stress on the crop. When the depletion of the root zone exceeds a certain threshold ($Dr = 0.5$ TAW in our case following Toumi *et al.*³¹), an automatic irrigation is carried out to reset the soil depletion. This calibrated version of the Aquacrop model is thus assumed to simulate with a reasonable accuracy yields and water requirements for wheat in our region of study.

Three typical sowing dates were evaluated: early sowing around November 15th; intermediate sowing around December 15th; and late sowing around January 15th. In order to assess the actual optimal wheat yields and water requirements, AquaCrop was run with observational data (“historical” experiment) with a climatology forcing corresponding to 20 years (1991–2010) using CO₂ concentrations, with the value of year 2000 set to 369 ppm. The results of this experiment were then used to determine the baseline of wheat yield, water requirements and productivity, from which any increases or decreases due to climate change could be estimated. In future-climate scenarios, the effects of increasing CO₂ concentration were isolated from predicted changes in climate variables (precipitation and temperature) with the help of three separate experiments: a CO₂-only change named the “CO₂” experiment; climate change only, including temperature and precipitation changes (“CC” experiment); and CO₂ and climate changes (“CCO₂” experiment). For experiments taking into account a change in CO₂ concentration (“CO₂” and “CCO₂”), the ambient atmospheric CO₂ was replaced by the values from the two RCP scenarios (Table S2). For each scenario, projections are carried out under two scenarios (RCP4.5, RCP8.5) and two time horizons (2041–2060, 2081–2100). For the “CC” and “CCO₂” experiments, AquaCrop was run with average of climate data and average plus and minus standard deviations between all RCM models to assess the uncertainties of projections associated with climate ensemble runs.

A summary of the data analysis and simulation steps used in this study is presented in the flowchart below (Fig. 6).

Received: 18 May 2019; Accepted: 21 November 2019;

Published online: 16 December 2019

References

1. IPCC. IPCC Fifth Assessment Synthesis Report-Climate Change 2014 Synthesis Report. *IPCC Fifth Assess. Synth. Report-Climate Chang. 2014 Synth. Rep.* pages: 167 (2014).
2. Giorgi, F. Climate change hot-spots. *Geophys. Res. Lett.* **33**, 1–4 (2006).
3. Chiffres, L. M. en. Sommaire Préambule. **537**, 212–66 (2015).
4. Blinda, M. & Giraud, J. Vers une meilleure efficacité de l'utilisation de l'eau en Méditerranée. *LES CAHIERS DU PLAN BLEU N°14* **44** (2012).
5. Lobell, D. B. *et al.* Prioritizing climate change adaptation needs for food security in 2030. *Science (80-)*. **319**, 607–610 (2008).
6. Morison, J. I. L. Intercellular CO₂ concentration and stomatal response to CO₂ in *Stomatal function* 229–252 (1987).
7. Drake, B. G., González-Meler, M. A. & Long, S. P. MORE EFFICIENT PLANTS: A Consequence of Rising Atmospheric CO₂? *Annu. Rev. Plant Physiol. Plant Mol. Biol.* **48**, 609–639 (1997).
8. Kimball, B. A. *et al.* Elevated CO₂, drought and soil nitrogen effects on wheat grain quality. *New Phytol.* **150** (2001).
9. Herwaarden, A. F., van, Farquhar, G. D., Angus, J. F., Richards, R. A. & Howe, G. N. ‘Haying-off’, the negative grain yield response of dryland wheat to nitrogen fertiliser. I. Biomass, grain yield, and water use. *Aust. J. Agric. Res.* **49**, 1067 (1998).
10. Burke, J. J., Mahan, J. R. & Hatfield, J. L. Crop-Specific Thermal Kinetic Windows in Relation to Wheat and Cotton Biomass Production. *Agron. J.* **80**, 553 (1988).
11. Mearns, L. O., Rosenzweig, C. & Goldberg, R. Mean and Variance Change in Climate Scenarios: Methods, Agricultural Applications and Measures of Uncertainty. *Clim. Change* **35**, 30 (1997).
12. Peng, S. *et al.* Rice yields decline with higher night temperature from global warming. *Proc. Natl. Acad. Sci.* **101**, 9971–9975 (2004).
13. Hafid, R. E., Smith, D. H., Karrou, M. & Samir, K. Morphological attributes associated with early-season drought tolerance in spring durum wheat in a mediterranean environment. *Crop Sci.* 273–282 (1998).
14. Heng, L. K., Asseng, S., Mejahed, K. & Rusan, M. Optimizing wheat productivity in two rain-fed environments of the West Asia–North Africa region using a simulation model. *Eur. J. Agron.* **26**, 121–129 (2007).
15. Ludwig, F. & Asseng, S. Climate change impacts on wheat production in a Mediterranean environment in Western Australia. *Agric. Syst.* **90**, 159–179 (2006).
16. Yang, Y., Liu, D. L., Anwar, M. R., Zuo, H. & Yang, Y. Impact of future climate change on wheat production in relation to plant-available water capacity in a semi-arid environment. *Theor. Appl. Climatol.* **115**, 391–410 (2014).
17. Saadi, S. *et al.* Climate change and Mediterranean agriculture: Impacts on winter wheat and tomato crop evapotranspiration, irrigation requirements and yield. *Agric. Water Manag.* **147**, 103–115 (2015).
18. Ruiz-Ramos, M. & Mínguez, M. I. Evaluating uncertainty in climate change impacts on crop productivity in the Iberian Peninsula. *Clim. Res.* **44**, 69–82 (2010).
19. Wang, B., Liu, D. L., Asseng, S., Macadam, I. & Yu, Q. Modelling wheat yield change under CO₂ increase, heat and water stress in relation to plant available water capacity in eastern Australia. *Eur. J. Agron.* **90**, 152–161 (2017).

20. Lovelli, S. *et al.* Effects of rising atmospheric CO₂ on crop evapotranspiration in a Mediterranean area. *Agric. Water Manag.* **97**, 1287–1292 (2010).
21. Tramblay, Y., Jarlan, L., Hanich, L. & Somot, S. Future Scenarios of Surface Water Resources Availability in North African Dams. *Water Resour. Manag.* **32**, 1291–1306 (2018).
22. Dettori, M., Cesaraccio, C. & Duce, P. Simulation of climate change impacts on production and phenology of durum wheat in Mediterranean environments using CERES-Wheat model. *F. Crop. Res.* **206**, 43–53 (2017).
23. Valverde, P. *et al.* Climate change impacts on rainfed agriculture in the Guadiana river basin (Portugal). *Agric. Water Manag.* **150**, 35–45 (2015).
24. Rodriguez-Diaz, A. J., Weatherhead, E. K., Knox, J. W. & Camacho, E. Climate change impacts on irrigation water requirements in the Guadalquivir river basin in Spain. *Reg. Environ. Chang.* **7**, 149–159 (2007).
25. Fader, M., Shi, S., Von Bloh, W., Bondeau, A. & Cramer, W. Mediterranean irrigation under climate change: More efficient irrigation needed to compensate for increases in irrigation water requirements. *Hydrol. Earth Syst. Sci.* **20**, 953–973 (2016).
26. Long, S. P., Ainsworth, E. A., Leakey, A. D. B., Ort, D. R. & No, J. Food for Thought: Lower-Than-Expected Crop Yield Stimulation with Rising CO₂ Concentrations. *Science (80-)*. **312**, 1918–1922 (2006).
27. Tubiello, F. N. & Ewert, F. Simulating the effects of elevated CO₂ on crops: approaches and applications for climate change. *Eur. J. Agron.* **00**, 1–18 (2002).
28. Ainsworth, E. A. & Long, S. P. What have we learned from 15 years of free-air CO₂ enrichment (FACE)? A meta-analytic review of the responses of photosynthesis, canopy properties and plant production to rising CO₂. *New Phytol.* **165**, 351–372 (2005).
29. Yin, X. Improving ecophysiological simulation models to predict the impact of elevated atmospheric CO₂ concentration on crop productivity. *Ann. Bot.* **112**, 465–475 (2013).
30. Steduto, P., Hsiao, T. C., Raes, D. & Fereres, E. AquaCrop—The FAO Crop Model to Simulate Yield Response to Water: I. Concepts and Underlying Principles. *Agron. J.* **101**, 426 (2009).
31. Toumi, J. *et al.* Performance assessment of AquaCrop model for estimating evapotranspiration, soil water content and grain yield of winter wheat in Tensift Al Haouz (Morocco): Application to irrigation management. *Agric. Water Manag.* **163**, 219–235 (2016).
32. Akumaga, U., Tarhule, A., Piani, C., Traore, B. & Yusuf, A. Utilizing Process-Based Modeling to Assess the Impact of Climate Change on Crop Yields and Adaptation Options in the Niger River Basin, West Africa. *Agronomy* **8**, 11 (2018).
33. Bird, D. N. *et al.* Modelling climate change impacts on and adaptation strategies for agriculture in Sardinia and Tunisia using AquaCrop and value-at-risk. *Sci. Total Environ.* **543**, 1019–1027 (2016).
34. Abedinpour, M., Sarangi, A., Rajput, T. B. S. & Singh, M. Prediction of maize yield under future water availability scenarios using the AquaCrop model. *J. Agric. Sci.* **152**, 558–574 (2014).
35. Stevens, T. & Madani, K. Future climate impacts on maize farming and food security in Malawi. *Sci. Rep.* **6**, 1–14 (2016).
36. Vanuytrecht, E., Raes, D. & Willems, P. Considering sink strength to model crop production under elevated atmospheric CO₂. *Agric. For. Meteorol.* **151**, 1753–1762 (2011).
37. Vanuytrecht, E., Raes, D., Willems, P. & Sam, G. Quantifying field-scale effects of elevated carbon dioxide concentration on crops. *Clim. Res.*, <https://doi.org/10.3354/cr01096> (2012).
38. McMaster, G. S. & Wilhelm, W. W. Growing degree-days: One equation, two interpretations. *Agric. For. Meteorol.* **87**, 291–300 (1997).
39. Dixit, P. N., Telleria, R., Al Khatib, A. N. & Allouzi, S. F. Decadal analysis of impact of future climate on wheat production in dry Mediterranean environment: A case of Jordan. *Sci. Total Environ.* **610–611**, 219–233 (2018).
40. Ewert, F. *et al.* Effects of elevated CO₂ and drought on wheat: Testing crop simulation models for different experimental and climatic conditions. *Agric. Ecosyst. Environ.* **93**, 249–266 (2002).
41. Pinter, P. J. *et al.* Free-air CO₂ enrichment (FACE): Blower effects on wheat canopy microclimate and plant development. *Agric. For. Meteorol.* **103**, 319–333 (2000).
42. Lawlor, D. W. & Mitchell, R. A. C. Crop ecosystem responses to climatic change: wheat. *Clim. Chang. Glob. Crop Product.* 57–80, <https://doi.org/10.1079/9780851994390.0057> (2000).
43. Jarlan, L. *et al.* Linkages between common wheat yields and climate in Morocco (1982–2008). *Int. J. Biometeorol.* **58** (2014).
44. Wang, J., Wang, E. & Liu, D. L. Modelling the impacts of climate change on wheat yield and field water balance over the Murray-Darling Basin in Australia. *Theor. Appl. Climatol.* **104**, 285–300 (2011).
45. Wardlaw, I. F. & Dunstone, R. L. Effect of temperature on seed development in jojoba (*Simmondsia chinensis* (Link) Schneider). I. Dry matter changes. *Aust. J. Agric. Res.* **35**, 685–691 (1984).
46. Hatfield, J. L. & Prueger, J. H. Temperature extremes: Effect on plant growth and development. *Weather Clim. Extrem.* **10**, 4–10 (2015).
47. Duchemin, B. *et al.* Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices. *Agric. Water Manag.* **79**, 1–27 (2006).
48. Er-Raki, S. *et al.* Combining FAO-56 model and ground-based remote sensing to estimate water consumptions of wheat crops in a semi-arid region. *Agric. Water Manag.* **87**, 41–54 (2007).
49. Aouade, G. *et al.* Combining stable isotopes, Eddy Covariance system and meteorological measurements for partitioning evapotranspiration, of winter wheat, into soil evaporation and plant transpiration in a semi-arid region. *Agric. Water Manag.* **177** (2016).
50. Diarra, A. *et al.* Performance of the two-source energy budget (TSEB) model for the monitoring of evapotranspiration over irrigated annual crops in North Africa. *Agric. Water Manag.* **193**, 71–88 (2017).
51. Rafi, Z. *et al.* Partitioning evapotranspiration of a drip-irrigated wheat crop: Inter-comparing eddy covariance-, sap flow-, lysimeter- and FAO-based methods. *Agric. For. Meteorol.* **265**, 310–326 (2019).
52. Hadria, R. *et al.* Calibration and validation of the STICS crop model for managing wheat irrigation in the semi-arid Marrakech/Al Haouzi plain. *Arab. J. Sci. Eng.* (2007).
53. Kharrou, M. H. *et al.* Assessment of Equity and Adequacy of Water Delivery in Irrigation Systems Using Remote Sensing-Based Indicators in Semi-Arid Region, Morocco. *Water Resour. Manag.* **27**, 4697–4714 (2013).
54. Hunsaker, D. J. *et al.* CO₂ enrichment and soil nitrogen effects on wheat evapotranspiration and water use efficiency. *Agric. For. Meteorol.*, [https://doi.org/10.1016/S0168-1923\(00\)00157-X](https://doi.org/10.1016/S0168-1923(00)00157-X) (2000).
55. Stoddard, F. L., Mäkelä, P. S. A. & Puhakainen, T. Adaptation of Boreal Field Crop Production to Climate Change. *Clim. Chang. - Res. Technol. Adapt. Mittig.* (2011).
56. Fischer, G., Tubiello, F. N., Velthuizen, H. V. & Wiberg, D. A. Climate change impacts on irrigation water requirements: Effects of mitigation, 1990–2080. *Technol. Forecast. Soc. Change* **74**, 1083–1107 (2007).
57. Haim, D., Shechter, M. & Berliner, P. Assessing the impact of climate change on representative field crops in Israeli agriculture: A case study of wheat and cotton. *Clim. Change* **86**, 425–440 (2008).
58. Marchane, A., Tramblay, Y., Hanich, L., Ruelland, D. & Jarlan, L. Climate change impacts on surface water resources in the Rheraya catchment (High Atlas, Morocco). *Hydrol. Sci. J.* **62**, 979–995 (2017).
59. Idso, S. B., Kimball, B. A. & Mauney, J. R. Atmospheric CO₂ enrichment and plant dry matter content. *Agric. For. Meteorol.* **43**, 171–181 (1988).
60. Wang, J., Wang, E., Luo, Q. & Kirby, M. Modelling the sensitivity of wheat growth and water balance to climate change in Southeast Australia. *Clim. Change* **96**, 79–96 (2009).

61. Amthor, J. S. Effects of atmospheric CO₂ concentration on wheat yield: Review of results from experiments using various approaches to control CO₂ concentration. *F. Crop. Res.* **73**, 1–34 (2001).
62. Fitzgerald, G. J. *et al.* Elevated atmospheric [CO₂] can dramatically increase wheat yields in semi-arid environments and buffer against heat waves. *Glob. Chang. Biol.* **22**, 2269–2284 (2016).
63. You, L., Rosegrant, M. W., Wood, S. & Sun, D. Impact of growing season temperature on wheat productivity in China. *Agric. For. Meteorol.* **149**, 1009–1014 (2009).
64. Wheeler, T. R. *et al.* The duration and rate of grain growth, and harvest index, of wheat (*Triticum aestivum* L.) in response to temperature and CO₂. *J. Exp. Bot.* **47**, 623–630 (1996).
65. Atkinson, C. J., Wookey, P. A. & Mansfield, T. A. Atmospheric pollution and the sensitivity of stomata on barley leaves to abscisic acid and carbon dioxide. *New Phytol.* **117**, 535–541 (1991).
66. Hendrey, G. R., Ellsworth, D. S., Lewin, K. F. & Nagy, J. A free-air enrichment system for exposing tall forest vegetation to elevated atmospheric CO₂. *Glob. Chang. Biol.* **5**, 293–309 (1999).
67. Woodward, F. I. Plant responses to past concentrations of carbon dioxide. 145–155 (1993).
68. Angulo, C. *et al.* Implication of crop model calibration strategies for assessing regional impacts of climate change in. *Europe. Agric. For. Meteorol.* **170**, 32–46 (2013).
69. Soussana, J. F., Graux, A. I. & Tubiello, F. N. Improving the use of modelling for projections of climate change impacts on crops and pastures. *J. Exp. Bot.* **61**, 2217–2228 (2010).
70. Farquhar, G. D., von Caemmerer, S. & Berry, J. A. A biochemical model of photosynthetic CO₂ assimilation in leaves of C3 species. *Planta* **149**, 78–90 (1980).
71. Jarlan, L. *et al.* Water Resources in South Mediterranean Catchments: Assessing climatic drivers and impacts. in *The Mediterranean Region under Climate Change* (eds. Thiébaud, S. & Moatti, J. P.) 303–309 (2016).
72. Voltz, M., Ludwig, W., Leduc, C. & Bouarfa, S. Mediterranean land systems under global change: current state and future challenges. *Reg. Environ. Chang.* **1–4**, <https://doi.org/10.1007/s10113-018-1295-9> (2018)
73. Photiades, I. & Hadjichristodoulou, A. Sowing date, sowing depth, seed rate and row spacing of wheat and barley under dryland conditions. *F. Crop. Res.* **9**, 151–162 (1984).
74. Boote, K. J. *et al.* Position statement on crop adaptation to climate change. *Crop Sci.* **51**, 2337–2343 (2011).
75. Hamdy, A. & Katerji, N. Water crisis in the Arab World. Analysis and solutions. in *IAM-Bari Editor* 60 p. (2006).
76. Khabba, S. *et al.* The SudMed Program and the Joint International Laboratory TREMA: A Decade of Water Transfer Study in the Soil-plant-atmosphere System over Irrigated Crops in Semi-arid Area. *Procedia Environ. Sci.* **19**, 524–533 (2013).
77. Nassah, H. *et al.* Evaluation and analysis of deep percolation losses of drip irrigated citrus crops under non-saline and saline conditions in a semi-arid area. *Biosyst. Eng.* **165**, 10–24 (2018).
78. Sefiani, S. *et al.* Evaluation of Groundwater Quality and Agricultural use Under a Semi-arid Environment: Case of Agafay, Western Haouz, Morocco. *Irrig. Drain.*, <https://doi.org/10.1002/ird.2363> (2019).
79. Jarlan, L. *et al.* Remote Sensing of Water Resources in Semi-Arid Mediterranean Areas: the joint international laboratory TREMA. *Int. J. Remote Sens.* **36**, 4879–4917 (2015).
80. Allen, R. G., Pereira, L. S., Raes, D., Smith, M. & W, A. B. Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56. *Irrig. Drain.* 1–15, <https://doi.org/10.1016/j.eja.2010.12.001> (1998).
81. Er-Raki, S. *et al.* Assessment of reference evapotranspiration methods in semi-arid regions: Can weather forecast data be used as alternate of ground meteorological parameters? *J. Arid Environ.* **74** (2010).
82. Ruti, P. M. *et al.* Med-CORDEX initiative for Mediterranean climate studies. *Bull. Am. Meteorol. Soc.* **97**, 1187–1208 (2016).
83. Hargreaves, G. H. & Samani, Z. A. Reference crop evapotranspiration from temperature. *Trans. ASAE* **1**, 96–99 (1985).
84. Flaounas, E. *et al.* Precipitation and temperature space-time variability and extremes in the Mediterranean region: Evaluation of dynamical and statistical downscaling methods. *Clim. Dyn.* **40**, 2687–2705 (2013).
85. Vaithinada Ayar, P. *et al.* Intercomparison of statistical and dynamical downscaling models under the EURO- and MED-CORDEX initiative framework: present climate evaluations. *Clim. Dyn.* **46**, 1301–1329 (2016).
86. Déqué, M. Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Glob. Planet. Change* **57**, 16–26 (2007).
87. Giulani, M., Li, Y., Anghileri, A., C. S. A. T. Plan: Introduction, [https://github.com/mxgiuliani00/ClimateScenarioAnalysisToolbox\(2015\)](https://github.com/mxgiuliani00/ClimateScenarioAnalysisToolbox(2015))
88. Ehret, U., Zehe, E., Wulfmeyer, V., Warrach-Sagi, K. & Liebert, J. HESS Opinions 'should we apply bias correction to global and regional climate model data?'. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-16-3391-2012> (2012).
89. Maraun, D. Bias Correcting Climate Change Simulations - a Critical Review. *Current Climate Change Reports*, <https://doi.org/10.1007/s40641-016-0050-x> (2016).
90. Grillakis, M. G., Koutroulis, A. G., Daliakopoulos, I. N. & Tsanis, I. K. A method to preserve trends in quantile mapping bias correction of climate modeled temperature. *Earth Syst. Dyn.* **8**, 889–900 (2017).
91. Chen, J. *et al.* Bias correcting climate model multi-member ensembles to assess climate change impacts on hydrology. *Clim. Change* **153**, 361–377 (2019).
92. Ali, H., Modi, P. & Mishra, V. Increased flood risk in Indian sub-continent under the warming climate. *Weather Clim. Extrem.* **25** (2019).
93. Cannon, A. J., Sobie, S. R. & Murdock, T. Q. Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes? *J. Clim.* **28**, 6938–6959 (2015).
94. Hsiao, T. C. *et al.* Aquacrop-The FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. *Agron. J.* **101**, 448–459 (2009).
95. Steduto, P. *et al.* Performance review of AquaCrop - The FAO crop-water productivity model. *ICID 21st Int. Congr. Irrig. Drain.* 231–248 (2011).
96. Araya, A., Habtu, S., Hadgu, K. M., Kebede, A. & Dejene, T. Test of AquaCrop model in simulating biomass and yield of water deficient and irrigated barley (*Hordeum vulgare*). *Agric. Water Manag.* **97**, 1838–1846 (2010).

Acknowledgements

This research was conducted within the frame of the International Joint Laboratory TREMA (<http://trema.ucam.ac.ma>). Funding were provided by SAGESSE PPR/2015/48 'Système d'Aide à la décision pour la Gestion des reSSources en Eau', the European Commission Horizon 2020 Programme for Research and Innovation (H2020) in the context of the Marie Skłodowska-Curie Research and Innovation Staff Exchange (RISE) action (ACCWA project, grant agreement no. 823965), ERANETMED3-062 CHAAMS 'global CHange: Assessment and Adaptation to Mediterranean region water Scarcity' and the MISTRALS/SICMED program. E.B. received a mobility grant from the PHC Toubkal #39064WG/2018.

Author contributions

L.J., S.K., E.B. and S.E. conceived the study and wrote the paper. E.B. processed the data and run the model. F.S., Y.T. and A.D. contributed to the results analysis and to the revision of the paper.

Competing interests

The authors declare no competing interests.

Additional information

Supplementary information is available for this paper at <https://doi.org/10.1038/s41598-019-55251-2>.

Correspondence and requests for materials should be addressed to L.J.

Reprints and permissions information is available at www.nature.com/reprints.

Publisher's note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons license, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons license, unless indicated otherwise in a credit line to the material. If material is not included in the article's Creative Commons license and your intended use is not permitted by statutory regulation or exceeds the permitted use, you will need to obtain permission directly from the copyright holder. To view a copy of this license, visit <http://creativecommons.org/licenses/by/4.0/>.

© The Author(s) 2019

1. Supplementary Methods

1.1. Description of the Aquacrop model

The complexity of crop responses to water deficits leads to the use of empirical production functions as the most practical option for assessing crop yield response. Among the empirical function approaches available, the FAO Irrigation & Drainage equation expresses the yield response as a function of the crop water status (Eq.1).

$$\left(\frac{Y_x - Y_a}{Y_x}\right) = K_y \left(\frac{ET_x - ET_a}{ET_x}\right) \text{ Eq. 1}$$

where Y_x and Y_a are the maximum and actual yields, ET_x and ET_a are the maximum and actual evapotranspirations, and K_y is the proportionality factor between relative yield loss and relative reduction in evapotranspiration. The AquaCrop model uses canopy cover (FC) as the basis for calculating plant transpiration (Tr) and soil evaporation (E)¹. Crop transpiration (Tr) is calculated by multiplying ET_0 by the crop transpiration coefficient (Kc_{Tr}) and by considering the effect of water stress K_s (Eq.2).

$$Tr = (K_s \cdot Kc_{Tr}) \cdot ET_0 \text{ Eq. 2}$$

ET_0 is estimated with the Hargreaves equation². Soil evaporation is calculated by multiplying ET_0 by the soil water evaporation coefficient (K_e) and by considering the effect of soil water evaporation reduction K_r (Eq.3):

$$E = (K_r \cdot K_e) \cdot ET_0 \text{ Eq. 3}$$

The separation of evapotranspiration into E and Tr avoids the confounding effect of the non-productive water³. Aboveground biomass is calculated as the product of the normalized crop water productivity (WP) and the accumulation of crop transpiration ($\sum Tr$) as follows (Eq.4):

$$B = WP \cdot \sum Tr \text{ Eq. 4}$$

where Tr is the crop transpiration (in mm/day) and WP is the water productivity parameter (kg of biomass per m² and per mm of cumulated water transpired over the time period during which the

biomass is produced). WP is considered constant for a given climate and crop: it is set between 15 and 20 g m⁻² for C3 crops such as wheat and between 30 and 35 g m⁻² for C4 crops⁴. The WP parameter in the model is normalized in order to make the model applicable to diverse locations and seasons, including future climate scenarios^{5,6}.

Crop yield (Y) is calculated as the product of biomass (B) and harvest index (HI) (Eq. 5).

$$Y = B.HI \text{ Eq. 5}$$

The impact of increasing CO₂ levels is calculated in AquaCrop by adjusting WP using a correction coefficient f_{CO_2} if the atmospheric CO₂ concentration differs from its reference value (369 ppm) as follows:

$$WP_{adj} = f_{CO_2} \cdot WP \text{ Eq. 6}$$

where WP_{adj} is the WP adjusted for CO₂ concentration and f_{CO_2} represents the difference between the reference value and the atmospheric composition for a specific year, as follows⁴:

$$f_{CO_2} = \frac{(C_{a,i}/C_{a,0})}{1+(C_{a,i}-C_{a,0})[(1-w)b_{Sted}+w(f_{Sink} \cdot b_{Sted}+(1-f_{Sink}) \cdot b_{FACE})]} \text{ Eq. 7}$$

where $C_{a,0}$ is the reference atmospheric CO₂ concentration (369 ppm); $C_{a,i}$ the atmospheric CO₂ concentration for year i (ppm); b_{Sted} and b_{FACE} are two empirical coefficients equal to 0.000138 and 0.001165 respectively (as derived from Free Air CO₂ Experiments -FACE; w a weighing factor; and f_{Sink} the crop sink strength coefficient ranging for wheat from 0.0 to 0.2⁷).

2. Supplementary tables

Table S1 :Med-CORDEX simulation characteristics and runs considered (MED 44 grid): Goethe University Frankfurt (GUF); Institut Pierre Simon Laplace (IPSL); Centre National de Recherches Météorologiques (CNRM); International Centre for Theoretical Physics (ICTP); Centro Euro-Mediterraneo sui Cambiamenti Climatici (CMCC).

Institute	RCM Model	Resolution	GCM Model	HIST	RCP4.5	RCP8.5
GUF	CCLM	50km	MPIESM	X	X	X
IPSL	LMDZ	50km	IPSL	X	X	X
CNRM	ALADIN	50km	CNRM	X	X	X
ICTP	REGCM4	50km	HAD	X	X	X
CMCC	CCLM	50km	CMCC	X	X	X

Table S2: Atmospheric CO₂ concentrations for RCP4.5 and RCP8.5 at two horizons. The values in the table are parts per million (ppm) equivalent and were obtained from [IPCC](#) ⁸.

	2000	2050	2090
Baseline	369	-	-
RCP4.5	-	487	541
RCP8.5	-	534	845

Table S3 : Main input parameters of the AquaCrop model and calibrated values from [Toumi et al.](#)⁹

Conservative	
Base temperature (°C)	5
Upper temperature (°C)	33
Initial canopy cover, CC0 (%)	5.06
Canopy cover per seeding (cm ² /plant)	1.5
Maximum coefficient for transpiration, K _{cTr,x}	1.07
Maximum coefficient for soil evaporation, K _{ex}	0.25
Upper threshold for canopy expansion, P _{exp,upper}	0.3
Lower threshold for canopy expansion, P _{exp,lower}	0.8
Leaf expansion stress coefficient curve shape	5.5
Upper threshold for stomatal closure, P _{sto,upper}	0.5
Stomatal stress coefficient curve shape	2.5
Canopy senescence stress coefficient, P _{sen, upper}	0.85
Senescence stress coefficient curve shape	2.5
Reference harvest index, HI0 (%)	46
Normalized crop water productivity, WP* (g/m ²)	16
Non conservative	
Time from sowing to emergence (CGDD)	82
Time from sowing to maximum CC (CGDD)	696
Time from sowing to start senescence (CGDD)	972

Time from sowing to maturity (CGDD)	1462
Maximum canopy cover, CCx (%)	0.95
Canopy growth coefficient, CGC (%/GDD)	0.89
Canopy decline coefficient, CDC (%/GDD)	0.6
Maximum effective rooting depth, Zx (m)	0.55

3. Supplementary Figures




Figure S 1 : Cumulative daily temperatures from observations and from the different scenarios and horizons during the theoretical wheat season (November to May).

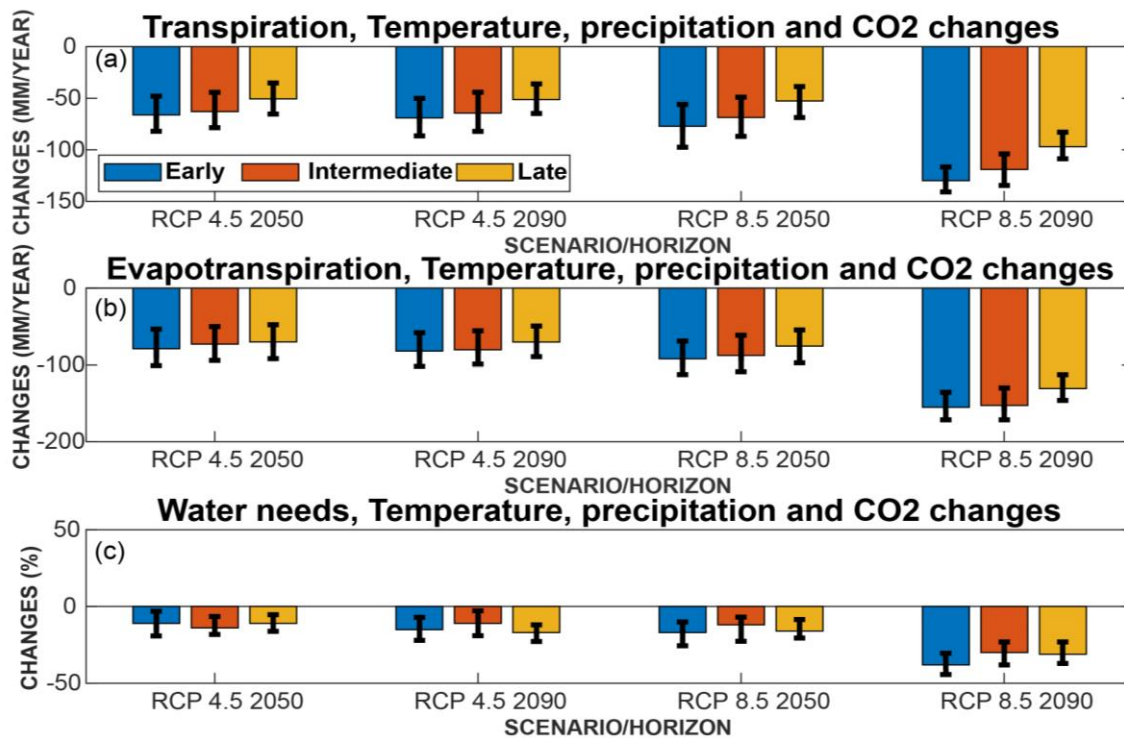


Figure S 2 : Relative change in (a) transpiration, (b) evapotranspiration and (c) water requirements) for temperature, precipitation and CO2 changes “CCO2” experiment. The error bars correspond to Mean \pm SD of the 5 RCM models.

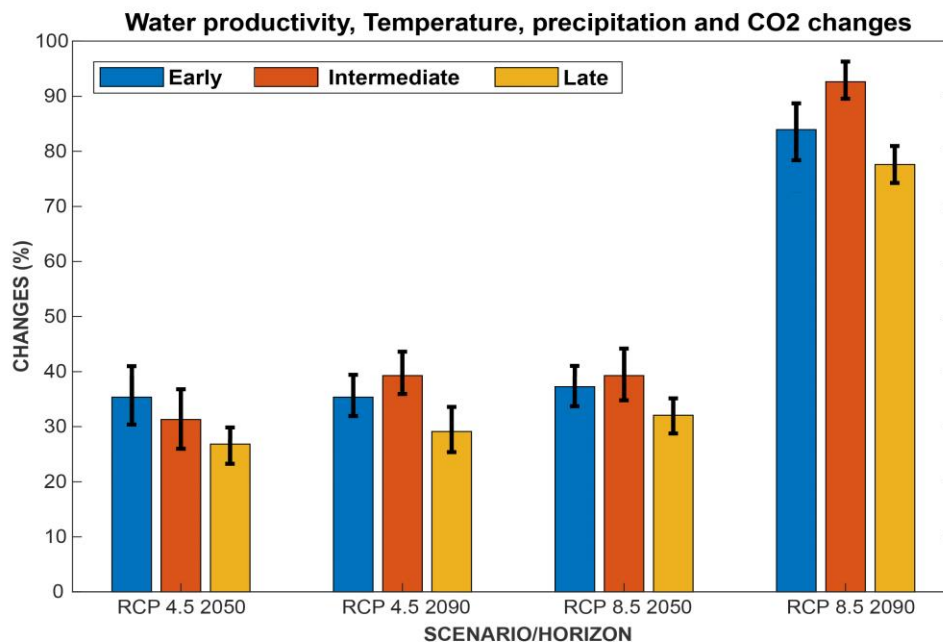


Figure S 3: Relative change in water productivity for all sowing date and scenario) for temperature, precipitation and CO2 changes “CCO2” experiment. The error bars correspond to Mean \pm SD of the 5 RCM models.

References

1. Raes, D., Steduto, P., Hsiao, T. C. & Fereres, E. Aquacrop-The FAO crop model to simulate yield response to water: II. main algorithms and software description. *Agron. J.* **101**, 438–447 (2009).
2. Hargreaves, G. H. & Samani, Z. A. Reference crop evapotranspiration from temperature. *Trans. ASAE* **1**, 96–99 (1985).
3. Araya, A., Habtu, S., Hadgu, K. M., Kebede, A. & Dejene, T. Test of AquaCrop model in simulating biomass and yield of water deficient and irrigated barley (*Hordeum vulgare*). *Agric. Water Manag.* **97**, 1838–1846 (2010).
4. Steduto, P. *et al.* Performance review of AquaCrop - The FAO crop-water productivity model. *ICID 21st Int. Congr. Irrig. Drain.* 231–248 (2011).
5. Steduto, P., Hsiao, T. C., Raes, D. & Fereres, E. Aquacrop-the FAO crop model to simulate yield response to water: I. concepts and underlying principles. *Agron. J.* **101**, 426–437 (2009).
6. Hsiao, T. C. *et al.* Aquacrop-The FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. *Agron. J.* **101**, 448–459 (2009).
7. Vanuytrecht, E., Raes, D. & Willems, P. Considering sink strength to model crop production under elevated atmospheric CO₂. *Agric. For. Meteorol.* **151**, 1753–1762 (2011).
8. IPCC. IPCC Fifth Assessment Synthesis Report-Climate Change 2014 Synthesis Report. *IPCC Fifth Assess. Synth. Report-Climate Chang. 2014 Synth. Rep.* pages: 167 (2014).
9. Toumi, J. *et al.* Performance assessment of AquaCrop model for estimating evapotranspiration, soil water content and grain yield of winter wheat in Tensift Al Haouz (Morocco): Application to irrigation management. *Agric. Water Manag.* **163**, 219–235 (2016).

IV) Conclusion

Dans ce travail, nous avons quantifié l'impact du changement climatique sur le rendement du blé et ses besoins en eau. Les résultats de notre travail pourraient avoir une implication sur les pratiques agricoles et la gestion de l'eau dans la région d'étude. Tout d'abord, la modification du calendrier de l'irrigation pourrait aider les gestionnaires de l'eau, qui pourraient tirer davantage profit des eaux de surface pour irriguer les céréales en hiver, tandis que les apports d'eau au printemps, provenant en partie de la fonte des neiges, pourraient être conservés pour arroser les cultures pérennes pendant l'été. Ce point est important dans le contexte de l'extension et de l'intensification actuelles des cultures arboricoles dans la zone méditerranéenne, qui limite davantage la demande en eau agricole, en particulier pendant les mois les plus chauds. La diminution des précipitations en automne pourrait favoriser un semis plus tardif et décaler la saison de deux mois au maximum, car les agriculteurs sèment après la première pluie, même dans les zones irriguées. Nous avons constaté qu'actuellement le semis précoce a un impact positif sur le rendement, en évitant la coïncidence entre la pollinisation et la période de température élevée. Notre étude suggère que dans le contexte du changement climatique, le semis tardif pourrait être préférable dans le futur, car il est moins impacté que le semis précoce. Une autre question qui découle du raccourcissement du cycle de croissance est liée au choix de variété de blé. Les variétés à longue durée de vie ne sont pas bien adaptées à la région méditerranéenne semi-aride à l'heure actuelle, car la phase de remplissage des grains coïncide avec les températures sévères de la fin du printemps. Compte tenu du raccourcissement du cycle, les variétés à plus longue durée et tolérantes à la sécheresse, qui peuvent s'avérer plus productives, pourraient devenir de plus en plus intéressantes dans le contexte du changement climatique dans le futur.

Enfin, nous avons évalué uniquement l'impact du changement climatique sur les rendements optimaux du blé et les besoins en eau des cultures sans tenir compte des contraintes en termes de disponibilité de l'eau, de pratiques agricoles et des conditions socio-économiques. En pratique, l'augmentation potentielle des rendements dans le cadre du changement climatique montrée dans cette étude dans des conditions optimales en termes d'irrigation et de fertilisation, ne pourrait peut-être pas être atteinte en raison de plusieurs contraintes pratiques. Parmi ces contraintes, la faible capacité financière de la plupart des petits agriculteurs de la région, qui ne permet pas d'apporter la quantité optimale de fertilisation (azote). Une autre contrainte majeure sera la disponibilité des ressources en eau dans le futur, en raison de la réduction des précipitations et de l'augmentation de la demande d'évaporation. [Tramblay et al., \(2018\)](#) ont

montré une diminution de la disponibilité des eaux de surface au Maroc (les barrages sont la principale source d'irrigation) qui pourrait atteindre 40% vers 2066-2095 selon le scénario RCP8.5. Dans ce contexte, l'eau allouée à l'irrigation pourrait diminuer à l'avenir compte tenu des nombreuses demandes concurrentes (industrie, tourisme, eau potable...).

Conclusion générale et perspectives

De par sa situation géographique, le Maroc est caractérisé par un climat fortement contrasté avec un régime pluviométrique dominé par une forte irrégularité dans l'espace et dans le temps. Ce régime entraîne une forte variabilité spatio-temporelle de la production agricole. Cette situation risque de se dégrader sous l'effet du changement climatique. La plupart des projections montrent qu'au cours des prochaines décennies, le pays affichera progressivement des signes d'aridité croissante en raison de la hausse des températures et de la diminution des précipitations. De même, d'autres études ont montré une augmentation de la fréquence des événements extrêmes (sécheresse, inondation ...) et une réduction des réserves en eau mobilisables dans notre pays (Tramblay et al., 2018; Zkhiri et al., 2019). Le secteur agricole, en raison de sa place prépondérante dans l'utilisations des ressources en eau (86 % des ressources en eau mobilisable), sera le secteur le plus impacté par la baisse prévue des précipitations. Il sera aussi affecté par la hausse prévue des températures (Harbouze et al., 2019).

Les céréales, cultivées sur 59 % de surface agricole utile, sont de loin la culture la plus importante dans notre pays. Les céréales sont à la fois pluviales et irriguées, en fonction de l'accès à l'eau et des conditions climatiques. Cependant, la production céréalière, réalisée essentiellement en zones pluviales, est sujette aux fortes fluctuations interannuelles de la pluviométrie. Les superficies irrigables qui pourraient réduire cette dépendance vis-à-vis du climat, représentent moins de 9% des superficies cultivées et contribuent à moins de 17% de la production totale (Harbouze et al., 2019). La production des céréales au Maroc fait donc face à un double défi : assurer une production face à une population croissante dans un contexte d'évolution du climat et en particulier, de l'augmentation de la fréquence des sécheresses tout en assurant la durabilité des ressources en eau et en sol.

Dans ce contexte, les objectifs de ce travail de thèse ont été : (1) de caractériser le lien entre la sécheresse agricole identifiée par des indices de télédétection et les sorties d'un LDAS et la production des céréales au Maroc ; (2) de développer des modèles empiriques de prévisions précoces du rendement des céréales basés sur la combinaison entre des données multi-sources (Télédétection, météo, climat) avec des algorithmes de machine learning à l'échelle de la province agricole au Maroc ; (3) de quantifier l'impact du changement climatique sur la

production optimale du blé (sans contrainte de disponibilité en eau et en fertilisant) et ses besoins en eau.

Le suivi de sécheresse agricole et son impact sur la production des céréales.

La sécheresse agricole se caractérise par un déficit d'humidité du sol, causé par un manque de précipitations et/ou une augmentation de la température qui entraîne une augmentation de l'évapotranspiration. La sécheresse agricole a des impacts négatifs sur la production des cultures. Ces impacts sont sévères lorsque les périodes de sécheresse ont lieu pendant les stades phénologiques clés du développement des cultures, par exemple pendant le stade de l'émergence et le remplissage des grains pour les céréales. Afin d'étudier le lien entre la sécheresse agricole et la production des céréales, les 15 provinces les plus productives au Maroc ont été sélectionnées. La sécheresse agricole a été identifiée par (i) les indices dérivés de la télédétection dans trois domaines de longueur d'onde (optique, infrarouge thermique et micro-ondes). Dans ce contexte, nous avons sélectionné le VCI qui est une normalisation de NDVI dérivé de MODIS dans le domaine optique. Le VCI est un indice qui permet de suivre l'état de la végétation et donc de détecter la sécheresse agricole. De plus, nous avons utilisé le TCI qui est une normalisation de LST du MODIS dans le domaine de l'infrarouge thermique. Pendant les périodes de sécheresse ou la plante est stressée, elle ferme ses stomates et sa température augmente. Dans le cas contraire, la plante transpire à son taux potentiel et sa température baisse. Concernant l'humidité du sol, le SMCI et le MAI qui sont des normalisations de l'humidité du sol. Dans notre étude, ils sont dérivés des produits de, respectivement, l'ESA CCI et du SWI de ASCAT. En plus des indices dérivés de la télédétection, nous avons identifié la sécheresse par les anomalies de plusieurs variables de sortie du LDAS de Météo-France : le LAI, la transpiration, l'évaporation et l'humidité du sol à différentes profondeurs.

A l'échelle mensuelle, les résultats obtenus montrent une forte corrélation entre les indices liés à la végétation (VCI, LAI) et le rendement des céréales durant les mois de Mars-Avril qui correspondent au stade d'épiaison. Cependant le lien entre l'indice dérivé de la température de surface (TCI) et la production est significative pendant tous les stades de développement en Janvier-février. Concernant les indices d'humidité du sol des couches superficielles, la corrélation avec le rendement est plus significative pendant le stade d'émergence en Décembre. Quand les indices ont été intégrés à l'échelle des principaux stades phénologiques au lieu de

l'échelle mensuelle traditionnellement utilisée dans ce contexte, une amélioration du coefficient de corrélation entre les indices et le rendement a été observé.

L'adaptation aux effets du changement climatique est un défi majeur pour les pays situés dans la région méditerranéenne. Ces effets comprennent une augmentation de la fréquence des périodes de sécheresse sévère. Par conséquent, une gestion intégrée de la sécheresse est nécessaire, à travers le développement et la mise en place d'un système d'alerte précoce de ce phénomène (Tramblay et al., 2020). Les résultats de notre travail peuvent être exploités pour atteindre cet objectif. Notre travail sera très utile pour développer un système d'alerte précoce de la sécheresse agricole au Maroc et pourrait potentiellement être généralisé dans d'autres zones d'Afrique par la suite. Cela peut se faire par le développement de nouveaux indices de suivi de la sécheresse agricole, qui tiennent compte de la spécificité de la région. Ces indices seront construits en combinant les observations de satellites disponibles, les observations météorologiques et les indices climat à grande échelle à l'aide des modèles physiques ou empiriques de Machine learning. Ces indices vont également permettre de suivre la réponse des cultures au déficit de précipitations, afin de mieux comprendre la propagation de la sécheresse météorologique vers la sécheresse agricole.

La prévision précoce de rendement des céréales avec des modèles empiriques.

La prévision saisonnière des rendements des cultures est un outil important pour assurer la sécurité alimentaire et pour l'équilibre de la balance entre la production et les besoins de population par la planification des importations ou/exportations. Dans ce contexte, nous avons développé des modèles empiriques de prévision des rendements des céréales à l'échelle provinciale sur les 15 provinces les plus productives au Maroc.

Dans le but de développer ces modèles, nous avons utilisé comme prédicteurs des rendements, trois sources de données qui sont (i) les indices de sécheresse dérivés de la télédétection (VCI, TCI et SMCI) ;(ii) les données météo (la température et les précipitations) ; (iii) les indices témoignant des pseudo-oscillations climatiques (ONA, SCA, les modes de SST). Aussi, outre la régression linéaire multiple, nous avons utilisé trois algorithmes non-linéaire de machine learning qui sont le SVM, RF et XGBoost. Tout d'abord, nous avons identifié la meilleure combinaison de prédicteurs pour la prévision de rendement. À cette fin, nous avons testé trois

combinaisons de données pour effectuer une prédiction en Avril, soit 1 à 2 mois avant la récolte. Les résultats obtenus montrent qu'avec chaque jeu de données considérés séparément, le coefficient de détermination (R^2) entre le rendement observé et prédit varie selon l'algorithme utilisé et la province agricole entre 0.67 et 0.81 alors que la combinaison des trois sources de données a permis d'obtenir de meilleures performances pour toutes les provinces et toutes les méthodes avec un R^2 qui peut atteindre 0.95 et un RMSE autour de 0.20 t. ha⁻¹ pour certaines provinces. De même, les résultats montrent que les méthodes non-linéaires sont plus performantes que la méthode linéaire. Ensuite, nous avons évalué la performance de ces modèles en fonction de la période de prévision. Pour cela, nous avons développé des modèles de prévision en Mars, Février et en Janvier qui correspondent respectivement à 2, 3 et 4 mois avant la récolte. Les résultats obtenus indiquent que la performance des modèles s'améliore en s'approchant de la date de récolte. Également, les résultats ont montré que les indices dérivés de la télédétection ont contribué à hauteur de 73% pour les modèles de prévision 2 mois avant la récolte, tandis que les données météorologiques et les indices climatiques, sont des variables clés pour la prévision précoce du rendement plus tôt dans la saison : leurs poids dans les modèles de prévision est notamment de l'ordre de 80% au mois de Janvier. Finalement, afin de tester la performance des modèles développés dans des cas pratiques, nous avons enlevé l'année où nous souhaitons faire la prévision et nous avons construit les modèles avec les données des autres années. Nos résultats indiquent que les modèles développés expliquent jusqu'à 89% de la variabilité du rendement au mois de janvier (4 mois avant la récolte) avec un RMSE de 0.22 t. ha⁻¹ témoignant de la robustesse des outils de prévision développés.

Le machine learning avec la Internet des objets (IoT, Internet of Things) sont des éléments clés de la prochaine révolution agricole (Sharma et al., 2021). Dans ce sens, nos résultats montrent que l'intégration des données multi-sources dans des algorithmes de machine learning peut fournir des outils utiles pour une prévision précoce du rendement des céréales au Maroc et peut être utilisée comme une source d'informations intéressante pour la prise de décision pour planifier les importations par les décideurs.

Parmi les perspectives, afin d'améliorer nos modèles de prévision, doivent être prises en considération d'autres variables qui influent sur le rendement, comme le type de sol, la date de semis et les pratiques de gestion. Une autre perspective de notre travail est de comparer les

modèles empiriques et les modèles de croissance des cultures alimentés par les prévisions météorologiques saisonnières comme le modèle AquaCrop, ainsi que de combiner les deux approches dans un modèle hybride (Shahhosseini et al., 2021) qui pourrait permettre de mieux représenter certains processus au sein du modèle qui sont mal représentés. La performance des modèles de croissance des cultures sont sensibles aux erreurs de mesure des variables d'entrée, incident climatique, maladie, etc. (Dorigo et al., 2007; Dumont et al., 2012; Marin et al., 2017). Plusieurs études ont montré que d'assimilation des observations par les satellites dans les modèles de croissances des cultures ont permis d'améliorer la performance de ces dernières en termes d'estimation de rendement final en grain et en biomasse (Huang et al., 2019; Lu et al., 2021; Mishra et al., 2021). Dans ce contexte, nous souhaitons assimiler les produits d'humidité à haute résolution spatiale telle que ceux produits par Ouaadi et al., (2020) ou par El Hajj et al. (2016) et des indices de végétation comme le NDVI dans le modèle AquaCrop pour obtenir des informations précises à échelle spatiale sur le rendement des céréales au Maroc.

Impact du changement climatique sur le rendement du blé et leurs besoins en eau.

L'objectif de cette partie est de quantifier l'impact du changement climatique sur le rendement du blé irrigué et ses besoins en eau dans la région de Tensift au Maroc. Les projections des températures et des précipitations extraites des bases données Med-CORDEX selon deux scénarios RCP4.5 et RCP8.5 et pour les deux horizons 2041-2060 et 2081-2100 sont premièrement, évaluées et désagrégées avec la méthode quantile-quantile. Les résultats montrent que pour tous les scénarios et les horizons, une augmentation des températures maximales et minimales est attendue. Cette augmentation allant de 1°C (RCP4.5 2050) à 6°C (RCP8.5 2090). Le cycle saisonnier de l'augmentation des températures est assez marqué, avec une augmentation plus forte pendant les mois d'hiver durant le cycle de développement du blé. L'augmentation des températures engendre une augmentation de l'évapotranspiration de référence, qui pourrait atteindre 9.2% selon RCP8.5 2090. Concernant les précipitations, selon les projections futures, une diminution est prévue pour la plupart des scénarios et les horizons. Cette baisse des précipitations est particulièrement importante au printemps (mars et avril) et en hiver (octobre à décembre). Cette baisse en printemps varié entre 38 % et 45 % selon les scénarios et les horizons.

Ensuite, nous avons étudié l'impact du changement climatique sur la durée des principaux stades phénologiques de développement du blé, en se basant sur l'approche degrés-jours, pour les trois dates de semis : semis précoce autour du 15 novembre, semis intermédiaire autour du 15 décembre et semis tardif autour du 15 janvier. Les résultats ont montré une réduction de la durée de la saison de croissance de blé de 10 à 32% selon la date de semis, scénario et horizon.

Les impacts de l'augmentation de la température, de concentration du CO₂ et des diminutions de précipitations sur les rendements du blé et les besoins en eau et leur productivité sont ensuite évalués, sur la base du modèle AquaCrop selon 3 expériences pour les 3 dates de semis : (i) Avec augmentation du CO₂ uniquement, (ii) avec augmentation de la température et changement des précipitations uniquement et (iii) avec augmentation de CO₂, de la température et changement des précipitations. Comme prévu, selon l'expérience qui ne prenait en compte que l'augmentation de la concentration de CO₂, les résultats indiquent une augmentation du rendement du blé pour tous les scénarios et pour toutes les périodes. Vers 2050, les rendements du blé pourraient augmenter de 21 à 26 % pour les scénarios RCP4.5 et RCP8.5 respectivement. Par contre, le rendement diminuera selon l'expérience qui prend en compte l'augmentation de température et le changement des précipitations uniquement. Par exemple, en 2050 pour les RCP4.5 et RCP8.5, les baisses de rendements prévues sont de l'ordre de 11 et 18% pour le semis précoce. Selon l'expérience qui tient compte de l'augmentation du CO₂, de la température et du changement des précipitations, une augmentation du rendement est prévue pour tous les scénarios RCP et tous les horizons. Cela signifie que l'effet fertilisant du CO₂ peut contrebalancer la diminution du rendement due à l'augmentation des Températures. Par exemple, En 2050, le rendement pourrait augmenter de 7 à 12 % pour le semis précoce et intermédiaire, selon le scénario RCP, et en 2090, les augmentations maximales des rendements sont attendues pour le semis tardif sous RCP8.5 (27%).

Les résultats obtenus montrent aussi une diminution des besoins en eau (pluie + irrigation) selon la troisième expérience. Concernant les besoins en irrigation (BR), pour le semis précoce, les BR actuels sont d'environ 160 mm répartis de décembre à mars avec un maximum en février (48 mm). En 2050, selon le scénario RCP4.5, les BR devraient augmenter de 2% pour atteindre 164 mm, avec un pic en février. En revanche, en 2090, selon le scénario RCP8.5, la demande en irrigation devrait diminuer de 33 mm (20 %) de décembre à février, avec un maximum

avancé d'un mois en janvier (49 mm). Pour le semis tardif et intermédiaire, le décalage du besoin maximal est d'environ 2 mois pour le semis tardif en 2090 selon le scénario RCP8.5

A la lumière de ces résultats nous envisageons certaines perspectives pour mieux évaluer l'impact du changement climatique sur le rendement et les besoins en eau du blé. Tout d'abord, on envisage d'utiliser des projections futures avec une résolution spatiale plus fine pour mieux reproduire les conditions climatiques futures. Par ailleurs, nous souhaitons nous intéresser aussi à l'agriculture pluviale qui mobilise une part importante de la main d'œuvre agricole et qui permet la survie de nombreuses familles au Maroc. La spatialisation de notre étude sur tout le Maroc sera importante afin de déterminer les provinces les plus vulnérables afin de planifier des stratégies d'adaptation spécifiques pour chaque région. Aussi, nous suggérons de réaliser des essais expérimentaux sur le blé en conditions contrôlées de température de l'air et de teneur en CO₂, afin de mieux comprendre comment la température, l'eau et la concentration de CO₂ interagissent pour avoir un impact sur les rendements. Dans ce contexte, trois expériences sous serre, liées aux scénarios climatiques futurs sont envisagées : (1) un essai de référence avec la température et la concentration de CO₂ actuelle, (2) un essai avec le scénario climatique réaliste RCP4.5, et (3) un essai avec le scénario climatique pessimiste RCP8.5. Finalement, on prendra en compte les évolutions des pratiques agricoles dans le futur par l'élaboration de scénarios anthropiques (Le Page et al., 2021) et nous étudierons leur impact sur le rendement et les besoins en eau.

Références

- Abbas, F., Afzaal, H., Farooque, A.A., Tang, S., 2020. Crop yield prediction through proximal sensing and machine learning algorithms. *Agronomy* 10. <https://doi.org/10.3390/AGRONOMY10071046>
- ABEDINPOUR, M., SARANGI, A., RAJPUT, T.B.S., SINGH, M., 2014. Prediction of maize yield under future water availability scenarios using the AquaCrop model. *J. Agric. Sci.* 152, 558–574. <https://doi.org/10.1017/S0021859614000094>
- Aggarwal, S., 2004. PRINCIPLES OF REMOTE SENSING, in: *Satellite remote sensing and GIS applications in agricultural meteorology*. bl 23–38.
- AghaKouchak, A., Farahmand, A., Melton, F.S., Teixeira, J., Anderson, M.C., Wardlow, B.D., Hain, C.R., 2015. Remote sensing of drought: Progress, challenges and opportunities. *Rev. Geophys.* <https://doi.org/10.1002/2014RG000456>
- Ahmed, M., Stöckle, C.O., Nelson, R., Higgins, S., 2017. Assessment of climate change and atmospheric CO₂ impact on winter wheat in the Pacific Northwest using a multimodel ensemble. *Front. Ecol. Evol.* <https://doi.org/10.3389/fevo.2017.00051>
- Akumaga, U., Tarhule, A., Piani, C., Traore, B., Yusuf, A., 2018. Utilizing Process-Based Modeling to Assess the Impact of Climate Change on Crop Yields and Adaptation Options in the Niger River Basin, West Africa. *Agronomy* 8, 11. <https://doi.org/10.3390/agronomy8020011>
- Albergel, C., Munier, S., Bocher, A., Bonan, B., Zheng, Y., Draper, C., Leroux, D.J., Calvet, J.C., 2018. LDAS-Monde sequential assimilation of satellite derived observations applied to the contiguous US: An ERA-5 driven reanalysis of the land surface variables. *Remote Sens.* <https://doi.org/10.3390/rs10101627>
- Albergel, C., Munier, S., Jennifer Leroux, D., Dewaele, H., Fairbairn, D., Lavinia Barbu, A., Gelati, E., Dorigo, W., Faroux, S., Meurey, C., Le Moigne, P., Decharme, B., Mahfouf, J.F., Calvet, J.C., 2017. Sequential assimilation of satellite-derived vegetation and soil moisture products using SURFEX-v8.0: LDAS-Monde assessment over the Euro-Mediterranean area. *Geosci. Model Dev.* <https://doi.org/10.5194/gmd-10-3889-2017>
- Albergel, C., Zheng, Y., Bonan, B., Dutra, E., Rodríguez-Fernández, N., Munier, S., Draper, C., de Rosnay, P., Muñoz-Sabater, J., Balsamo, G., Fairbairn, D., Meurey, C., Calvet, J.-C., 2020. Data assimilation for continuous global assessment of severe conditions over terrestrial surfaces. *Hydrol. Earth Syst. Sci.* <https://doi.org/10.5194/hess-24-4291-2020>
- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., Notarnicola, C., 2015. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. *Remote Sens.* <https://doi.org/10.3390/rs71215841>
- Amri, R., Zribi, M., Lili-Chabaane, Z., Wagner, W., Hasenauer, S., 2012. Analysis of C-band scatterometer moisture estimations derived over a semiarid region. *IEEE Trans. Geosci. Remote Sens.* <https://doi.org/10.1109/TGRS.2012.2186458>
- Amthor, J.S., 2001. Effects of atmospheric CO₂ concentration on wheat yield: Review of results from experiments using various approaches to control CO₂ concentration. *F. Crop. Res.* 73, 1–34. [https://doi.org/10.1016/S0378-4290\(01\)00179-4](https://doi.org/10.1016/S0378-4290(01)00179-4)
- Anderson, M.C., hain, C., Otkin, J., Zhan, X., Mo, K., Svoboda, M., Wardlow, B., Pimstein, A., 2013. An intercomparison of drought indicators based on thermal remote sensing and NLDAS-2 simulations with U.S. drought monitor classifications. *J. Hydrometeorol.* 14. <https://doi.org/10.1175/JHM-D-12-0140.1>

- Anderson, M.C., Zolin, C.A., Hain, C.R., Semmens, K., Tugrul Yilmaz, M., Gao, F., 2015. Comparison of satellite-derived LAI and precipitation anomalies over Brazil with a thermal infrared-based Evaporative Stress Index for 2003-2013. *J. Hydrol.* 526, 287–302. <https://doi.org/10.1016/j.jhydrol.2015.01.005>
- Anderson, M.C., Zolin, C.A., Sentelhas, P.C., Hain, C.R., Semmens, K., Tugrul Yilmaz, M., Gao, F., Otkin, J.A., Tetrault, R., 2016. The Evaporative Stress Index as an indicator of agricultural drought in Brazil: An assessment based on crop yield impacts. *Remote Sens. Environ.* 174, 82–99. <https://doi.org/10.1016/j.rse.2015.11.034>
- Anjum, S.A., Xie, X. yu, Wang, L. chang, Saleem, M.F., Man, C., Lei, W., 2011. Morphological, physiological and biochemical responses of plants to drought stress. *African J. Agric. Res.* <https://doi.org/10.21921/jas.5.3.7>
- Asseng, S., Ewert, F., Martre, P., Rötter, R.P., Lobell, D.B., Cammarano, D., Kimball, B.A., Ottman, M.J., Wall, G.W., White, J.W., Reynolds, M.P., Alderman, P.D., Prasad, P.V.V., Aggarwal, P.K., Anothai, J., Basso, B., Biernath, C., Challinor, A.J., De Sanctis, G., Doltra, J., Fereres, E., Garcia-Vila, M., Gayler, S., Hoogenboom, G., Hunt, L.A., Izaurralde, R.C., Jabloun, M., Jones, C.D., Kersebaum, K.C., Koehler, A.K., Müller, C., Naresh Kumar, S., Nendel, C., O’leary, G., Olesen, J.E., Palosuo, T., Priesack, E., Eyshi Rezaei, E., Ruane, A.C., Semenov, M.A., Shcherbak, I., Stöckle, C., Stratonovitch, P., Streck, T., Supit, I., Tao, F., Thorburn, P.J., Waha, K., Wang, E., Wallach, D., Wolf, J., Zhao, Z., Zhu, Y., 2015. Rising temperatures reduce global wheat production. *Nat. Clim. Chang.* <https://doi.org/10.1038/nclimate2470>
- Asseng, S., Ewert, F., Rosenzweig, C., Jones, J.W., Hatfield, J.L., Ruane, A.C., Boote, K.J., Thorburn, P.J., Rötter, R.P., Cammarano, D., Brisson, N., Basso, B., Martre, P., Aggarwal, P.K., Angulo, C., Bertuzzi, P., Biernath, C., Challinor, A.J., Doltra, J., Gayler, S., Goldberg, R., Grant, R., Heng, L., Hooker, J., Hunt, L.A., Ingwersen, J., Izaurralde, R.C., Kersebaum, K.C., Müller, C., Naresh Kumar, S., Nendel, C., O’Leary, G., Olesen, J.E., Osborne, T.M., Palosuo, T., Priesack, E., Ripoche, D., Semenov, M.A., Shcherbak, I., Steduto, P., Stöckle, C., Stratonovitch, P., Streck, T., Supit, I., Tao, F., Travasso, M., Waha, K., Wallach, D., White, J.W., Williams, J.R., Wolf, J., 2013. Uncertainty in simulating wheat yields under climate change. *Nat. Clim. Chang.* <https://doi.org/10.1038/nclimate1916>
- Asseng, S., Jamieson, P.D., Kimball, B., Pinter, P., Sayre, K., Bowden, J.W., Howden, S.M., 2004. Simulated wheat growth affected by rising temperature, increased water deficit and elevated atmospheric CO₂. *F. Crop. Res.* 85, 85–102. [https://doi.org/10.1016/S0378-4290\(03\)00154-0](https://doi.org/10.1016/S0378-4290(03)00154-0)
- Balaghi, R., 2006. PhD thesis “Wheat grain yield forecasting models for food security in Morocco”.
- Balaghi, R., Jlibene, M., Tychon, B., Eerens, H., 2013a. Agrometeorological Cereal Yield Forecasting in Morocco. *Int. J. Water Resour. Dev.* 26, 157. <https://doi.org/10.13140/RG.2.1.3645.6805>
- Balaghi, R., Jlibene, M., Tychon, B., Eerens, H., 2013b. Agrometeorological Cereal Yield Forecasting in Morocco. *Int. J. Water Resour. Dev.* 26, 157. <https://doi.org/10.13140/RG.2.1.3645.6805>
- Balaghi, R., Tychon, B., Eerens, H., Jlibene, M., 2008. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco. *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2006.12.001>
- Balaghi, R.J.M., 2009. Le risque sécheresse en agriculture pluviale. *Inra* 77–80.
- Basso, B., Cammarano, D., Carfagna, E., 2013. Review of Crop Yield Forecasting Methods and Early Warning Systems. *First Meet. Sci. Advis. Comm. Glob. Strateg. to Improv. Agric. Rural Stat.*
- Basso, B., Liu, L., 2019. Seasonal crop yield forecast: Methods, applications, and accuracies, in: *Advances in Agronomy.* <https://doi.org/10.1016/bs.agron.2018.11.002>
- Beck, H.E., McVicar, T.R., van Dijk, A.I.J.M., Schellekens, J., de Jeu, R.A.M., Bruijnzeel, L.A., 2011. Global

- evaluation of four AVHRR-NDVI data sets: Intercomparison and assessment against Landsat imagery. *Remote Sens. Environ.* 115. <https://doi.org/10.1016/j.rse.2011.05.012>
- Beck, H.E., Pan, M., Miralles, D.G., Reichle, R.H., Dorigo, W.A., Hahn, S., Sheffield, J., Karthikeyan, L., Balsamo, G., Parinussa, R.M., van Dijk, A.I.J.M., Du, J., Kimball, J.S., Vergopolan, N., Wood, E.F., 2021. Evaluation of 18 satellite- And model-based soil moisture products using in situ measurements from 826 sensors. *Hydrol. Earth Syst. Sci.* 25. <https://doi.org/10.5194/hess-25-17-2021>
- Beck, P.S.A., Atzberger, C., Høgda, K.A., Johansen, B., Skidmore, A.K., 2006. Improved monitoring of vegetation dynamics at very high latitudes: A new method using MODIS NDVI. *Remote Sens. Environ.* 100. <https://doi.org/10.1016/j.rse.2005.10.021>
- Becker-Reshef, I., Vermote, E., Lindeman, M., Justice, C., 2010. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2010.01.010>
- Beguiría, S., Vicente-Serrano, S.M., Reig, F., Latorre, B., 2014. Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *Int. J. Climatol.* <https://doi.org/10.1002/joc.3887>
- Belaqziz, S., Khabba, S., Er-Raki, S., Jarlan, L., Le Page, M., Kharrou, M.H., Adnani, M. El, Chehbouni, A., 2013. A new irrigation priority index based on remote sensing data for assessing the networks irrigation scheduling. *Agric. Water Manag.* <https://doi.org/10.1016/j.agwat.2012.12.011>
- Bennett, D., Izanloo, A., Reynolds, M., Kuchel, H., Langridge, P., Schnurbusch, T., 2012. Genetic dissection of grain yield and physical grain quality in bread wheat (*Triticum aestivum* L.) under water-limited environments. *Theor. Appl. Genet.* <https://doi.org/10.1007/s00122-012-1831-9>
- Bento, V.A., Gouveia, C.M., DaCamara, C.C., Libonati, R., Trigo, I.F., 2020. The roles of NDVI and Land Surface Temperature when using the Vegetation Health Index over dry regions. *Glob. Planet. Change* 190, 103198. <https://doi.org/10.1016/j.gloplacha.2020.103198>
- Bento, V.A., Gouveia, C.M., DaCamara, C.C., Trigo, I.F., 2018a. A climatological assessment of drought impact on vegetation health index. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2018.05.014>
- Bento, V.A., Trigo, I.F., Gouveia, C.M., DaCamara, C.C., 2018b. Contribution of Land Surface Temperature (TCI) to Vegetation Health Index: A comparative study using clear sky and all-weather climate data records. *Remote Sens.* <https://doi.org/10.3390/rs10091324>
- Bird, D.N., Benabdallah, S., Gouda, N., Hummel, F., Koeberl, J., La Jeunesse, I., Meyer, S., Pretenthaler, F., Soddu, A., Woess-Gallasch, S., 2016a. Modelling climate change impacts on and adaptation strategies for agriculture in Sardinia and Tunisia using AquaCrop and value-at-risk. *Sci. Total Environ.* 543, 1019–1027. <https://doi.org/10.1016/j.scitotenv.2015.07.035>
- Bird, D.N., Benabdallah, S., Gouda, N., Hummel, F., Koeberl, J., La Jeunesse, I., Meyer, S., Pretenthaler, F., Soddu, A., Woess-Gallasch, S., 2016b. Modelling climate change impacts on and adaptation strategies for agriculture in Sardinia and Tunisia using AquaCrop and value-at-risk. *Sci. Total Environ.* 543, 1019–27. <https://doi.org/10.1016/j.scitotenv.2015.07.035>
- Blyverket, J., Hamer, P.D., Schneider, P., Albergel, C., Lahoz, W.A., 2019. Monitoring soil moisture drought over northern high latitudes from space. *Remote Sens.* <https://doi.org/10.3390/rs11101200>
- Bocchiola, D., 2015. Impact of potential climate change on crop yield and water footprint of rice in the Po valley of Italy. *Agric. Syst.* 139, 223–237. <https://doi.org/10.1016/j.agsy.2015.07.009>

- Bolten, J.D., Crow, W.T., 2012. Improved prediction of quasi-global vegetation conditions using remotely-sensed surface soil moisture. *Geophys. Res. Lett.* <https://doi.org/10.1029/2012GL053470>
- Bolton, D.K., Friedl, M.A., 2013. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2013.01.007>
- Bouras, E., Jarlan, L., Khabba, S., Er-Raki, S., Dezetter, A., Sghir, F., Trambly, Y., 2019. Assessing the impact of global climate changes on irrigated wheat yields and water requirements in a semi-arid environment of Morocco. *Sci. Rep.* 9. <https://doi.org/10.1038/s41598-019-55251-2>
- Bouras, E.H., Jarlan, L., Er-Raki, S., Albergel, C., Richard, B., Balaghi, R., Khabba, S., 2020. Linkages between rainfed cereal production and agricultural drought through remote sensing indices and a land data assimilation system: A case study in Morocco. *Remote Sens.* 12, 1–35. <https://doi.org/10.3390/rs12244018>
- Breiman, L., 2001. Random forests. *Mach. Learn.* <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., 1996. Bagging predictors. *Mach. Learn.* <https://doi.org/10.1007/bf00058655>
- Brocca, L., Hasenauer, S., Lacava, T., Melone, F., Moramarco, T., Wagner, W., Dorigo, W., Matgen, P., Martínez-Fernández, J., Llorens, P., Latron, J., Martin, C., Bittelli, M., 2011. Soil moisture estimation through ASCAT and AMSR-E sensors: An intercomparison and validation study across Europe. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2011.08.003>
- Burke, J.J., Mahan, J.R., Hatfield, J.L., 1988. Crop-Specific Thermal Kinetic Windows in Relation to Wheat and Cotton Biomass Production. *Agron. J.* 80, 553. <https://doi.org/10.2134/agronj1988.00021962008000040001x>
- Cai, X.L., Sharma, B.R., 2010. Integrating remote sensing, census and weather data for an assessment of rice yield, water consumption and water productivity in the Indo-Gangetic river basin. *Agric. Water Manag.* <https://doi.org/10.1016/j.agwat.2009.09.021>
- Cai, Y., Guan, K., Lobell, D., Potgieter, A.B., Wang, S., Peng, J., Xu, T., Asseng, S., Zhang, Y., You, L., Peng, B., 2019. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agric. For. Meteorol.* 274, 144–159. <https://doi.org/10.1016/j.agrformet.2019.03.010>
- Calvet, J.C., Noilhan, J., Roujean, J.L., Bessemoulin, P., Cabelguenne, M., Olioso, A., Wigneron, J.P., 1998. An interactive vegetation SVAT model tested against data from six contrasting sites. *Agric. For. Meteorol.* [https://doi.org/10.1016/S0168-1923\(98\)00091-4](https://doi.org/10.1016/S0168-1923(98)00091-4)
- Campbell, J.B., 1987. Introduction to remote sensing. *Introd. to Remote Sens.*
- Cao, J., Zhang, Z., Tao, F., Zhang, L., Luo, Y., Han, J., Li, Z., 2020. Identifying the contributions of multi-source data for winter wheat yield prediction in China. *Remote Sens.* 12, 1–22. <https://doi.org/10.3390/rs12050750>
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., Grégoire, J.M., 2001. Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sens. Environ.* 77, 22–33. [https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/10.1016/S0034-4257(01)00191-2)
- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., Tarantola, S., 2002. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sens. Environ.* 82, 198–207. [https://doi.org/10.1016/S0034-4257\(02\)00036-6](https://doi.org/10.1016/S0034-4257(02)00036-6)
- Ceglar, A., Turco, M., Toreti, A., Doblas-Reyes, F.J., 2017. Linking crop yield anomalies to large-scale atmospheric circulation in Europe. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2017.03.019>
- Chaves, M.M., Maroco, J.P., Pereira, J.S., 2003. Understanding plant responses to drought - From genes to the whole plant. *Funct. Plant Biol.* <https://doi.org/10.1071/FP02076>
- Chen, C., Quilang, E.J.P., Alosnos, E.D., Finnigan, J., 2011. Rice area mapping, yield, and production forecast for the

- province of Nueva Ecija using RADARSAT imagery. *Can. J. Remote Sens.* <https://doi.org/10.5589/m11-024>
- Chen, T., Guestrin, C., 2016. XGBoost: A scalable tree boosting system, in: *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.* <https://doi.org/10.1145/2939672.2939785>
- Cheng, K., Lu, Z., Wei, Y., Shi, Y., Zhou, Y., 2017. Mixed kernel function support vector regression for global sensitivity analysis. *Mech. Syst. Signal Process.* 96. <https://doi.org/10.1016/j.ymssp.2017.04.014>
- Chlingaryan, A., Sukkariéh, S., Whelan, B., 2018. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Comput. Electron. Agric.* <https://doi.org/10.1016/j.compag.2018.05.012>
- Christensen, J.H., Carter, T.R., Giorgi, F., 2002. PRUDENCE employs new methods to assess european climate change. *Eos (Washington, DC).* <https://doi.org/10.1029/2002EO000094>
- Ciais, P., Reichstein, M., Viovy, N., Granier, A., Ogee, J., Allard, V., Aubinet, M., Buchmann, N., Bernhofer, C., Carrara, A., Chevallier, F., De Noblet, N., Friend, A.D., Friedlingstein, P., Grünwald, T., Heinesch, B., Keronen, P., Knohl, A., Krinner, G., Loustau, D., Manca, G., Matteucci, G., Miglietta, F., Ourcival, J.M., Papale, D., Pilegaard, K., Rambal, S., Seufert, G., Soussana, J.F., Sanz, M.J., Schulze, E.D., Vesala, T., Valentini, R., 2005. Europe-wide reduction in primary productivity caused by the heat and drought in 2003. *Nature.* <https://doi.org/10.1038/nature03972>
- Colmet-daage, A., Les, A.C., 2019. Les impacts du changement climatique sur les pluies et les inondations extrêmes de bassins versants méso-échelles méditerranéens, PhD Thesis, Université Montpellier.
- Crago, R.D., 1996. Conservation and variability of the evaporative fraction during the daytime. *J. Hydrol.* 180. [https://doi.org/10.1016/0022-1694\(95\)02903-6](https://doi.org/10.1016/0022-1694(95)02903-6)
- Crocetti, L., Forkel, M., Fischer, M., Jurečka, F., Grlj, A., Salentinig, A., Trnka, M., Anderson, M., Ng, W.T., Kokalj, Ž., Bucur, A., Dorigo, W., 2020. Earth Observation for agricultural drought monitoring in the Pannonian Basin (southeastern Europe): current state and future directions. *Reg. Environ. Chang.* <https://doi.org/10.1007/s10113-020-01710-w>
- Cubasch, U., Waszkewitz, J., Hegerl, G., Perlwitz, J., 1995. Regional climate changes as simulated in time-slice experiments. *Clim. Change.* <https://doi.org/10.1007/BF01095150>
- Dai, A., 2011. Drought under global warming: A review. *Wiley Interdiscip. Rev. Clim. Chang.* <https://doi.org/10.1002/wcc.81>
- Das, N.N., Entekhabi, D., Njoku, E.G., 2011. An algorithm for merging SMAP radiometer and radar data for high-resolution soil-moisture retrieval. *IEEE Trans. Geosci. Remote Sens.* 49. <https://doi.org/10.1109/TGRS.2010.2089526>
- de Graaff, M.A., van Groenigen, K.J., Six, J., Hungate, B., van Kessel, C., 2006. Interactions between plant growth and soil nutrient cycling under elevated CO₂: A meta-analysis. *Glob. Chang. Biol.* <https://doi.org/10.1111/j.1365-2486.2006.01240.x>
- de Wit, C.T., 1965. Photosynthesis of leaf canopies, *Agricultural Research Reports.*
- Déqué, M., 2007. Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Glob. Planet. Change* 57, 16–26. <https://doi.org/10.1016/j.gloplacha.2006.11.030>
- Déqué, M., Dreveton, C., Braun, A., Cariolle, D., 1994. The ARPEGE/IFS atmosphere model: a contribution to the French community climate modelling. *Clim. Dyn.* <https://doi.org/10.1007/BF00208992>
- Déqué, M., Jones, R.G., Wild, M., Giorgi, F., Christensen, J.H., Hassell, D.C., Vidale, P.L., Rockel, B., Jacob, D.,

- Kjellström, E., de Castro, M., Kucharski, F., van den Hurk, B., 2005. Global high resolution versus Limited Area Model climate change projections over Europe: Quantifying confidence level from PRUDENCE results. *Clim. Dyn.* <https://doi.org/10.1007/s00382-005-0052-1>
- Deschênes, O., Greenstone, M., 2007. The economic impacts of climate change: Evidence from agricultural output and random fluctuations in weather. *Am. Econ. Rev.* <https://doi.org/10.1257/aer.97.1.354>
- Dettori, M., Cesaraccio, C., Duce, P., 2017. Simulation of climate change impacts on production and phenology of durum wheat in Mediterranean environments using CERES-Wheat model. *F. Crop. Res.* 206, 43–53. <https://doi.org/10.1016/j.fcr.2017.02.013>
- Dewaele, H., Munier, S., Albergel, C., Planque, C., Laanaia, N., Carrer, D., Calvet, J.C., 2017. Parameter optimisation for a better representation of drought by LSMs: Inverse modelling vs. sequential data assimilation. *Hydrol. Earth Syst. Sci.* <https://doi.org/10.5194/hess-21-4861-2017>
- Dobson, M.C., Ulaby, F.T., 1986. Active Microwave Soil Moisture Research. *IEEE Trans. Geosci. Remote Sens.* GE-24. <https://doi.org/10.1109/TGRS.1986.289585>
- Doorenbos, J., Kassam, A.H., Bentvelsen, C., Uittenbogaard, G., 1980. Yield Response to Water, in: *Irrigation and Agricultural Development*. <https://doi.org/10.1016/b978-0-08-025675-7.50021-2>
- Dorigo, W., Wagner, W., Albergel, C., Albrecht, F., Balsamo, G., Brocca, L., Chung, D., Ertl, M., Forkel, M., Gruber, A., Haas, E., Hamer, P.D., Hirschi, M., Ikonen, J., de Jeu, R., Kidd, R., Lahoz, W., Liu, Y.Y., Miralles, D., Mistelbauer, T., Nicolai-Shaw, N., Parinussa, R., Pratola, C., Reimer, C., van der Schalie, R., Seneviratne, S.I., Smolander, T., Lecomte, P., 2017. ESA CCI Soil Moisture for improved Earth system understanding: State-of-the-art and future directions. *Remote Sens. Environ.* 203, 185–215. <https://doi.org/10.1016/j.rse.2017.07.001>
- Dorigo, W.A., Zurita-Milla, R., de Wit, A.J.W., Brazile, J., Singh, R., Schaepman, M.E., 2007. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *Int. J. Appl. Earth Obs. Geoinf.* 9. <https://doi.org/10.1016/j.jag.2006.05.003>
- Dracup, J.A., Lee, K.S., Paulson, E.G., 1980. On the definition of droughts. *Water Resour. Res.* <https://doi.org/10.1029/WR016i002p00297>
- Drake, B.G., González-Meler, M.A., Long, S.P., 1997. MORE EFFICIENT PLANTS: A Consequence of Rising Atmospheric CO₂? *Annu. Rev. Plant Physiol. Plant Mol. Biol.* 48, 609–639. <https://doi.org/10.1146/annurev.arplant.48.1.609>
- Driouech, F., Déqué, M., Mokssit, A., 2009. Numerical simulation of the probability distribution function of precipitation over Morocco. *Clim. Dyn.* <https://doi.org/10.1007/s00382-008-0430-6>
- Driouech, F., ElRhaz, K., Moufouma-Okia, W., Arjald, K., Balhane, S., 2020. Assessing Future Changes of Climate Extreme Events in the CORDEX-MENA Region Using Regional Climate Model ALADIN-Climate. *Earth Syst. Environ.* 4, 477–492. <https://doi.org/10.1007/s41748-020-00169-3>
- Du, L., Tian, Q., Yu, T., Meng, Q., Jancso, T., Udvardy, P., Huang, Y., 2013a. A comprehensive drought monitoring method integrating MODIS and TRMM data. *Int. J. Appl. Earth Obs. Geoinf.* 23, 245–253. <https://doi.org/10.1016/j.jag.2012.09.010>
- Du, L., Tian, Q., Yu, T., Meng, Q., Jancso, T., Udvardy, P., Huang, Y., 2013b. A comprehensive drought monitoring method integrating MODIS and TRMM data. *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2012.09.010>
- Dubois, P.C., Engman, T., 1995. Measuring Soil Moisture with Imaging Radars. *IEEE Trans. Geosci. Remote Sens.* <https://doi.org/10.1109/36.406677>

- Dumont, B., Basso, B., Leemans, V., Bodson, B., Destain, J.P., Destain, M.F., 2015. A comparison of within-season yield prediction algorithms based on crop model behaviour analysis. *Agric. For. Meteorol.*
<https://doi.org/10.1016/j.agrformet.2015.01.014>
- Dumont, B., Leemans, V., Ferrandis, S., Bodson, B., Destain, J.P., Destain, M.F., 2014. Assessing the potential of an algorithm based on mean climatic data to predict wheat yield. *Precis. Agric.* <https://doi.org/10.1007/s11119-014-9346-9>
- Dumont, B., Vancutsem, F., Seutin, B., Bodson, B., Destain, J.P., Destain, M.F., 2012. Simulation de la croissance du blé à l'aide de modèles écophysologiques: Synthèse bibliographique des méthodes, potentialités et limitations. *Biotechnol. Agron. Soc. Environ.*
- El Hajj, M., Baghdadi, N., Zribi, M., Belaud, G., Cheviron, B., Courault, D., Charron, F., 2016. Soil moisture retrieval over irrigated grassland using X-band SAR data. *Remote Sens. Environ.* 176.
<https://doi.org/10.1016/j.rse.2016.01.027>
- Elfarkh, J., 2021. Évaluation de l' évapotranspiration des zones irriguées en piémont du Haut Atlas , Maroc : modélisation , mesures micro-météorologiques et télédétection spatiale. Université Paul Sabatier - Toulouse III; Université Cadi Ayyad (Marrakech, Maroc).
- Entekhabi, D., Njoku, E.G., O'Neill, P.E., Kellogg, K.H., Crow, W.T., Edelstein, W.N., Entin, J.K., Goodman, S.D., Jackson, T.J., Johnson, J., Kimball, J., Piepmeier, J.R., Koster, R.D., Martin, N., McDonald, K.C., Moghaddam, M., Moran, S., Reichle, R., Shi, J.C., Spencer, M.W., Thurman, S.W., Tsang, L., Van Zyl, J., 2010. The soil moisture active passive (SMAP) mission. *Proc. IEEE.* <https://doi.org/10.1109/JPROC.2010.2043918>
- Ewert, F., Rodriguez, D., Jamieson, P., Semenov, M. a., Mitchell, R. a C., Goudriaan, J., Porter, J.R., Kimball, B. a., Pinter, P.J., Manderscheid, R., Weigel, H.J., Fangmeier, a., Fereres, E., Villalobos, F., 2002. Effects of elevated CO2 and drought on wheat: Testing crop simulation models for different experimental and climatic conditions. *Agric. Ecosyst. Environ.* 93, 249–266. [https://doi.org/10.1016/S0167-8809\(01\)00352-8](https://doi.org/10.1016/S0167-8809(01)00352-8)
- FAO, 2017. The impact of of natural hazards and disasters on agriculture, food security and nutrition.
- FAO, 2016. Climate change and food security: risks and responses, Food and Agriculture Organization of the United Nations. <https://doi.org/10.1080/14767058.2017.1347921>
- Feng, P., Wang, B., Liu, D.L., Waters, C., Xiao, D., Shi, L., Yu, Q., 2020. Dynamic wheat yield forecasts are improved by a hybrid approach using a biophysical model and machine learning technique. *Agric. For. Meteorol.* 285–286, 107922. <https://doi.org/10.1016/j.agrformet.2020.107922>
- Feng, P., Wang, B., Liu, D.L., Yu, Q., 2019. Machine learning-based integration of remotely-sensed drought factors can improve the estimation of agricultural drought in South-Eastern Australia. *Agric. Syst.* 173, 303–316.
<https://doi.org/10.1016/j.agry.2019.03.015>
- Fensholt, R., Huber, S., Proud, S.R., Mbow, C., 2010. Detecting Canopy Water Status Using Shortwave Infrared Reflectance Data From Polar Orbiting and Geostationary Platforms. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 3. <https://doi.org/10.1109/JSTARS.2010.2048744>
- Fensholt, R., Sandholt, I., 2003. Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment. *Remote Sens. Environ.*
<https://doi.org/10.1016/j.rse.2003.07.002>
- Filippi, P., Jones, E.J., Wimalathunge, N.S., Somarathna, P.D.S.N., Pozza, L.E., Ugbaje, S.U., Jephcott, T.G., Paterson, S.E., Whelan, B.M., Bishop, T.F.A., 2019. An approach to forecast grain crop yield using multi-layered, multi-farm data sets and machine learning. *Precis. Agric.* <https://doi.org/10.1007/s11119-018-09628-4>

- Flaounas, E., Drobinski, P., Vrac, M., Bastin, S., Lebeaupin-Brossier, C., Stéfanon, M., Borga, M., Calvet, J.C., 2013. Precipitation and temperature space-time variability and extremes in the Mediterranean region: Evaluation of dynamical and statistical downscaling methods. *Clim. Dyn.* 40, 2687–2705. <https://doi.org/10.1007/s00382-012-1558-y>
- Fong-Chiau Chang, Wallace, J.M., 1987. Meteorological conditions during heat waves and droughts in the United States Great Plains. *Mon. Weather Rev.* [https://doi.org/10.1175/1520-0493\(1987\)115<1253:mcdhwa>2.0.co;2](https://doi.org/10.1175/1520-0493(1987)115<1253:mcdhwa>2.0.co;2)
- Food and Agriculture Organization of the United Nations (FAO), 2017. The Impact of disasters and crises on agriculture and Food Security.
- Fraisse, C.W., Sudduth, K.A., Kitchen, N.R., 2001. Calibration of the CERES-Maize model for simulating site-specific crop development and yield on claypan soils. *Appl. Eng. Agric.*
- Franch, B., Vermote, E.F., Becker-Reshef, I., Claverie, M., Huang, J., Zhang, J., Justice, C., Sobrino, J.A., 2015. Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR Growing Degree Day information. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2015.02.014>
- Freeman, C., Kim, S.Y., Lee, S.H., Kang, H., 2004. Effects of elevated atmospheric CO₂ concentrations on soil microorganisms. *J. Microbiol.*
- Freund, Y., Schapire, R.E., 1996. Experiments with a New Boosting Algorithm. *Proc. 13th Int. Conf. Mach. Learn.* <https://doi.org/10.1.1.133.1040>
- Friedman, J.H., 2001. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* <https://doi.org/10.1214/aos/1013203451>
- Gao, B.C., 1996. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- García-León, D., Contreras, S., Hunink, J., 2019. Comparison of meteorological and satellite-based drought indices as yield predictors of Spanish cereals. *Agric. Water Manag.* <https://doi.org/10.1016/j.agwat.2018.10.030>
- Genovese, G.P., Fritz, S., Bettio, M., 2006. A comparison and evaluation of performances among crop yield forecasting models based on remote sensing: Results from the geoland observatory of food monitoring. *Int. Arch. Photogramm. Remote Sens. Spacial Inf. Sci* 36, 71–77.
- Genuer, R., Poggi, J.-M., 2017. Arbres CART et Forêts aléatoires Importance et sélection de variables Table des matières. *arXiv:1610.08203v2[stat.ME]*.
- Ghulam, A., Li, Z.L., Qin, Q., Yimit, H., Wang, J., 2008. Estimating crop water stress with ETM+ NIR and SWIR data. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2008.05.020>
- Ghulam, A., Qin, Q., Zhan, Z., 2007. Designing of the perpendicular drought index. *Environ. Geol.* 52. <https://doi.org/10.1007/s00254-006-0544-2>
- Giorgi, F., 2006. Climate change hot-spots. *Geophys. Res. Lett.* 33. <https://doi.org/10.1029/2006GL025734>
- Giorgi, F., 2002. Dependence of the surface climate interannual variability on spatial scale. *Geophys. Res. Lett.* 29. <https://doi.org/10.1029/2002GL016175>
- Giorgi, F., Bi, X., Pal, J., 2004. Mean, interannual variability and trends in a regional climate change experiment over Europe. II: Climate change scenarios (2071-2100). *Clim. Dyn.* <https://doi.org/10.1007/s00382-004-0467-0>
- Giorgi, F., Lionello, P., 2008. Climate change projections for the Mediterranean region. *Glob. Planet. Change* 63, 90–104. <https://doi.org/10.1016/j.gloplacha.2007.09.005>
- Giorgi, F., Mearns, L.O., 1999. Introduction to special section: Regional climate modeling revisited. *J. Geophys. Res.*

- Atmos. <https://doi.org/10.1029/98JD02072>
- Giorgi, F., Mearns, L.O., 1991. Approaches to the simulation of regional climate change: A review. *Rev. Geophys.* <https://doi.org/10.1029/90RG02636>
- Giri, A.K., Bhan, M., Agrawal, K.K., 2017. Districtwise wheat and rice yield predictions using meteorological variables in eastern Madhya Pradesh. *J. Agrometeorol.*
- Govender, M., Dye, P.J., Weiersbye, I.M., Witkowski, E.T.F., Ahmed, F., 2009. Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water SA.* <https://doi.org/10.4314/wsa.v35i5.49201>
- Gruber, A., Scanlon, T., Van Der Schalie, R., Wagner, W., Dorigo, W., 2019. Evolution of the ESA CCI Soil Moisture climate data records and their underlying merging methodology. *Earth Syst. Sci. Data* 11. <https://doi.org/10.5194/essd-11-717-2019>
- Gu, Y., Brown, J.F., Verdin, J.P., Wardlow, B., 2007. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. *Geophys. Res. Lett.* <https://doi.org/10.1029/2006GL029127>
- Gu, Y., Hunt, E., Wardlow, B., Basara, J.B., Brown, J.F., Verdin, J.P., 2008. Evaluation of MODIS NDVI and NDWI for vegetation drought monitoring using Oklahoma Mesonet soil moisture data. *Geophys. Res. Lett.* <https://doi.org/10.1029/2008GL035772>
- Gurung, B., Panwar, S., Singh, K.N., Banerjee, R., Gurung, S.R., Rathore, A., 2017. Wheat yield forecast using detrended yield over a sub-humid climatic environment in five districts of Uttar Pradesh, India. *Indian J. Agric. Sci.*
- Guttman, N.B., 1998. Comparing the palmer drought index and the standardized precipitation index. *J. Am. Water Resour. Assoc.* <https://doi.org/10.1111/j.1752-1688.1998.tb05964.x>
- Hafid, R. El, Smith, D.H., Karrou, M., Samir, K., 1998. Morphological attributes associated with early-season drought tolerance in spring durum wheat in a mediterranean environment. *Crop Sci.* 273–282.
- Hajhouji, Y., Fakir, Y., Simonneaux, V., Gascoin, S., Bouras, E.H., Chehbouni, A., 2020. Effects of climate change at the 2040's horizon on the hydrology of the pluvio-nival rheraya watershed near marrakesh, morocco, in: *Lecture Notes in Electrical Engineering.* https://doi.org/10.1007/978-3-030-53187-4_48
- Han, E., Crow, W.T., Holmes, T., Bolten, J., 2014. Benchmarking a soil moisture data assimilation system for agricultural drought monitoring. *J. Hydrometeorol.* 15, 1117–1134. <https://doi.org/10.1175/JHM-D-13-0125.1>
- Han, H., Bai, J., Yan, J., Yang, H., Ma, G., 2019. A combined drought monitoring index based on multi-sensor remote sensing data and machine learning. *Geocarto Int.* <https://doi.org/10.1080/10106049.2019.1633423>
- Han, J., Zhang, Z., Cao, J., Luo, Y., Zhang, L., Li, Z., Zhang, J., 2020. Prediction of winter wheat yield based on multi-source data and machine learning in China. *Remote Sens.* 12. <https://doi.org/10.3390/rs12020236>
- Han, S., Cao, Q., Han, M., 2012. Parameter selection in SVM with RBF kernel function, in: *World Automation Congress Proceedings.*
- Hanks, R.J., 1983. *Yield and Water-Use Relationships : An Overview.* Utah State University Logan, Utah.
- Hanson, R.L., 1991. *Evapotranspiration and droughts.* US Geol. Surv. Water-Supply Pap.
- Harbouze, R., Pellissier, J.-P., Rolland, J.-P., Khechimi, W., 2019. Rapport de synthèse sur l ' agriculture au Maroc. 105.
- Hatfield, J.L., Boote, K.J., Kimball, B.A., Ziska, L.H., Izaurralde, R.C., Ort, D., Thomson, A.M., Wolfe, D., 2011. Climate impacts on agriculture: Implications for crop production. *Agron. J.*

- <https://doi.org/10.2134/agronj2010.0303>
- Hayes, M., Svoboda, M., Wall, N., Widhalm, M., 2011. The lincoln declaration on drought indices: Universal meteorological drought index recommended, in: *Bulletin of the American Meteorological Society*.
<https://doi.org/10.1175/2010BAMS3103.1>
- Hayes, M.J., Svoboda, M.D., Wilhite, D.A., Vanyarkho, O. V., 1999. Monitoring the 1996 Drought Using the Standardized Precipitation Index. *Bull. Am. Meteorol. Soc.* 80. [https://doi.org/10.1175/1520-0477\(1999\)080<0429:MTDUTS>2.0.CO;2](https://doi.org/10.1175/1520-0477(1999)080<0429:MTDUTS>2.0.CO;2)
- Heng, L.K., Asseng, S., Mejahed, K., Rusan, M., 2007. Optimizing wheat productivity in two rain-fed environments of the West Asia-North Africa region using a simulation model. *Eur. J. Agron.* 26, 121–129.
<https://doi.org/10.1016/j.eja.2006.09.001>
- Herwaarden, A.F. van, Farquhar, G.D., Angus, J.F., Richards, R.A., Howe, G.N., 1998. “Haying-off”, the negative grain yield response of dryland wheat to nitrogen fertiliser. I. Biomass, grain yield, and water use. *Aust. J. Agric. Res.* 49, 1067. <https://doi.org/10.1071/A97039>
- Hewitt, C.D., Griggs, D.J., 2004. Ensembles-based predictions of climate changes and their impacts, in: *Eos*.
<https://doi.org/10.1029/2004EO520005>
- Hsiao, T.C., 1973. Plant Responses to Water Stress. *Annu. Rev. Plant Physiol.* 24.
<https://doi.org/10.1146/annurev.pp.24.060173.002511>
- Hsiao, T.C., Heng, L., Steduto, P., Rojas-Lara, B., Raes, D., Fereres, E., 2009. Aquacrop-The FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. *Agron. J.* 101, 448–459.
<https://doi.org/10.2134/agronj2008.0218s>
- Hsiao, T.C., Steduto, P., Fereres, E., 2007. A systematic and quantitative approach to improve water use efficiency in agriculture. *Irrig. Sci.* 25. <https://doi.org/10.1007/s00271-007-0063-2>
- Hu, T., Renzullo, L.J., van Dijk, A.I.J.M., He, J., Tian, S., Xu, Z., Zhou, J., Liu, T., Liu, Q., 2020. Monitoring agricultural drought in Australia using MTSAT-2 land surface temperature retrievals. *Remote Sens. Environ.* 236. <https://doi.org/10.1016/j.rse.2019.111419>
- Huang, J., Gómez-Dans, J.L., Huang, H., Ma, H., Wu, Q., Lewis, P.E., Liang, S., Chen, Z., Xue, J.H., Wu, Y., Zhao, F., Wang, J., Xie, X., 2019. Assimilation of remote sensing into crop growth models: Current status and perspectives. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2019.06.008>
- Hunt, E.D., Hubbard, K.G., Wilhite, D.A., Arkebauer, T.J., Dutcher, A.L., 2009. The development and evaluation of a soil moisture index. *Int. J. Climatol.* <https://doi.org/10.1002/joc.1749>
- Hunt, E.R., Rock, B.N., 1989. Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. *Remote Sens. Environ.* [https://doi.org/10.1016/0034-4257\(89\)90046-1](https://doi.org/10.1016/0034-4257(89)90046-1)
- IPCC, 2019. *Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems* 1–864.
- IPCC, 2014a. *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Ipcc.
- IPCC, 2014b. *IPCC Fifth Assessment Synthesis Report-Climate Change 2014 Synthesis Report. IPCC Fifth Assess. Synth. Report-Climate Chang. 2014 Synth. Rep.* pages: 167.
- Izaurrealde, R.C., Thomson, A.M., Morgan, J.A., Fay, P.A., Polley, H.W., Hatfield, J.L., 2011. Climate impacts on agriculture: Implications for forage and rangeland production. *Agron. J.* <https://doi.org/10.2134/agronj2010.0304>
- Jackson, T.J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., Hunt, E.R., 2004. *Vegetation*

- water content mapping using Landsat data derived normalized difference water index for corn and soybeans, in: *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2003.10.021>
- Jackson, T.J., Schmugge, T.J., Wang, J.R., 1982. Passive microwave sensing of soil moisture under vegetation canopies. *Water Resour. Res.* <https://doi.org/10.1029/WR018i004p01137>
- Jalota, S.K., Vashisht, B.B., Sharma, S., Kaur, S., 2018. Climate Change Impact on Crop Productivity and Field Water Balance, in: *Understanding Climate Change Impacts on Crop Productivity and Water Balance*. <https://doi.org/10.1016/b978-0-12-809520-1.00003-3>
- Jamieson, P.D., Semenov, M.A., Brooking, I.R., Francis, G.S., 1998. Sirius: A mechanistic model of wheat response to environmental variation. *Eur. J. Agron.* 8, 161–179. [https://doi.org/10.1016/S1161-0301\(98\)00020-3](https://doi.org/10.1016/S1161-0301(98)00020-3)
- Jarlan, L., 2016. Observation spatiale du fonctionnement éco-hydrologique des surfaces naturelles et cultivées en régions semi-arides. Mémoire d'Habilitation à Diriger des Recherches; Spécialité : Sciences de la Terre et de l'Univers; Université Toulouse III – Paul Sabatier, Toulouse, France.
- Jarlan, L., Abaoui, J., Duchemin, B., Ouldabba, A., Tourre, Y.M., Khabba, S., Le Page, M., Balaghi, R., Mokssit, A., Chehbouni, G., 2014. Linkages between common wheat yields and climate in Morocco (1982-2008). *Int. J. Biometeorol.* 58, 1489–1502. <https://doi.org/10.1007/s00484-013-0753-9>
- Jarlan, L., Khabba, S., Er-Raki, S., Le Page, M., Hanich, L., Fakir, Y., Merlin, O., Mangiarotti, S., Gascoin, S., Ezzahar, J., Kharrou, M.H., Berjamy, B., Saaïdi, A., Boudhar, A., Benkaddour, A., Laftouhi, N., Abaoui, J., Tavernier, A., Boulet, G., Simonneaux, V., Driouech, F., El Adnani, M., El Fazziki, A., Amenzou, N., Raïbi, F., El Mandour, A., Ibouh, H., Le Dantec, V., Habets, F., Trambly, Y., Mougenot, B., Leblanc, M., El Faïz, M., Drapeau, L., Coudert, B., Hagolle, O., Filali, N., Belaqziz, S., Marchane, A., Szczypta, C., Toumi, J., Diarra, A., Aouade, G., Hajhouji, Y., Nassah, H., Bigeard, G., Chirouze, J., Boukhari, K., Abourida, A., Richard, B., Fanise, P., Kasbani, M., Chakir, A., Zribi, M., Marah, H., Naimi, A., Mokssit, A., Kerr, Y., Escadafal, R., 2015. Remote Sensing of Water Resources in Semi-Arid Mediterranean Areas: the joint international laboratory TREMA. *Int. J. Remote Sens.* 36, 4879–4917. <https://doi.org/10.1080/01431161.2015.1093198>
- Jarlan, L., Khabba, S., Szczypta, C., Lili-Chabaane, Z., Driouech, F., Page, M. Le, Hanich, L., Fakir, Y., Boone, A., Boulet, F., 2016. Water Resources in South Mediterranean Catchments: Assessing climatic drivers and impacts, in: Thiébaud, S., Moatti, J.P. (Eds.), *The Mediterranean Region under Climate Change*. Paris, bll 303–309.
- Jellali, M.M., 1997. Développement des ressources en eau au Maroc, in: *Aspects économiques de la gestion de l'eau dans le bassin méditerranéen*.
- Jiao, W., Tian, C., Chang, Q., Novick, K.A., Wang, L., 2019. A new multi-sensor integrated index for drought monitoring. *Agric. For. Meteorol.* 268, 74–85. <https://doi.org/10.1016/j.agrformet.2019.01.008>
- Jiao, W., Wang, L., McCabe, M.F., 2021. Multi-sensor remote sensing for drought characterization: current status, opportunities and a roadmap for the future. *Remote Sens. Environ.* 256, 112313. <https://doi.org/10.1016/j.rse.2021.112313>
- Jiao, W., Zhang, L., Chang, Q., Fu, D., Cen, Y., Tong, Q., 2016. Evaluating an enhanced vegetation condition index (VCI) based on VIUPD for drought monitoring in the continental United States. *Remote Sens.* 8. <https://doi.org/10.3390/rs8030224>
- Jiménez-Muñoz, J.C., Sobrino, J.A., 2010. A single-channel algorithm for land-surface temperature retrieval from ASTER data. *IEEE Geosci. Remote Sens. Lett.* 7. <https://doi.org/10.1109/LGRS.2009.2029534>
- Johnson, D.M., 2014. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2013.10.027>

- Johnson, M.D., Hsieh, W.W., Cannon, A.J., Davidson, A., Bédard, F., 2016a. Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2015.11.003>
- Johnson, M.D., Hsieh, W.W., Cannon, A.J., Davidson, A., Bédard, F., 2016b. Crop yield forecasting on the Canadian Prairies by remotely sensed vegetation indices and machine learning methods. *Agric. For. Meteorol.* 218–219, 74–84. <https://doi.org/10.1016/j.agrformet.2015.11.003>
- Joiner, J., Yoshida, Y., Vasilkov, A.P., Yoshida, Y., Corp, L.A., Middleton, E.M., 2011. First observations of global and seasonal terrestrial chlorophyll fluorescence from space. *Biogeosciences* 8. <https://doi.org/10.5194/bg-8-637-2011>
- Kamir, E., Waldner, F., Hochman, Z., 2020. Estimating wheat yields in Australia using climate records, satellite image time series and machine learning methods. *ISPRS J. Photogramm. Remote Sens.* 160, 124–135. <https://doi.org/10.1016/j.isprsjprs.2019.11.008>
- Kang, Y., Khan, S., Ma, X., 2009. Climate change impacts on crop yield, crop water productivity and food security - A review. *Prog. Nat. Sci.* <https://doi.org/10.1016/j.pnsc.2009.08.001>
- Kang, Y., Ozdogan, M., Zhu, X., Ye, Z., Hain, C., Anderson, M., 2020. Comparative assessment of environmental variables and machine learning algorithms for maize yield prediction in the US Midwest. *Environ. Res. Lett.* 15. <https://doi.org/10.1088/1748-9326/ab7df9>
- Karthikeyan, L., Pan, M., Wanders, N., Kumar, D.N., Wood, E.F., 2017. Four decades of microwave satellite soil moisture observations: Part 1. A review of retrieval algorithms. *Adv. Water Resour.* 109. <https://doi.org/10.1016/j.advwatres.2017.09.006>
- Kerr, Y.H., Lagouarde, J.P., Imbernon, J., 1992. Accurate land surface temperature retrieval from AVHRR data with use of an improved split window algorithm. *Remote Sens. Environ.* 41, 197–209. [https://doi.org/10.1016/0034-4257\(92\)90078-X](https://doi.org/10.1016/0034-4257(92)90078-X)
- Kerr, Y.H., Waldteufel, P., Richaume, P., Wigneron, J.P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S.E., Leroux, D., Mialon, A., Delwart, S., 2012. The SMOS soil moisture retrieval algorithm. *IEEE Trans. Geosci. Remote Sens.* 50. <https://doi.org/10.1109/TGRS.2012.2184548>
- Keyantash, J., Dracup, J.A., 2002. The quantification of drought: An evaluation of drought indices. *Bull. Am. Meteorol. Soc.* [https://doi.org/10.1175/1520-0477\(2002\)083<1191:TQODAE>2.3.CO;2](https://doi.org/10.1175/1520-0477(2002)083<1191:TQODAE>2.3.CO;2)
- Khabba, S., Jarlan, L., Er-Raki, S., Le Page, M., Ezzahar, J., Boulet, G., Simonneaux, V., Kharrou, M.H., Hanich, L., Chehbouni, G., 2013. The SudMed Program and the Joint International Laboratory TREMA: A Decade of Water Transfer Study in the Soil-plant-atmosphere System over Irrigated Crops in Semi-arid Area. *Procedia Environ. Sci.* 19, 524–533. <https://doi.org/10.1016/j.proenv.2013.06.059>
- Khaki, S., Wang, L., 2019. Crop yield prediction using deep neural networks. *Front. Plant Sci.* 10. <https://doi.org/10.3389/fpls.2019.00621>
- Kharrou, M.H., Er-Raki, S., Chehbouni, A., Duchemin, B., Simonneaux, V., LePage, M., Ouzine, L., Jarlan, L., 2011. Water use efficiency and yield of winter wheat under different irrigation regimes in a semi-arid region. *Agric. Sci.* <https://doi.org/10.4236/as.2011.23036>
- Kim, S., Liu, Y.Y., Johnson, F.M., Parinussa, R.M., Sharma, A., 2015. A global comparison of alternate AMSR2 soil moisture products: Why do they differ? *Remote Sens. Environ.* 161. <https://doi.org/10.1016/j.rse.2015.02.002>
- Kimball, B.A., 2016. Crop responses to elevated CO₂ and interactions with H₂O, N, and temperature. *Curr. Opin. Plant Biol.* <https://doi.org/10.1016/j.pbi.2016.03.006>

- Kimball, B.A., Morris, C.F., Pinter Jr., P.J., Wall, G.W., Hunsaker, D.J., Adamsen, F.J., LaMorte, R.L., Leavitt, S.W., Thompson, T.L., Matthias, A.D., Brooks, T.J., 2001. Elevated CO₂, drought and soil nitrogen effects on wheat grain quality. *New Phytol.* 150. <https://doi.org/10.1046/j.1469-8137.2001.00107.x>
- Knippertz, P., Christoph, M., Speth, P., 2003. Long-term precipitation variability in Morocco and the link to the large-scale circulation in recent and future climates. *Meteorol. Atmos. Phys.* <https://doi.org/10.1007/s00703-002-0561-y>
- Kogan, F., 2019. Vegetation Health for Insuring Drought-Related Yield Losses and Food Security Enhancement. https://doi.org/10.1007/978-3-319-96256-6_7
- Kogan, F., Guo, W., Yang, W., 2020. Near 40-year drought trend during 1981-2019 earth warming and food security. *Geomatics, Nat. Hazards Risk* 11. <https://doi.org/10.1080/19475705.2020.1730452>
- Kogan, F., Guo, W., Yang, W., 2019. Drought and food security prediction from NOAA new generation of operational satellites. *Geomatics, Nat. Hazards Risk.* <https://doi.org/10.1080/19475705.2018.1541257>
- Kogan, F., Kussul, N., Adamenko, T., Skakun, S., Kravchenko, O., Kryvobok, O., Shelestov, A., Kolotii, A., Kussul, O., Lavrenyuk, A., 2013. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2013.01.002>
- Kogan, F., Stark, R., Gitelson, A., Jargalsaikhan, L., Dugrajav, C., Tsooj, S., 2004. Derivation of pasture biomass in Mongolia from AVHRR-based vegetation health indices. *Int. J. Remote Sens.* 25. <https://doi.org/10.1080/01431160410001697619>
- Kogan, F., Sullivan, J., 1993. Development of global drought-watch system using NOAA/AVHRR data. *Adv. Sp. Res.* 13, 219–222. [https://doi.org/10.1016/0273-1177\(93\)90548-P](https://doi.org/10.1016/0273-1177(93)90548-P)
- Kogan, F., Yang, B., Guo, W., Pei, Z., Jiao, X., 2005. Modelling corn production in China using AVHRR-based vegetation health indices. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160500034235>
- Kogan, F.N., 1997. Global Drought Watch from Space. *Bull. Am. Meteorol. Soc.* [https://doi.org/10.1175/1520-0477\(1997\)078<0621:GDWFS>2.0.CO;2](https://doi.org/10.1175/1520-0477(1997)078<0621:GDWFS>2.0.CO;2)
- Kogan, F.N., 1995a. Application of vegetation index and brightness temperature for drought detection. *Adv. Sp. Res.* [https://doi.org/10.1016/0273-1177\(95\)00079-T](https://doi.org/10.1016/0273-1177(95)00079-T)
- Kogan, F.N., 1995b. Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bull. - Am. Meteorol. Soc.* [https://doi.org/10.1175/1520-0477\(1995\)076<0655:DOTLIT>2.0.CO;2](https://doi.org/10.1175/1520-0477(1995)076<0655:DOTLIT>2.0.CO;2)
- Kogan, F.N., 1990. Remote sensing of weather impacts on vegetation in non-homogeneous areas. *Int. J. Remote Sens.* 11. <https://doi.org/10.1080/01431169008955102>
- Kukul, M.S., Irmak, S., 2018. Climate-Driven Crop Yield and Yield Variability and Climate Change Impacts on the U.S. Great Plains Agricultural Production. *Sci. Rep.* <https://doi.org/10.1038/s41598-018-21848-2>
- Kumar, V., 1998. An early warning system for agricultural drought in an arid region using limited data. *J. Arid Environ.* <https://doi.org/10.1006/jare.1998.0437>
- Kumar, V., Panu, U., 1997. Predictive assessment of severity of agricultural droughts based on agro-climatic factors. *J. Am. Water Resour. Assoc.* <https://doi.org/10.1111/j.1752-1688.1997.tb03550.x>
- Kumar, S. V., Jasinski, M., Mocko, D.M., Rodell, M., Borak, J., Li, B., Beaudoin, H.K., Peters-Lidard, C.D., 2019. NCA-LDAS Land Analysis: Development and Performance of a Multisensor, Multivariate Land Data Assimilation System for the National Climate Assessment. *J. Hydrometeorol.* <https://doi.org/10.1175/jhm-d-17-0125.1>

- Lal, M., Singh, K.K., Rathore, L.S., Srinivasan, G., Saseendran, S.A., 1998. Vulnerability of rice and wheat yields in NW India to future changes in climate. *Agric. For. Meteorol.* [https://doi.org/10.1016/S0168-1923\(97\)00064-6](https://doi.org/10.1016/S0168-1923(97)00064-6)
- Lary, D.J., Alavi, A.H., Gandomi, A.H., Walker, A.L., 2016. Machine learning in geosciences and remote sensing. *Geosci. Front.* 7, 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- Lawless, C., Semenov, M.A., 2005. Assessing lead-time for predicting wheat growth using a crop simulation model. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2006.01.002>
- Lawlor, D.W., Mitchell, R.A.C., 2000. Crop ecosystem responses to climatic change: wheat. *Clim. Chang. Glob. Crop Product.* 57–80. <https://doi.org/10.1079/9780851994390.0057>
- Le Page, M., 2021. Une contribution pour l' utilisation de la télédétection spatiale à la gestion de l' eau agricole. Université Toulouse III - Paul Sabatier, Toulouse, France. <https://doi.org/10.13140/RG.2.2.13855.69289>
- Le Page, M., Fakir, Y., Jarlan, L., Boone, A., Berjamy, B., Zribi, M., 2021. Projection of irrigation water demand based on the simulation of synthetic crop coefficients and climate change. *Hydrol. Earth Syst. Sci.* 25. <https://doi.org/10.5194/hess-25-637-2021>
- Lehmann, J., Kretschmer, M., Schauburger, B., Wechsung, F., 2020. Potential for Early Forecast of Moroccan Wheat Yields Based on Climatic Drivers. *Geophys. Res. Lett.* <https://doi.org/10.1029/2020GL087516>
- Li, F., Crow, W.T., Kustas, W.P., 2010. Towards the estimation root-zone soil moisture via the simultaneous assimilation of thermal and microwave soil moisture retrievals. *Adv. Water Resour.* <https://doi.org/10.1016/j.advwatres.2009.11.007>
- Liakos, K.G., Busato, P., Moshou, D., Pearson, S., Bochtis, D., 2018. Machine learning in agriculture: A review. *Sensors (Switzerland)* 18, 1–29. <https://doi.org/10.3390/s18082674>
- Lionello, P., Scarascia, L., 2018. The relation between climate change in the Mediterranean region and global warming. *Reg. Environ. Chang.* 18. <https://doi.org/10.1007/s10113-018-1290-1>
- Liu, W.T., Kogan, F., 2002. Monitoring Brazilian soybean production using NOAA/AVHRR based vegetation condition indices. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160110076126>
- Lobell, D.B., Burke, M.B., Tebaldi, C., Mastrandrea, M.D., Falcon, W.P., Naylor, R.L., 2008. Prioritizing climate change adaptation needs for food security in 2030. *Science (80-.)*. <https://doi.org/10.1126/science.1152339>
- Lobell, D.B., Schlenker, W., Costa-Roberts, J., 2011. Climate trends and global crop production since 1980. *Science (80-.)*. 333. <https://doi.org/10.1126/science.1204531>
- Long, S.P., Ainsworth, E.A., Leakey, A.D.B., Ort, D.R., No, J., 2006. Food for Thought: Lower-Than-Expected Crop Yield Stimulation with Rising CO₂ Concentrations. *Science (80-.)*. 312, 1918–1922.
- López-Lozano, R., Duveiller, G., Seguíni, L., Meroni, M., García-Condado, S., Hooker, J., Leo, O., Baruth, B., 2015. Towards regional grain yield forecasting with 1km-resolution EO biophysical products: Strengths and limitations at pan-European level. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2015.02.021>
- Lovelli, S., Perniola, M., Di Tommaso, T., Ventrella, D., Moriondo, M., Amato, M., 2010. Effects of rising atmospheric CO₂ on crop evapotranspiration in a Mediterranean area. *Agric. Water Manag.* 97, 1287–1292. <https://doi.org/10.1016/j.agwat.2010.03.005>
- Lu, Y., Chibarabada, T.P., Ziliani, M.G., Onema, J.M.K., McCabe, M.F., Sheffield, J., 2021. Assimilation of soil moisture and canopy cover data improves maize simulation using an under-calibrated crop model. *Agric. Water Manag.* 252. <https://doi.org/10.1016/j.agwat.2021.106884>
- Ludwig, F., Asseng, S., 2006. Climate change impacts on wheat production in a Mediterranean environment in Western Australia. *Agric. Syst.* 90, 159–179. <https://doi.org/10.1016/j.agsy.2005.12.002>

- Maes, W.H., Steppe, K., 2012. Estimating evapotranspiration and drought stress with ground-based thermal remote sensing in agriculture: A review. *J. Exp. Bot.* <https://doi.org/10.1093/jxb/ers165>
- Mahfouf, J.F., Bergaoui, K., Draper, C., Bouyssel, F., Taillefer, F., Taseva, L., 2009. A comparison of two off-line soil analysis schemes for assimilation of screen level observations. *J. Geophys. Res. Atmos.* <https://doi.org/10.1029/2008JD011077>
- Malhi, G.S., Kaur, M., Kaushik, P., 2021. Impact of climate change on agriculture and its mitigation strategies: A review. *Sustain.* <https://doi.org/10.3390/su13031318>
- Manderscheid, R., Erbs, M., Burkart, S., Wittich, K.P., Löpmeier, F.J., Weigel, H.J., 2016. Effects of Free-Air Carbon Dioxide Enrichment on Sap Flow and Canopy Microclimate of Maize Grown under Different Water Supply. *J. Agron. Crop Sci.* <https://doi.org/10.1111/jac.12150>
- Manjunath, K.R., Potdar, M.B., Purohit, N.L., 2002. Large area operational wheat yield model development and validation based on spectral and meteorological data. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160110104692>
- Marchane, A., Tramblay, Y., Hanich, L., Ruelland, D., Jarlan, L., 2017. Climate change impacts on surface water resources in the Rheraya catchment (High Atlas, Morocco). *Hydrol. Sci. J.* 62, 979–995. <https://doi.org/10.1080/02626667.2017.1283042>
- Marin, F., Jones, J.W., Boote, K.J., 2017. A stochastic method for crop models: Including uncertainty in a sugarcane model. *Agron. J.* 109. <https://doi.org/10.2134/agronj2016.02.0103>
- Martinez, C.J., Baigorria, G.A., Jones, J.W., 2009. Use of climate indices to predict corn yields in southeast USA. *Int. J. Climatol.* <https://doi.org/10.1002/joc.1817>
- Masson, V., Le Moigne, P., Martin, E., Faroux, S., Alias, A., Alkama, R., Belamari, S., Barbu, A., Boone, A., Bouyssel, F., Brousseau, P., Brun, E., Calvet, J.C., Carrer, D., Decharme, B., Delire, C., Donier, S., Essauini, K., Gibelin, A.L., Giordani, H., Habets, F., Jidane, M., Kerdraon, G., Kourzeneva, E., Lafaysse, M., Lafont, S., Lebeaupin Brossier, C., Lemonsu, A., Mahfouf, J.F., Marguinaud, P., Mokhtari, M., Morin, S., Pigeon, G., Salgado, R., Seity, Y., Taillefer, F., Tanguy, G., Tulet, P., Vincendon, B., Vionnet, V., Voldoire, A., 2013. The SURFEXv7.2 land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geosci. Model Dev.* <https://doi.org/10.5194/gmd-6-929-2013>
- Mateo-Sanchis, A., Piles, M., Muñoz-Marí, J., Adsuaara, J.E., Pérez-Suay, A., Camps-Valls, G., 2019. Synergistic integration of optical and microwave satellite data for crop yield estimation. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2019.111460>
- Mather, P.M., 1987. Computer processing of remotely-sensed images: an introduction. *Comput. Process. Remote. images an Introd.* <https://doi.org/10.2307/633899>
- Mathieu, J.A., Aires, F., 2018. Assessment of the agro-climatic indices to improve crop yield forecasting. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2018.01.031>
- McDowell, N., Pockman, W.T., Allen, C.D., Breshears, D.D., Cobb, N., Kolb, T., Plaut, J., Sperry, J., West, A., Williams, D.G., Yezpez, E.A., 2008. Mechanisms of plant survival and mortality during drought: Why do some plants survive while others succumb to drought? *New Phytol.* <https://doi.org/10.1111/j.1469-8137.2008.02436.x>
- McKee, T.B., Nolan, J., Kleist, J., 1993. The relationship of drought frequency and duration to time scales. *Prepr. Eighth Conf. Appl. Climatol. Amer. Meteor. Soc.*
- McVicar, T.R., Bierwirth, P.N., 2001. Rapidly assessing the 1997 drought in papua new guinea using composite avhrr imagery. *Int. J. Remote Sens.* 22. <https://doi.org/10.1080/01431160120728>

- McVicar, T.R., Jupp, D.L.B., 1998. The current and potential operational uses of remote sensing to aid decisions on drought exceptional circumstances in Australia: A review. *Agric. Syst.* [https://doi.org/10.1016/S0308-521X\(98\)00026-2](https://doi.org/10.1016/S0308-521X(98)00026-2)
- Mearns, L.O., Rosenzweig, C., Goldberg, R., 1997. Mean and Variance Change in Climate Scenarios: Methods, Agricultural Applications and Measures of Uncertainty. *Clim. Change* 35, 30. <https://doi.org/10.1023/A:1005358130291>
- Mearns, L.O., Sain, S., Leung, L.R., Bukovsky, M.S., McGinnis, S., Biner, S., Caya, D., Arritt, R.W., Gutowski, W., Takle, E., Snyder, M., Jones, R.G., Nunes, A.M.B., Tucker, S., Herzmann, D., McDaniel, L., Sloan, L., 2013. Climate change projections of the North American Regional Climate Change Assessment Program (NARCCAP). *Clim. Change.* <https://doi.org/10.1007/s10584-013-0831-3>
- Meng, L., Dong, T., Zhang, W., 2016. Drought monitoring using an Integrated Drought Condition Index (IDCI) derived from multi-sensor remote sensing data. *Nat. Hazards* 80. <https://doi.org/10.1007/s11069-015-2014-1>
- Meroni, M., Fasbender, D., Balaghi, R., Dali, M., Haffani, M., Haythem, I., Hooker, J., Lahlou, M., Lopez-Lozano, R., Mahyou, H., Ben Moussa, M., Sghaier, N., Wafa, T., Leo, O., 2016. Evaluating NDVI Data Continuity Between SPOT-VEGETATION and PROBA-V Missions for Operational Yield Forecasting in North African Countries. *IEEE Trans. Geosci. Remote Sens.* <https://doi.org/10.1109/TGRS.2015.2466438>
- Meyer, S.J., Hubbard, K.G., Wilhite, D.A., 1993. A Crop-Specific Drought Index for Corn: I. Model Development and Validation. *Agron. J.* <https://doi.org/10.2134/agronj1993.00021962008500020040x>
- Mishra, A.K., Singh, V.P., 2010. A review of drought concepts. *J. Hydrol.* <https://doi.org/10.1016/j.jhydrol.2010.07.012>
- Mishra, V., Cruise, J.F., Mecikalski, J.R., 2021. Assimilation of coupled microwave/thermal infrared soil moisture profiles into a crop model for robust maize yield estimates over Southeast United States. *Eur. J. Agron.* 123. <https://doi.org/10.1016/j.eja.2020.126208>
- Molteni, F., Stockdale, T., Balsameda, M., Balsamo, G., Buizza, R., Ferranti, L., Magnusson, L., Mogensen, K., Palmer, T., Vitart, F., 2011. The new ECMWF seasonal forecast system (System 4) 49.
- Monteith, J.L., 1981. Climatic variation and the growth of crops. *Q. J. R. Meteorol. Soc.* <https://doi.org/10.1002/qj.49710745402>
- Monteith, J.L., 1977. Climate and the efficiency of crop production in Britain. *Philos. Trans. R. Soc. London. B, Biol. Sci.* 281. <https://doi.org/10.1098/rstb.1977.0140>
- Monteith, J.L., Scott, R.K., Unsworth, M.H., 1994. Resource capture by crops. *Resour. capture by Crop.* <https://doi.org/10.2307/2404664>
- Morison, J.I.L., 1987. Intercellular CO₂ concentration and stomatal response to CO₂, in: *Stomatal function.* bll 229–252.
- Moss, R., Babiker, M., Brinkman, S., Calvo, E., Carter, T., Edmonds, J., Elgizouli, I., Emori, S., Erda, L., Hibbard, K., Jones, R., Kainuma, M., Kelleher, J., Lamarque, J.F., Manning, M., Matthews, B., Meehl, J., Meyer, L., Mitchell, J., Nakicenovic, N., O'Neill, B., Pichs, R., Riahi, K., Rose, S., Runci, P., Stouffer, R., Vuuren, D. van, Weyant, J., Wilbanks, T., Ypersele, J.P. van, Zurek, M., 2008. *Towards New Scenarios for Analysis of Emissions, Climate Change, Impacts and Response Strategies, IPCC Expert Meeting Report.*
- Moucha, A., Hanich, L., Trambly, Y., Saaidi, A., Gascoin, S., Martin, E., Le Page, M., Bouras, E., Szczypta, C., Jarlan, L., 2021. Present and future high-resolution climate forcings over semiarid catchments: Case of the tensift (Morocco). *Atmosphere (Basel).* 12. <https://doi.org/10.3390/atmos12030370>

- Mulholland, B.J., Craigon, J., Black, C.R., Colls, J., Atherton, J., Landon, G., 1998. Growth, light interception and yield responses of spring wheat (*Triticum aestivum* L.) grown under elevated CO₂ and O₃ in open-top chambers. *Glob. Chang. Biol.* <https://doi.org/10.1046/j.1365-2486.1998.00112.x>
- Mulholland, B.J., Craigon, J., Black, C.R., Colls, J.J., Atherton, J., Landon, G., 1997. Impact of elevated atmospheric CO₂ and O₃ on gas exchange and chlorophyll content in spring wheat (*Triticum aestivum* L.). *J. Exp. Bot.* <https://doi.org/10.1093/jxb/48.10.1853>
- Myneni, R.B., Hoffman, S., Knyazikhin, Y., Privette, J.L., Glassy, J., Tian, Y., Wang, Y., Song, X., Zhang, Y., Smith, G.R., Lotsch, A., Friedl, M., Morisette, J.T., Votava, P., Nemani, R.R., Running, S.W., 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote Sens. Environ.* 83. [https://doi.org/10.1016/S0034-4257\(02\)00074-3](https://doi.org/10.1016/S0034-4257(02)00074-3)
- Myneni, R.B., Maggion, S., Jaquinta, J., Privette, J.L., Gobron, N., Pinty, B., Kimes, D.S., Verstraete, M.M., Williams, D.L., 1995. Optical remote sensing of vegetation: Modeling, caveats, and algorithms. *Remote Sens. Environ.* 51, 169–188. [https://doi.org/10.1016/0034-4257\(94\)00073-V](https://doi.org/10.1016/0034-4257(94)00073-V)
- Narasimhan, B., Srinivasan, R., 2005. Development and evaluation of Soil Moisture Deficit Index (SMDI) and Evapotranspiration Deficit Index (ETDI) for agricultural drought monitoring, in: *Agricultural and Forest Meteorology*. <https://doi.org/10.1016/j.agrformet.2005.07.012>
- Nassah, H., Er-Raki, S., Khabba, S., Fakir, Y., Raibi, F., Merlin, O., Mougnot, B., 2018. Evaluation and analysis of deep percolation losses of drip irrigated citrus crops under non-saline and saline conditions in a semi-arid area. *Biosyst. Eng.* 165, 10–24. <https://doi.org/10.1016/j.biosystemseng.2017.10.017>
- Nasser, T.T., 2020. Evaluation et impact de la sécheresse sur une région agricole : Cas de la plaine irriguée de la Beqaa Thierry Tarek Nasser. Université d'Orléans, Paris, France.
- Nguyen-Huy, T., Deo, R.C., An-Vo, D.A., Mushtaq, S., Khan, S., 2017. Copula-statistical precipitation forecasting model in Australia's agro-ecological zones. *Agric. Water Manag.* 191, 153–172. <https://doi.org/10.1016/j.agwat.2017.06.010>
- Norby, R.J., 1994. Issues and perspectives for investigating root responses to elevated atmospheric carbon dioxide. *Plant Soil.* <https://doi.org/10.1007/BF00009958>
- Olsen, J.L., Ceccato, P., Proud, S.R., Fensholt, R., Grippa, M., Mougnot, E., Ardö, J., Sandholt, I., 2013. Relation between seasonally detrended shortwave infrared reflectance data and land surface moisture in semi-arid Sahel. *Remote Sens.* 5. <https://doi.org/10.3390/rs5062898>
- Olukayode Oladipo, E., 1985. A comparative performance analysis of three meteorological drought indices. *J. Climatol.* <https://doi.org/10.1002/joc.3370050607>
- OMM, 2018. Guide des pratiques climatologiques.
- Orlowsky, B., Seneviratne, S.I., 2012. Global changes in extreme events: Regional and seasonal dimension. *Clim. Change* 110. <https://doi.org/10.1007/s10584-011-0122-9>
- Ouaadi, N., Jarlan, L., Ezzahar, J., Zribi, M., Khabba, S., Bouras, E., Bousbih, S., Frison, P.-L., 2020. Monitoring of wheat crops using the backscattering coefficient and the interferometric coherence derived from Sentinel-1 in semi-arid areas. *Remote Sens. Environ.* 251, 112050. <https://doi.org/10.1016/j.rse.2020.112050>
- Palmer, W.C., 1968. Keeping Track of Crop Moisture Conditions, Nationwide: The New Crop Moisture Index. *Weatherwise.* <https://doi.org/10.1080/00431672.1968.9932814>
- Palmer, W.C., 1965. Meteorological Drought. U.S. Weather Bur. Res. Pap. No. 45.
- Paloscia, S., Macelloni, G., Santi, E., 2006. Soil moisture estimates from AMSR-E brightness temperatures by using a

- dual-frequency algorithm. *IEEE Trans. Geosci. Remote Sens.* 44. <https://doi.org/10.1109/TGRS.2006.881714>
- Paloscia, S., Macelloni, G., Santi, E., Koike, T., 2001. A multifrequency algorithm for the retrieval of soil moisture on a large scale using microwave data from SMMR and SSM/I satellites. *IEEE Trans. Geosci. Remote Sens.* 39. <https://doi.org/10.1109/36.942543>
- Panu, U.S., Sharma, T.C., 2002. Challenges in drought research: Some perspectives and future directions [Défis de la recherche sur les sécheresses: Quelques perspectives et directions futures]. *Hydrol. Sci. J.*
- Park, Seonyoung, Im, J., Park, Sumin, Rhee, J., 2017. Drought monitoring using high resolution soil moisture through multi-sensor satellite data fusion over the Korean peninsula. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2017.02.022>
- Páscoa, P., Gouveia, C.M., Russo, A., Trigo, R.M., 2017. The role of drought on wheat yield interannual variability in the Iberian Peninsula from 1929 to 2012. *Int. J. Biometeorol.* <https://doi.org/10.1007/s00484-016-1224-x>
- Peng, S., Huang, J., Sheehy, J.E., Laza, R.C., Visperas, R.M., Zhong, X., Centeno, G.S., Khush, G.S., Cassman, K.G., 2004. Rice yields decline with higher night temperature from global warming. *Proc. Natl. Acad. Sci.* 101, 9971–9975. <https://doi.org/10.1073/pnas.0403720101>
- Peng, Y.H., Hsu, C.S., Huang, P.C., 2016. Developing crop price forecasting service using open data from Taiwan markets, in: TAAI 2015 - 2015 Conference on Technologies and Applications of Artificial Intelligence. <https://doi.org/10.1109/TAAI.2015.7407108>
- Podestá, G., Letson, D., Messina, C., Royce, F., Ferreyra, R.A., Jones, J., Hansen, J., Llovet, I., Grondona, M., O'Brien, J.J., 2002. Use of ENSO-related climate information in agricultural decision making in Argentina: A pilot experience. *Agric. Syst.* [https://doi.org/10.1016/S0308-521X\(02\)00046-X](https://doi.org/10.1016/S0308-521X(02)00046-X)
- Prasad, Anup K., Chai, L., Singh, R.P., Kafatos, M., 2006. Crop yield estimation model for Iowa using remote sensing and surface parameters. *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2005.06.002>
- Prasad, Anup K., Chai, L., Singh, R.P., Kafatos, M., 2006. Crop yield estimation model for Iowa using remote sensing and surface parameters 8, 26–33. <https://doi.org/10.1016/j.jag.2005.06.002>
- Prata, F., 2002. Land Surface Temperature Measurement from Space: AATSR Algorithm Theoretical Basis Document. Contract Rep. to ESA, CSIRO Atmos. Res. Aspendale, Victoria, Aust. 2002, 1–34.
- Purcell, C., Batke, S.P., Yiotis, C., Caballero, R., Soh, W.K., Murray, M., McElwain, J.C., 2018. Increasing stomatal conductance in response to rising atmospheric CO₂. *Ann. Bot.* <https://doi.org/10.1093/aob/mcx208>
- Qian, B., De Jong, R., Warren, R., Chipanshi, A., Hill, H., 2009. Statistical spring wheat yield forecasting for the Canadian prairie provinces. *Agric. For. Meteorol.* <https://doi.org/10.1016/j.agrformet.2008.12.006>
- Quiring, S.M., Papakryiakou, T.N., 2003. An evaluation of agricultural drought indices for the Canadian prairies. *Agric. For. Meteorol.* [https://doi.org/10.1016/S0168-1923\(03\)00072-8](https://doi.org/10.1016/S0168-1923(03)00072-8)
- Raes, D., Steduto, P., Hsiao, T.C., Fereres, E., 2009. Aquacrop-The FAO crop model to simulate yield response to water: II. main algorithms and software description. *Agron. J.* 101, 438–447. <https://doi.org/10.2134/agronj2008.0140s>
- Rahimzadeh-Bajgiran, P., Omasa, K., Shimizu, Y., 2012. Comparative evaluation of the Vegetation Dryness Index (VDI), the Temperature Vegetation Dryness Index (TVDI) and the improved TVDI (iTVDI) for water stress detection in semi-arid regions of Iran. *ISPRS J. Photogramm. Remote Sens.* <https://doi.org/10.1016/j.isprsjprs.2011.10.009>
- Rahman, A., Roytman, L., Krakauer, N., Nizamuddin, M., Goldberg, M., 2009. Use of Vegetation Health Data for Estimation of Aus Rice Yield in Bangladesh. *Sensors.* <https://doi.org/10.3390/s90402968>

- Ray, D.K., Gerber, J.S., Macdonald, G.K., West, P.C., 2015. Climate variation explains a third of global crop yield variability. *Nat. Commun.* 6. <https://doi.org/10.1038/ncomms6989>
- Raymond, F., Ullmann, A., Trambly, Y., Drobinski, P., Camberlin, P., 2019. Evolution of Mediterranean extreme dry spells during the wet season under climate change. *Reg. Environ. Chang.* 19. <https://doi.org/10.1007/s10113-019-01526-3>
- Reichle, R.H., Koster, R.D., Liu, P., Mahanama, S.P.P., Njoku, E.G., Owe, M., 2007. Comparison and assimilation of global soil moisture retrievals from the Advanced Microwave Scanning Radiometer for the Earth Observing System (AMSR-E) and the Scanning Multichannel Microwave Radiometer (SMMR). *J. Geophys. Res. Atmos.* <https://doi.org/10.1029/2006JD008033>
- Rembold, F., Atzberger, C., Savin, I., Rojas, O., 2013. Using low resolution satellite imagery for yield prediction and yield anomaly detection. *Remote Sens.* <https://doi.org/10.3390/rs5041704>
- Rhee, J., Im, J., Carbone, G.J., 2010a. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sens. Environ.* 114, 2875–2887. <https://doi.org/10.1016/j.rse.2010.07.005>
- Rhee, J., Im, J., Carbone, G.J., 2010b. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2010.07.005>
- Ribeiro, A.F.S., Russo, A., Gouveia, C.M., Páscoa, P., 2019. Modelling drought-related yield losses in Iberia using remote sensing and multiscalar indices. *Theor. Appl. Climatol.* <https://doi.org/10.1007/s00704-018-2478-5>
- RICARD, D., BEAULANT, A.-L., BOE, J., DEQUE, M., DUCROCQ, V., JOLY, A., JOLY, B., MARTIN, E., NUISSIER, O., QUINTANA-SEGUI, P., RIBES, A., SEVAULT, F., SOMOT, S., 2009. Projet Cyprim, partie II : Impact du changement climatique sur les événements de pluie intense du bassin méditerranéen. *La Météorologie.* <https://doi.org/10.4267/2042/30036>
- Richards, J.A., Jia, X., 2006. Remote sensing digital image analysis: An introduction, *Remote Sensing Digital Image Analysis: An Introduction.* <https://doi.org/10.1007/3-540-29711-1>
- Rind, D., Goldberg, R., Hansen, J., Rosenzweig, C., Ruedy, R., 1990. Potential evapotranspiration and the likelihood of future drought. *J. Geophys. Res.* <https://doi.org/10.1029/jd095id07p09983>
- Ritchie, J.T., 1985. A User-Orientated Model of the Soil Water Balance in Wheat, in: *Wheat Growth and Modelling.* https://doi.org/10.1007/978-1-4899-3665-3_27
- Rock, B.N., Vogelmann, J.E., Williams, D.L., Vogelmann, A.F., Hoshizaki, T., 1986. Remote Detection of Forest Damage. *Bioscience* 36. <https://doi.org/10.2307/1310339>
- Rodell, M., Houser, P.R., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C.J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., Entin, J.K., Walker, J.P., Lohmann, D., Toll, D., 2004. The Global Land Data Assimilation System. *Bull. Am. Meteorol. Soc.* <https://doi.org/10.1175/BAMS-85-3-381>
- Rodriguez-Iturbe, I., Porporato, A., Laio, F., Ridolfi, L., 2001. Plants in water-controlled ecosystems: Active role in hydrologic processes and response to water stress I. Scope and general outline. *Adv. Water Resour.* 24. [https://doi.org/10.1016/S0309-1708\(01\)00004-5](https://doi.org/10.1016/S0309-1708(01)00004-5)
- Rojas, O., Vrieling, A., Rembold, F., 2011. Assessing drought probability for agricultural areas in Africa with coarse resolution remote sensing imagery. *Remote Sens. Environ.* 115, 343–352. <https://doi.org/10.1016/j.rse.2010.09.006>
- Ruiz-Ramos, M., Mínguez, M.I., 2010. Evaluating uncertainty in climate change impacts on crop productivity in the Iberian Peninsula. *Clim. Res.* 44, 69–82. <https://doi.org/10.3354/cr00933>
- Ruti, P.M., Somot, S., Giorgi, F., Dubois, C., Flaounas, E., Obermann, A., Dell’Aquila, A., Pisacane, G., Harzallah,

- A., Lombardi, E., Ahrens, B., Akhtar, N., Alias, A., Arsouze, T., Aznar, R., Bastin, S., Bartholy, J., Bèranger, K., Beuvier, J., Bouffies-Clochic, S., Brauch, J., Cabos, W., Calmanti, S., Calvet, J.C., Carillo, A., Conte, D., Coppola, E., Djurdjevic, V., Drobinski, P., Elizalde-Arellano, A., Gaertner, M., Galì, P., Gallardo, C., Gualdi, S., Goncalves, M., Jorba, O., Jordic, G., L'Heveder, B., Lebeau-pin-Brossier, C., Li, L., Liguori, G., Lionello, P., Macii, D., Nabat, P., i, B., Raikovic, B., Ramage, K., Sevault, F., Sannino, G., Struglia, M. V., Sanna, A., Torma, C., Vervatis, V., 2016. Med-CORDEX initiative for Mediterranean climate studies. *Bull. Am. Meteorol. Soc.* 97, 1187–1208. <https://doi.org/10.1175/BAMS-D-14-00176.1>
- Saadi, S., Todorovic, M., Tanasijevic, L., Pereira, L.S., Pizzigalli, C., Lionello, P., 2015. Climate change and Mediterranean agriculture: Impacts on winter wheat and tomato crop evapotranspiration, irrigation requirements and yield. *Agric. Water Manag.* 147, 103–115. <https://doi.org/10.1016/j.agwat.2014.05.008>
- Sain, S.R., Vapnik, V.N., 1996. *The Nature of Statistical Learning Theory*. Technometrics. <https://doi.org/10.2307/1271324>
- Salazar, L., Kogan, F., Roytman, L., 2007. Use of remote sensing data for estimation of winter wheat yield in the United States. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160601050395>
- Salman, A.Z., Al-Karablieh, E.K., 2001. An early warning system for wheat production in low rainfall areas of Jordan. *J. Arid Environ.* <https://doi.org/10.1006/jare.2001.0799>
- Samaniego, L., Thober, S., Kumar, R., Wanders, N., Rakovec, O., Pan, M., Zink, M., Sheffield, J., Wood, E.F., Marx, A., 2018. Anthropogenic warming exacerbates European soil moisture droughts. *Nat. Clim. Chang.* 8. <https://doi.org/10.1038/s41558-018-0138-5>
- Samuel, A., 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM J. Res. Dev.* 3.
- Santos, J.F., Pulido-Calvo, I., Portela, M.M., 2010. Spatial and temporal variability of droughts in Portugal. *Water Resour. Res.* 46. <https://doi.org/10.1029/2009WR008071>
- Schepen, A., Everingham, Y., Wang, Q.J., 2020. An improved workflow for calibration and downscaling of GCM climate forecasts for agricultural applications – A case study on prediction of sugarcane yield in Australia. *Agric. For. Meteorol.* 291, 107991. <https://doi.org/10.1016/j.agrformet.2020.107991>
- Schilling, J., Hertig, E., Trambly, Y., Scheffran, J., 2020. Climate change vulnerability, water resources and social implications in North Africa. *Reg. Environ. Chang.* <https://doi.org/10.1007/s10113-020-01597-7>
- Schwalbert, R.A., Amado, T., Corassa, G., Pott, L.P., Prasad, P.V.V., Ciampitti, I.A., 2020. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agric. For. Meteorol.* 284, 107886. <https://doi.org/10.1016/j.agrformet.2019.107886>
- Scian, B. V., 2004. Environmental variables for modeling wheat yields in the southwest pampa region of Argentina. *Int. J. Biometeorol.* <https://doi.org/10.1007/s00484-004-0198-2>
- Sefiani, S., El Mandour, A., Laftouhi, N., Khalil, N., Chehbouni, A., Jarlan, L., Hanich, L., Khabba, S., Kamal, S., Markhi, A., Nassah, H., 2019. Evaluation of Groundwater Quality and Agricultural use Under a Semi-arid Environment: Case of Agafay, Western Haouz, Morocco. *Irrig. Drain.* <https://doi.org/10.1002/ird.2363>
- Semenov, M.A., Barrow, E.M., 1997. Use of a stochastic weather generator in the development of climate change scenarios. *Clim. Change* 35. <https://doi.org/10.1023/A:1005342632279>
- Senapati, N., Halford, N.G., Semenov, M.A., 2021. Vulnerability of European wheat to extreme heat and drought around flowering under future climate. *Environ. Res. Lett.* 16. <https://doi.org/10.1088/1748-9326/abd3f3>
- Senay, G.B., Velpuri, N.M., Bohms, S., Budde, M., Young, C., Rowland, J., Verdin, J.P., 2014. Drought Monitoring and Assessment: Remote Sensing and Modeling Approaches for the Famine Early Warning Systems Network.

- Remote Sensing and Modeling Approaches for the Famine Early Warning Systems Network., in: Hydro-Meteorological Hazards, Risks, and Disasters. <https://doi.org/10.1016/B978-0-12-394846-5.00009-6>
- Seneviratne, S.I., Donat, M.G., Pitman, A.J., Knutti, R., Wilby, R.L., 2016. Allowable CO2 emissions based on regional and impact-related climate targets. *Nature*. <https://doi.org/10.1038/nature16542>
- Shahhosseini, M., Hu, G., Huber, I., Archontoulis, S. V., 2021. Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt. *Sci. Rep.* 11. <https://doi.org/10.1038/s41598-020-80820-1>
- Shahhosseini, M., Martinez-Feria, R.A., Hu, G., Archontoulis, S. V., 2019. Maize yield and nitrate loss prediction with machine learning algorithms. *Environ. Res. Lett.* <https://doi.org/10.1088/1748-9326/ab5268>
- Sharma, A., Jain, A., Gupta, P., Chowdary, V., 2021. Machine Learning Applications for Precision Agriculture: A Comprehensive Review. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.3048415>
- Shen, R., Huang, A., Li, B., Guo, J., 2019. Construction of a drought monitoring model using deep learning based on multi-source remote sensing data. *Int. J. Appl. Earth Obs. Geoinf.* 79, 48–57. <https://doi.org/10.1016/j.jag.2019.03.006>
- Sibley, A.M., Grassini, P., Thomas, N.E., Cassman, K.G., Lobell, D.B., 2014. Testing remote sensing approaches for assessing yield variability among maize fields. *Agron. J.* <https://doi.org/10.2134/agronj2013.0314>
- Siegenthaler, U., Stocker, T.F., Monnin, E., Lüthi, D., Schwander, J., Stauffer, B., Raynaud, D., Barnola, J.M., Fischer, H., Masson-Delmotte, V., Jouzel, J., 2005. Atmospheric science: Stable carbon cycle-climate relationship during the late pleistocene. *Science* (80-.). <https://doi.org/10.1126/science.1120130>
- Singh, R.P., Roy, S., Kogan, F., 2003. Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. *Int. J. Remote Sens.* <https://doi.org/10.1080/0143116031000084323>
- Skakun, S., Franch, B., Roger, J.C., Vermote, E., Becker-Reshef, I., Justice, C., Santamaria-Artigas, A., 2016. Incorporating yearly derived winter wheat maps into winter wheat yield forecasting model, in: International Geoscience and Remote Sensing Symposium (IGARSS). <https://doi.org/10.1109/IGARSS.2016.7730869>
- Smola, A.J., Schölkopf, B., 2004. A tutorial on support vector regression. *Stat. Comput.* <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Sobrino, J.A., Jiménez-Muñoz, J.C., Paolini, L., 2004. Land surface temperature retrieval from LANDSAT TM 5. *Remote Sens. Environ.* 90, 434–440. <https://doi.org/10.1016/j.rse.2004.02.003>
- Somot, S., 2005. Modélisation climatique du bassin méditerranéen: variabilité et scénarios de changement climatique, PhD Thesis, Université Paul Sabatier - Toulouse III 347.
- Spennemann, P.C., Rivera, J.A., Osman, M., Celeste Saulo, A., Penalba, O.C., 2017. Assessment of seasonal soil moisture forecasts over Southern South America with emphasis on dry and wet events. *J. Hydrometeorol.* <https://doi.org/10.1175/JHM-D-17-0015.1>
- Steduto, P., Albrizio, R., 2005. Resource use efficiency of field-grown sunflower, sorghum, wheat and chickpea: II. Water use efficiency and comparison with radiation use efficiency. *Agric. For. Meteorol.* 130, 269–281. <https://doi.org/10.1016/j.agrformet.2005.04.003>
- Steduto, Pasquale, Hsiao, T.C., Raes, D., Fereres, E., 2009. Aquacrop-the FAO crop model to simulate yield response to water: I. concepts and underlying principles. *Agron. J.* 101, 426–437. <https://doi.org/10.2134/agronj2008.0139s>
- Steduto, P., Hsiao, T.C., Raes, D., Fereres, E., Izzi, G., Heng, L., Hoogeveen, J., 2011. Performance review of AquaCrop - The FAO crop-water productivity model. *ICID 21st Int. Congr. Irrig. Drain.* 231–248.
- Steduto, P., Raes, D., Hsiao, T.C., Fereres, E., Heng, L.K., Howell, T.A., Evett, S.R., Rojas-Lara, B.A., Farahani, H.J.,

- Izzi, G., Oweis, T.Y., Wani, S.P., Hoogeveen, J., Geerts, S., 2009. Concepts and Applications of AquaCrop: The FAO Crop Water Productivity Model, in: *Crop Modeling and Decision Support*. https://doi.org/10.1007/978-3-642-01132-0_19
- Stevens, T., Madani, K., 2016. Future climate impacts on maize farming and food security in Malawi. *Sci. Rep.* <https://doi.org/10.1038/srep36241>
- Stocker, B.D., Zscheischler, J., Keenan, T.F., Prentice, I.C., Peñuelas, J., Seneviratne, S.I., 2018. Quantifying soil moisture impacts on light use efficiency across biomes. *New Phytol.* 218. <https://doi.org/10.1111/nph.15123>
- Swann, A.L.S., 2018. Plants and Drought in a Changing Climate. *Curr. Clim. Chang. Reports*. <https://doi.org/10.1007/s40641-018-0097-y>
- Tallaksen, L.M., Madsen, H., Clausen, B., 1997. On the definition and modelling of streamflow drought duration and deficit volume / Définition et modélisation de la durée et du volume déficitaire des étiages. *Hydrol. Sci. J.*
- Teuling, A.J., Van Loon, A.F., Seneviratne, S.I., Lehner, I., Aubinet, M., Heinesch, B., Bernhofer, C., Grünwald, T., Prasse, H., Spank, U., 2013. Evapotranspiration amplifies European summer drought. *Geophys. Res. Lett.* <https://doi.org/10.1002/grl.50495>
- Theis, S.W., Blanchard, B.J., Newton, R.W., 1983. UTILIZATION OF VEGETATION INDICES TO IMPROVE MICROWAVE SOIL MOISTURE ESTIMATES OVER AGRICULTURAL LANDS. *IEEE Trans. Geosci. Remote Sens.* <https://doi.org/10.1109/tgrs.1984.6499159>
- Thompson, L.M., 1969. Weather and Technology in the Production of Corn in the U. S. Corn Belt 1. *Agron. J.* <https://doi.org/10.2134/agronj1969.00021962006100030037x>
- Todd, G.W., 1982. Photosynthesis and respiration of vegetative and reproductive parts of wheat and barley plants in response to increasing temperature. *Proc. Oklahoma Acad. Sci.* 62, 57–62.
- Todorovic, M., Albrizio, R., Zivotic, L., Abi Saab, M.T., Stöckle, C., Steduto, P., 2009. Assessment of aquacrop, cropsyst, and WOFOST models in the simulation of sunflower growth under different water regimes. *Agron. J.* 101. <https://doi.org/10.2134/agronj2008.0166s>
- Toreti, A., Deryng, D., Tubiello, F.N., Müller, C., Kimball, B.A., Moser, G., Boote, K., Asseng, S., Pugh, T.A.M., Vanuytrecht, E., Pleijel, H., Webber, H., Durand, J.-L., Dentener, F., Ceglar, A., Wang, X., Badeck, F., Lecerc, R., Wall, G.W., van den Berg, M., Hoegy, P., Lopez-Lozano, R., Zampieri, M., Galmarini, S., O’Leary, G.J., Manderscheid, R., Mencos Contreras, E., Rosenzweig, C., 2020. Narrowing uncertainties in the effects of elevated CO₂ on crops. *Nat. Food*. <https://doi.org/10.1038/s43016-020-00195-4>
- Torino, M.S., Ortiz, B. V., Fulton, J.P., Balkcom, K.S., Wood, C.W., 2014. Evaluation of vegetation indices for early assessment of corn status and yield potential in the southeastern United States. *Agron. J.* <https://doi.org/10.2134/agronj13.0578>
- Toumi, J., Er-Raki, S., Ezzahar, J., Khabba, S., Jarlan, L., Chehbouni, A., 2016. Performance assessment of AquaCrop model for estimating evapotranspiration, soil water content and grain yield of winter wheat in Tensift Al Haouz (Morocco): Application to irrigation management. *Agric. Water Manag.* 163, 219–235. <https://doi.org/10.1016/j.agwat.2015.09.007>
- Tramblay, Y., El Adlouni, S., Servat, E., 2013a. Trends and variability in extreme precipitation indices over maghreb countries. *Nat. Hazards Earth Syst. Sci.* 13. <https://doi.org/10.5194/nhess-13-3235-2013>
- Tramblay, Y., Jarlan, L., Hanich, L., Somot, S., 2018. Future Scenarios of Surface Water Resources Availability in North African Dams. *Water Resour. Manag.* 32, 1291–1306. <https://doi.org/10.1007/s11269-017-1870-8>
- Tramblay, Y., Koutroulis, A., Samaniego, L., Vicente-Serrano, S.M., Volaire, F., Boone, A., Le Page, M., Llasat,

- M.C., Albergel, C., Burak, S., Cailleret, M., Kalin, K.C., Davi, H., Dupuy, J.L., Greve, P., Grillakis, M., Hanich, L., Jarlan, L., Martin-StPaul, N., Martínez-Vilalta, J., Mouillot, F., Pulido-Velazquez, D., Quintana-Seguí, P., Renard, D., Turco, M., Türkeş, M., Trigo, R., Vidal, J.P., Vilagrosa, A., Zribi, M., Polcher, J., 2020. Challenges for drought assessment in the Mediterranean region under future climate scenarios. *Earth-Science Rev.* <https://doi.org/10.1016/j.earscirev.2020.103348>
- Tramblay, Y., Ribes, A., Somot, S., Neppel, L., Lucas-, P., Vinet, F., Sauquet, E., Tramblay, Y., Ribes, A., Somot, S., Neppel, L., Lucas-, P., 2021. Impacts du changement climatique sur les pluies intenses et les crues en méditerranée. *LHB* 107, 1–5. <https://doi.org/10.1080/00186368.2021.1912971>
- Tramblay, Y., Ruelland, D., Somot, S., Bouaicha, R., Servat, E., 2013b. High-resolution Med-CORDEX regional climate model simulations for hydrological impact studies: A first evaluation of the ALADIN-Climate model in Morocco. *Hydrol. Earth Syst. Sci.* 17, 3721–3739. <https://doi.org/10.5194/hess-17-3721-2013>
- Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Tucker, C.J., Choudhury, B.J., 1987. Satellite remote sensing of drought conditions. *Remote Sens. Environ.* [https://doi.org/10.1016/0034-4257\(87\)90040-X](https://doi.org/10.1016/0034-4257(87)90040-X)
- Tucker, C.J., Pinzon, J.E., Brown, M.E., Slayback, D.A., Pak, E.W., Mahoney, R., Vermote, E.F., El Saleous, N., 2005. An extended AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160500168686>
- Tuvdendorj, B., Wu, B., Zeng, H., Batdelger, G., Nanzad, L., 2019. Determination of appropriate remote sensing indices for spring wheat yield estimation in Mongolia. *Remote Sens.* 11. <https://doi.org/10.3390/rs11212568>
- Unganai, L.S., Kogan, F.N., 1998. Drought monitoring and corn yield estimation in southern Africa from AVHRR data. *Remote Sens. Environ.* [https://doi.org/10.1016/S0034-4257\(97\)00132-6](https://doi.org/10.1016/S0034-4257(97)00132-6)
- van Diepen, C.A., Wolf, J., van Keulen, H., Rappoldt, C., 1989. WOFOST: a simulation model of crop production. *Soil Use Manag.* 5. <https://doi.org/10.1111/j.1475-2743.1989.tb00755.x>
- van Ittersum, M.K., Ewert, F., Heckeley, T., Wery, J., Alkan Olsson, J., Andersen, E., Bezlepkina, I., Brouwer, F., Donatelli, M., Flichman, G., Olsson, L., Rizzoli, A.E., van der Wal, T., Wien, J.E., Wolf, J., 2008. Integrated assessment of agricultural systems - A component-based framework for the European Union (SEAMLESS). *Agric. Syst.* <https://doi.org/10.1016/j.agry.2007.07.009>
- van Klompenburg, T., Kassahun, A., Catal, C., 2020. Crop yield prediction using machine learning: A systematic literature review. *Comput. Electron. Agric.* <https://doi.org/10.1016/j.compag.2020.105709>
- Vanuytrecht, E., Raes, D., Willems, P., 2011. Considering sink strength to model crop production under elevated atmospheric CO₂. *Agric. For. Meteorol.* 151, 1753–1762. <https://doi.org/10.1016/j.agrformet.2011.07.011>
- Vicente-Serrano, S., Cuadrat-Prats, J.M., Romo, A., 2006. Early prediction of crop production using drought indices at different time-scales and remote sensing data: Application in the Ebro Valley (north-east Spain). *Int. J. Remote Sens.* <https://doi.org/10.1080/01431160500296032>
- Vicente-Serrano, S.M., Beguería, S., López-Moreno, J.I., 2011. Comment on Characteristics and trends in various forms of the Palmer Drought Severity Index (PDSI) during 1900–2008 by Aiguo Dai. *J. Geophys. Res. Atmos.* <https://doi.org/10.1029/2011jd016410>
- Vicente-Serrano, S.M., Beguería, S., López-Moreno, J.I., 2010. A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *J. Clim.* <https://doi.org/10.1175/2009JCLI2909.1>

- Vicente-Serrano, S.M., Quiring, S.M., Peña-Gallardo, M., Yuan, S., Domínguez-Castro, F., 2020. A review of environmental droughts: Increased risk under global warming? *Earth-Science Rev.*
<https://doi.org/10.1016/j.earscirev.2019.102953>
- Vidal, J.P., Martin, E., Kitova, N., Najac, J., Soubeyroux, J.M., 2012. Evolution of spatio-temporal drought characteristics: Validation, projections and effect of adaptation scenarios. *Hydrol. Earth Syst. Sci.* 16.
<https://doi.org/10.5194/hess-16-2935-2012>
- Vogel, J., Paton, E., Aich, V., Bronstert, A., 2021. Increasing compound warm spells and droughts in the Mediterranean Basin. *Weather Clim. Extrem.* 32, 100312. <https://doi.org/10.1016/j.wace.2021.100312>
- Vogel, M.M., Hauser, M., Seneviratne, S.I., 2020. Projected changes in hot, dry and wet extreme events' clusters in CMIP6 multi-model ensemble. *Environ. Res. Lett.* <https://doi.org/10.1088/1748-9326/ab90a7>
- Voloudakis, D., Karamanos, A., Economou, G., Kalivas, D., Vahamidis, P., Kotoulas, V., Kapsomenakis, J., Zerefos, C., 2015. Prediction of climate change impacts on cotton yields in Greece under eight climatic models using the AquaCrop crop simulation model and discriminant function analysis. *Agric. Water Manag.* 147, 116–128.
<https://doi.org/10.1016/j.agwat.2014.07.028>
- Wan, Z., Li, Z.L., 1997. A physics-based algorithm for retrieving land-surface emissivity and temperature from eos/modis data. *IEEE Trans. Geosci. Remote Sens.* 35. <https://doi.org/10.1109/36.602541>
- Wang, B., Feng, P., Waters, C., Cleverly, J., Liu, D.L., Yu, Q., 2020. Quantifying the impacts of pre-occurred ENSO signals on wheat yield variation using machine learning in Australia. *Agric. For. Meteorol.* 291, 108043.
<https://doi.org/10.1016/j.agrformet.2020.108043>
- Wang, J., Wang, E., Liu, D.L., 2011. Modelling the impacts of climate change on wheat yield and field water balance over the Murray-Darling Basin in Australia. *Theor. Appl. Climatol.* 104, 285–300.
<https://doi.org/10.1007/s00704-010-0343-2>
- Wang, J., Wang, E., Luo, Q., Kirby, M., 2009. Modelling the sensitivity of wheat growth and water balance to climate change in Southeast Australia. *Clim. Change* 96, 79–96. <https://doi.org/10.1007/s10584-009-9599-x>
- Wang, L., Qu, J.J., Hao, X., Zhu, Q., 2008. Sensitivity studies of the moisture effects on MODIS SWIR reflectance and vegetation water indices. *Int. J. Remote Sens.* 29. <https://doi.org/10.1080/01431160802226034>
- Wang, M., Tao, F.L., Shi, W.J., 2014. Corn yield forecasting in northeast china using remotely sensed spectral indices and crop phenology metrics. *J. Integr. Agric.* [https://doi.org/10.1016/S2095-3119\(14\)60817-0](https://doi.org/10.1016/S2095-3119(14)60817-0)
- Wang, Y., Leung, L.R., McGregor, J.L., Lee, D.K., Wang, W.C., Ding, Y., Kimura, F., 2004. Regional climate modeling: Progress, challenges, and prospects. *J. Meteorol. Soc. Japan.* <https://doi.org/10.2151/jmsj.82.1599>
- West, H., Quinn, N., Horswell, M., 2019. Remote sensing for drought monitoring & impact assessment: Progress, past challenges and future opportunities. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2019.111291>
- Wheeler, T.R., Craufurd, P.Q., Ellis, R.H., Porter, J.R., Vara Prasad, P. V., 2000. Temperature variability and the yield of annual crops. *Agric. Ecosyst. Environ.* [https://doi.org/10.1016/S0167-8809\(00\)00224-3](https://doi.org/10.1016/S0167-8809(00)00224-3)
- Whisler, F.D., Acock, B., Baker, D.N., Fye, R.E., Hodges, H.F., Lambert, J.R., Lemmon, H.E., McKinion, J.M., Reddy, V.R., 1986. *Crop Simulation Models in Agronomic Systems*. Adv. Agron.
[https://doi.org/10.1016/S0065-2113\(08\)60282-5](https://doi.org/10.1016/S0065-2113(08)60282-5)
- White, J.W., Hoogenboom, G., Kimball, B.A., Wall, G.W., 2011. Methodologies for simulating impacts of climate change on crop production. *F. Crop. Res.* 124, 357–368. <https://doi.org/10.1016/j.fcr.2011.07.001>
- Wigley, T.M.L., Jones, P.D., Briffa, K.R., Smith, G., 1990. Obtaining sub-grid-scale information from coarse-resolution general circulation model output. *J. Geophys. Res.* <https://doi.org/10.1029/JD095iD02p01943>

- Wigneron, J.P., Calvet, J.C., Pellarin, T., Van De Griend, A.A., Berger, M., Ferrazzoli, P., 2003. Retrieving near-surface soil moisture from microwave radiometric observations: Current status and future plans. *Remote Sens. Environ.* [https://doi.org/10.1016/S0034-4257\(03\)00051-8](https://doi.org/10.1016/S0034-4257(03)00051-8)
- Wilby, R.L., Wigley, T.M.L., 1997. Downscaling general circulation model output: A review of methods and limitations. *Prog. Phys. Geogr.* <https://doi.org/10.1177/030913339702100403>
- Wilhite, D.A., 2007. CHAPTER 7 DROUGHT 2 . Drought as a Natural Hazard. *Drought A Glob. Assess.*
- Wilhite, D.A., 2000. Drought as a natural hazard: Concepts and definitions. *Drought A Glob. Assess.*
- Wilhite, D.A., Glantz, M.H., 1985. Water International Understanding: the Drought Phenomenon: The Role of Definitions Understanding: the Drought Phenomenon : The Role of Definitions*. *Water Int.* 10, 111–120. <https://doi.org/10.1080/02508068508686328>
- Wilhite, D.A., Pulwarty, R.S., 2017. Drought and Water Crises, *Drought and Water Crises.* <https://doi.org/10.1201/b22009>
- WMO, 2012. Standardized Precipitation Index User Guide WMO-No. 1090. WMO-No. 1090 ©.
- WMO, 2006. Suivi de la sécheresse et alerte précoce: principes, progrès et enjeux futurs.
- Wolanin, A., Mateo-García, G., Camps-Valls, G., Gómez-Chova, L., Meroni, M., Duveiller, G., Liangzhi, Y., Guanter, L., 2020. Estimating and understanding crop yields with explainable deep learning in the Indian Wheat Belt. *Environ. Res. Lett.* 15. <https://doi.org/10.1088/1748-9326/ab68ac>
- Wold, S., Esbensen, K., Geladi, P., 1987. Principal component analysis. *Chemom. Intell. Lab. Syst.* 2, 37–52. [https://doi.org/10.1016/0169-7439\(87\)80084-9](https://doi.org/10.1016/0169-7439(87)80084-9)
- Wu, J., Zhou, L., Liu, M., Zhang, J., Leng, S., Diao, C., 2013. Establishing and assessing the Integrated Surface Drought Index (ISDI) for agricultural drought monitoring in mid-eastern China. *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2012.11.003>
- Xue, J., Su, B., 2017. Significant remote sensing vegetation indices: A review of developments and applications. *J. Sensors.* <https://doi.org/10.1155/2017/1353691>
- Yano, T., Aydin, M., Haraguchi, T., 2007. Impact of climate change on irrigation demand and crop growth in a Mediterranean environment of Turkey. *Sensors* 7, 2297–2315. <https://doi.org/10.3390/s7102297>
- Yevjevich, V., 1967. An Objective Approach to Definitions and Investigations of Continental Droughts. *Hydrol. Pap.*
- You, L., Rosegrant, M.W., Wood, S., Sun, D., 2009. Impact of growing season temperature on wheat productivity in China. *Agric. For. Meteorol.* 149, 1009–1014. <https://doi.org/10.1016/j.agrformet.2008.12.004>
- Yu, Q., Li, L., Luo, Q., Eamus, D., Xu, S., Chen, C., Wang, E., Liu, J., Nielsen, D.C., 2014. Year patterns of climate impact on wheat yields. *Int. J. Climatol.* <https://doi.org/10.1002/joc.3704>
- Zambrano, F., Lillo-Saavedra, M., Verbist, K., Lagos, O., 2016. Sixteen years of agricultural drought assessment of the biobío region in Chile using a 250 m resolution vegetation condition index (VCI). *Remote Sens.* 8. <https://doi.org/10.3390/rs8060530>
- Zargar, A., Sadiq, R., Naser, B., Khan, F.I., 2011. A review of drought indices. *Environ. Rev.* <https://doi.org/10.1139/a11-013>
- Zhang, A., Jia, G., 2013. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. *Remote Sens. Environ.* <https://doi.org/10.1016/j.rse.2013.02.023>
- Zhang, J., Xu, Y., Yao, F., Wang, P., Guo, W., Li, L., Yang, L., 2010. Advances in estimation methods of vegetation water content based on optical remote sensing techniques. *Sci. China Technol. Sci.* 53. <https://doi.org/10.1007/s11431-010-0131-3>

- Zhang, L., Jiao, W., Zhang, H., Huang, C., Tong, Q., 2017. Studying drought phenomena in the Continental United States in 2011 and 2012 using various drought indices. *Remote Sens. Environ.* 190, 96–106. <https://doi.org/10.1016/j.rse.2016.12.010>
- Zhang, N., Hong, Y., Qin, Q., Liu, L., 2013. VSDI: A visible and shortwave infrared drought index for monitoring soil and vegetation moisture based on optical remote sensing. *Int. J. Remote Sens.* <https://doi.org/10.1080/01431161.2013.779046>
- Zhang, X., Chen, N., Li, J., Chen, Z., Niyogi, D., 2017. Multi-sensor integrated framework and index for agricultural drought monitoring. *Remote Sens. Environ.* 188, 141–163. <https://doi.org/10.1016/j.rse.2016.10.045>
- Zkhiri, W., Trambly, Y., Hanich, L., Jarlan, L., Ruelland, D., 2019. Spatiotemporal characterization of current and future droughts in the High Atlas basins (Morocco). *Theor. Appl. Climatol.* 135. <https://doi.org/10.1007/s00704-018-2388-6>